



T.C.

GAZİANTEP İSLAM BİLİM VE TEKNOLOJİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

DERİN ÖĞRENME YÖNTEMLERİNİ KULLANARAK AKCİĞER
GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ VE
SINIFLANDIRILMASI

Yüksek Lisans Tezi

Murat Kaan AKAR

Danışman
Doç. Dr. İpek ATİK

GAZİANTEP
2025

T.C.
GAZİANTEP İSLAM BİLİM VE TEKNOLOJİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

DERİN ÖĞRENME YÖNTEMLERİNİ KULLANARAK AKCİĞER
GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ VE SINIFLANDIRILMASI

Yüksek Lisans Tezi

Murat Kaan AKAR

Danışman
Doç. Dr. İpek ATİK

GAZİANTEP
2025

TEZ KABUL ve ONAYI

Murat Kaan AKAR tarafından, *Doç. Dr. İpek ATİK* danışmanlığında hazırlanan “*Derin öğrenme yöntemlerini kullanarak akciğer görüntülerinden hastalık tespiti ve sınıflandırılması*” başlıklı bu çalışma, jürimiz tarafından 08.12.2025 tarihinde yapılan sınav sonucunda oy birliği/oy çokluğu ile başarılı bulunarak Yüksek Lisans Tezi/Doktora Tezi/Sanatta Yeterlik Tezi olarak kabul edilmiştir.

Unvanı,

Adı/Soyadı Üniversitesi

Ana Bilim/Ana Sanat Dalı

İmza

Sonuç

Başkan

Doç. Dr. İpek ATİK

Gaziantep İslam Bilim ve Teknoloji Üniversitesi

Elektrik Elektronik Mühendisliği A.B.D

☐

Kabul

☐

Ret

Üye

Doç. Dr. Hakan AÇIKGÖZ

Kahramanmaraş İstiklal Üniversitesi

Mühendislik, Mimarlık ve Tasarım A.B.D

☐

Kabul

☐

Ret

Üye

Dr. Öğr. Üyesi Yüksel TOKUR BOZKURT

Gaziantep İslam Bilim ve Teknoloji Üniversitesi

Elektrik Elektronik Mühendisliği A.B.D

☐

Kabul

☐

Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

ONAY

... / ... / ...

(Dr. Öğr. Üyesi Adnan Akalın)

Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım yüksek lisans/doktora/sanatta yeterlik tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

İmza

... / ... / 2025

Murat Kaan AKAR

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı: Derin öğrenme yöntemlerini kullanarak akciğer görüntülerinden hastalık tespiti ve sınıflandırılması

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 24/11/2025 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : %8
Tek kaynak oranı : %1 çıkmıştır.

İmza

... / ... / 2025

Doç. Dr. İpek ATİK

ÖZET

Derin Öğrenme Yöntemlerini Kullanarak Akciğer Görüntülerinden Hastalık Tespiti ve Sınıflandırılması

Murat Kaan AKAR

Gaziantep İslam Bilim ve Teknoloji Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik Elektronik Mühendisliği Ana Bilim Dalı

Yüksek Lisans, Aralık / 2025

Danışman: Doç. Dr. İpek ATİK

Akciğer hastalıkları her geçen gün sağlık alanında ele alınması gereken önemli rahatsızlıkların başında gelmektedir. Hastalığın erken aşamada tespit edilmesi ve doğru tedaviye hızlı bir şekilde yanıt vermesi hastalar için hayatı bir öneme sahiptir. Doktorların hastalığı erken aşamada belirlemesinde ve hastalıklı bireylerde tedaviye erken başlanması hastalığın seyrini yüksek oranda etkilemiştir. Akciğer hastalık tespiti ve sınıflandırılması uzmanlık gerektiren zor bir süreç olup gerekli müdahalenin doğru zamanda yapılması tedavinin başarısını ortaya koymaktadır. Akciğer hastalıkları her geçen gün çeşitlenmekte ve analiz edilmesi zor bir durum haline gelmektedir. Yanlış hastalık tespiti ve hastalığın doğru şekilde analiz edilememesi insan sağlığını büyük oranda etkilemiştir. Günümüzde yapılan çalışmalarda yapay zeka yönteminin kullanımı hastalığı tespit edebilmede ön plana çıkmaktadır. Görüntülerin analizi ve doğru bir şekilde sınıflandırılması hastalığın durumunu hafifletmekte ve ölüm riskini azaltmaktadır.

Bu tez çalışmasında YOLO modelleri kullanılarak akciğer görüntülerinden oluşan bakterili, virüslü ve normal hastalık görüntüleri olan veri kümesi kullanılıp YOLO algoritmasının farklı sürümleri (YOLOv8, YOLOv9, YOLOv10, YOLOv11, YOLOv12) karşılaştırmalı olarak incelenmiş ve hastalık tespitinin gerçekleştirilmesi amaçlanmıştır. Yapılan deneylerde sırasıyla YOLOv8 %87,9, YOLOv9 %85, YOLOv10 %86,8, YOLOv11 %87,8 ve YOLOv12 %86,1 ortalama hassasiyet (mAP) değerine ulaşmıştır. Çalışmada YOLOv8 diğer modellere göre model mimarisindeki yapısı ve özellik çıkarımı sayesinde nesne tespitini genelleştirme yeteneğinden dolayı en iyi performansı göstermiştir. Çalışmanın hastalık tespit yeteneğini arttırmak için en iyi performans gerçekleştiren YOLOv8 modeline SE ve uzlamsal dikkat modülü entegre edilmiştir. Geliştirilen YOLOv8 modeli %88,7 mAP, %88 duyarlılık, %78,6 kesinlik ve %83 F1 skoruyla en iyi başarıyı yakalamıştır. YOLOv8 modeline entegre edilen SE ve uzlamsal dikkat modülü çalışmanın sonucunu %1,01 oranında iyileştirmiştir.

Anahtar Sözcükler: Akciğer Hastalığı, Hastalık Tespiti, Yapay Zeka, Derin Öğrenme, YOLO

ABSTRACT

DISEASE DETECTION AND CLASSIFICATION FROM LUNG IMAGES USING DEEP LEARNING METHOD

Murat Kaan AKAR

Gaziantep Islam Science and Technology University

Institute of Graduate Studies

Department of Electrical and Electronics Engineering

Master's Thesis, December / 2025

Supervisor: Assoc. Doç Dr. İpek ATİK

Lung diseases are among the most important health issues that need to be addressed in the healthcare field. Early detection of the disease and a rapid response to the correct treatment are of vital importance. Doctors' ability to identify the disease at an early stage and the early initiation of treatment in affected individuals have significantly influenced the course of the disease. The detection and classification of lung diseases is a difficult process requiring expertise, and the timely implementation of the necessary intervention determines the success of the treatment. Lung diseases are diversifying every day and have become difficult to analyze. Incorrect disease detection and failure to analyze the disease correctly have greatly affected human health. In today's studies, the use of artificial intelligence methods is at the forefront in detecting disease. Analyzing images and classifying them correctly alleviates the condition of the disease and reduces the risk of death.

In this thesis, a dataset consisting of bacterial, viral, and normal disease images from lung images was used with YOLO models, and different versions of the YOLO algorithm (YOLOv8, YOLOv9, YOLOv10, YOLOv11, YOLOv12) were examined comparatively with the aim of detecting disease. In the experiments, YOLOv8 achieved an average precision (mAP) value of 87.9%, YOLOv9 achieved 85%, YOLOv10 achieved 86.8%, YOLOv11 achieved 87.8%, and YOLOv12 achieved 86.1%. In the study, YOLOv8 showed the best performance compared to other models due to its ability to generalize object detection thanks to its model architecture and feature extraction. To improve the disease detection capability of the study, the SE and attention modules were integrated into the YOLOv8 model, which performed the best. The developed YOLOv8 model achieved the best performance with 88.7% mAP, 88% sensitivity, 78.6% precision, and 83% F1 score. The SE and attention module integrated into the YOLOv8 model improved the study's result by 1.01%.

Keywords: Lung Disease, Disease Detection, Artificial Intelligence, Deep Learning, YOLO

ÖNSÖZ

Bu tez hazırlama aşamasında birlikte emek harcadığım ve lisans hayatımın en başından beri desteklerini hiçbir zaman esirgemeyen danışman hocam Doç. Dr. İpek ATİK'e teşekkürlerimi borç bilirim. Lisans hayatım serüvenimden beri her konuda bilgisi, tecrübesi ve uzmanlığıyla hayatımın her noktasına katkısı olan ve bu tezin hazırlanmasında da çok büyük katkıları olmuştur.

Ömrüm boyunca hep yanımda bulunan ve sürekli bana her konuda destek olan canım aileme şükranlarımı sunuyorum.

Murat Kaan AKAR
GAZİANTEP-2025

İÇİNDEKİLER

ÖZET	iii
ABSTRACT	iv
ÖNSÖZ	v
İÇİNDEKİLER.....	vi
ŞEKİLLER DİZİNİ.....	ix
TABLOLAR DİZİNİ	xi
1. GİRİŞ	1
1.1. Akciğer Hastalıkları.....	2
1.2. Akciğer Hastalık Görüntüleri Tespiti.....	3
1.3. Literatür Araştırması	4
1.4. Çalışmanın Amacı	10
2. YAPAY ZEKA	12
2.1. Makine Öğrenme.....	12
2.2. Derin Öğrenme.....	13
2.2.1. Derin Öğrenmede Sinir Ağı Modelleri.....	13
2.2.2. Evrişimsel Sinir Ağı (ESA).....	14
2.2.3. Evrişimsel Sinir Ağının Görüntü İşlemede Önemi	16
3. YOLO	17
3.1. Geçmişten Günümüze YOLO	17
3.2. YOLO ve Nesne Algılama.....	20
3.3. YOLO Kullanım Alanları	21
4. MATERYAL ve METOD	23
4.1. YOLOv8.....	23
4.2. YOLOv8 İç Mimarisi	25
4.2.1. OMURGA.....	25
4.2.1.1. C2f Modülü (Concatenate-2-Feature).....	25
4.2.1.2. SPPF (Spatial Pyramid Pooling-Fast).....	26
4.2.1.3 SiLU.....	26
4.2.2. Boyun.....	26
4.2.3. Kafa.....	26
4.3 Dikkat Modülleri.....	27
4.3.1. SE (Sıkıştırma- Uyarma).....	28
4.3.1.1 Kanal Dikkat.....	29
4.3.2 Konvolüsyonel Blok Dikkat Modülü.....	30
4.3.2.1 Uzamsal Dikkat.....	31
4.3.3 SE ve Uzamsal Dikkat	32

4.4. YOLOv8 Modelleri	34
4.4.1. YOLOv8n.....	34
4.4.2. YOLOv8s	35
4.4.3. YOLOv8m	35
4.4.4. YOLOv8l	35
4.4.5. YOLOv8x.....	36
4.5. YOLOv9.....	36
4.5.1. YOLOv9 İç Mimarisi.....	37
4.5.1.1. GELAN (Generalized Efficient Layer Aggregation Network)	38
4.5.1.2. PGI (Programmable Gradient Information).....	38
4.5.2. Omurga	39
4.5.3. Boyun.....	39
4.6. YOLOv10.....	39
4.7. YOLOv11	42
4.7.1. Omurga	42
4.7.2. Boyun.....	43
4.8. YOLOv12.....	44
4.8.1. YOLOv12 İç Mimari Yapısı.....	45
4.8.1.1. Alan Dikkat (A^2)	45
4.8.1.2. Kalan Verimli Katman Toplama Ağları (R-ELAN)	46
4.9. YOLO Performans Metrikleri	46
4.9.1. Kesinlik.....	48
4.9.2. Duyarlılık	48
4.9.3. Ortalama Hassasiyet (mAP).....	48
4.9.4. F1Puanı	49
5. BULGULAR ve TARTIŞMA.....	50
5.1. Veri Seti ve Deneyler.....	50
5.2. YOLOv8 Deney Sonuçları	52
5.3. Geliştirilen YOLOv8 Modeli Deney Sonuçları.....	55
5.4. YOLOv9 Deney Sonuçları	60
5.5. YOLOv10 Deney Sonuçları	63
5.6. YOLOv11 Deney Sonuçları	67
5.7. YOLOv12 Deney sonuçları.....	71
5.8. Deney Sonuçları Karşılaştırmaları ve Tartışma.....	75
6. SONUÇLAR ve ÖNERİLER.....	79
7. KAYNAKÇA	81
ÖZGEÇMİŞ	84

KISALTMALAR

BT	: Bilgisayarlı Tomografi
MR	: Manyetik Rezonans Görüntüleme
ARDS	: Akut solunum sıkıntısı sendromu
mAP	: Ortalama Hassasiyet
SODL	: Küçük Nesne Katmanı
MSRF	: Çok Ölçekli Alıcı Modülü
MSDA	: Çok Ölçekli Çift Dallı Dikkat
CSPDarknet	: Derin Öğrenme Ağı
R-ELAN	: Katman Toplama Ağları
YOLOR	: Yalnızca Bir Temsil Öğrenirsin
ResNet	: Artık Bağlantılı Sinir Ağı
COVID-19	: Koronavirüs Hastalığı
İHA	: İnsansız Hava Araçları
SSPF	: Hızlı Uzaysal Piramit Tamamlama
SiLU	: Sigmoid Ağırlıklı Lineer Birim
GPU	: Grafik İşlem Birimi
PANet	: İyileştirilmiş Bir Yol Toplama Ağı
MS	: Çok Ölçekli
PGI	: Programlanabilir Gradyan Bilgisi
CSPNet	: Çapraz Aşamalı Kısmi Ağ
PAN	: Yol Toplama Ağı
PSA	: Kısmi Uzamsal Dikkat
IOU	: Kesişim Üzerinden Birleşme
GP	: Gerçek Pozitif
YP	: Yanlış Pozitif
YN	: Yanlış Negatif
GN	: Gerçek Negatif
ESA	: Evrimsel Sinir Ağı

ŞEKİLLER DİZİNİ

Şekil 2. 1 ESA yapısı (Panwar, 2018)	14
Şekil 2. 2 Evrişim Katmanı	15
Şekil 4. 1. YOLOv8 model mimarisi.....	24
Şekil 4. 2. YOLOv8 modelinin iç mimarisi (Khan et al, 2024).....	27
Şekil 4.3. SE blok yerleşimleri (Hu, Shen ve Sun, 2017).....	29
Şekil 4.4 Kanal dikkat yapısı.....	30
Şekil 4.5 Konvolüsyonel blok dikkat modülü.....	31
Şekil 4.6 Uzamsal dikkat yapısı	31
Şekil 4.7 SE ve uzamsal dikkat modülü	32
Şekil 4.8 Geliştirilmiş YOLOv8 mimarisi.....	33
Şekil 4.9 YOLOv9 genel yapısı (Chien-Yao Wang, 2020).....	37
Şekil 4.10. GELAN mimarisi (Chien-Yao Wang., 2023)	38
Şekil 4.11 YOLOv10 mimarisi genel yapısı (Ferreira, F. R. T., & do Couto, L. M, 2025)	40
Şekil 4.12 Çift kafa yapısı (Ao Wang, Vd, 2024).....	41
Şekil 4.13 Evrişimsel blok ve şişe boğazı (Rao, 2024)	43
Şekil 4.14 YOLOv11 mimarisi genel yapısı (Jian Xu., vd, 2025).....	44
Şekil 4.15 YOLOv12 genel mimarisi (Tian et al., 2025)	45
Şekil 4.16 R-ELAN mimarisi (Wang ve Jocher, 2025).	46
Şekil 4.17. Karmaşıklık matrisi	47
Şekil 5. 1. Veri seti örnek görüntüler	51
Şekil 5. 2. YOLOv8 model performans metriği grafikleri	53
Şekil 5. 3. YOLOv8 ile hastalıklı görüntülerin tespit edildiği örnek görüntüler	54
Şekil 5.4. YOLOv8 test sonucu oluşan örnek görüntüler	54
Şekil 5.5 YOLOv8 karmaşıklık matrisi (test).....	55
Şekil 5.6 Geliştirilen YOLOv8 model performans metriği grafikleri.....	57
Şekil 5. 7 Geliştirilen YOLOv8 ile hastalıklı görüntülerin tespit edildiği örnek görüntüler	58
Şekil 5.8 Geliştirilen Yolov8 test sonucu oluşan örnek görüntüler.....	59
Şekil 5.9 Geliştirilen YOLOv8 karmaşıklık matrisi (test).....	59
Şekil 5.10 YOLOv9 model performans metriği grafikleri	61

Şekil 5. 11 YOLOv9 ile hastalıklı görüntülerin eğitim sonucu örnek görüntüler	62
Şekil 5.12 Yolov9 test sonucu oluşan örnek görüntüler	62
Şekil 5.13 YOLOv9 karmaşıklık matrisi (test).....	63
Şekil 5.14 YOLOv10 model performans metriği grafikleri	65
Şekil 5. 15 YOLOv10 ile hastalıklı görüntülerin tespit edildiği örnek görüntüler	66
Şekil 5.16 YOLOv10 test sonucu oluşan örnek görüntüler	66
Şekil 5.17 YOLOv10 karmaşıklık matrisi (test).....	67
Şekil 5.18 YOLOv11 model performans metriği grafikleri.....	69
Şekil 5.19 YOLOv11 ile hastalıklı görüntülerin tespit edildiği örnek görüntüler	70
Şekil 5. 20 YOLOv11 test sonucu oluşan örnek görüntüler	70
Şekil 5.21 YOLOv11 karmaşıklık matrisi(test)	71
Şekil 5.22 YOLOv12 model performans metriği grafikleri	73
Şekil 5.23 YOLOv12 ile Hastalıklı görüntülerin tespit edildiği örnek görüntüler	74
Şekil 5.24 YOLOv12 test sonucu oluşan örnek görüntüler	74
Şekil 5.25 YOLOv12 karmaşıklık matrisi(test).....	75
Şekil 5.26 Toplam mAP değerleri	76
Şekil 5.27 Tüm sınıflarda toplam mAP sonuçları	77

TABLÖLAR DİZİNİ

Tablo 4. 1 YOLO modelleri arasındaki farklar.....	36
Tablo 5. 1. YOLO modeli eğitim parametreleri	51
Tablo 5.2. YOLOv8 eğitim parametre değerleri.....	52
Tablo 5.3. Geliştirilen YOLOv8 Modeli eğitim parametre değerleri	56
Tablo 5.4. YOLOv9 eğitim parametre değerleri.....	60
Tablo 5.5. YOLOv10 eğitim parametre değerleri.....	64
Tablo 5.6. YOLOv11 eğitim parametre değerleri.....	68
Tablo 5.7. YOLOv12 eğitim parametre değerleri.....	72
Tablo 5.8 Tüm modellerin deney sonuçları.....	76

1. GİRİŞ

Günümüzde her geçen gün nüfus artışı ve hastalıkların günden güne artması beraberinde sağlıkta tedaviye hızlı yanıtı geciktirmektedir. Hastaların sayısı günden güne arttıkça doktorların herhangi bir hastayı anında teşhis etmesi de zor bir durum haline gelmektedir. Teşhis edilemeyen hastalık ve tedavinin gecikmesi hem hasta sağlığı açısından hem de hastalığın ileri evreye ilerlemesi gibi sorunları beraberinde getirmektedir.

Sağlık günümüzde insanların en önem verdiği temel ihtiyaçlardan biridir. Bu yüzden hastalığın tedavisi için sağlık kurumlarına başvuru önem arz etmektedir. Hastaneye şikayet için başvuranların arasında akciğer hastalıkları en yaygın şikayetlerden birisidir. Öksürük, nefes darlığı, solunum yolu hastalıkları gibi sık karşılaşılan durumlar hastaneye başvurmada ön sıralarda gelir.

Astım ve diğer akciğer hastalıkları da hastane başvurularında önemli bir paya sahiptir. Antalya Eğitim ve Araştırma Hastanesi'nde yapılan bir çalışmada, KOAH alevlenmeleri (%30,8), pnömoni (%28,3) ve astım atakları (%10,7) hastane yatış nedenleri arasında en sık görülenler olarak raporlanmıştır (Toraks Derneği, 2020).

Akciğer hastalıklarının tanısı uzman doktorlar tarafından fiziki muayene, laboratuvar ya da görüntüleme teknikleri kullanılarak yapılır. Her sağlık kuruluşlarında tanı koymak zordur. Fiziki şartlar, gerekli ekipman eksikliği gibi faktörler tanıyı belirlemede eksik kalmaktadır. Nüfusun artması, her geçen gün hastalıkların çoğalması gibi etkenler tıbbi görüntüleme tekniklerini de kullanımını zorlaştırmıştır. Akciğer hastalıklarının yaygınlaşması görüntü sistemlerinde istenilen tanıyı erken belirlemede ve tedavi etmede gecikmektedir. Doktorlar hastalıklı görüntüleri röntgen (X-Ray) filmleri, bilgisayarlı tomografi (BT) ve MR (Manyetik Rezonans Görüntüleme) görüntülerinden tespit etmektedir.

Her geçen gün yapay zekanın ilerlemesi sağlık alanında da büyük değişiklikler meydana getirmektedir. Yapay zekanın kullanımı sağlık alanında erken teşhis ve doğru tanıda önemli bir rol oynar. Sağlık alanında kullanılan tıbbi ekipmanlar, görüntüleme sistemleri bunlara örnek verilebilir.

Günümüzde yapay zeka her geçen gün büyümekte ve çoğu işlerimizde bize kolaylık sağlamaktadır. Yapay zekanın alt dalları olan Makine öğrenmesi ve Derin öğrenmenin gelişimi bize sağlık alanında da kolaylıklar sağlamaktadır. Hastalığın

erken teşhisi, tedaviye hızlı yanıt verme, hastalıkları belli bir gruba sınıflandırma gibi kolaylıkları beraberinde getirip hem sağlık açısından hem de hastalıklı bireyleri belirlemede çok önemli bir yeri vardır.

Derin öğrenme hastalıkları tespit etmede ve sınıflandırmada kolaylıklar sağlamaktadır. Görüntülerin analizi, hangi yaş aralığında sık görülmesi ve tedavide kullanılacak ilacın belirlenmesinin hasta sağlığı ve doktorlar tarafından tespit edilmesi önemlidir. Derin öğrenme hastalığının doğru tespiti açısından da büyük doğruluk vermektedir. Derin öğrenme sayesinde vücudun belli bölümlerinde olan hastalıklar daha doğru ve kısa sürede tespit edilmektedir. Bu sayede hem erken teşhis hem de doğru tespit sağlanıp, hastalığın ilerlemesinin önüne geçilmektedir.

1.1. Akciğer Hastalıkları

Akciğer, insan sağlığı için hayati bir öneme sahip olan organların başında gelir. İnsanın hayatını devam ettirebilmesi, sağlıklı bir yaşam geçirmesi için akciğerin sağlıklı olması gereklidir. Hastanelere başvurularda akciğer hastalıkları şikayetiyle gelen hasta sayısı oldukça fazladır. Spor yapılmaması, sigara kullanımı ve düzensiz beslenme gibi faktörler akciğer hastalıklarını ortaya çıkarmaktadır. Akciğer hastalıklarının birçok türü vardır ve bazıları şunlardır.

- Zatürre (Pnömoni)
- Akciğer Kanseri
- Tüberküloz
- Nefes darlığı
- Göğüste su toplanması
- İnterstisyel akciğer hastalığı
- Bronşit
- Amfizem
- Akut solunum sıkıntısı sendromu

Akciğer hastalıklarının teşhisi ve sınıflandırılmasında kullanılan bazı yöntemler vardır. Bu yöntemler tıbbi görüntüleme, vücut analizi ve doktorun muayenesine göre şekillenebilir. Akciğer hastalıklarını belirlemede görüntüleme tekniklerinin önemi

fazladır. Görüntüleme teknikleri sayesinde doktorlar hastalığı anlamlandırmada ve hastanın hangi görüntüleme sistemine gireceğine karar verir.

1.2. Akciğer Hastalık Görüntüleri Tespiti

Akciğer hastalıklarını tespit etmede ön muayene, klinik bulgular, laboratuvar testleri ve görüntüleme cihazları kullanılır. Akciğer hastalıklarını tespit etmede en doğru sonuca varmak ve daha doğru veri bulmak için görüntüleme yöntemleri sık kullanılmaktadır. Bu görüntüleme yöntemleri hastanın şikayetine göre hangi cihaza gireceğine göre farklılık göstermektedir. Doktorlar hastanın hangi görüntüye göre hastalığının teşhis edileceğini hastaya iletir ve ona göre akciğerin görüntüsü istenir. Daha sonra istenen görüntüler analiz edilir ve hastalığının tanısının ne olduğuna karar verilir. Hastalığın belirlenmesinde görüntüler net olması, doğru bir görüntüleme tekniği tarafından görüntülenmesi ve görüntünün doğru şekilde konumlandırılması önem arz etmektedir.

Her hastalıkta olduğu gibi akciğer hastalıklarında da görüntüyü tespit etmek için belirli yollar vardır. Akciğer hastalıklarında kullanılan görüntüleme teknikleri birbirinden maliyet, hızlı veri alma, hastalığı erken teşhis etme gibi nedenlerle ayrılır. Hastanın radyasyona maruz kalma süresine göre farklılık gösterir. Hastanın teşhisi için gerekli olan görüntüleme teknikleri aşağıdaki gibidir.

Akciğer Grafisi (Röntgen/X-Ray): X ışınları kullanılarak çekilen göğüs boşluğundaki yapıları görüntülemek için kullanılır. Akciğer hastalığı tespit etmede kullanılan en yaygın görüntüleme tekniklerinin başında gelir. Doktorların ilk müdahale durumlarında erken teşhis için istediği görüntüleme tekniğidir. Maliyet açısından diğer görüntüleme tekniklerinden daha uygundur. Akciğer grafisi röntgen ile akciğer kanseri, zatüre, bronşit ve akciğerde sıvı birikmesi gibi hastalıklar tespit edilebilir.

Akciğer grafisi hastanelerde kısa sürede sonuç almada kullanılır. Ayakta kısa bir sürede çekilen görüntü doktora teşhis için kolaylık sağlar. Akciğer grafisi genelde ileri derece hastalarda kullanılmayan daha çok ilerlememiş hastalıkların kullanımının başında gelir. Maliyet açısından daha ucuz, daha kolay ve ulaşılabilir.

Bilgisayarlı tomografi (BT/CT): Bilgisayarlı tomografi akciğer grafisine göre daha ayrıntılı tespit eden bir görüntüleme sistemidir. Bilgisayarlı tomografide daha ayrıntılı nodüller görülür. Bu nodüller 2 boyutlu ya da 3 boyutlu olarak belirli bir model haline getirilebilir. Dezavantaj olarak işlem süresi daha uzundur ve radyasyon

yayabilir. Hastaların Bilgisayarlı tomografi çekirmesi için cihaza vücut uzanmış şekilde görüntüsü alınır. Bu görüntüleme sisteminde üç boyutlu görüntüler alınır ve akciğerin görüntüsü daha detaylı bir şekilde görülür. Bilgisayarlı tomografide kanserin erken teşhisindeki nodüller tespit edilebilir. Bu görüntüleme yönteminde kronik akciğer hastalıkları, iyi veya kötü huylu tümör, akciğerlerde sıvı birikimi gibi hastalıklar teşhis için kullanılır.

MR (Manyetik Rezonans Görüntüleme): MR daha kapsamlı ve ayrıntılı olarak vücut görüntülerini analiz eder. İşlem süresi diğerlerine göre daha uzundur. Akciğer hastalıklarını tespit etmede daha bir sınırlıdır. Akciğer hastalıklarında tümör, akciğer zarları ve akciğerlerde olan anormal durumları görüntülemeye kullanılır.

Akciğer hastalıklarını teşhis etmede MR ve benzerleri gibi görüntüleme sistemleri vardır. Ama görüntüleri sınıflandırmada ve kısa sürede hastalığı tespit etmede bize çok fazla fayda sağlamaz ve bu yüzden derin öğrenme modelleri ortaya çıkmıştır. Hastalığın erken teşhisi ve tedaviye başlanılacak ilaç durumlarında derin öğrenmenin görüntülerde tespiti ve analizi çok önemlidir.

1.3. Literatür Araştırması

Son yıllarda akciğer hastalıklarında görüntüleri tespit etmek için yeni yöntemler bulunmuştur. Pranav Rajpurkar arkadaşları ile her yıl Amerika’da zatüreye hastaneye yatan ve ölen insanların sayısının neden çok olduğunu anlamak için bir model önermiştir. Doktorların zatüreyi tespit etmede zorlandıklarını ve bu yüzden geliştirdikleri modelle doktorların tespit ettiği görüntüleri kendi yaptıkları çalışmayla karşılaştırmak istemişlerdir. Bu model üzerinden zatüreye yakalanan insanların görüntülerini kullanmışlardır. Modelde CheXNet evrişimli sinir ağı kullanarak zatüreye işaret eden alanların ısı haritalarını göstermişlerdir. Çalışmada 420 tane görüntü toplanmış ve bu görüntüler üzerinden verilerin doğruluk oranını ispatlamak için bir kısım doktorları bir araya getirmişlerdir. Geliştirdikleri modelde veri setlerini %70 test, %20 test ve %10 doğrulama olarak ayırmışlardır. Eğitimden sonra hastaların görüntülerinden alınan verilerde zatüreye tam yakalanan, bazı kısımları hasarlı bazı kısımları hasarsız olan görüntüleri tespit etmişlerdir. Yapılan çalışmanın sonucunda doktorların tespit ettikleri başarı oranının %95, geliştirdikleri çalışmanın sonucunu ise %97,5 olarak raporlamışlardır. (Pranav Rajpurkar, vd., 2017).

Bir başka çalışmada COVID-19’un dünya üzerinde hızla yayılmasıyla Linda Wang ve Alexander Wong açık kaynaklar üzerinden herkesin erişimine açık olan

verilerin olduğu evrişimli sinir ağı COVID-NET kullanarak belli hastaların bilgilerine erişmişlerdir. COVID-NET hastalık için ilk açık kaynaklı tasarımlardan birisi olduğunu belirtmişlerdir. Bu çalışmada herkesin bilgilerinin açık olduğu COVID-X veri seti kullanılmıştır. Linda Wang ve Alexander Wong'un burada tek amacı hastalıkla ilgili verileri edinmek değil aynı zamanda COVID-NET'İN nasıl tahminler yaptığını öğrenmektir. Çalışma sonucunda COVID-NET'in otomatik olarak hastalığı tespit ettiğini aynı zamanda diğer akciğer hastalık bulgularını bulduğunu da gözlemlenmiştir. Eğitim sonucunda doğruluğun %92,4 oranında performans gerçekleştirdiğini belirtmişlerdir. Bir başka kaynaktan alınan görüntü verileri eğitim veri seti olarak kullanıldığında ise bu oranın dahada düşeceğini açıklamışlardır. (Linda Wang & Alexander Wong 2020).

Bir diğer çalışmada YOLOv5 kullanılarak akciğer nodüllerinin BT taramasıyla tespiti önerilmektedir. Bu çalışmada akciğer kanserini erken teşhis etmede kullanılan BT cihazının yanlış sonuç vermesinden kaynaklı hastalığın ilerlemesi ve tam teşhis edilememesinden ötürü radyasyonun verdiği zarara değinilmiştir. Hastalıkları teşhis etmede radyologlar önem arz etmektedir. Akciğer nodüllerinin tespit edilmesinde doktorların tek radyolog ile %68, iki radyolog ile %82 oranında hastalığı doğru tespit ettiği belirtilmiştir. Radyologların nodülleri erken teşhis etmesinin sonucu olarak hem yanlış bilgiler belirlediğini hem de sürecin uzun zaman almasından dolayı başka bir kaynağa ihtiyaç duyulduğunu açıklamışlardır. Bu çalışmada YOLOv5 kullanılarak bir hastalık tespit çalışması yapılmıştır. Görüntüler halka açık olan LIDC-IDRI veri kümesinden alınmıştır. Alınan görüntülerden nodüllerin işaretlendiği ve açıklamalı lezyonlara sahip BT taramaları da dahil edilmiştir. Toplam 270 BT görüntüleri kullanılmış bunların 239'u eğitim, 41'i ise doğrulama veri seti olarak kullanılmıştır. Model sonucunda yapılan çalışmanın doğruluğunu %92,82 olarak tespit etmişlerdir. Alınan görüntüler halka açık veri seti olduğundan dolayı doğrulama değerinin düşeceğini ve özel veri kullanılırsa bu oranın dahada artacağını belirtmişlerdir. (Haytham Al Ewaidat & Youness El Brag 2022).

Razlighi ve arkadaşları her yıl milyonlarca insanın öldüğü akciğer hastalığı sebebiyle BT görüntülerinden akciğer hastalığındaki nodülleri tespit eden ve sınıflandıran bir çalışma yapmak istemişlerdir. Bu çalışmada YOLOv5s modelini kullanarak 397 BT görüntüsünü yeniden eğitmişlerdir. İlk aşamada model hassasiyetini yüksek görmek için 0.3 güven değeri belirlemişlerdir. İlk amaçları düşük

bir yanlış negatif ile modeli test etmektir. Kendi verileri hariç hastalığı farklı yöntem olan YOLO modeli üzerinden 888 BT görüntüsünden alınan verilerle test edildiğinde daha düşük doğruluk değerleri tespit ettiler. Güven yüzeyini her düşürdüklerinde alınan verilerin doğrulama oranlarını dahada düşürdüklerini gözlemlediler. Hiyerarşik nodül tespiti (HND) olarak adlandırdıkları bu model 2 aşamalıdır. İlk aşamada YOLO üzerinden nodüllerin yeri ve sınırını belirtmişlerdir diğer aşamada ise 3 boyutlu ESA üzerinden buldukları nodüllerin doğru olup olmadıklarına karar vermiştir. Model sonucunda 2 aşamalı eğittikleri modellerin doğruluğu %98,4 olasılıkla yüksek tespit ettiği görülmüştür. (Razlighi, vd., 2022).

Shangjie Yao ve arkadaşları zatüre hastalığının akciğer x görüntülerinden yaptıkları bir çalışmada doktorlara konum bilgisi sağlamayan ikili sınıf algoritmalarından dolayı YOLOv3 geliştirerek bir model önermişlerdir. 3 başlıkta yapılan modelde iyileştirme sunmuşlardır. Düşük pikselli görüntülerde hatanın görüntü değerlerini arttırmaya çalışmışlardır. Yaptıkları çalışmada hem hastalığın görüntülerini daha iyi analiz etmeyi hem de doğruluk olarak hastalığı tespit etmeyi amaçlamışlardır. YOLO üzerinden aldıkları eğitim sonuçlarıyla kendilerinin tasarladıkları modeli PYOLO'yu karşılaştırmışlardır. 4 farklı modelde karşılaştırma yaptıktan sonra kendi eğittikleri modelin mAP değerini %46,84, F1 değerini (f değeri duyarlılık ve kesinlik değerlerin harmonik ortalamasını temsil eden bir performans ölçütüdür) ise %81 bulmuşlardır. Bu model sonucunda hem kendi eğitim görüntülerinin piksel değerlerini yüksek bulmuşlar hem de doktorların görüntüleri daha iyi tespit ettiklerini anlamışlardır (Yao, vd., 2020).

Başka bir çalışmada Antonella Santone ve arkadaşları akciğer kanseri için yaklaşık %30 oranında kanseri erken tespit edecek ve kanser riskini ilerlemeden erken aşamada belirleyecek bir model önerdiler. Yapılan modelde sadece nodülleri tespit etmekle kalmayıp aynı zamanda çıplak gözle görülmeyen kanserli küçük nodülleri de tespit etmeyi amaçladılar. Akciğer görüntülerinde üst üste katman haline gelmiş ve tespit edilemeyen küçük lezyon ve nodülleri tespit etmeye çalışmışlardır. Geleneksel YOLO modelinde nesneyi tespit etme şeklinin sınıflandırarak ve dikdörtgen biçimde kutu gibi nodülleri tespit ederek bulduğunu ön plana sürmüşlerdir. Santone ve arkadaşlarının yaptıkları modelde YOLO yapısı ile maskeye benzettikleri görüntüleri kendi bölümlerinde bir araya getirerek görüntüler içinden kanserli nodülleri ayırt etmeyi hedeflemektedir. Kendilerine has olan bu yöntem görüntülerde fark edilmeyen

küçük katman yapılarını bile tespit etmektedir. Model sonucunda sınıflandırmada doğruluk değeri yaklaşık %75,7, maskeye benzettikleri kendi bölümlerinde ise doğruluk değeri %73,3 olarak elde edilmiştir. Çalışma sonucunda bir araya gelmiş görüntülerdeki tespit edilemeyen nodüllerin ve erken aşamada kanserli hücrelerin tespit edilebildiğini göstermişlerdir. (Antonella Santone, vd., 2024).

Başka bir yapılan çalışmada Mohammed Saifuddin Munna ve arkadaşları zatürenin doğru bir şekilde tanımlanabilmesi için YOLO (YOLOv3, YOLOv4 ve YOLOv6) modellerini önermişlerdir. 3 grupta yapılan karşılaştırmada hangi YOLO yapısının daha doğru sınıflandırma gerçekleştirdiğini amaçlamışlardır. Görüntü olarak kaggle'den aldıkları veri setinden 2150 fotoğraf kullanmışlardır. Geliştirdikleri modelde görüntüleri 3 veri setine ayırmışlardır. Bu veri setleri bakterili, virüslü ve normal veri setleri olarak 3 sınıfta incelenmiştir. Görüntüleri geliştirdikleri modelde eğitmek için verileri %80 eğitim ve %20 test olarak ayırmışlardır. Eğittikleri model sonucunda YOLO3'ün YOLO6'ya göre çok daha yavaş olduğunu en doğru tespiti YOLO6'nın yaptığını ve görüntüleri daha iyi analiz ettiğini belirlemişlerdir. (Muhammed Seyfeddin Munna, vd., 2024).

Yeni bir çalışmada Wu ve arkadaşları YOLOv7 kullanarak akciğer hastalarındaki küçük nodüllerin şekillerinin net olmaması ve karışık bir biçimde durmasından dolayı yeni bir küçük nesne katmanı SODL ortaya önermişlerdir. İkinci olarak da akciğer nodüllerinin aşağı kaymasından dolayı tanımlanmasının zor olduğu bu yüzden de modelin kanal iyileştirmesi için çok ölçekli alıcı modülü (MSRF) kullanılmasını önermişlerdir. Geliştirdikleri bu modelde her şekilde nodül yapılarını tespit etmeye çalıştıkları ve modelin yapısında da farklı şekil boyutları ile istedikleri doğrultuda algılayabilen sistem ortaya çıkarıp başardıklarını kanıtlamışlardır. Veri kümesini bilgisayarlı tomografi görüntülerinden yaklaşık 1186 hastanın görüntüsünden elde etmişlerdir. Çalışmaların sonucunda yaptıkları eğitimde doğruluk değerini %95,41 olarak bulmuşlardır. Bu model sayesinde hem en küçük dokuları hem de karmaşık yapıları istedikleri boyutta ayarlayabilmişler ve bu sayede hastalığı tespit etmeyi hedeflemişlerdir. (Xiaosheng Wu, vd., 2024).

Yapılan bir çalışmada Cheng Ren ve arkadaşları akciğerlerde küçük olan nodülleri tespit etmek için geleneksel YOLO modellerinden farklı olarak bir model tasarlamayı önermişlerdir. Kansere neden olan küçük nodülleri tespit etmek için SwiF-YOLO adında model eğitmişlerdir ve bu model küçük lezyonları istenilen ölçekte ve

çerçevede ayarlamaya çalışmış geleneksel yöntemlere göre daha doğru sonuçlar elde etmiştir. Verilerden alınan doğru sonuçlarda hastalık tespiti doğru ve daha hassas bir şekilde ele alınmıştır. Çalışmanın sonucunda modelin doğruluğunu %94,8 olarak elde etmişlerdir. (Cheng Ren, vd., 2024).

Covid-19'un hızla ilerlemesi ve erken aşamada tespit edilememesi sonucunda Sadik Kamel ve arkadaşları değiştirilmiş bir evrişimli sinir ağı kullanarak (ESA) hastalık görüntülerini tespit etmeyi amaçlamışlardır. Toplam 500 hastanın görüntülerini kullanmışlardır. Kullandıkları modelde kendileri geliştirdikleri ESA modelini entegre ederek aldıkları görüntülerden COVID-19 hastalığına yakalanıp, yakalanmadığını tespit etmeye çalışmışlardır. Alınan veriler hem laboratuvar ortamından hem de hastaların vücut yapılarından alınan örneklerle harmanlanmış ve kendileri geliştirdikleri modelde eğitimi yapmışlardır. Eğitim hastalardan ilk başta görüntülerden alınan verileri topluyor ve laboratuvarında alınan örneklerle birleştirip tahmin yapmaya çalışıyor. Bu sayede test kitlerinden alınan sonuçtan ziyade çok daha kısa sürede kendi geliştirdikleri modelde hastalığın tespitini ve doğruluğunu ortaya çıkarıyor. Çalışma çok yönlü olduğu için hastalıklı bireyin hemen tespit edilmesi sağlanıyor. Kendi yaptıkları modelde F1 skorunu %99,33 buluyorlar ve bu sayede hastalık daha algılanabilir şekilde tespit ediliyor. (Sadik Kamel Gharghan, vd., 2022).

Başka bir yöntemde COVID-19'un sadece zatüreye sebep olmadığını ve diğer başka karaciğer hastalıklarını da etkilediğini düşünen Tareque Rahman Ornob ve arkadaşları az sayıda görüntüden akciğerde zatüreyi ve diğer hastalıkları ayıran bir model geliştirdiler. Modelde çok az sayıda veri kullanarak üçüz siyam ağı mimarisini kullanmışlar. Üçüz siyam ağı mimarisi dedikleri 3 farklı şekilde benzerlik ve farklılıkları kıyaslayan bir mimaridir. Mimari hastalığı 3 gruba ayırır bunlar; Covid'li normal hastalıklı ve zatüre olarak adlandırılır. Mimaride geleneksel ESA modelinde önceden eğitilmiş görüntüleri kullanmışlardır. Toplam modelde en az veriden faydalanmak için 200 adet BT görüntüsü vardır. Kendi istedikleri doğrultuda çıkarttıkları modelin doğruluk oranını yaklaşık %98,719 bulmuşlardır ve bu sayede hastalığı istenilen şekilde tespit etmeyi ve diğer hastalıklarla karıştırmamayı sağlamışlardır (Tareque Rahman Ornob, vd., 2023).

Başka bir çalışmada MICHAEL J. HARRY ve arkadaşları COVID-19 hastalığında teşhisi tespit etmede doktorların zorlandığına dikkat çekerek bu sayede doktorların üs üste bakmakta zorlandıkları ve yorgun anlarında tespit etmeye

çalıştıkları görüntülere daha kapsamlı ve çabuk bir şekilde bakmaya yarayan bir model önermişlerdir. Önerdikleri modelde X-Ray, ultrason ve BT taramalarından görseller kullanmışlardır. Yaptıkları çalışmada önceden eğitilmiş ESA, VGG19, ResNet vb. modelleri karşılaştırıp en iyi sonuç verene yönelmişler. Geliştirdikleri modelde en uygun analizi VGG19 modelinde bulmuşlardır. İlk olarak modeli belli aşamalardan geçirmişler daha sonra yaptıkları çalışmada görüntünün gürültüsü, parlaklığı, bozukluğu ve şeklin daha görünür olmasını sağlamışlardır. Görüntülerde kendi özel veriler kullandıklarında halka açık hali hazırdaki veriye kıyasla daha yüksek oranda doğruluk sağlayacak modele yönelmişlerdir. Eğitim verilerinde en yüksek doğruluk oranını Ultrason görüntülerinden %100 olarak elde etmişlerdir. Bir diğer görüntü verileri X-Ray'dan %86 ve BT görüntülerinden %84 olarak doğruluk değerini belirlemişlerdir. Eğitimde en çarpıcı durum veriden ziyade hiç dokunulmamış normal verilerin bile çalışma sonucunda başarılı bir şekilde ortaya çıktığını ve tespitin gerçekleştiğini belirtmişlerdir (Michael j. Horry, vd., 2020).

Bir diğer çalışmada Chaosheng Tang ve arkadaşları akciğer hastalığındaki kanserli görüntülerden YOLOv6 kullanarak daha hızlı ve daha iyi tespit sağlamasını sağlayan bir model Lung-YOLO'yu önermişlerdir. Bu mekanizma tespit edilemeyen çok küçük nodülleri tespit edip hastalığı erken aşamada ortaya çıkmasını sağlamaktır. Model çok ölçekli çift dallı dikkat (MSDA) adında bir mekanizmadır. Bu mekanizma iki durumda görüntüleri tespit etmeyi amaçlamaktadır. İlk olarak küçük şekilde nesneleri tespit etmeye yarayan bir modülü büyük ölçekte tespit etmeye yarayan nodülle birleştirip bir araya getirmektir. Bunun sonucunda görüntülerden her iki nodül şeklide aynı anda görüntülenmektedir. Çalışmanın sonucunda hastalık açısından görünmeyen nodülleri ve karmaşık yapıdaki nodülleri aynı katmandan belirleyip çok küçük detayların bile kaçmayacağını raporlamışlardır. Çalışma bir çapraz mekanizmaya benzetilmiş bu mekanizmanın sonucunda en küçük ayrıntıdaki görüntüler bile fark edilebilmiştir. Çalışmada alınan veriler LUNA16 veri seti genelde edilmiştir. Model sonucunda toplam eğitim değerlerini sırasıyla hassasiyet %97,5, kesinlik %96,5, duyarlılık %96,9 ve mAP değerini de %97,5 olarak elde etmişlerdir. Geliştirilen modelin kendi özel verilerle eğitildiğinde daha yüksek doğrular alınabileceğini raporlamışlardır. (Chaosheng Tang, vd. 2025).

Xing Wang ve arkadaşları akciğer hastalıklarından kanser nedeniyle her yıl binlerce insanın ölmesinden dolayı kanseri erken aşamada tespit edecek bir modül

önermişlerdir. Yaptıkları çalışma özellikle küçük ayrıntısız ve gözden kaçan görüntülerdeki nodülleri tespit etmeyi hedeflemektedir. Modelde 3 tespit yöntemi U-Net, YOLOv8s ve Swin ağlarını kullanmışlardır. Burada amaç çift aşamalı model geliştirip doğruluğu arttırmaktır. Görüntülerde LUNA veri setinden 888 BT görüntüsü ve başka yerden aldıkları 308 görüntüyü bir arada kullanmışlardır. İlk aşamada U-Net'i kullanıp daha sonra akciğerin içindeki dokuları belli başlı parçalara ayırarak nodülün dışındaki her şeyi pasif hale getirmişlerdir. İkinci aşamada YOLOv8s ve Swin ağlarını birleştirerek modeldeki küçük detayları, ağ yapılarını, modelin şeklini ve hasarlı yerleri tespit etmeyi amaçlamışlardır. Model sonucunda LUNA veri setinden aldıkları değerler sırasıyla şu şekildedir; 0,898 hassasiyet, 0,851 kesinlik ve mAP50 0,879 olarak elde edilmiştir. Modelin sonucunda yüksek doğruluk ve yanlış sayısının daha az olduğunu bu sayede kanseri erken aşamada tespit edebilen 2 aşamalı modelle daha ayrıntılı incelenebileceğini raporlamışlardır. Geliştirdikleri model akciğerde hastalık tespiti için kullanılmış ve akciğerdeki lezyonların iyileştirilmesine katkıda bulunmuştur. (Xing Wang, vd., 2025)

1.4. Çalışmanın Amacı

Bu tezin amacı YOLO algoritması kullanılarak akciğer hastalığındaki virüs, bakteri ve normal görüntüleri hızlı ve etkili biçimde tespit edebilmek ve görüntüleri doğru oranda sınıflandırmayı amaçlamaktır. Yapılan çalışma 3 farklı sınıfa ayrılmıştır ve görüntülerde hastalıklı, virüslü ve normal olan akciğer görüntüleri kullanılmıştır. Görüntüler daha sonra YOLO algoritmasına entegre edilmiştir. YOLO algoritmasının farklı versiyonları YOLOv8, YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 kullanılarak elde edilen sonuçlar karşılaştırılmıştır. En iyi performans gerçekleştiren YOLO modeline SE ve uzamsal dikkat modülü entegre edilmiştir. Bu sayede sınıflandırma ve nesne tespiti yapılmak istenen çalışmada maksimum performans değeri hedeflenmiştir.

Literatürde yapılan çalışmalara göre görüntüleri tespit etmekte ve sınıflandırmakta YOLO'nun bazı modelleri kullanılmıştır ve diğer YOLO modellerine göre kıyaslaması yapılarak akciğer hastalığı görüntülerinin farklı YOLO modellerinde hızlı bir şekilde tespit edilebilmesini amaçlamaktır. Her yenilikte yapay zekanın günden güne geliştiği durumlarda daha doğru tespit ve doğru modellerin kullanıldığını düşündüğümüzde literatürde yapılan çalışmaların yeni YOLO modelleri ile yapılmadığı ve kıyaslama açısından sınırlı sayıdaki modellere yönelindikleri

gözlemlenmiştir. Günümüzde görüntülerin daha net ve hastalıklı verilerin yaygın olduğu düşünüldüğünde yapılan bu çalışmada modern verilerin birbirinden daha detaylı ve kapsamlı bir şekilde farklı modellerde ele alınması ve ayrıntılı bir biçimde incelenmesi amaçlanmıştır. Genel kapsamda bu çalışma ile günümüzle bütünleşmiş bir şekilde ilerleyen modellerin doğruluk tespitinde birbirinden kıyasla farklı doğruluk oranları çıkardığını ve karşılaştırmaların daha detaylı bir biçimde ele alındığını göstermiştir. Sağlık alanında günümüzde gelişen durumlarla beraber YOLO algoritmalarının geliştirilmesi ve sağlıkta yapılan çalışmalarla iç içe olmasından kaynaklı hastalıklı görüntüleri doğru tespit edebilmek açısından yapılan çalışmalara katkı sunmuş ve iç içe bir sarmal yapıda yerini almıştır. Kapsamlı olarak bu çalışma mevcut yöntemleri değerlendirdiğimizde daha doğru ve gerçekçi bir yenilik katmayı amaçlamaktır. Bu doğrultuda dünyada her geçen gün gelişen duruma ayak uydurmakla beraber YOLO algoritmalarını dahada geliştirerek kapsamlı bir şekilde ortaya sunmaktadır.

2. YAPAY ZEKA

Eski çağlardan beri her geçen yüzyıl dünya üzerinde köklü değişiklikler olmaktadır. Her bir dönemde insanoğlu teknolojiye ilgi duymuş, teknolojinin bir ihtiyaç olduğunu öne sürmüştür. Teknoloji bir devrim gibi her sene gelişmekte ve çağımızda insan hayatını tamamen kapsama alanına dahil etmiştir. Gelişen durumlarla beraber yapay zeka insanların kendilerini taklit etmeyi sağlayan ve insanın yapmadığı ama insan eliyle ortaya sunulan durumlar olduğunu ortaya çıkarmıştır. Yapay zeka insan aklını taklit eden, insanın yaptığı düşünebilme, akılda tutabilme ve istenilen komutlara cevap verebilen bir daldır. Yapay zeka bilimi her türlü alanda var olan bilim, mühendislik, sağlık, felsefe gibi alanlarda en ince detaylarda bile kendini gösterebilen bir alandır. Yapay zeka bir insan beyni algoritması gibi komutları işleyebilen aldığı cevapları değerlendirebilen ve uygulamaya koyan insan zihni gibi hareket edebilen bir yapıdır. Yapay zeka yapısı belli bir algoritma ile çalışır. Önce kendi için aldığı veriyi düşünür daha sonra bilgiyi belli bir birikimde depolar ve depoladığı veriyi kullanacağı doğrultuda kendi yaratıcı dünyasında ortaya sunar.

Yapay zekanın günümüzde var olduğu konumda insanlar genelde kendi istedikleri doğrultuda yapay zekayı yönlendirmeye çalışırlar. Bu durumda daha çok yapay zekanın ne yaptığına çok detay vermeden yapay zekanın istedikleri şekilde zihin gücü gibi yönetilmesini isterler. Bu durumda ortaya çıkan yapılarda bazen istenilen doğrulukta veri olmayabilir. Her gelişen teknoloji yapay zekanın da olumlu olumsuz yönlerini daha da arttırabilir. Gelişen dünyayla beraber yapay zekanın ne gibi bir ilerleme göstereceği de merak konusudur.

Yapay zekanın bazı konularda eksik ve karmaşıklığından dolayı belli başlı alt dalları ortaya çıkmıştır. Makine öğrenme ve Derin öğrenme yapay zekanın bir alt dalıdır. Makine öğrenme ve Derin öğrenme gelişen modellerden analiz çıkarmayı ve çözilemeyecek karmaşıklık anlarında gelişen teknolojiyle beraber ortaya çıkmıştır.

2.1. Makine Öğrenme

Yapay zekanın bir alt dalıdır. Verilerin karmaşık bir yapıda ve fark edilemeyen durumlarda ortaya koyulan verilerden bir analiz yapmayı ve bilgiyi analiz ederek doğru bir şekilde ortaya çıkarmaya yarar. Verileri matematik denklemi gibi sonuç yapılı girdi ve çıktı almaya ve onları kullanım için bir işlem haline getirmeye yarar. Makine öğrenimi aldığı verileri iyi analiz edebilen ve tahminler doğrultusunda istenilen sonuca uygun algoritmalar geliştirebilen bir yapıdır. Geliştirdiği algoritmaları

uygun bir küme haline getirip aldığı veriler doğrultusunda işleme koyup istenilen sonuca yakın bilgi üretmektir. Makine öğrenimi algoritması insan zihninin tahmin ettiği ve sonuca ulaştığı yapıları kendi yapısında analiz ederek belirli katmanlı yapılardan geçirmeye yarar. Bir nevi insan zekasının öğrenme sistemi gibi hareket ettiği bir yapıda kendi içerisindeki yapıdan aynı insan zihni gibi hareket edebilen bir yapı ortaya çıkarmaktır.

2.2. Derin Öğrenme

Derin öğrenme makine öğreniminden daha derin ve kapsamlı bir yapay zeka biçimidir. Derin öğrenme insan beyninde ortaya konulan yapıların bir nevi matematiksel denklem gibi karmaşık yapıların insan sinir ağlarını taklit ederek ortaya sunduğu bir yapay zeka alt dalıdır. Derin öğrenme bir yapıda insan gücü olmadan kendi verilerini kapsamlı bir sinir ağı kullanarak ortaya çıkarır. Derin öğrenme diğer geleneksel yapılardan farkı hazır bilgi kullanmadan kendi istediği bilgiyi kullanarak ortaya koyan bir yapıdır.

Derin öğrenme kullanım alanları çoğu yerde kendini göstermiştir. Mevcut görüntülerinin iyileştirilmesi, otonom sistemler, turizm, sağlık, veri bilimleri, robotlar, savunma sanayi, turizm gibi her alanda varlığını ortaya koymuştur. Derin öğrenme gelişen teknolojiyle birlikte insan hayatını kolaylaştırmış ve her geçen gün kendisini her alanda göstermeye devam etmektedir.

Derin öğrenme çalışma basamaklarında ilk önce problem belirlenir. Daha sonra problem için veri kümesi toplanır ve toplanan veri kümesinde algoritma belirlenir. Model eğitiminde belirlenen algoritma test edilir ve probleme uygun olup olmadığını, problem sonucunda neler ortaya çıkacağını söyler. Derin öğrenmenin temelinde ortaya çıkan sinir ağları mevcuttur.

2.2.1. Derin Öğrenmede Sinir Ağı Modelleri

Yapay sinir ağları insan beynini taklit ederek ortaya çıkan, insan zihnindeki verilere dayalı bir algoritma gibi düşünülerek ortaya çıkmıştır. Derin öğrenmeyle iç içe bir halka şeklinde olan sinir ağları derin öğrenmenin katman yapısından faydalanarak insan zihnindeki gibi hareket etmeye yarayan algoritmalar belirlemektir. Yapay sinir ağları verileri modern olarak işleyip, doğru katmanda bizi istenilen veriye ulaştırmada bir yol gibi karşımıza çıkmaktadır. Belirli sinir ağı modelleri vardır. Günümüzle iç içe geçmiş yapılar belli katmanlardan oluşmaktadır. Sinir ağları da bu

katmanlar gibi iç içe geçmiş sarmal yapılardan oluşmaktadır. Derin öğrenme yöntemlerinde en sık kullanılan sinir ağı yapısı Evrişimsel Sinir Ağı'dır.


2.2.2. Evrişimsel Sinir Ağı (ESA)

Derin öğrenmenin kullanımı her geçen gün artmaktadır. Gelişen teknoloji ile derin öğrenme katmanları genişlemekte bu sayede kullanım alanları artmaktadır. Evrişimsel sinir ağları belli problemleri çözmek, analiz etmek ve bu problemler üzerinden görüntüleri belli bir analiz çerçevesinde tespit etmeyi sağlar.

Evrişimler sinir ağları problemlerin sınıflandırılmasında genel anlamda kullanılmaktadır. ESA genel olarak bir görüntüyü istenilen boyutta algılamamızı sağlamaya çalışan ve görüntüde istenilen modelin tespit edilmesini ortaya çıkaran bir ağıdır. Evrişimsel sinir ağları matematik modellemesinde hali hazırdaki bilgiyi kendi hazır verimizle birleştirip ortaya farklı bir model sunmaktadır. ESA katmanları Evrişim, aktivasyon, havuzlama, tam bağlantı katmanlarından oluşmaktadır.


Evrişimsel sinir ağı tanınan nesnenin belli bölümlerinin tekrar istenilen boyutta ve kısımda nesneyi algılamayı sağlar.

Nesneler her alandan görüntülerle kullanılabilir. Dünyanın hızlı ilerlemesi teknoloji görüntülerini dahada yaygınlaştırmaya devam etmektedir. Örneğin bir araba görüntüsünden ya da bir havada uçan nesne görüntüsünden bile her nesne aygıtı yapılabilir Şekil 2.1'de ESA yapısı gösterilmiştir.



Şekil 2. 1 ESA yapısı (Panwar, 2018)

Evrişim Katmanı: Evrişim katmanında elde ettiğimiz görüntüden belli kısımda görüntülerin kırılıp, istenilen görüntü şekline çevrilmesiyle oluşur. Bu katmanda 3x3, 4x4, 5x5 gibi boyutların matrislere indirgemesiyle oluşur. Şekil 2.2’de 5x5’lik matrisin 3x3’lük filtre uygulanması örneğidir. Evrişim katmanı formülü denklem 2.1’de gösterilmiştir.



Şekil 2. 2 Evrişim Katmanı

$$O(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (2.1)$$

Burada;

$O(i, j)$ = Çıkış matrisi

$I(i+m, j+n)$ = Giriş matrisi

$K(m, n)$ =Evrişim filtresi

Aktivasyon Katmanı: Aktivasyon katmanı doğrusal yapıdaki çıktıları doğrusal olmayan katmana dönüştürür. Amaç burada her türden katman yapısına entegre olmak ve çıktıda doğrusal olmayan yapıdaki modellere de görüntüleri hazırlamaktır. Model yapısını değiştirir ve karmaşık bir sarmal yapı haline getirir.

Havuzlama katmanı: Havuzlama katmanında görsellerin boyu büyük olduğundan modeli daha doğru ve anlaşılır hale getirmek için küçültme işlemi yapar. Burada 2 tür havuzlama işlemi yapılır. İlki Ortalama havuzlama fotoğrafın boyutunu küçülttüğünde oluşan değer ortalamasını alır. İkincisi Maksimum havuzlamadır burada 4x4 bir görüntünün 2x2 ye indirgemesiyle küçülen değerin en büyüğünü alır. Havuzlama katmanı formülü denklem 2.2’de gösterilmiştir.

$$(Y_{i,j}) = \frac{1}{k^2} \sum_{m=0}^{k-1} \sum_{n=0}^{k-1} X_{si+m, sj+n} \quad (2.2)$$

Burada;

X = Giriş matrisi

Y= Çıkış matrisi

Kxk = Boyut

s= kaydırma çıkış matrisi

Tam Bağlantı Katmanı: Tam bağlantı katmanında amaç bir önceki nöronun kendisinden sonra gelen nörona bir sarmal yapıda bağlanmasıdır. Bu sarmal yapı her zaman kendisinden sonraki yapıyı takip eder ve katmanı en aza indirmeye çalışır. Tam bağlantı katmanında en son kısımda bütün nöronlar birleşir.

2.2.3. Evrimsel Sinir Ağının Görüntü İşlemede Önemi

Görüntü işleme yıllar geçtikçe her geçen gün kendini geliştirmektedir. Bu gelişmelerin sonucunda evrimsel sinir ağları ile beraber hayatımızın her alanında karşımıza çıkmaktadır. ESA kullandığımız görüntüyü istediğimiz bir şekilde ayarlayıp ekran küçültme, mimari yapı değişikliği gibi şekil üzerinde istediğimiz her bir görüntünün analizini bize yaptırmaktadır. Yıllar geçtikçe yapılan çalışmalar bize daha doğru sonuç ve istediğimiz veriyi sunmaktadır.

2012 yılında hayatımıza bir devrim gibi giren AlexNET yeni bir çağın bize sunduğu avantajları gözler önüne sermiştir. Bu model yapay sinir ağının görüntü üzerinde ne kadar etkili ve güçlü olabileceğini karşımıza çıkarmıştır. Günümüzde hala etkisini sürdüren birçok modele örnek olmuştur.

AlexNet'in devrim gibi hayatımıza girmesinden sonra VGGNet (2014), GoogLeNet (2015), ResNet (2016) gibi modeller de hayatımıza girmiştir. Otonom sistemlerde, yapay zeka çalışmalarında gözden kaçan en ince ayrıntıyı bile fark etmemizi sağlamaya çalışır. Bu mimarilerin gelişmesiyle günümüzde yapılan çalışmalarda istenilen verilerle istenilen sonuçlara ulaşılmaya çalışılmıştır.

3. YOLO

Nesne tespiti günümüzde her alanda kullanılan ve problemleri ayrıntılı bir biçimde ele alan bir algoritmadır. Bu algoritmalarından birisi her alanda varlığını gösteren ve en ufak nesneleri bile tespit etmeye yarayan YOLO'dur. YOLO varlığını her alanda karşımıza çıkaran tek bir görüntüden hem tespit hem de sınıflandırma yapmaya yarayan bir algoritmadır. İsminin uzun hali "You Only Look Once" olarak tanımlanır.

Günümüzde teknolojinin daha da ilerlemesi görüntü tespitlerini yaygın bir hale getirmiştir. İnsanlar bu doğrultuda ellerindeki verilerle tespit yapabilmeyi ve verileri belirli bir kümede halinde toplayabilmelerini amaçlamışlardır. Bu doğrultuda YOLO alanını geniş yelpazede tutup görüntülerin açılarını istenilen seviyede ayarlamaya ve doğru şekilde görüntüleri tespit etmeye yaramaktadır.

Diğer nesne tespit uygulamalarına kıyasla YOLO'nun tek bir açıdan sınıflandırmak ve görüntüleri tespit edebilmek yeteneği vardır. YOLO hız olarak diğer geleneksel nesne tanıma yöntemlerinden çok daha hızlıdır. Görüntüyü tek bir ağıdan 2 türlü kontrol edebildiği için geleneksel yapılardan daha çok günümüzde kullanılmaktadır.

3.1. Geçmişten Günümüze YOLO

Nesne tespiti, bir görüntü içindeki nesnelerin uzamsal konumunun tanımlanmasını ve ilgili sınıf etiketlerinin belirlenmesini içerir. Kullanım alanı oldukça yaygın olmakla birlikte bilgisayarlı görüde öne çıkan bir araştırma alanıdır. (Yücel & Çetintaş, 2024).

You Only Look Once (YOLO), evrişimli sinir ağlarına dayalı bir dizi gerçek zamanlı nesne algılama sistemidir. İlk olarak Joseph Redmon ve arkadaşları tarafından 2016 yılında tanıtılmıştır. (Redmon et al., 2016). YOLO geçmişten günümüze değişikliklerden geçerek günümüzde en yaygın kullanılan nesne tespit algılama sistemidir. Sistem tek seferde bir ağıdan tespit yapabilmeyi ve sınıflandırmayı başarmıştır. Daha sonra YOLO'nun farklı modelleri ortaya çıkmıştır. 2017 yılında YOLOv2 hayatımıza girmiştir. YOLOv2 hız olarak kendisinden öncekinden daha hızlı olduğunu kanıtlamıştır. YOLOv2 9000 görüntüden fazla tespit yapmaya çalışmış ve doğruluğunu kanıtlamıştır. Her sene gelişen sistemlerle birlikte YOLO'da güncel sürümlerini ortaya çıkarmış ve tespiti daha doğru hale getirmek için çalışmalar yapmış.

Hayatımıza 11 Ocak 2023 tarihinde YOLOv8 girmiştir. YOLOv8 kendisinden önceki sürümlere kıyasla çok daha fazla yenilikle görüntüleri algılamayı başarmıştır.

YOLOv8 5 farklı görevde nesneleri tespit etmek için karşımıza çıkan derin öğrenme modelidir. YOLOv5'in geliştiricisi Ultralytics tarafından piyasaya sürülmüştür. Hayatımıza 11 Ocak 2023 tarihinde YOLOv8 dahil olmuştur. YOLOv8 kendisinden önceki sürümlere göre çok daha fazla yenilikle görüntüleri algılamayı başarmıştır. Önceki sürümlere göre model hızı ve performansı açısından daha iyi olan YOLOv8 açık kaynaklı bir kütüphane barındırmaktadır. YOLOv8 önceki sürümlere göre yine tek bir ağ üzerinden görüntü tespiti ve sınıflandırma yapmayı başarmıştır.

YOLOv8'in nesne algılamadaki yüksek performansı yalnızca mimari gelişmelerine değil, aynı zamanda gelişmiş eğitim metodolojilerine de atfedilmektedir (Yaseen, 2024). YOLOv8 mimarisi kendi içerisinde gelişmiş 5 farklı model sunar. Modeller şu şekilde sıralanır; YOLOv8n, YOLOv8, YOLOv8m, YOLOv8l, YOLOv8x.

Modeller kendilerinden önce gelen sürümleri dahada geliştirerek ortaya üstün performans hizmeti sunar. YOLOv8 mimari yapısında omurgası özellikleri ortaya çıkarır. YOLOv5'e göre katmandan aldığı veri daha derindir. Omurga yapısında tespit algılamasını arttırmak ve modeli daha iyi iyileştirmek için CSPDarknet53 kullanılır. YOLOv8 mimarilerinden biri olan boyun kısmında YOLOv5'in kullandığı CSPDarknet yerine CSPDarknet modelini kullanır. Kafa yapısında ise modelin tahminlerini, görüntülerin sınırları ve nesnenin doğruluğunu kullanır.

Her geçen gün gelişmekte olan YOLO modellerine bir yenisi 2024 yılında YOLOv9 olarak hayatımıza girmiştir. YOLOv9 geliştiricisi Meituan Vision AI'dır. YOLOv9 daha çok çeşitli kaynak içinden az sayıda modelin doğruluğunu belirlemeye yarar. YOLOv8'de boyun kısmında çok az veriden daha iyi sonuç çıkarmaya yarayan C2f modeli yerine YOLOv9'da yelpazesi geniş ve doğrulamayı daha etkin kılan Genel Verimli Katman Toplama Ağı (GELAN) modeli kullanılmıştır. GELAN modeli farklı özellikte çok kaynaktan bir arayan gelen verileri doğru ve istenilen bir biçimde birleştirerek nesneleri daha doğru konuma yerleştirmemizi sağlar. GELAN kullanım açısından daha rahat ve istenilen veriyi daha esnek kılmaktadır.

Nesne algılamada hayatımıza giren Mayıs 2024 yılında yayınlanan YOLOv10 Tsinghua Üniversitesi araştırmacıları tarafından yeni bir nesne algılama yöntemi

olarak karşımıza çıkmıştır. YOLOv10 ile hayatımıza giren LKC + Light Backbone yapısı daha az veriden daha doğru sonuçlara ulaşmamızı sağlar. YOLO 10 geleneksel derin öğrenme modellerine kıyasla çift etiket yöntemi kullanır. Bu yöntem aynı zamanda çift veriye etiket yapıp doğruluğu iki türlü kontrol etmektir. YOLOv9 mimarisinde daha doğru sonuç ve esneklik varken YOLOv10 mimarisinde daha az veriden daha hızlı ve esnek sonuç vardır.

YOLOv11 hızlı gelişen derin öğrenme uygulamalarında 2024 yılında Ultralytics tarafından karşımıza yenilikçi, modern ve daha dinamik bir şekilde ortaya çıkan derin öğrenme mimarisidir. Eski modellere kıyasla daha hızlı ve doğru veriyi gösteren esnek bir modeldir. Mimari yapısı ile önceki modellerden ayrılan YOLOv11 mimarisinde C3k2 bloğu, önceki YOLO sürümlerindeki C2f bloğunun yerine geçmektedir; bu değişiklik, hesaplama verimliliğini artırmış ve modelin çıkarım (inference) hızını önemli ölçüde iyileştirmiştir (Khanam & Hussain, 2024).

C3k2 modeli evrişim olarak 2 küçük yapı sayesinde daha hızlı veri ortaya sunmaktadır. YOLOv11'de görüntü üzerinde tespit dikkatinin diğer modellere göre daha gelişmiş olması görüntüde istenilen kısma doğru odak ve tespiti arttırmaktadır.

18 Şubat 2025 tarihinde yenilikçi ve daha gelişmiş bir model olarak karşımıza çıkan YOLOv12 daha kısa sürede ve daha doğru şekilde görüntüleri tespit edebilmeyi amaçlamaktadır. YOLOv12'de diğer modellere göre geliştirilen bir diğer mimari Artık Verimli Katman Toplama Ağları (R-ELAN) R-ELAN, blok düzeyinde artık bağlantılara ve ölçekleme stratejilerine sahip bir özellik birleştirme modülüdür. Bu yapı, gradyan akışını stabilize ederken parametre verimliliğini artırır ve modelin optimize edilmiş şekilde eğitim almasını sağlar (Tian, Ye & Doermann, 2025).

Bir diğer yenilik A2 görüntüleri eşit şekilde bölümlere ayırarak doğruluğu daha odaklı ve gelişmiş bir modelde ortaya koyar. Tüm YOLO modelleri gelişen derin öğrenme teknikleri sayesinde kısa sürede nesne algılama ve nesneyi doğru bir şekilde sınıflara ayırmada kolaylıklar sağlar. Hayatımıza giren YOLO modellerinin genel ve kısa tarih akışı şu şekildedir:

- YOLOv1 Mayıs 2015 tarihinde ortaya çıkan tek bir aşama üzerinden nesne tespiti yapmaya yarar.
- YOLOv2 (diğer adıyla YOLO9000) Aralık 2016 tarihinde piyasaya çıkan Darknet-19 ile piyasaya sürülen modeldir.

- YOLOv3 aslen Joseph Redmon tarafından geliştirilmiş ve 2016 Mayıs tarihinde tanıtımı yapılan yenilikçi Darknet-53 modeli ile piyasaya sürülmüştür.
- YOLOv4 Nisan 2020 tarihinde Alexey Bochkovskiy ve diğerleri tarafından piyasaya sürülmüştür.
- YOLOv5 25 Haziran 2020 tarihinde Ultralytics tarafından geliştirilen ilk sürümü ortaya çıkmıştır.
- YOLOR 2021 tarihinde Chu et al tarafından geliştirilerek piyasaya sürülmüştür.
- YOLOX 2021 tarihinde ortaya çıkan ve Megvii Research tarafından geliştirilerek piyasaya sürülmüştür.
- YOLOv6 2022'de Meituan tarafından piyasaya sürülmüş olan bir modeldir.
- YOLOv7 2022 yılında YOLOv4'ün yazarları tarafından piyasaya sürülen modeldir.
- YOLOv8 Ultralytics tarafından 10 Ocak 2023 tarihinde piyasaya sürülmüş ve kendinden önceki modellerden üstün performans sağlamıştır.
- YOLO-NAS Mayıs 2023 tarihinde Deci AI tarafından piyasaya sürüldü.
- YOLO-World 31 Ocak 2024 tarihinde piyasaya sürülmüştür. YOLOv8 mimarisi kullanmaktadır.
- YOLOv9 Nisan 2024 tarihinde piyasaya sürülen ve Chien-Yao Wang ve diğerleri tarafından geliştirilen yeni GELAN modeliyle ortaya çıkmıştır.
- YOLOv10 23 Mayıs 2024 tarihinde Tsinghua University tarafından geliştirilip piyasaya sürülen modeldir.
- YOLOv11 30 Eylül 2024 tarihinde Ultralytics tarafından piyasaya sürülmüştür.
- YOLOv12 18 Şubat 2025 tarihinde Yunjie Tian ve arkadaşları tarafından geliştirilmiş YOLO serisinin son modeli olarak ortaya çıkmıştır.

3.2. YOLO ve Nesne Algılama

Nesne algılama bilgisayar sistemlerinde istenilen veriyi analiz edip tespit etmeye yarar. Günümüzde her alanda gelişen teknolojiyle birlikte insanlar nesne tanıma ve algılamaya yönelik çalışmalarda bulunmuştur. Nesne algılama problemlerinde makine öğrenimi ve derin öğrenme teknikleri yaygın olarak kullanılmaktadır. Her iki yöntem de görüntülerdeki nesneleri tanımlamayı öğrenmekle birlikte, uygulama biçimleri ve yaklaşımları bakımından farklılık gösterir (Zhao, Zheng, Xu ve Wu, 2019).

Makine öğreniminde nesne algılama, görüntünün belli kısımlarının seçilip daha sonra ayar verildikten sonra ortaya çıkan görüntünün özelliklerini istenilen doğrultuda ayarlamaya yarar. Nesne algılama derin öğrenmede ise ESA ağ yapılarını ResNet, LeNet-5, AlexNet vb. kullanır. Örnek vermek gerekirse kırmızı ıřıkta geen arabaları tespit etmede diğerk araçlardan ayırım yaparak istenilen görüntüleri analiz ederek doğru ve hızlı bir şekilde algılamayı sağlar. Nesne algılama için ESA modeller 2 aşamalı bir şekilde nesneyi algılamamıza yarar. Nesnenin görüntüsü önce belirlenir daha sonra istenilen sınıfta ayarlanmaya çalışılır. ESA'nın ve derin öğrenmenin bu yavaş algılamaları bizlere daha doğru sonuç ve tek bir yapı üzerinden hem sınıflandırmayı hem de görüntüyü tespit etmeye yarayan bir arayış sunar. Bu arayışın sonucunda hızla gelişen YOLO nesne algılama uygulamalarını hızlı bir modelde ortaya çıkarmıştır. YOLO modellerinin hız, kapsam ve daha fazla veri üzerinden etkili olması sebebiyle günümüzde derin öğrenme modellerinden YOLO kullanımı oldukça popüler hale gelmiştir. YOLO'nun esnek, donanım açısından daha kuvvetli ve nesneleri hem algılayıp hem de sınıflandırma yapabilmesi derin öğrenmede bir devrimi ortaya çıkarmıştır. YOLO görüntüleri belirli kutucuklara ayırarak, etiket işlemi yapmayı ve görüntüleri en ince detayına kadar şekillendirmede kullanılır. Halka açık bir kütüphane üzerinden daha kapsamlı veri analizi yapmada diğerk derin öğrenme yöntemlerine göre avantaj sağlar.

3.3. YOLO Kullanım Alanları

Nesne algılamada derin öğrenme yöntemleri birçok alanda kullanılmaktadır. YOLO kullanım kolaylığı, hızı, doğruluğı ve sınıflandırma açısından pek çok sektörde kullanılmaktadır. Sağlık alanında her sene binlerce insan hastalığının bilinmemesinden ya da geç teşhis edilmesinden kaynaklı ölmektedir. Hastanelerde yapılan göğüs röntgenleri, kas eklem görüntüleri ve kanserli hücre görüntülerinin tespitinde büyük önem sağlamaktadır. YOLO sağlık alanında sadece görüntülerle kalmayıp aynı zamanda ameliyatta kullanılan ekipmanlarda ya da COVID-19 gibi yaygın görülen halk arasında sağlık taraması çalışmalarında da sınıflandırma açısından kullanılmaktadır.

Kamusal güvenlik açısından YOLO şehirlerde trafik kurallarında, insan görüntüleri tespitlerinde ve şehirlerin düzeni açısından nesne tespitlerinde kullanılmaktadır. YOLO şehir içindeki yerleşim yerlerinde yaya geçidi düzenlemesi, kural ihlali vb. birçok alanda varlığını göstermektedir.

Gelişen dünyada askeri alanda birçok çalışmalar yapılmaktadır. İHA araçları günümüzde askeri alanda çoğu yerde kullanılmaktadır. Bu araçlar ülkenin güvenliliği ve gücü açısından öneme sahiptir. Bu doğrultuda YOLO askeri alanda İHA'larda insanları ve nesneleri algılamaya yarayan çalışmalarda kullanılmaktadır. Algıladığı nesneleri ve görüntüleri belirli bir sınıf halinde ortaya koyarak görüntüleri tespit etmede kullanılmaktadır. YOLOv4–v8 sürümü askeri nesneler üzerinden görüntüleri tanımak, belli bir sınıfa ayırmak için özel olarak kullanılmaktadır. YOLOv5 modeli, İHA görüntülerinde askeri araçları %90'ın üzerinde doğrulukla tanımlayabilmiştir (Kamanlı, 2024).

Günümüzde gelişen online alışverişlerle birlikte insanların çoğu online alışveriş kullanımını arttırmaktadır. Bu kullanım sektörde müşteri takibini ve ürün listesini kontrol etmeyi zorlaştırmaktadır. Mağazacılık ve perakende sektöründe müşteri ihtiyaçlarını kontrol etmek ve bunları listelemekte YOLO modelleri kullanılmaktadır. Yüz algılama teknolojisinde YOLO'nun önemi oldukça fazladır. Sensörler sayesinde yüz algılama modeli nesnenin özel olarak eğitildiği biçimde insan yüzlerindeki ufak ayrıntıları kendi algoritmasında eğitmektedir. Bu yaygın kullanım telefonlar ve bilgisayarlarda aktif olarak kullanılmaktadır.

YOLO tarım alanında ürün çeşitliliği ve ürünün korunma aşamasında oldukça rol oynamaktadır. Yılın belirli bir dönemlerinde tarlalara ekilen ürünü bozacak ve yıpratacak zararlı böcekler gelmektedir. YOLO kullanımı tarımda çiftçilerin işini kolaylaştırmak ve ürünleri koruyacak biçimde nesne tanıma algoritması geliştirir. Bu algoritma tarlada zararlı böceklerin tespitini yapmakta ve ne tür bir böcek geldiğini sınıflandırmaktadır.

YOLO mühendislik alanında kalite kontrol, otomasyon, girişimcilik, görüntü işleme gibi alanlarda kullanılmaktadır. Jeoloji mühendisleri depremilerin hareketleri ve geçmişten günümüze olan depremilerin anlık görüntüleri, yer kabuğu gibi hareketleri incelemede YOLO modellerini kullanmaktadır.

4. MATERYAL ve METOD

Bu bölümde nesne tespit uygulamalarından YOLO modelleri kullanılarak akciğer hastalığındaki görüntüleri tespit etmeyi ve sınıflandırmayı amaçlayan çalışma amaçlanmıştır. Görüntüler halka açık veri setinden alınmıştır. Oluşan görüntüler normal, bakterili ve virüslü olarak 3 sınıfa ayrılmaktadır. YOLO modellerinden YOLOv8, YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 kullanılarak modellerin performansları analiz edilmiş ve aynı veri setinden görüntülerle 5 farklı deney çalışması yapılmıştır. Model parametre sonuçlarında en iyi performans sunan modelin omurga kısmına SE+uzamsal dikkat entegre edilerek modelin tespit yeteneği arttırılmaya çalışılmıştır. İlk olarak YOLO modellerinin genel kapsam yapıları verilmiş daha sonra yapıların test sonuçları analiz edilerek model ölçütleri sıralanmıştır. Modeller arasında performanslar karşılaştırılmış aynı veri seti kullanılarak modellerin doğruluğu ve karşılaştırılmalı yapısı gösterilmiştir. Alt başlıklarda YOLO yapıları sırasıyla verilmiştir.


4.1. YOLOv8

Ultralytics tarafından 10 Ocak 2023 tarihinde piyasaya sürülen YOLOv8 “You Only Look Once” ailesinin en güncel ve kapsamlı bir modelidir. YOLOv8 üstün performansı ve hızlılığı sayesinde güçlü bir yapı ortaya koymaktadır. Tek bir ağ üzerinden önceki modeller gibi aynı anda tespit yapmayı ve sınıflandırmayı başaran YOLOv8 üstün performans göstermektedir. Nesne tespiti, görüntü işleme ve belirli bir sınıf karşılaştırması yapan YOLOv8 özellik bakımından kendisinden önceki sürümlerde gelişmişliğini ortaya koymuştur. Geliştiricilerin kullanımı için oldukça detaylı bir mimari sunar. YOLOv8 eğitim anında kullanıcıya elindeki verilen daha detaylı bir şekilde analizini yapmayı ve doğru bir nesne tespitiyle sınıflandırmayı başarır.

YOLOv8’in en belirgin özelliklerinden biri, yalnızca nesne tespiti değil; aynı zamanda görüntü sınıflandırma, segmentasyon, poz tahmini) ve nesne takibi gibi çoklu görevleri tek bir model mimarisi altında gerçekleştirebilmesidir. Bu çok amaçlı yapı, Ultralytics tarafından geliştirilmiş açık kaynaklı API ile desteklenmekte ve farklı görevler için ayrı ayrı modeller tasarlama ihtiyacını ortadan kaldırmaktadır (Ultralytics, 2023a; Ultralytics, 2023b). YOLO 8 derin bir görüntü ağını ve önceden eğitilmiş her bir görüntünün üzerine daha doğru bir şekilde modelin gösterilmesini

sağlar. YOLOv8 önceden eğitilmiş görüntülere ihtiyaç duymaz bunun yerine eğitime verilen görüntülerin istenilen şekilde tespit yapmasını amaçlar.

YOLOv8 kullanıcı ile iç içe bir yapısı vardır, kullanıcılar verileri istediği şekilde analiz etmeyi ve kolay bir şekilde sonuçlara ulaşmayı sağlar. YOLOv8 verileri tahmin ederek uygun formata dönüştürebilme özelliği sayesinde kendisinden önceki modellere göre üstün yetenekler gerçekleştirir. YOLOv8 (You Only Look Once), nesne algılama iş akışını modernize eden çeşitli mimari ve işlevsel iyileştirmeler sunan açık kaynaklı, önceden eğitilmiş bir nesne algılama modelidir. Önceki sürümlerde kullanılan YAML tabanlı yapılandırma dosyalarından uzaklaşarak, Python tabanlı bir yapılandırma yaklaşımı benimseyerek entegrasyon, özelleştirme ve dağıtım süreçlerini kolaylaştırmaktadır (Ultralytics, 2023). Aşağıdaki şekil 4.1’de YOLO mimarisinin genel yapısı verilmiştir.



Şekil 4. 1. YOLOv8 model mimarisi

4.2. YOLOv8 İç Mimarisi

YOLOv8 mimarisi omurga, boyun ve kafa olmak üzere 3 ana bölümden oluşur. YOLOv8 mimarisinde katmanlar en ince detayına kadar ilk olarak işlenir daha sonra gelen özellikler zenginleştirilmiş haritalarla gösterilir ve nesnelerin tahmin olasılıkları, doğrulukları hesaplanır. Aşağıda adım adım vereceğim bölümlerde YOLOv8'in iç mimari yapısı adım adım anlatılmıştır.

4.2.1. OMURGA

Omurga girdiden belli özelliklerin çıkarılmasından sorumludur. Omurganın O yapısı diğer YOLO modellerine göre ağırlığı daha azdır. Omurga kısmında girilen görüntünün boyutu küçültülür ve görüntüden istenen kısım çıkarılır. Omurga girdiden istenilen özellikleri belirtmede önemli bir yere sahiptir. Aşağıda omurganın işlevleri sıralanmıştır. Omurga yapısı gelişmiş bir evrişimli sinir ağı (ESA) kullanır.

- **Özellik Çıkarma:** Omurga ilk katmandaki görüntülerin kenar yapılarını ve model desenlerini yakalamaya yarar. Burada görüntü açısından boyutu küçük, renk geçişleri anlamsız özellikler ortaya çıkarılır.
- **Çoklu Gösterim:** Ağdan alınan görüntüden farklı özellikteki görüntüleri birleştirerek çok özellikli görüntüler üretir.
- **Kapsamlı Çıktı:** Modele gelen basit verilerin kapsamlı ve zengin içerikli olarak ortaya çıkmasını sağlar.

4.2.1.1. C2f Modülü (Concatenate-2-Feature)

Verilerdeki doğruluğu arttırmak için C2f modülü daha karmaşık olan yapıları düzene koymak için özellik çıkarıma yardım eder. YOLO'nun eski sürümlerinde CSP kullanılmaktadır yeni sürümlerinde kullanılan C2f modülü eski sürümlere göre daha hızlıdır ve doğruluğu yüksektir.

Birinci Geçiş Katmanı: Girilen kanalları sayısını önemli ölçüde azaltan yerdir.

Kanal Ayırma: Girilen katmandaki verileri 2 eş parçaya ayırarak sıralı bir şekilde gösterir.

Kanal Boğaz Süreci: Sıralı şekilde olan veriler katmandaki dar bir boğaz üzerinden geçirilir.

Bağlantı ve İkinci Geçiş Katmanı: Bağlantılı veriyi başka bir katmandan geçirir.

4.2.1.2. SPPF (Spatial Pyramid Pooling-Fast)

SPPF amacı girdideki özelliklerden çok ölçekli bir yapı ortaya koymaktır. Modelleri aynı anda yüksek verimlilikte tanınmasını sağlar. SPPF yapısı aynı üç çekirdeğin havuzlamasını değiştirir.

5X5 üç matris işleminin aynı havuz katmanında birleşmesiyle kanal sayısı azaltılır ve ortaya çok ölçekli bir yapı koyulur.

4.2.1.3 SiLU

Sigmoid doğrusal birim olarak tanımlanır. Daha yüksek doğruluğa sahip olan SiLU, tanımlanmayan bölgelerin küçük değerlerini gösterir. Ağın daha doğru sonuçlar çıkarmasını sağlar ve görüntüleri öğrenme hızını arttırmayı başarır. SiLU önceki model yapılarında kullanılan ReLU'ya göre çok daha hızlı ve negatif girişlere yanıt vermesi nedeniyle ön plana çıkmaktadır. SiLU'nun matematiksel denklemi denklem 4.1'de gösterilmiştir.

$$\text{SiLU}(x) = x \times \sigma(x) = \frac{x}{1 + e^{-x}} \quad (4.1)$$

x: Denkleme verilen giriş sinyali

$\sigma(x)$: Denkleme verilen sigmoid aktivasyon fonksiyonudur.

4.2.2. Boyun

Boyun (neck) omurga ve baş arasında iletimi sağlayan köprü görevi üstlenir. Omurgadan aldığı özellikleri güçlendirerek daha özellikli hale getirir. Düşük çözünürlükteki görüntülerin yüksek çözünürlüğe çıkarılması için ortaya üstün performans koyar. Boyun omurganın farklı aşamalarından gelen verileri toplayarak özelliklerin ayrıntılı biçimde bakılmasına olanak sağlar.

Özellik Birleştirme: Omurga yapısında çeşitli özellikleri algılayıp yorumlayabilmesi için farklı özellikteki verileri birleştirir

Bağlam Tümlüşimi: Doğruluğu arttırmak için tüm verileri belli bir kümeye koyar.

Boyut İndirgemesi: Görüntülerin boyutlarını indirgeyerek daha yüksek hızda doğruluğu ortaya çıkarmaya yarar.

4.2.3. Kafa


Kafa model ağının en son kısmıdır. Omurga ve boyun kısmından geçtikten sonra model en son sonuç olarak ortaya çıkar. Belirleyici nesneler ve modelin doğruluğunun çıktısını almaktan sorumludur.

Belirleyici Alan Oluřturma: Görüntüdeki nesnelerle ilgili belirli bölümlerin belirlenmesinden sorumludur. Nesneleri kutucuk içine alır.

Güven Puanlaması: Görüntüdeki nesnelerin en son çıktıda güven puanını olası bir şekilde ortaya koyar.

Alan Sınıflandırma: Güven puanını verdikten sonra nesneleri alanlara ayırarak sınıflandırma işlemini gerçekleştirir.

Kafa kısmında elde ettiđi verileri doğru bir algorithmada tahmin yapmak için kullanır. Şekil 4.2’de YOLOv8 modelinin iç mimarisi gösterilmektedir.



Şekil 4. 2. YOLOv8 modelinin iç mimarisi (Khan et al, 2024)

4.3 Dikkat Modülleri

Dikkat derin öğrenme gibi yapay zekanın alt dallarında modelin daha iyi yerlere odaklanmasını ve öğrenmesini sağlar. İnsan beyninin yapısına benzer şekilde algoritmayla çalışır. Modelin katmanlarında çoklu bilgiye değil önemli bilgilere

odaklanmasını sağlar. Dikkat bilgisayarlı görüş alanında ESA yapılarında kullanılır. 6 çeşit dikkat modülleri vardır bunlar;

1-Konvolüsyonel Blok Dikkat Modülü: Hem kanal hem de uzlamsal dikkat uygular.

2-SE (Sıkıştırma ve Uyarma): Kanal bazında dikkat uygular.

3-Etkin Kanal Dikkat Modülü SE'ye benzerdir ama tam bağlantı katmanı uygulamaz bunun yerine 1D konvolüsyon kullanır.

4-Şişirilmiş Dikkat Modülü Kanal ve uzlamsal dikkatları paralel bir şekilde uygulamaya çalışır.

5-Yerel Olmayan Dikkat: Bazı konumlardaki özellikleri diğer konumlarla uyarlamaya çalışır.

6- Self-Dikkat Tabanlı Modüller: Görüntüleri belli özelliklere bölüp dikkat tabanlı model uygular.

4.3.1. SE (Sıkıştırma- Uyarma)

SE kanallar arasındaki bağlantıyı incelemek için sıkıştırma ve uyarım bloğu olarak adlandırılan ağların farklı yönleri üzerinde yoğunlaşan bir mimaridir. SE evrimsel özellikte kanalların içi içe geçmiş karmaşık yapılarını açıkça modernize ederek ağın yapısındaki özellikleri arttırmaya yarar. SE ağın yapısındaki belli özellikleri daha iyi vurgulayarak ve modelde az yapıda bulunan katmanları geri planda koyarak genel yapı özelliklerini kullanmayı öğrenir.


(SE) bloğu, Hu, Shen ve Sun (2018) tarafından piyasaya çıkan konvolüsyonel sinir ağlarında kanal düzleminde daha seçici şekilde dikkat mekanizması kazandırmak amacıyla tasarlanmıştır. SE bloğu, üç temel aşamadan oluşmaktadır. (Hu et al., 2018).

Sıkıştırma (Squeeze): İlk adımda SE bloğu ağın yapısındaki her bir kanalı belli bir tek sayısal değere sıkıştırarak yeni bir yöntem kazanır. Bu uygulamada her kanalın uzlamsal boyutları üzerinde dönüştürme yapılmasını içerir ve n boyutlarında bir vektör elde eder, burada n giriş kanal sayısına göre belirlenmeye çalışılır.

Uyarma (Excitation): İkinci adımda ilk aşamada elde edilen n vektör iki katmanlı ileri bir beslemeli bir ağ yapısına iletilir. Bu ağ kanalların arasında uyumsuzlukları ve birbiriyle olan karışıklıkları etkili bir şekilde anlamaya çalışır. Bu ağın çıktısı n yapısında vektörlerden oluşur.

Ölçekleme ve Birleştirme: Son adımda girişteki her kanalı ölçeklendirmek için uyarma aşamasında elde edilen n vektörü kullanır. Bu uyarlanabilir ağırlıklar gerçek kanallara uygulanarak, SE bloğu en önemli özellikleri etkili bir şekilde vurgular ve alakasız özellikleri gizlemeye çalışır.

SE blok artık bloklara yerleşim şeması şekil 4.3'te gösterilmiştir. Burada ilk aşamada girdi doğrudan toplama bloğuna gider ve daha sonra artık blok çıkışına uygulanır. 3. Aşamada girdi artık blok öncesinde uygulanır ve 4. aşamada artık blok girdi aşamasından önce uygulanır daha sonra son aşamada ise giriş alt bloğuyla birleşir ve toplama yapılır.




Şekil 4.3. SE blok yerleşimleri (Hu, Shen ve Sun, 2017).

4.3.1.1 Kanal Dikkat

Özellik haritasındaki dikkat mekanizmasını temsil eder. Genel olarak evrişim katmanlarında ağırlıkları eğitmek için değerler sıfıra yakın öğrenmeye çalışılır ve bundan dolayı benzer özellik haritaları ortaya çıkar. Bu benzerlik aynı gibi görünse de bazı öğrenmeler dikey bazıları ise yatay görüntüyü öğrenmeye çalışır ve belli bir kısma odaklanır. Uzamsal dikkat her bir kanal yapısı için öğrenme sağlar ve modelin kanal katmanlarını geliştirir ve performansı artırır.

Kanal dikkat modülü üç katlı ardışık bir işlem den oluşur. İlk kısmı kanal havuzu olarak adlandırılır ve burada $(c \times h \times w)$ boyutlarında giriş 2 kanala ayrıştırılır, yani $(2 \times h \times w)$, burada 2 kanalın her biri tüm kanallar boyunca maksimum havuzlamayı ve ortalama havuzlamayı temsil eder. Temsil edilen yapı bir özellik haritası çıkarır ve

evrişim katmanına girer. Bu çıktının boyutuda $(1 \times h \times w)$ 'dir. Şekil 4.4'te kanal dikkat yapısı gösterilmiştir.




Şekil 4.4 Kanal dikkat yapısı

4.3.2 Konvolüsyonel Blok Dikkat Modülü

Konvolüsyonel blok dikkat modülü, kanal dikkat modülü ve uzamsal dikkat modülünden oluşur. Derin öğrenme alanında özelliklerin daha iyi öğrenmesini sağlamaktadır.

Konvolüsyonel blok dikkat modülü belirli bloklara entegre edilerek modelin daha iyi öğrenmesini sağlamaktadır. Ara özellikte olan haritaları hem kanal hem de uzamsal boyutlarda dikkat uygulayarak modelin daha iyi iyileştirilmesini sağlayan bir dikkat modülüdür.

Belirli yapıda olan ağ yapması gerekeni açıkça söyleyerek özellikleri daha belirgin hale getirmeye çalışır. Konvolüsyonel blok dikkat modülü gelişmiş özellikteki öğrenimlerde karmaşık yapılarda ve dengesiz dağılımlarda modelin daha iyi seviyeye gelmesine fayda sağlar. Nesne ve özelliklerde algılamayı artırır.

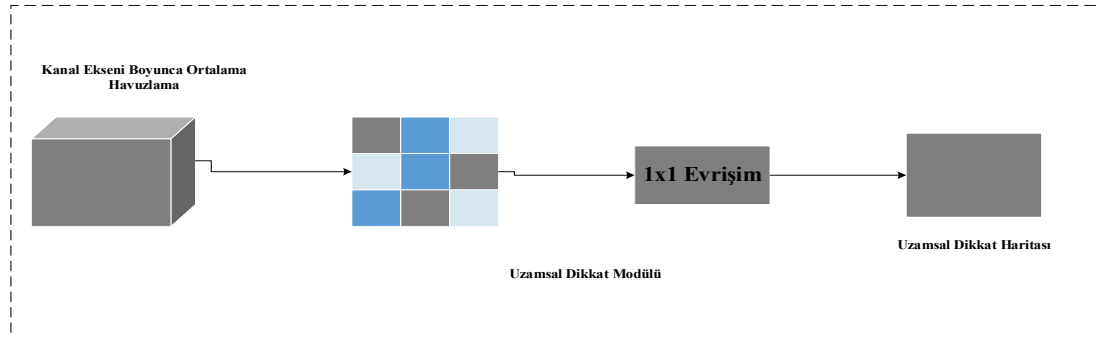


Şekil 4.5 Konvolüsyonel blok dikkat modülü yapısı

4.3.2.1 Uzamsal Dikkat

Uzamsal dikkat çok boyutlu veri yapısını havuzlama işlemi ve evrimsel bir aktivasyon aracılığıyla görür. Girişte çok boyutlu veri yapısı kanallar boyunca maksimum havuzlama ve ortalama havuzlama işlemlerini bir araya getirir. Maksimum havuzlama ve ortalama havuzlama iki ayrı özellik haritası oluşturur.

Uzamsal dikkat özellik haritalarında kaplanmış alanı ifade eder. Özellik haritalarında dikkat mekanizmasını tek bir parça olarak temsil eder. Uzamsal dikkat ilk başta geliştirmek istediği yapıyı dikkat mekanizması kullanarak entegre eder daha sonra evrim katmanlarında entegre edilen mekanizmayı geliştirerek modele daha iyi performans imkanı sunar. Şekil 4.5'te uzamsal dikkat yapısı şeması gösterilmiştir.



Şekil 4.6 Uzamsal dikkat yapısı


4.3.3 SE ve Uzamsal Dikkat

Çalışmada YOLOv8 modelinin performansını geliştirmek için SE ve uzamsal dikkat modülü entegre edilmiştir. SE ve uzamsal dikkat modülü YOLOv8 mimarisinin omurga kısmındaki C2f bloklarından sonra ardışık olarak entegre edilmiştir.

SE modülünün üst katmanında dikkat mekanizması bulunur. Hem maksimum havuzlama hem de ortalama havuzlama işlemleri kullanılarak mekânsal özellikler çıkarılır. Özellik haritaları daha sonra kanal destekli özel haritalarla birleştirilir.

SE modülü, kanallar arası bağlantıları modelleyerek önemli kanalları vurgulayan bir sıkıştırma ve uyarma (SE) bloğundan ve bir mekansal dikkat modülünden oluşur.

SE modülü önce girdideki özellik haritalarını daha sonra uzamsal dikkat modülünü işler. Son olarak, çıktıdan elde edilen özellik haritasını birleştirilir. İşlem şekil olarak 4.6’da gösterilmiştir.



Şekil 4.7 SE ve uzlamsal dikkat modülü


Burada girdi özellik haritası $X \in B \times H \times C \times W$ olarak veriliğinde SE modülü bir ortalama havuzlama işlemi uygular. Doğrusal olmayan kanallar arasındaki bağlantıyı

öğrenmek için z , darboğaz yapısına sahip iki katmanlı bir ağdan geçirilir bu da hesaplama yükünü azaltır. Bu süreç önemsiz kanal lezyonları bastırır, önemli özellik haritalarını güçlendirir.

SE modülünün çıktısı olan X' , önce kanal eksenini boyunca maksimum havuzlama yapar daha sonra ortalama havuzlama işlemleriyle aynı ekseninde toplanır ve iki 2B mekansal dikkat tanımlayıcısı elde edilir

Bu iki harita, sırasıyla her bir mekansal konumdaki güçlü ve ortalama özellikleri yansıtarak, mekansal dikkati daha belirgin hale getirir.

Elde edilen özellikler birleştirilir ve 7×7 'lik bir evrişim katmanından geçirilir ve ardından sigmoid aktivasyon fonksiyonunu uzlamsal düzeyde takip ederek mekansal dikkat haritası $S \in R^{1 \times H \times W}$ oluşturulur.



Şekil 4.8 Geliştirilmiş YOLOv8 mimarisi

Geliştirilmiş YOLOv8 mimarisinde omurga kısmında C2f bloklarından sonra ilk önce SE dikkat modülü eklenmiştir. Daha sonra ardışık olarak uzlamsal dikkat modülü omurga yapısına entegre edilmiştir.

Orta katmanlara entegre edilen yapı yüksek özellik çıkarımında harita çözünürlüklerinde ve nesne haritalarında en güçlü özellikleri ön plana çıkarır. Omurga yapısının ilk katmanlarına entegre edilen SE ve uzlamsal dikkat erken aşamada öğrenmeyi yavaşlatmaktadır bu da modelin erken katmanlarında özellik haritalarının düşüklüğüne neden olmaktadır.

SE ve uzlamsal dikkat modülü C2f yapısının çıkışlarına entegre edilmesiyle yüksek çözünürlükte haritalar iyileştirilmiş ve modelin özellik çıkarımında maksimum sonuçlar elde edilmiştir. Geliştirilen YOLOv8 mimarisi omurga kısmına orta katman haritalarında C2f(128) ve C2f(256) bloklarının çıkışına ardışık olarak eklenmesiyle özellik çıkarımı daha maksimum bir yapı haline gelmiştir.

4.4. YOLOv8 Modelleri

YOLOv8 modeldeki katmanlar için farklı şekilde 5 farklı model sunar. Bu modeller sınıflandırma, bölüm ve nesneyi algılamaya yarar. Model seçimi kullanıcının seçimine göre şekillenmiştir. Her bir model farklı değerlerde doğruluk, kesinlik ve hız gibi parametreler sağlar. Modellerin seçimine göre kullanıcıya tespiti daha farklı değerlerde sağlamayı ve sınıflandırmayı istenilen optimum seviyede yapmayı sağlar.

YOLOv8 mimarisi, son derece verimli YOLOv8n'den en gelişmiş YOLOv8x'e kadar, her biri farklı hesaplama ortamlarına göre uyarlanmış model sunar. Bu modeller, önceki sürümlerde yapılan iyileştirmeler üzerine inşa edilmiş olup, gelişmiş özellik çıkarımı ve daha sofistike bir mimariyi birleştirerek üstün performans elde etmektedir (A. Bochkovskiy, & J. Redmon, 2023). 5 farklı YOLOv8 modelleri şu şekildedir;

4.4.1. YOLOv8n

YOLOv8'in en hızlı ve boyut olarak en küçük modeli olan YOLOv8n hesaplaması düşük olan modeller için tasarlanmıştır. Nesne tespitinde en küçük ve hafif kalan görüntüler için piyasaya sürülmüş olan YOLOv8n küçük donanımlar için nesne algısını büyük ölçüde yapmaktadır.

YOLOv8n, en iyi duruma getirmek için ağ katmanları kullanarak parametreleri azaltmış ve bu parametreler INT8 formatında 2 MB ve FP32 formatında 3,8 MB olan toplam ölçü boyutuna ulaşmıştır.

YOLOv8n modeli akıllı teknolojilerde, gömülü sistemlerde, tarım alanında, otomasyonlarda kullanımı yaygındır.

4.4.2. YOLOv8s

YOLOv8 mimarisinin en temel modellerinden biridir. 9 milyona yakın içinde parametre bulundurur. Parametreler sayesinde nesne algılama dahada artmış hale gelir. YOLOv8s yapısında CPU'larda hem de GPU'larda katmanla hız ve doğruluk arasında optimum denge sağlar.

Model gradyan parametrelerini artırır, doğruluğu maximum hale getirmeye çalışır.

Gelişmiş uzamsal piramit havuzlaması ve iyileştirilmiş bir yol toplama ağı (PANet) sunarak, özellikle küçük nesneler için daha iyi özellik birleştirme ve daha yüksek algılama doğruluğu sağlar (Bochkovskiy et al., 2020; Zhang, 2024)

YOLOv8s modeli akıllı ulaşımlarda, tarif uygulamaları tespitinde, kalite kontrol sistemlerinde kullanımı yaygındır.

4.4.3. YOLOv8m

25 milyona yakın parametreye sahip olan YOLOv8s YOLOv8'in orta paket modelidir. Hesaplama ve hassasiyet üzerinde maksimum değer sağlamaya yarar ve bu değerleri normal bir şekilde optimize eder.

Birçok alanda doğruluğu kanıtlanmış ve eğitim açısından verimliliği arttırmıştır. Omurga ve boyun açısından kullanıcılara daha kapsamlı yapı verir. Model doğruluğunun ve sınıflandırmanın yüksek çıkması modeli yüksek seviyede optimum eder ve kullanıcıya kolaylık sağlar.

YOLOv8m modeli tıbbi sağlık görüntüleme sistemlerinde, güvenlik ağlarında, yüz tanıma sistemleri gibi yerlerde kullanımı yaygındır.

4.4.4. YOLOv8l

Ultralytics tarafından yüksek modellerde daha doğru veriler için geliştirilmiştir. Büyük model olmasından dolayı karmaşık yapıları düzenleyerek, daha anlaşılır hale getirir. Modelde 55 milyona yakın parametre bulundurur.

YOLOv8l modelinde diğer modellere göre daha fazla katman ve nesne algılamada daha dikkatli olmasından dolayı yüksek verileri doğru şekilde algılamayı

sağlar. YOLOv8l modeli makalelerde, bilimsel araştırmalarda, yapay zeka tabanlı oyunlarda kullanımı yaygındır.

4.4.5. YOLOv8x

YOLOv8x modeli YOLOv8 ailesinin en donanımlı, en güçlü ve en hızlı modelidir. Model içerisinde 90 milyona yakın parametre vardır. Üstüm model sayesinde çok karmaşık yapılar basit hale indirgenebilir. Hesaplama olarak daha fazla veriyle güçlü bir model tasarlar.

YOLOv8x modeli diğer modellere göre en yüksek mAP değeri ortaya koyar. YOLOv8x modeli sanal simülasyonlarda, askeri alanlarda, endüstriyel uygulama alanları gibi yerlerde kullanımı yaygındır.

COCO üzerinden eğitilmiş yaklaşık 80 adet veri üzerinden çıkan sonuçlar karşılaştırılmış mAP, hız, floplar ve parametrelerin her bir YOLOv8 modelindeki çıkan sonuçlar tablo 4.1’de gösterilmiştir. (ultralytics 2023)


Tablo 4. 1 YOLO modelleri arasındaki farklar

Model	Boyut	mAP	Hız CPU	Hız A100	Parametreler	Flop
YOLOv8n	640	37.3	80.4	0.99	3.2	8.7
YOLOv8s	640	44.9	128.4	1.20	11.2	28.6
YOLOv8m	640	50.2	234.7	1.83	25.9	78.9
YOLOv8l	640	52.9	375.2	2.39	43.7	165.2
YOLOv8x	640	53.9	479.1	3.53	68.2	257.8

4.5. YOLOv9

Zamanla gelişen YOLO modelleriyle birlikte Nisan 2024 tarihinde piyasaya sürülen ve Chien-Yao Wang ve diğerleri tarafından geliştirilen YOLOv9 modeli yeni bir modern tespitin kapısını aralamıştır. Önceki modellere göre PGI ve çok yönlü GELAN mimarisini ortaya çıkarmıştır. YOLOv9 gelişmişlik olarak YOLOv8’e benzerdir ama daha eski modellere kıyasla kaybolan gradyan ve dar boğazlar gibi yapıların üzerine daha ayrıntılı bir biçimde düşer. YOLOv9, verimlilik ve doğruluk açısından önceki gerçek zamanlı nesne algılama modellerinden önemli ölçüde daha iyi performans göstermektedir. YOLO MS gibi hafif ve orta ölçekli modellerle karşılaştırıldığında, YOLOv9 yaklaşık %10 daha az parametre ve %5 ila %15 daha az

hesaplama maliyetine sahipken, doğruluğu (AP) %0,4 ila %0,6 oranında artırmaktadır (Ultralytics, 2025). MS COCO veri setinde eğitilen YOLOv9, daha az görüntü ve doğruluğu artırarak önceki modellere göre verimlilik ve modelin doğru bir şekilde analiz edilmesinde rol oynadı. Aşağıdaki şekil 4.6’da YOLOv9 mimarisinin genel yapısı gösterilmiştir.



Şekil 4.9 YOLOv9 genel yapısı (Chien-Yao Wang, 2020)

4.5.1. YOLOv9 İç Mimarisi


YOLOv9, gerçek zamanlı nesne algılamada önemli bir ilerlemeyi işaret ederek Programlanabilir gradyan bilgisi (PGI) ve verimli katman toplama ağı (GELAN) gibi çığır açan teknikler sunar. Bu model, verimlilik, doğruluk ve uyarlanabilirlik açısından dikkat çekici gelişmeler göstererek COCO veri kümesinde yeni ölçütler belirlemektedir (Wang et al., 2024).

YOLOv9 bilgi ağlarında kaybolan bilgi eksikliğini gidermek ve bilgilerin doğru ve güvenli bir biçimde korunmasını sağlayan PGI kavramını ortaya çıkarmıştır. Bununla beraber genelleşmiş bir şekilde ağ katmanını ortaya koyan GELAN'ı ortaya çıkarmıştır.

4.5.1.1. GELAN (Generalized Efficient Layer Aggregation Network)

YOLOv9 modelinde mimarinin hız ve optimum seviyede dengeli olması için mimarinin etkin bir rol oynaması gerekmektedir. Wang ve arkadaşları tarafından geliştirilen GELAN en küçük veriden en yüksek doğruluk için tasarlanmıştır. GELAN bir araya getirilen 2 temel yapı özelliklerini içinde barındırır.

Verimli Katman Toplama Blokları ağdaki gibi dönüşüm için birden fazla blokları bir araya getirir. Hesaplamalı bloklar CSPNet blokları katmanlar arasında verilerin yayılması ve genişlemesine yardımcı olur. Hesaplamalı bloklarda herhangi bir katman yer değiştirilebilir. GELAN, bu blokları özenli bir şekilde dengeleyip bir araya getirerek performans, parametreler ve hız arasında en minimize bir noktaya ulaşır. GELAN katmanında aynı yapılar boyut olarak değiştirilip ölçeklendirilebilir. Farklı çıkarımlar için istenilen seviyede uygun blok seçmeye yarar. GELAN yüksek hızda istenilen değerlerin maksimuma ulaşmasını sağlar. Aşağıdaki şekil 4.7’de GELAN mimarisi gösterilmiştir.



Şekil 4.10. GELAN mimarisi (Chien-Yao Wang., 2023)

4.5.1.2. PGI (Programmable Gradient Information)

PGI derin sinir ağlarında sık görülen bilgi kabı için temel olarak ortaya çıkmıştır. PGI sayesinde model daha etkili ve hızlı öğrenerek modelin sonuçlarını önemli

seviyelere getirir. Ek ağıla gradyanları tanır ve modelin istenilen özelliğe gitmesine katkı sağlar. PGI daha küçük modellerde istenilen seviyede ağa yardımcı olmaya çalışır ve sinyalin doğruluğunu artırır.

Yardımcı Dallar: RevCols gibi bloklar kullanarak girişe farklı yönden bağlantılarla olası yolu daha optimum hale getirir.

Çok Seviyeli İndirme: Farklı dallardan gelen sinyal ve sapmaların önlenmesinde rol oynar. Ana dala geçişte farklı indirmeleri birleştirir ve tek bir hale getirir.

Daha güvenilir gradyan kullanarak olası sapmaları önler. Daha büyük modellerin ağa katılmasına yardımcı olur.

4.5.2. Omurga

YOLOv9 ve YOLOv8 arasında benzer tabanlı yaklaşımlar vardır. YOLOv8de bu koruma C2f ile gerçekleşirken YOLOv9 GELAN ile daha üstün performans sağlamaktadır. GELAN ağların karışıklığına müdahale etmeden bünyesinde bulunan CSP bloklarını kullanarak GELAN'ın ağını genişletir. Bu genişleme modelin ağ ile arasında olan yapısını korurken doğruluğu hesaplamada üstün performans sunar.

4.5.3. Boyun

YOLOv8'de kullanılan PANet'in yerine PGI kullanarak özellikleri daha tutucu bir şekilde bir araya getirmeye yarar. PGI çok sayıda yardımcı kaynak sağlamasından dolayı verinin ağda kaybını önleme yardımcı olur. Bu kayıpların minimuma indirilmesiyle nesne algılamada çok önemli yol kat eder.

4.5.4. Kafa

Başlık, YOLOv9, YOLOv8'de tanıtılan çapa içermeyen sınırlayıcı kutu tahmin yöntemiyle devam ediyor, ancak PGI tarafından sağlanan geri döndürülebilir işlevlerden faydalaniyor. Geri döndürülebilir mimari, ileri ve geri geçişler sırasında hiçbir önemli verinin kaybolmamasını sağlayarak daha düşük hesaplama yüküyle daha güvenilir tahminler sağlıyor.


Bu tasarım hem çıkarım hızını hem de doğruluğunu artırarak gerçek zamanlı uygulamalar için daha verimli hale getiriyor (Muhammad Yaseen, 2024).

4.6. YOLOv10

23 Mayıs 2024 tarihinde Tsinghua University tarafından geliştirilip piyasaya sürülen YOLO'nun en yeni modellerinden biridir. YOLOv10 modelin hızını ve tespitini arttırarak maksimum olmayan baskılamayı (NMS) kaldırıp üstün performans

hizmeti ortaya koyuyor. YOLOv10'da iki çift ana bileşen vardır. Bu bileşimler tahmin performansını arttırmak için kullanılır.

YOLOv10, nesne algılama modellerinin eğitimi sırasında kullanılan görüntü eşleşmelerinin doğru açısını birleştirir. Bire bir eşleştirme, her bir tahmin katsayısına tek değer atayarak, Maksimum Olmayan Bastırma (NMS) ihtiyacını ortadan kaldırarak işlemi karmaşıklıktan kurtarır ve basit hale getirir. Bununla birlikte, bu karmaşıklık ve nesneye yanlış atama daha zayıf model gelişmesine yol açarak eğitim sırasında daha düşük doğruluk ve daha yavaş şekilde eğitimin sonuçlanmasını ortaya çıkarır. Eğitim verilerinin daha hızlı ilerlemesi ve doğru sonuç üretmesi için bire bir kafaları kullanan çift etiketli bir atama ortaya koyar. Şekil 4.8'de YOLOv10 mimarisi genel yapısı gösterilmiştir.



Şekil 4.11 YOLOv10 mimarisi genel yapısı (Ferreira, F. R. T., & do Couto, L. M, 2025)

YOLOv10 iç mimarisinde diğer eski modellere kıyasla kafa yerine birden çok kafa ve birebir kafa yapıları eklenmiştir. YOLOv10 iç mimarisindeki yapılar aşağıda gösterilmiştir.

Omurga: Omurga özellikleri bir araya getirerek çıkarmaya yarar. Gradyanları iyileştirmeye yarayan omurga hesaplamada meydana gelen hasatları azaltmaya yarar.

Kendisinden daha eski diğer YOLO modellerinde olan CSPNet'in (Çapraz Aşamalı Kısmi Ağ) çok daha hızlı ve algılaması yüksektir.


Boyun: Farklı özellikleri bir arada toplayıp kafa kısmına iletmek için kullanılır. Etkinliği arttırmak için özellikleri bir araya getirip PAN (Yol Toplama Ağı) kullanır.

YOLO modellerinde nesneyi algılama için her bir kutucuk belli bir sınırı tahmin etmeyle uğraşıyordu, YOLOv10 modelinde bu kutucuk bir den fazla nesne sınırını tahmin etmeyi amaçlamaktadır.

Bire Çok Kafa: modelin orijinalliğinden sapmasını muhafaza eder ve görüntü netliğini korur.

Bire Bir Kafa: Tek bir tahmin algoritmasıyla eşleşmeyi sağlar ve tek bir eşleşmeyle doğruluğu yürütür. Eğitim süresi diğer modellere göre daha az kısa sürede gerçekleşir.

Bu 2 kafa eğitim sırasında beraber kullanılır. Modelin verimli ve doğru bir şekilde ortaya çıkmasını sağlar. Modelin daha kısa sürede görüntüleri öğrenip, hızını arttırmaya yarar. Şekil 4.6'da YOLOv10 çift kafa yapısı örneği şeması verilmiştir



Şekil 4.12 Çift kafa yapısı (Ao Wang, Vd, 2024)

YOLOv10, nesne algılamada bire bir ve bire çok başlıkları eşzamanlı olarak eğitmek için tutarlı bir eşleştirme metriği kullanır. Bu metrik, sınıflandırma doğruluğu ve yerleştirme uyumunu ağırlıklı olarak birleştirerek hem bire bir hem de bire çok başlıkların aynı örnekler üzerinde hizalanmasını sağlar. Böylece, bire çok başlık tarafından seçilen en iyi tahminler, bire bir başlık için de optimal eşleşmeler olarak

kabul edilir. Bu yöntem, modelin öğrenme kararlılığını ve doğruluğunu artırmaktadır (Zhang ve ark., 2024). Denklem 4.2’de matris denkleminin formülü gösterilmiştir.

$$m(\alpha, \beta) = s.p^\alpha . IoU(\hat{b}, b)^\beta \quad (4.2)$$

YOLOv10 modelinde tek kafa yerine iki kafa kullanılması omurga ve boyuna daha hızlı veri akışı ve pratiklik sağlar. Birden çok nesneyi tanınması açısından tek kafadan daha çok doğruluk ve maksimum ilerlemeye ulaşır.


4.7. YOLOv11

30 Eylül 2024 tarihinde YOLOv5 ve YOLOv8 tasarımcısı Ultralytics tarafından geliştirilen YOLO modelleri ile birlikte daha donanımlı ve daha algılayıcı model ortaya koyan YOLOv11 iç mimari yapısındaki iyileştirmelerle kendinden önceki sürümlerine göre daha avantajlıdır. İç mimari yapısında daha hassas ve gelişmiş omurga ve boyun yapısı sunmaktadır. YOLOv10 kendinden önceki modellere göre hızlıdır ve ayrıntıları tespit etme mekanizması daha gerçekçidir. YOLOv11 sınıflandırma, görüntü işleme ve nesne tespitinde iyileştirmeler ortaya koymuştur. Mimari tasarım ve üstün algoritma YOLOv11’in hız açısından modellerinden ön planda olmayı sağlamıştır. YOLOv11, zorlu durumlarda bile hassas ayrıntıların daha hassas bir şekilde algılanmasını sağlayan geliştirilmiş bir tasarıma sahiptir. Ayrıca daha iyi özellik çıkarımına sahiptir, yani fotoğraflardan birden fazla desen ve ayrıntı çıkarılabilir (Boesch, G. 2024). YOLOv11 diğer modellerden farklı olarak iç mimari yapısına göre C3K2 SPFF ve C2PSA modüllerini ortaya çıkarmıştır. YOLOv11 iç mimari yapısı aşağıda ayrıntılı biçimde ele alınmıştır.

4.7.1. Omurga

Omurga yapısı evrişimsel blok, şişe boğazı, C3K2 bloğundan oluşmaktadır. Evrişimsel Blok; Bu blok verilen sinyali evrişimsel katmandan geçirir. Evrişimsel bloktan geçirildikten sonra SİLU yardımıyla 2 boyutlu CONV bloğunu ortaya çıkarır.

Şişe boğazı: Sinyalden gelen özellikleri daha katmanlı bir yapıya dönüştürür. Bu boğaz kanalları dağıtır, gelen verinin doğruluğunun arttırır. Sinyalden eksi gelen kısmın tekrar aktif hale getirilip getirilmeyeceğine karar verir. Şekil 1.9’da evrişimsel blok ve şişe boğazı yapısı gösterilmiştir. Şekil 4.10’da evrişimsel blok ve şişe boğazı yapısı gösterilmiştir.




Şekil 4.13 Evrişimsel blok ve şişe boğazı (Rao, 2024)

C3K2 bloğu; YOLOv11 omurga kısmında özellik çıkarmada blok olarak diğer modellere göre C3K2 modelini kullanır. Küçük matris işlemlerini gerçekleştirir ve modeli optimum seviyeye getirir. Modelin katman yapısındaki bilgileri hızlı ve pratik olarak sunar. Görüntülerin içinde taranan alanın en küçük ayrıntısına kadar işleyerek model tahminini yukarılara çıkarır. Girdi ilk olarak Conv bloğuna girer ve en son olarak CONV bloğundan çıktıyı alır. C3K2, bilgileri toplamak ve dizayn etmek için için C3K bloğunu kullanır. En son çıkan yapı CONV'dan bilgiyi işleyerek modelin hızlı ve net olmasını sağlar.

4.7.2. Boyun

YOLOv11 boyun kısmında SPFF katmanını kullanır. SPFF katmanı birden fazla havuzlama katmanı yaparak bilgilerin bir araya gelmesini sağlar. Toplanan bilgiler bir araya getirilince en küçük nesneler bile bu sayede algılanabilir. SPFF katmanı birden fazla nesneyi algılamada YOLOv11'e yardımcı olur. Aşağıda şekil 4.11'de YOLOv11 iç mimari yapısı gösterilmiştir.




Şekil 4.14 YOLOv11 mimarisi genel yapısı (Jian Xu., vd, 2025)

YOLOv11’de diğer modellere kıyasla C2PSA bloğuna çaprazlama kısmı eklenmesidir. Çaprazlama işlemi daha küçük nesneleri ayırt etmeye ve hızı daha fazla arttırmaya yarar. Pozisyona duyarlı dikkat yapısı YOLOv11’de görüntüyü algılarken daha dikkatli bir biçimde nesneyi belirli konuma atar. C2PSA bloğunda model dallarını ayırmak için PSA (Kısmi Uzamsal Dikkat) yapısını kullanır. Bu yapı daha hassas bir şekilde görüntüyü algılamaya yarar.

4.8. YOLOv12

YOLOv12 18 Şubat 2025 tarihinde Yunjie Tian ve arkadaşları tarafından geliştirilmiş YOLO serisinin son modeli olarak ortaya çıkan üstün performans ve doğruluk sağlayan modelidir. YOLOv12 ile yenilikçi bir modern olarak ortaya çıkan Alan Dikkat Modülü (A2) karışıklıkları azaltıp modeli eşit parçala bölerek modern nesne algılayışının daha dikkatli olmasını sağlamıştır. Eski YOLO modellerine göre hayatımıza giren Artık Verimli Katman Toplama Ağları (R-ELAN) kararlı yapıyı daha

doğru hale getirmek için yüksek ölçekli ve ayrıntılı mimari ortaya sunar. Performans ve verimlilik açısından optimum seviye sağlayan R-ELAN dikkat mekanizmasını yüksek seviyede geliştirmektedir. R-ELAN bellek erişimlerinde daha hızlı ve çitli bir yapı ortaya koyar. Şekil 4.12’de YOLOv12 genel yapısı gösterilmiştir.



Şekil 4.15 YOLOv12 genel mimarisi (Tian et al., 2025)

Özellikle YOLOv12-N, T4 GPU’da yalnızca 1,64 ms gecikmeyle %40,6 mAP’ye ulaşarak, benzer bir hızla YOLOv10-N ve YOLOv11-N’yi geride bırakır. Ayrıca, daha az parametre ve hesaplama kullanarak %42 daha hızlı çalışarak RT-DETR ve RT-DETRv2 gibi uçtan uca gerçek zamanlı dedektörleri de geride bırakarak üstün performans gösterir. (Sinha, S. 2025).

4.8.1. YOLOv12 İç Mimari Yapısı

YOLOv12 yenilikçi ve modern yapısıyla hızlı veri ve daha doğru sonuçlar için mimari yapısında birkaç yeni model ve iyileştirmeler ortaya çıkarmıştır. Modeldeki karmaşıklık daha da iyileştirilmiş ve model basit hale getirilmiştir. Bunlar sıralı şekilde aşağıda açıklanmıştır;

4.8.1.1. Alan Dikkat (A^2)

YOLOv12 diğer modellere göre klasik ESA’dan kurtulmuş modeli daha iyi iki yönlü anlamaya çalışan dikkat merkezli tasarım ortaya koymuştur. Alan Dikkat:

ortalama hassasiyet (MaP), kesinlik, doğruluk, duyarlılık ve F1 skoru metriklerini kullanarak modeller değerlendirilmiştir. Eğitim sonucunda karışıklık matrisi ile belli parametrelerle model sonuçları karşılaştırılmıştır. Karışıklık matrisi, makine öğreniminde kullanılan ve gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif tahminleri tablo haline getirerek bir sınıflandırma modelinin performansını özetleyen bir performans değerlendirme aracıdır. Modelin tahminlerinin doğruluğunu ve etkinliğini değerlendirmeye yardımcı olur (Encord Glossary, t.y., erişim: 3 Ağustos 2025). Karışıklık matrisleri 4 şekilde sınıflandırılmaktadır.

Gerçek Pozitif (GP): Model sonucunda eğitimin doğru olduğu ve sınıfların doğru biçimde tahmin edilmesidir. Kesişim Üzerinden Birleşme (IOU) eşiğine eşit ve daha büyük olması durumuna denir. Tezimizde kullanılan akciğer hastalık görüntülerinin doğru bir şekilde model sonucunda tahmin edilmesi buna örnektir.

Yanlış Pozitif (YP): Model sonucunda görüntülerin doğru diye tahmin ettiği sonuçların yanlış şekilde tahmin edilmesi durumudur. Birleşme (IOU) eşiğinin tahminlerinin altında kalması durumudur. Model sonucunda virüslü hastaların normal hasta gibi gösterilmesi buna örnektir.

Yanlış Negatif (YN): Model sonucunda istenilen görüntülerin yanlış diye tahmin ettiği sonuçların doğru tahmin olması durumudur. İstenilen görüntüyü doğru bir tahmine yönlendirmez. Eğitim sonucunda bakterili diye tespit edemediği görüntülerin aslında bakterili sınıfta olması durumudur.

Gerçek Negatif (GN): Eğitim sonucunda tahminleri tamamen yanlış yaptığı durumudur. Virüslü diye tahmin yaptığı tüm görüntülerin hiçbirisi virüslü hastaya ait olmaması durumudur. Şekil 4.14’de karışıklık matrisi tablosu gösterilmiştir.

		Pozitif (Hasta)	Negatif (Sağlıklı)
Gerçek Tahmin (Sağlıklı)	Gerçek (Hasta)	Doğru Pozitif	Yanlış Negatif
	Tahmin (Sağlıklı)	Yanlış Pozitif	Doğru Negatif

Şekil 4.17. Karmaşıklık matrisi

4.9.1. Kesinlik

Model sonucunda ortaya çıkan verilerde olumlu tahminlerin ne kadar çok ortaya çıktığını belirler. Model sonucunda doğru olarak tahmin sayısının kaç adet çıktığını gösterir. Yaptığımız çalışmada akciğer hastalıklarının virüslü toplam görüntülerini bakterili olarak algılasa model sonucunda kesinlik değeri düşük olur bu durumda istenilen tahminler gerçekleşmez. Yüksek bir kesinlik puanı, modelin yanlış değerlendirmelerden az sayıda olduğu ve güvenilir olumlu tahminler yaptığını gösterir. Denklem 4.3’de kesinlik hesaplama formülü gösterilmiştir.

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} \quad (4.3)$$

4.9.2. Duyarlılık

Gerçek nesnelerin doğru şekilde algılanma oranını ölçer. Nesne algılamada yapılan sınıflandırma ve tespitin performansını belirler. Duyarlılık oranı ne kadar yüksekse modeli o kadar etkili biçimde tanımladığı anlaşılır. Denklem 4.4’de hassasiyet formülü gösterilmiştir. Çalışmamızda kullandığımız normal görüntülerin belli kısımlarda virüslü olarak tanımlanması model tahmininin yanlış olmasına sorun olur.

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (4.4)$$

4.9.3. Ortalama Hassasiyet (mAP)

Nesne algılama ve sınıflandırmada en iyi performans karşılaştırılmasını veren ölçümdür. Tüm sınıfların ortalaması mAP’yi oluşturur. Gerçek deneylerde duyarlılık ve Kesinlik parametreleri yüksek seviyelere ulaştığından dolayı bunların ikisini birleştirecek bir parametreye ihtiyaç duyulmuştur. (Atik,2022). Denklem 4.5’de Ortalama Hassasiyet (mAP) formülü verilmiştir.

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N \text{AP}_i \quad (4.5)$$

Buradaki denklemde;

N: Sınıf sayısı

AP_i: i’inci sınıfın ortalama doğruluğu

4.9.4. F1Puanı

Kesinlik ve duyarlılığın harmonik ortalamasıdır. Hem yanlış pozitifleri hem de yanlış negatifleri göz önünde bulundurarak modelin performansını ölçmeye yarar. Bu değer özellikle veri kümesindeki pozitif ve negatif sınıflar arasında tahmin sonuçlarında dengesizlik olduğunu gösterir. Denklem 4.6'da F1 puanı formülü gösterilmiştir.

$$F1=2\times\frac{\text{Kesinlik}\times\text{Duyarlılık}}{\text{Kesinlik}+\text{Duyarlılık}} \quad (4.6)$$

5. BULGULAR ve TARTIŞMA

5.1. Veri Seti ve Deneyler


Çalışmada akciğer hastalığındaki virüslü, bakterili ve normal olarak 3 farklı sınıf görüntüleri YOLOv8, YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 kullanılarak model eğitimi ve sınıflandırılması yapılmıştır. Modeller 100 devir (epoch) boyutunda eğitilmiştir ve aynı eğitim, doğrulama ve test veri tabanında test edilmiştir.

Daha sonra yapılan model analizlerinden en yüksek mAP değerine sahip olan YOLOv8 modeline model performansını arttırmak için omurganın (backbone) orta katmanlarına SE ve uzlamsal dikkat modülü entegre edilmiştir.

Literatürde tıbbi görüntüler üzerinde SE ve uzlamsal dikkat modülü entegre edilmesi mAP oranında belirli artışlar sağlamaktadır. Bu çalışmada geliştirilen modülde omurga yapısının orta katmanlarına entegre edilen modüller ağız yapısındaki özellik haritalarının iyileştirilmesine ve mekânsal dikkati daha belirgin hale getirmeye çalışır. Bu sayede sınıf bazlı ve toplam mAP değerinde artış sağlanır.

Çalışmada veri seti olarak 3 farklı akciğer görüntülerinden oluşan halka açık veri seti kullanılmıştır. Veri setinden toplam 4479 fotoğraftan %80'i eğitim, %10'u doğrulama ve %10'u test için kullanılmıştır ve YOLO modellerinin Ortalama hassasiyet (MaP), kesinlik, duyarlılık ve F1 skoru metrikleri test edilmiştir.

Eğitim Google Colab üzerinden Python yazılımında YOLO kütüphaneleri kullanılarak yapılmıştır. Veri setindeki bakterili fotoğrafların boyutu 930x930, virüslü fotoğrafların boyutları 1300x1300 ve normal fotoğrafların boyutları 1200x1200 arasında değişiklik göstermektedir. Her bir modelin karşılaştırılmasının yapılması için 3 farklı sınıfta aynı veri seti üzerinden eğitilmiş ve test edilmiştir. Şekil 5.1'de hastalıklı görüntü veri kümesinden örnek görüntüler gösterilmiştir.



Şekil 5. 1. Veri seti örnek görüntüler

Çalışmada YOLOv8, YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 kullanılarak 5 farklı YOLO modelinin performansları değerlendirilmiştir. Model eğitimlerinde V100 GPU'nun kullanımı modelin performansını önemli ölçüde etkilemiştir. Model eğitimlerinde 640x640 boyutunda görseller kullanılmıştır. Devir (Epoch) değeri her bir YOLO modelinde 100 alınmıştır. Her bir modelin öğrenme oranı $lr=0,01$ olarak belirlenmiştir. Her bir modelde ağı gönderilen görüntü sayısı 16 parametre değeri ile gerçekleşmiştir. Burada Optimizasyon algoritması olarak Adam seçilmiştir. Tablo 5.1’de YOLO modeli eğitim parametreleri gösterilmiştir.

Tablo 5. 1. YOLO modeli eğitim parametreleri

Parametre	Değer
Görüntü Boyutu	640x640
Devir (Epoch)	100
Optimizasyon algoritması	Adam
Öğrenme Oranı	0.01
Yığın Boyutu	16

5.2. YOLOv8 Deney Sonuçları

YOLOv8 modeli ile yapılan deney çalışması sonucunda modelin eğitim parametre değerleri aşağıdaki tablo 5.3’de verilmiştir. Toplam model sonuçlarına bakıldığında tüm hastalık sınıfı için hesaplanan mAP değeri %87,9 oranında başarı yakalamıştır. Tüm sınıflar içinde en yüksek mAP değerine sahip sınıf normal görüntülerin olduğu sınıftır. En düşük mAP değerine sahip olan sınıf %81,8 ile virüs görüntülerinin olduğu sınıf bulunmuştur.

Modelin üç farklı sınıfa ait ortalama hassasiyet (mAP) değerleri incelendiğinde Normal görüntülerin diğer sınıf görüntülerinden daha belirgin seviyede yüksek performans göstermesi bakterili ve virüslü sınıf görüntülerinin birbirine yakın oranda görsel benzerlikler içermesinden kaynaklanmaktadır. Normal hastalık görüntülerinin daha homojen ve belirgin seviyede görüntü netliği oluşturması model performansında yüksek oranda başarıyı yakalamıştır. Aynı zamanda eğitim sonucunda bakterili ve virüslü sınıf görüntülerini birbirine benzer şekilde algılayıp karıştırdığından dolayı 2 sınıf görüntüleri yakın oranda başarı yakalamıştır. Tablo 5.2’de YOLOv8 eğitim parametre değerleri gösterilmiştir.


YOLOv8 modeli ile yapılan deney sonuçlarına göre en yüksek kesinlik oranı %91,2 ile normal görüntülerin olduğu sınıf, en düşük kesinlik değerine sahip sınıf ise %70,1 ile virüs görüntülerinin olduğu sınıf görülmüştür. Bakteri sınıfı görüntülerin kesinlik değeri ise %70,8 olarak elde edilmiştir. Duyarlılık oranına bakıldığında tüm sınıf bazında oran %89,3 olarak elde edilmiştir. Sınıf bazında duyarlılık oranına bakıldığında bakteri sınıfında %88,1, normal sınıfta %96,5 ve virüslü sınıfta %83,5 oranında elde edilmiştir.

Tablo 5.2. YOLOv8 eğitim parametre değerleri

Hastalık Sınıfı	Kesinlik	Duyarlılık	F1	mAP
Tümü	0.774	0.893	0.829	0.879
Bakteri	0.708	0.881	0.785	0.835
Normal	0.912	0.965	0.937	0.984
Virüs	0.701	0.835	0.762	0.818

YOLOv8 modeli ile yapılan eğitim sonuçlarında eğitim YOLOv8’in model sürümlerinden biri olan YOLOv8n ile yapılmıştır. Aşağıdaki grafikte yatay eksen


epoch sayısını verir. Dikey eksen ise eğitimin kesinlik, mAP, duyarlılık değerlerini gösterir. Eğitim boyunca kayıp fonksiyonları her epochta düzenli bir şekilde azalış göstermiştir. Eğitim sonucunda elde edilen grafikler eğitim aşamasında bazı grafiklerin düştüğünü ama yükselerek devam ettiğini göstermektedir. Aşağıdaki şekil 5.2’de YOLOv8 modeli performans metriği grafikleri gösterilmiştir.




Şekil 5. 2. YOLOv8 model performans metriği grafikleri

YOLOv8 modeli ile 3 farklı sınıf görüntülerinden eğitim yapılmıştır. Deney sonucunda eğitim sonrası örnek görüntülerin resimleri şekil 5.3’de gösterilmiştir. Eğitim sonucunda 3 farklı sınıf içerisinde en başarılı tahminleri normal görüntüler olan sınıf sağlamıştır.

En düşük tahmin verisine sahip olan sınıf virüslü görüntülerin olduğu sınıftır. Virüslü görüntülerin en düşük tahmin sonucuna sahip olması bakterili sınıfla benzer görüntülere sahip olmasından ve görüntü kalitesi açısından diğer sınıf görüntülerine göre küçük, rastgele veya düşük kontrastlı lezyonlar içermesinden kaynaklanmaktadır. Şekil 5.4’de test sonrası oluşan örnek görüntülerin resimleri verilmiştir.




Şekil 5. 3. YOLOv8 ile hastalıklı görüntülerin tespit edildiği örnek görüntüler



Şekil 5.4 YOLOv8 test sonucu oluşan örnek görüntüler

Şekil 5.5’de YOLOv8 ile yapılan çalışmaya ait karmaşıklık matrisi verilmiştir. Burada normal hasta sınıfı olan görüntülerden 291 tane görüntünün hepsinden 273 tanesini normal hastalıklı görüntü olarak tespit etmiş ve 5 görüntüyü de bakterili görüntü olarak algılamıştır. Bakteri sınıfındaki görüntülerde 256 tane görüntünün hepsinden 196 görüntüyü bakterili olarak ve 59 görüntüyü de virüslü görüntü olarak algılamıştır. Virüs sınıf görüntülerinden ise 286 tane görüntünün hepsinden 209 tanesini virüslü görüntü olarak tahmin yapmıştır.



Şekil 5.5 YOLOv8 karmaşıklık matrisi (test)

5.3. Geliştirilen YOLOv8 Modeli Deney Sonuçları

Çalışmada YOLOv8, YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 kullanılarak 5 farklı modelde aynı veri setiyle eğitim yapılmış ve test edilmiştir. Model performans sonuçlarına göre en yüksek mAP değeri YOLOv8 modelinde görülmüştür. En iyi sonucu veren modele modelin performansını arttırmak için bir dikkat mekanizması olan SE ve uzlamsal dikkat modülü omurganın orta katmanlarına entegre edilmiştir. Bu sayede toplam mAP ve sınıf bazında mAP değerlerinin performansı artırılmaya çalışılmıştır. Omurganın orta kısmına SE ve uzlamsal dikkat modülü entegre edilmesi orta özellikteki haritaları düşük ve yüksek seviyede özelliklerle birleştirerek modelin dikkatini dahada arttırmaya yarar.

Radyolojik görüntülerde hastalıklı bölgeler tek bir bölge üzerinde toplanması ve sınırlı sayıda görülmesinden dolayı SE ve uzlamsal dikkat farklı bölgelerdeki semptomların belirginliğini artırarak modeldeki hastalıklı bölgeleri daha iyi yakalamaya çalışır.

SE ve uzlamsal dikkat modülü önce kanal dikkati daha sonra uzlamsal dikkati uygulayarak özellik haritalarının iyileştirilmesine ve mekânsal dikkati daha belirgin hale getirmeye çalışır.

Model geliştirilmeden önce YOLOv8’de toplam mAP değeri %87,9 iken geliştirilen modelle birlikte bu değer %88,7 oranında performans göstermiştir. Sınıf bazında mAP oranlarına bakıldığında virüs sınıfında mAP değeri %81,8’den %83,6’ya yükselerek daha iyi performans geliştirmiştir.

Geliştirilen model virüs sınıfında sınırlı dokuları ve karmaşık yapıları daha yüksek konsantrasyon ile değerlendirdiği için virüs sınıfı diğer sınıf bazında daha yüksek artış yakalamıştır. Geliştirilen model yanlış pozitif oranını arttırdığı için bu başarı toplam sınıf bazında kesinlik oranının artmasına da zemin hazırlamıştır. Tablo 5.3’de geliştirilen YOLOv8 modeli eğitim parametre değerleri gösterilmiştir.

Duyarlılık oranına bakıldığında toplam sınıf bazında YOLOv8 modeline göre duyarlılık azalmıştır. Bunun nedeni geliştirilen modelin belirli bölgelere daha seçici davranıp karmaşık modelleri göz ardı edebilmesinden dolayı duyarlılık oranında azalma görülmüştür.

Tablo 5.3. Geliştirilen YOLOv8 Modeli eğitim parametre değerleri


Hastalık Sınıfı	Kesinlik	Duyarlılık	F1	mAP
Tümü	0.786	0.880	0.830	0.887
Bakteri	0.758	0.836	0.795	0.839
Normal	0.923	0.968	0.944	0.985
Virüs	0.678	0.836	0.748	0.836

Geliştirilen YOLOv8 modeli ile yapılan eğitim sonuçlarında eğitim YOLOv8 ile aynı eğitim parametrelerine sahip değerler ile gerçekleşmiştir. Aşağıdaki grafikte yatay eksen epoch sayısını verir. Dikey eksen ise eğitimin kesinlik, mAP, duyarlılık değerlerini gösterir. Eğitim boyunca kayıp fonksiyonları geliştirilen modelde de her epochta düzenli bir şekilde azalış göstermiştir. Geliştirilen modelde eğitim ve

doğrulama eğrilerinde normal YOLOv8 modeline göre dalgalanmalar meydana gelmiştir.

Her katmanda ortaya çıkan özellik haritaları geliştirilen modelde ağırlıkları değiştirmiş ve daha gürültülü bir yapı haline gelmiştir. Başlangıçta geliştirilen modelin öğrenmesi daha güçlü ve keskin bir şekilde grafikte görülmektedir. Her bir devir (epoch) sayısında yeni parametreler eklenmesi geliştirilen modelin dalgalanmalara sebep olmasını sağlamıştır ve buna rağmen geliştirilen model performansı yüksek mAP oranında başarı yakalamıştır. Dikkat mekanizmasının modele entegre edilmesi, ağırlık özellik haritalarını daha seçici şekilde güncellemesine neden olduğundan, eğitim sürecinde optimizasyonun daha kararlı bir hâl olarak optimum seviyeye ulaşmıştır


Loss eğrilerinin ilk kısımlarda daha düzensiz bir hal alması ve ani düşmeler meydana gelmesi geliştirilmiş modelde daha belirgindir. Bu dalgalanmalara rağmen epochlar ilerledikçe geliştirilmiş model daha yüksek mAP değerlerine ulaşmış ve daha iyi performans göstermiştir. Son performans metrikleri incelendiğinde SE ve uzlamsal dikkat modülü entegre edilince modele katkı yaptığı anlaşılmıştır. Şekil 5.6'da geliştirilen YOLO modelinin performans metriği grafikleri verilmiştir.




Şekil 5.6 Geliştirilen YOLOv8 model performans metriği grafikleri

Geliştirilen YOLOv8 modeli ile 3 farklı sınıf görüntülerinden diğer modellerle aynı eğitim veri seti eğitimi yapılmış ve test edilmiştir. Deney sonucunda geliştirilen

modelin eğitim sonrası örnek görüntüleri resimleri şekil 5.5'te gösterilmiştir. Geliştirilen model eğitimi sonucunda en fazla mAP artışı tüm sınıf görüntülerinde görülmüştür. Sınıf bazında en iyi artış virüs görüntülerinin olduğu sınıfta yaşanmıştır. Virüs sınıf görüntülerinde mAP artışı %81,8'den %83,6'ya yükselmiştir. SE ve uzlamsal dikkat modülü entegre edilmesiyle modele hem kanal hem de uzlamsal dikkat uyguladığı için belirli görüntü sınıflarında semptomlarda iyileştirmeler mevcuttur. Bu durum virüslü görüntülere daha belirgin seviyede odaklanabilmesini sağlamıştır. Normal görüntülere göre bakterili ve virüslü sınıflarda daha iyi oranda mAP artışı sağlanması dikkat modülünün belirli görüntü lokasyonlarına daha iyi odaklanmasını gösterir. Modele dikkat modülü entegre edilmesiyle eğitim sonrası oluşan örnek görüntülerin resimleri şekil 5.7'da gösterilmiştir. Geliştirilen modelin test sonrası oluşan örnek görüntüleri şekil 5.8'de verilmiştir.




Şekil 5.7 Geliştirilen YOLOv8 ile hastalıklı görüntülerin tespit edildiği örnek görüntüler



Şekil 5.8 Geliştirilen Yolov8 test sonucu oluşan örnek görüntüler

Şekil 5.9’da geliştirilen YOLOv8 ile yapılan çalışmaya ait karmaşıklık matrisi verilmiştir. Burada normal hasta olan görüntülerden 292 tane görüntünün hepsinden 276 tanesini normal hastalıklı görüntü olarak tespit etmiş ve 4 görüntüyü de bakterili görüntü olarak algılamıştır. Bakteri sınıfındaki görüntülerde 270 tane görüntünün hepsinden 206 görüntüyü bakterili olarak ve 64 görüntüyü de virüslü görüntü olarak algılamıştır. Bakteri sınıfında normal hastalık diye hiçbir görüntüyü tahmin etmemiştir. Virüs sınıf görüntülerinden ise 301 tane görüntünün hepsinden 216 tanesini virüslü görüntü olarak yakalamıştır.



Şekil 5.9 Geliştirilen YOLOv8 karmaşıklık matrisi (test)

5.4. YOLOv9 Deney Sonuçları

YOLOv9 modeli ile yapılan deney çalışması sonucunda modelin eğitim parametre değerleri aşağıdaki tablo 5.4’de verilmiştir. Toplam model sonuçlarına bakıldığında tüm hastalık sınıfı için hesaplanan mAP değeri %85 oranında başarı yakalamıştır. Tüm sınıflar içinde en yüksek mAP değerine sahip sınıf normal görüntülerin olduğu sınıftır. En düşük mAP değerine sahip olan sınıf %81,5 ile virüs görüntülerinin olduğu sınıftır.

Modelin üç farklı sınıfa ait ortalama hassasiyet (mAP) değerleri incelendiğinde Normal görüntülerin diğer sınıf görüntülerinden daha belirgin seviyede yüksek performans göstermesi bakterili ve virüslü sınıf görüntülerinin birbirine yakın oranda görsel benzerlikler içermesinden kaynaklanmaktadır. Normal hastalık görüntülerinin daha homojen ve belirgin seviyede görüntü netliği oluşturması model performansında yüksek oranda başarıyı yakalamıştır. Aynı zamanda eğitim sonucunda bakterili ve virüslü sınıf görüntülerini birbirine benzer şekilde algılayıp karıştırdığından dolayı 2 sınıf görüntüleri yakın oranda başarı yakalamıştır.


YOLOv9 modeli ile yapılan deney sonuçlarına göre en yüksek kesinlik oranı %93,9 ile normal görüntülerin olduğu sınıf, en düşük kesinlik değerine sahip sınıf ise %61,7 ile virüs görüntülerinin olduğu sınıf görülmüştür. Duyarlılık oranına bakıldığında tüm sınıf bazında oran %90 olarak elde edilmiştir. Sınıf bazında duyarlılık oranına bakıldığında bakteri sınıfında %81,8, normal sınıfta %96,8 ve virüslü sınıfta %91,5 oranında elde edilmiştir.

Tablo 5.4. YOLOv9 eğitim parametre değerleri

Hastalık Sınıfı	Kesinlik	Duyarlılık	F1	mAP
Tümü	0.772	0.878	0.831	0.850
Bakteri	0.758	0.818	0.786	0.833
Normal	0.939	0.968	0.953	0.984
Virüs	0.617	0.915	0.737	0.815

YOLOv9 modeli ile yapılan eğitim sonuçlarında eğitim YOLOv9’un model sürümlerinden biri olan YOLOv9t ile yapılmıştır. Aşağıdaki grafikte yatay eksen epoch sayısını verir. Dikey eksen ise eğitimin kesinlik, mAP, duyarlılık değerlerini gösterir. Eğitim boyunca kayıp fonksiyonları her epochta düzenli bir şekilde azalış göstermiştir. Eğitim sonucunda elde edilen grafikler eğitim aşamasında bazı

grafiklerin düştüğünü ama yükselerek devam ettiğini göstermektedir. Aşağıdaki şekil 5.10’da YOLOv9 modeli performans metriği grafikleri gösterilmiştir.




Şekil 5.10 YOLOv9 model performans metriği grafikleri


YOLOv9 modeli ile 3 farklı sınıf görüntülerinden eğitim yapılmıştır. Deney sonucunda eğitim sonrası örnek görüntülerin resimleri şekil 5.11’de gösterilmiştir.

Eğitim sonucunda 3 farklı sınıf içerisinde en başarılı tahminleri normal görüntüler olan sınıf sağlamıştır. En düşük tahmin verisine sahip olan sınıf virüslü görüntülerin olduğu sınıftır.

Virüslü görüntülerin en düşük tahmin sonucuna sahip olması bakterili sınıfla benzer görüntülere sahip olmasından ve görüntü kalitesi açısından diğer sınıf görüntülerine göre küçük, rastgele veya düşük kontrastlı lezyonlar içermesinden kaynaklanmaktadır. Şekil 5.12’de test sonrası oluşan örnek görüntülerin resimleri verilmiştir.




Şekil 5. 11 YOLOv9 ile hastalıklı görüntülerin eğitim sonucu örnek görüntüler



Şekil 5.12 Yolov9 test sonucu oluşan örnek görüntüler

Şekil 5.13'te YOLOv9 ile yapılan çalışmaya ait karmaşıklık matrisi verilmiştir. Burada normal hasta olan görüntülerden 265 tane görüntünün hepsinden 246 tanesini normal hastalıklı görüntü olarak tespit etmiş ve 5 görüntüyü de bakterili görüntü olarak algılamıştır. Bakteri sınıfındaki görüntülerde 254 tane görüntünün hepsinden 185 görüntüyü bakterili olarak ve 67 görüntüyü de virüslü görüntü olarak algılamıştır. Virüs sınıf görüntülerinden ise 281 tane görüntünün hepsinden 201 tanesini virüslü görüntü olarak algılamıştır.



Şekil 5.13 YOLOv9 karmaşıklık matrisi (test)

5.5. YOLOv10 Deney Sonuçları

YOLOv10 modeli ile yapılan deney çalışması sonucunda modelin eğitim parametre değerleri aşağıdaki tablo 5.5'de verilmiştir. Toplam model sonuçlarına bakıldığında tüm hastalık sınıfı için hesaplanan mAP değeri %86,7 oranında başarı yakalamıştır. Tüm sınıflar içinde en yüksek mAP değerine sahip sınıf normal görüntülerin olduğu sınıftır. En düşük mAP değerine sahip olan sınıf %80,5 ile bakterili görüntülerinin olduğu sınıftır.

Modelin üç farklı sınıfa ait ortalama hassasiyet (mAP) değerleri incelendiğinde Normal görüntülerin diğer sınıf görüntülerinden daha belirgin seviyede yüksek performans göstermesi bakterili ve virüslü sınıf görüntülerinin birbirine yakın oranda


görsel benzerlikler içermesinden kaynaklanmaktadır. Normal hastalık görüntülerinin daha homojen ve belirgin seviyede görüntü netliği oluşturması model performansında yüksek oranda başarıyı yakalamıştır. Aynı zamanda eğitim sonucunda bakterili ve virüslü sınıf görüntülerini birbirine benzer şekilde algılayıp karıştırdığından dolayı 2 sınıf görüntüleri yakın oranda başarı yakalamıştır.

YOLOv10 modeli ile yapılan deney sonuçlarına göre en yüksek kesinlik oranı %95 ile normal görüntülerin olduğu sınıf, en düşük kesinlik değerine sahip sınıf ise %65,3 ile virüs görüntülerinin olduğu sınıf görülmüştür. Duyarlılık oranına bakıldığında tüm sınıf bazında oran %87,6 olarak elde edilmiştir. Sınıf bazında duyarlılık oranına bakıldığında bakteri sınıfında %79,6, normal sınıfta %95,1 ve virüslü sınıfta %88,3 oranında elde edilmiştir.

Tablo 5.5. YOLOv10 eğitim parametre değerleri

Hastalık Sınıfı	Kesinlik	Duyarlılık	F1	mAP
Tümü	0.773	0.876	0.821	0.868
Bakteri	0.715	0.796	0.753	0.805
Normal	0.950	0.951	0.950	0.983
Virüs	0.653	0.883	0.750	0.815

YOLOv10 modeli ile yapılan eğitim sonuçlarında eğitim YOLOv10'un model sürümlerinden biri olan YOLOv10n ile yapılmıştır. Aşağıdaki grafikte yatay eksen epoch sayısını verir. Dikey eksen ise eğitimin kesinlik, mAP, duyarlılık değerlerini gösterir. Eğitim boyunca kayıp fonksiyonları her epochta düzenli bir şekilde azalış göstermiştir. Eğitim sonucunda elde edilen grafikler eğitim aşamasında bazı grafiklerin düştüğünü ama yükselerek devam ettiğini göstermektedir. Aşağıdaki şekil 5.14'de YOLOv10 modeli performans metriği grafikleri gösterilmiştir.




Şekil 5.14 YOLOv10 model performans metriği grafikleri

YOLOv10 modeli ile 3 farklı sınıf görüntülerinden eğitim yapılmıştır. Deney sonucunda eğitim sonrası örnek görüntülerin resimleri Şekil 5.15'te gösterilmiştir.


Eğitim sonucunda 3 farklı sınıf içerisinde en başarılı tahminleri normal görüntüler olan sınıf sağlamıştır. En düşük tahmin verisine sahip olan sınıf bakteri görüntülerin olduğu sınıftır.

Bakteri görüntülerin en düşük tahmin sonucuna sahip olması virüslü sınıfla benzer görüntülere sahip olmasından ve YOLOv10 mimarisindeki özellik çıkarımının bakterili görüntülerdeki lezyonlar üzerinde düşük kalmasından kaynaklanmaktadır.

YOLOv8 ve YOLOv9 ile yapılan eğitimlerde virüslü sınıf en düşük tahmin sonucuna ulaşmıştır. YOLOv10 ile yapılan eğitimde en düşük tahmin sonucunun bakteri sınıfında olması YOLO mimari yapılarının her modelde farklı görüntü işleyişlerine odaklanmasından meydana gelmektedir. Şekil 5.16'da test sonrası oluşan örnek görüntülerin resimleri verilmiştir.




Şekil 5. 15 YOLOv10 ile hastalıklı görüntülerin tespit edildiği örnek görüntüler



Şekil 5.16 YOLOv10 test sonucu oluşan örnek görüntüler

Şekil 5.17’de YOLOv10 ile yapılan çalışmaya ait karmaşıklık matrisi verilmiştir. Burada normal hasta olan görüntülerden 275 tane görüntünün hepsinden 266 tanesini normal hastalıklı görüntü olarak tespit etmiş ve 3 görüntüyü de bakterili görüntü olarak algılamıştır. Bakteri sınıfındaki görüntülerde 251 tane görüntünün hepsinden 189 görüntüyü bakterili olarak ve 59 görüntüyü de virüslü görüntü olarak algılamıştır. Virüs sınıf görüntülerinden ise 306 tane görüntünün hepsinden 216 tanesini virüslü görüntü olarak algılamıştır. 77 tane görüntüyü de bakterili görüntü sınıfı olarak tahmin etmiştir.



Şekil 5.17 YOLOv10 karmaşıklık matrisi (test)

5.6. YOLOv11 Deney Sonuçları

YOLOv11 modeli ile yapılan deney çalışması sonucunda modelin eğitim parametre değerleri aşağıdaki tablo 5.6’da verilmiştir. Toplam model sonuçlarına bakıldığında tüm hastalık sınıfı için hesaplanan mAP değeri %87,8 oranında başarı yakalamıştır. Tüm sınıflar içinde en yüksek mAP değerine sahip sınıf normal görüntülerin olduğu sınıftır. En düşük mAP değerine sahip olan sınıf %82,1 ile virüslü görüntülerinin olduğu sınıftır.

Modelin üç farklı sınıfa ait ortalama hassasiyet (mAP) değerleri incelendiğinde Normal görüntülerin diğer sınıf görüntülerinden daha belirgin seviyede yüksek

performans göstermesi bakterili ve virüslü sınıf görüntülerinin birbirine yakın oranda görsel benzerlikler içermesinden kaynaklanmaktadır. Normal hastalık görüntülerinin daha homojen ve belirgin seviyede görüntü netliği oluşturması model performansında yüksek oranda başarıyı yakalamıştır. Aynı zamanda eğitim sonucunda bakterili ve virüslü sınıf görüntülerini birbirine benzer şekilde algılayıp karıştırdığından dolayı 2 sınıf görüntüleri yakın oranda başarı yakalamıştır.


YOLOv11 modeli ile yapılan deney sonuçlarına göre en yüksek kesinlik oranı %98,8 ile normal görüntülerin olduğu sınıf, en düşük kesinlik değerine sahip sınıf ise %75,1 ile bakteri görüntülerinin olduğu sınıf görülmüştür. Duyarlılık oranına bakıldığında tüm sınıf bazında oran %84,9 olarak elde edilmiştir. Sınıf bazında duyarlılık oranına bakıldığında bakteri sınıfında %84, normal sınıfta %93,3 ve virüslü sınıfta %77,3 oranında elde edilmiştir.

Tablo 5.6. YOLOv11 eğitim parametre değerleri

Hastalık Sınıfı	Kesinlik	Duyarlılık	F1	mAP
Tümü	0.831	0.849	0.839	0.878
Bakteri	0.751	0.840	0.793	0.826
Normal	0.988	0.933	0.959	0.985
Virüs	0.754	0.773	0.763	0.821

YOLOv11 modeli ile yapılan eğitim sonuçlarında eğitim YOLOv11'in model sürümlerinden biri olan YOLOv11n ile yapılmıştır. Aşağıdaki grafikte yatay eksen epoch sayısını verir. Dikey eksen ise eğitimin kesinlik, mAP, duyarlılık değerlerini gösterir.

Eğitim boyunca kayıp fonksiyonları her devir(epoch) düzenli bir şekilde azalış göstermiştir. Eğitim sonucunda elde edilen grafikler eğitim aşamasında bazı grafiklerin düştüğünü ama yükselerek devam ettiğini göstermektedir. Aşağıdaki şekil 5.18'de YOLOv9 modeli performans metriği grafikleri gösterilmiştir.




Şekil 5.18 YOLOv11 model performans metriği grafikleri


YOLOv11 modeli ile 3 farklı sınıf görüntülerinden eğitim yapılmıştır. Deney sonucunda eğitim sonrası örnek görüntülerin resimleri şekil 5.19’da gösterilmiştir.

Eğitim sonucunda 3 farklı sınıf içerisinde en başarılı tahminleri normal görüntüler olan sınıf sağlamıştır. En düşük tahmin verisine sahip olan sınıf virüslü görüntülerin olduğu sınıftır.

Virüslü görüntülerin en düşük tahmin sonucuna sahip olması bakterili sınıfla benzer görüntülere sahip olmasından ve görüntü kalitesi açısından diğer sınıf görüntülerine göre küçük, rastgele veya düşük kontrastlı lezyonlar içermesinden kaynaklanmaktadır. Şekil 5.20’de test sonrası oluşan örnek görüntülerin resimleri verilmiştir.




Şekil 5.19 YOLOv11 ile hastalıklı görüntülerin tespit edildiği örnek görüntüler



Şekil 5. 20 YOLOv11 test sonucu oluşan örnek görüntüler

Şekil 5.21’de YOLOv11 ile yapılan çalışmaya ait karmaşıklık matrisi verilmiştir. Burada normal hasta olan görüntülerden 269 tane görüntünün hepsinden 259 tanesini normal hastalıklı görüntü olarak tespit etmiş ve 2 görüntüyü de bakterili görüntü olarak algılamıştır. Bakteri sınıfındaki görüntülerde 275 tane görüntünün hepsinden 212 görüntüyü bakterili olarak ve 58 görüntüyü de virüslü görüntü olarak algılamıştır. Virüs sınıf görüntülerinden ise 288 tane görüntünün hepsinden 215 tanesini virüslü görüntü olarak algılamıştır ve 55 tane görüntüyü de bakterili görüntü sınıfı olarak tahmin etmiştir.



Şekil 5.21 YOLOv11 karmaşıklık matrisi(test)

5.7. YOLOv12 Deney sonuçları

YOLOv12 modeli ile yapılan deney çalışması sonucunda modelin eğitim parametre değerleri aşağıdaki tablo 5.7’de verilmiştir. Toplam model sonuçlarına bakıldığında tüm hastalık sınıfı için hesaplanan mAP değeri %86,1 oranında başarı yakalamıştır. Tüm sınıflar içinde en yüksek mAP değerine sahip sınıf normal görüntülerin olduğu sınıftır. En düşük mAP değerine sahip olan sınıf %79,5 ile bakterili görüntülerinin olduğu sınıftır.

Modelin üç farklı sınıfa ait ortalama hassasiyet (mAP) değerleri incelendiğinde Normal görüntülerin diğer sınıf görüntülerinden daha belirgin seviyede yüksek


performans göstermesi bakterili ve virüslü sınıf görüntülerinin birbirine yakın oranda görsel benzerlikler içermesinden kaynaklanmaktadır. Normal hastalık görüntülerinin daha homojen ve belirgin seviyede görüntü netliği oluşturması model performansında yüksek oranda başarıyı yakalamıştır. Aynı zamanda eğitim sonucunda bakterili ve virüslü sınıf görüntülerini birbirine benzer şekilde algılayıp karıştırdığından dolayı 2 sınıf görüntüleri yakın oranda başarı yakalamıştır.

YOLOv12 modeli ile yapılan deney sonuçlarına göre en yüksek kesinlik oranı %92,6 ile normal görüntülerin olduğu sınıf, en düşük kesinlik değerine sahip sınıf ise %67,6 ile bakteri görüntülerinin olduğu sınıf görülmüştür. Duyarlılık oranına bakıldığında tüm sınıf bazında oran %85,2 olarak elde edilmiştir. Sınıf bazında duyarlılık oranına bakıldığında bakteri sınıfında %87, normal sınıfta %93,6 ve virüslü sınıfta %75,1 oranında elde edilmiştir.

Tablo 5.7. YOLOv12 eğitim parametre değerleri

Hastalık Sınıfı	Kesinlik	Duyarlılık	F1	mAP
Tümü	0.774	0.852	0.811	0.861
Bakteri	0.676	0.87	0.760	0.795
Normal	0.926	0.936	0.930	0.984
Virüs	0.719	0.751	0.734	0.804

YOLOv12 modeli ile yapılan eğitim sonuçlarında eğitim YOLOv12'nin model sürümlerinden biri olan YOLOv12n ile yapılmıştır. Aşağıdaki grafikte yatay eksen epoch sayısını verir. Dikey eksen ise eğitimin kesinlik, mAP, duyarlılık değerlerini gösterir. Eğitim boyunca kayıp fonksiyonları her epochta düzenli bir şekilde azalış göstermiştir. Eğitim sonucunda elde edilen grafikler eğitim aşamasında bazı grafiklerin düştüğünü ama yükselerek devam ettiğini göstermektedir. Aşağıdaki şekil 5.22'de YOLOv12 modeli performans metriği grafikleri gösterilmiştir.




Şekil 5.22 YOLOv12 model performans metriği grafikleri

YOLOv12 modeli ile 3 farklı sınıf görüntülerinden eğitim yapılmıştır. Deney sonucunda eğitim sonrası örnek görüntülerin resimleri şekil 5.23’de gösterilmiştir.


Eğitim sonucunda 3 farklı sınıf içerisinde en başarılı tahminleri normal görüntüler olan sınıf sağlamıştır. En düşük tahmin verisine sahip olan sınıf bakteri görüntülerin olduğu sınıftır.

Bakteri görüntülerin en düşük tahmin sonucuna sahip olması virüslü sınıfla benzer görüntülere sahip olmasından ve görüntü kalitesi açısından diğer sınıf görüntülerine göre YOLOv12 mimarisindeki özellik çıkarımının bakterili görüntülerdeki lezyonlar üzerinde düşük kalmasından kaynaklanmaktadır

YOLOv8, YOLOv9 ve YOLOv11 ile yapılan eğitimlerde virüslü sınıf en düşük tahmin sonucuna ulaşmıştır. YOLOv12 ile yapılan eğitimde en düşük tahmin sonucunun bakteri sınıfında olması YOLO mimari yapılarının her modelde farklı görüntü işleyişlerine odaklanmasından meydana gelmektedir. Şekil 5.24’de test sonrası oluşan örnek görüntülerin resimleri verilmiştir.




Şekil 5.23 YOLOv12 ile Hastalıklı görüntülerin tespit edildiği örnek görüntüler



Şekil 5. 24 YOLOv12 test sonucu oluşan örnek görüntüler

Şekil 5.24’de YOLOv12 ile yapılan çalışmaya ait karmaşıklık matrisi verilmiştir. Burada normal hasta olan görüntülerden 266 tane görüntünün hepsinden 251 tanesini normal hastalıklı görüntü olarak tespit etmiş ve 4 görüntüyü de bakterili görüntü olarak algılamıştır. Bakteri sınıfındaki görüntülerde 278 tane görüntünün hepsinden 197 görüntüyü bakterili olarak ve 75 görüntüyü de virüslü görüntü olarak algılamıştır. Virüs sınıf görüntülerinden ise 288 tane görüntünün hepsinden 195 tanesini virüslü görüntü olarak algılamıştır ve 68 tane görüntüyü de bakterili görüntü sınıfı olarak tahmin etmiştir.




Şekil 5. 25 YOLOv12 karmaşıklık matrisi(test)

5.8. Deney Sonuçları Karşılaştırmaları ve Tartışma

Deney sonucunda YOLOv8, geliştirilmiş YOLOv8, YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 modelleri kullanılarak aynı veri setinden parametrelerle deney yapılmış ve test edilmiştir. Toplam mAP bazında karşılaştırmalar şekil 5.25’de gösterilmiştir. Deney sonuçlarında en iyi mAP sonucunu veren model %88,7 oranında geliştirilmiş YOLOv8 modelidir. Grafikte görüldüğü gibi YOLOv8 %87,9, YOLOv9 %85, YOLOv10 %86,8, YOLOv11 %87,8 ve YOLOv12 %86,1 oranında mAP ortalama hassasiyet değerlerine ulaşarak başarı yakalamıştır. En iyi sonucu veren modele SE ve uzlamsal dikkat modülü entegre edilmesi mAP oranında en iyi başarı

oranını yakalamıştır. YOLOv8 ve YOLOv11 modeli birbirine çok yakın başarı performansı göstermiştir. 2 modelin mimari yapısı ve eğitim parametresi başarı oranını benzer şekilde belirleyerek tahminler sağlamıştır. Deney sonuçlarında en düşük modelin YOLOv9 gelmesi YOLOv9'un mimari yapısında küçük ve ince detayları yakalamada diğer modellere göre düşük kalmasından kaynaklanmaktadır. Elde edilen sonuçlar tatmin edici sonuçlardır veri setlerinde görüntü kalitesinin üst düzeyde olması akciğer görüntülerindeki lezyonlu bölgelerin daha seçici davranmasını ve eğitim sonuçlarını dahada arttıracakını ortaya koymaktadır. Tüm sınıf bazında kesinlik değerlerine bakıldığında YOLOv8 %77,4, YOLOv9 %77,2, YOLOv10 %77,3, YOLOv11 %83,1, YOLOv12 %74 ve geliştirilmiş YOLOv8 modeli ise %78,6 oranında kesinlik değerine ulaşmıştır. Şekil 5.27'da 3 sınıf görüntülerinin tüm modellerde mAP değerleri gösterilmiştir.




Şekil 5. 26 Toplam mAP değerleri

Tablo 5.8 Tüm modellerin deney sonuçları

Modeller	Kesinlik	Duyarlılık	F1	mAP
YOLOV8	0.774	0.893	0.829	0.879
YOLOV9	0.772	0.878	0.831	0.850
YOLOV10	0.773	0.876	0.821	0.868
YOLOV11	0.831	0.849	0.839	0.878
YOLOV12	0.740	0.852	0.811	0.861
Geliştirilmiş YOLOV8	0.786	0.880	0.830	0.887

Tablo5.8’de tüm deney sonuçları gösterilmiştir. Deney sonuçlarında sınıf bazında mAP sonuçlarına baktığımızda en iyi performans gösteren bakteri sınıfı %83,9 ile geliştirilmiş YOLOv8 modelinde görülmüştür. Normal sınıf görüntülerine baktığımızda YOLOv11 ile geliştirilen YOLOv8 modeli aynı mAP değerini yakalamıştır. Virüs sınıfı görüntülerine baktığımızda ise en iyi sonucu veren model %83,6 ile geliştirilen YOLOv8 modelinde görülmüştür.



Şekil 5.27 Tüm sınıflarda toplam mAP sonuçları

5 farklı model arasından toplam sınıf bazında mAP oranı en yüksek olan model YOLOv8’e bir dikkat modülü olan SE ve uzlamsal dikkat modülü entegre edilmiştir. Bu sayede modelin özellik haritaları güçlendirilip kanal dikkat ve uzlamsal dikkat uygulanmıştır. Tüm sınıfta bazında mAP oranlarında da başarı yakalamaya çalışılmıştır.

Tüm bakteri sınıfları içinde en iyi mAP ortalama hassasiyet değeri YOLOv8 modelinde %87,5 oranında görülmüştür. Dikkat mekanizması entegre edilmesiyle geliştirilen YOLOv8 modelinde bu oran %83,9’a yükselerek bakteri sınıfının tahmin başarısını arttırmıştır.

Virüslü görüntüler YOLOv8, YOLOv9 ve YOLOv11’de 3 sınıf bazında en düşük mAP ortalama hassasiyet değerine sahiptir. Sınıflar bazında değişimler YOLO mimarisinin iç mimari yapısındaki değişimlerinden, akciğer görüntülerinin belirli

YOLO modellerinde lezyonları daha iyi yakalamasından ve hastalıklı bölgeleri daha ayrıntılı ayırt etmesinden meydana gelmektedir.

Normal sınıflar tüm model sınıflar içinde en iyi başarı oranını yakalanmıştır. Normal görüntü sınıfının diğer iki sınıf görüntülerinden daha iyi mAP oranı elde etmesi bakterili ve virüslü görüntülerin hastalıklı bölge lezyonlarının benzer şekilde gelmesi ve 2 sınıfı birbirine karıştırmamasından kaynaklanmaktadır.

Normal sınıf görüntülerinde herhangi bir hastalık bulgusuna rastlamaması normal görüntü sınıfının mAP değerine maksimum seviyeye ulaşmasına zemin hazırlamıştır. Normal görüntü sınıfında en iyi mAP oranı YOLOv11 ve geliştirilen YOLOv8 modelinde görülmüştür. SE ve uzlamsal dikkat modülü modele entegre edilmesiyle geliştirilen YOLOv8 modelinde virüslü hastalıklı görüntü sınıfı diğer sınıflara göre mAP oranı önemli ölçüde arttırmıştır.

Modele entegre edilen dikkat modülü hastalıklı görüntülerde lezyonların ve radyolojik bulguların belirli olduğu alanlarda seçiciliği dahada arttırmış ve modelin görüntüleri daha iyi yakalamasına olanak sağlamıştır. Bu sayede normal akciğer görüntü sınıfına göre hastalıklı sınıflarda mAP artış oranı daha optimum seviyeye ulaşmıştır.

6. SONUÇLAR ve ÖNERİLER

Her geçen gün gelişmekte olan yapay zeka varlığını tüm alanlarda sürdürmektedir. Yapay zeka dalı makine öğrenimi ve derin öğrenme gibi alt dallarını ortaya koyarak görseller üzerinde nesne algılama ve nesne tespiti gibi uygulamalarda bize kolaylıklar sağlamaktadır. Günümüzde neredeyse her alanda kullanılan derin öğrenme yöntemleri nesne tespiti uygulamalarında bir çığır açmıştır. Nesnelerin görüntüsünü algılamak, hataları tespit etmek ve modern çağın istenilen seviyede görüntüleri analiz etmede yapay zekanın nesne tespiti uygulamaları önem taşımaktadır.

Nesne tespiti ve sınıflandırma çalışmaları bakımından YOLO modelleri geçmişten günümüze kadar var olan derin öğrenme yöntemlerinde yeni bir alan ortaya çıkarmıştır. İnsanlar daha basit ve karmaşık olmayan bir yapıda nesneleri sınıflandırmak ve görüntülerini analiz etmek için YOLO modellerini kullanması günümüz dünyasında daha gerçekçi sonuçlar ortaya çıkaracaktır.

YOLO modelleri her alanda karşımıza nesne tespiti ve sınıflandırma için çıkmaktadır. Günden güne YOLO modellerinin değişimi ve ilerlemesi nesne tespitinde algılamayı ve verimliliği arttırmaktadır. YOLO modelleri nesne tespitinde ve uygulamalarında istenilen görüntüleri daha iyi analiz etmede ve yapılan çalışmaların arasındaki benzerlikler ve farklılıklarda kolaylıklar sağlamaktadır.

Literatürde yapılan çalışmalarda YOLO modellerine dikkat modülü entegre edilmesiyle modelin performansı artmış ve seçicilik davranışı istenilen seviyelere getirilmeye çalışılmıştır. Yapılan çalışmalara dikkat modülü entegre edilmesiyle özellik haritaları iyileştirilmiş ve tahminleri daha doğru biçimde istenilen seviyede tutmaya çalışmıştır. Gelişen dünya ile birlikte YOLO modellerinin nesne tespitinde daha iyi yerlere geleceği ve istenilen uygulamaları hatasız bir biçimde ele alması mümkün olabilecektir.

Çalışmada halka açık veri setinden alınan görüntülerde akciğer hastalıklarında bulunan virüslü, bakterili ve normal görüntülerinden oluşan 3 sınıfta nesne tespiti ve sınıflandırma yapıp test edilmiştir. Çalışmada YOLO modellerinden YOLOv8, YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 kullanılarak en iyi sonucu veren modele mAP değerini arttırmak için SE ve uzlamsal dikkat modülü entegre edilmiş ve tüm YOLO modellerinin performansı karşılaştırılmıştır. Modele Dikkat modülü

entegre edilmesiyle sınıf bazlı ve toplam mAP oranında başarı arttırılmıştır. Deney sonuçlarında en iyi sonucu veren sınıf normal görüntülerin olduğu sınıftır. Normal görüntü sınıfı diğer sınıflara göre hastalık bulgusu taşımaması ve görüntü kalitesinin tam ölçekte ve netliği açısından maksimum seviyede olması başarı oranını optimum seviyeye getirmiştir. Çalışmada toplam mAP bazında en iyi oran geliştirilmiş YOLOv8 modelinde %88,7 oranında başarı yakalamıştır. Sırasıyla en yüksek mAP değerleri YOLOv8 %87,9, YOLOv11 %87,8, YOLOv10 %86,8, YOLOv12 %86,1 ve YOLOv9 %85 oranında başarı yakalamıştır. Model sonuçlarında akciğer görüntülerinde YOLO mimari yapılarının tahmin yakalama başarısı ve görüntülerin ayırt ediciliğinde önemini ortaya koymuştur.

YOLO modelleri kullanılarak yapılan eğitimde görüntüler piksel açısından yüksek olması deney açısından daha sağlıklı sonuçlar verecektir. Akciğer hastalıklarında sınıf bazında görüntülerin doğru oranda çeşitlendirilmesi ve hastalıklı bulguların doğru şekilde yakalanması sınıf bazında performansları dahada arttıracaktır. YOLO modellerine dikkat modülü doğru şekilde entegre edilmesiyle model performans ölçütleri yüksek oranda başarı yakalayacaktır. Literatürde yapılmış olan çalışmalarda daha fazla YOLO modeli kullanılarak genişletilmiş veri setleri kullanmak model performanslarını önemli ölçüde iyileştirecektir. Nesne tespiti yaparken sınıf sayısını arttırmak modelin eğitim parametrelerini doğru oranda analiz ederek literatüre daha fazla katkı sağlayacaktır. Çalışmada yapılan YOLOv8 mimarisine SE ve uzlamsal dikkat modülü entegre edilmesi model performanslarını önemli ölçüde iyileştirmiştir. Gelecek çalışmalarda dikkat modüllerinin model mimarilerine doğru bir şekilde entegre edilmesi çalışmaların sonucunu etkileyecektir. Gelecekte yapılacak çalışmalarda, modele dikkat mekanizmalarının eklenmesiyle model yapısında özellik çıkarım kapasitesinin artırılması ve tespit performansında iyileştirmeler göstermesi hedeflenmektedir.

7. KAYNAKÇA

- Ahmadyar Razlighi, Y., Kamali-Asl, A., & Arabi, H. (2024). *A hierarchical approach for pulmonary-nodule identification from CT images using YOLO model and a 3D neural network classifier. Radiological Physics and Technology*, 17(1), 124–134.
- Al Ewaidat, H., & El Brag, Y. (2022). *Identification of lung nodules CT scan using YOLOv5 based on convolution neural network. arXiv preprint arXiv:2301.02166*.
- Ao Wang, Hui Chen, Lihao Liu, Kai Chen, Zijia Lin, Jungong Han, and Guiguang Ding. Yolov10: Real-time end-to-end object detection. arXiv preprint arXiv:2405.14458, 2024.
- Bektaş, J. (2024). Evaluation of YOLOv8 model series with HOP for object detection in complex agriculture domains. *International Journal of Pure and Applied Sciences*, 10(1), 162–173.
- Benzer, S., & Benzer, R. (2017). Uluslararası PISA test sonuçlarının yapay sinir ağları ve regresyon yöntemleri ile incelenmesi (*Examination of international PISA test results with artificial neural networks and regression methods*). *Savunma Bilimleri Dergisi / The Journal of Defense Sciences*, 16(2), 65–78.
- Boesch, G. (2024, June 6). YOLOv10: Evolution in real-time object detection. *Viso Suite*. Retrieved August 13, 2025, from <https://viso.ai/deep-learning/yolov10/>
- Cheng, T., Song, L., Ge, Y., Liu, W., Wang, X., & Shan, Y. (2024, January). YOLO-World: Real-time open-vocabulary object detection. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 16935–16944.
- Cong, X., Li, S., Chen, F., Liu, C., & Meng, Y. (2023, ?) A Review of YOLO Object Detection Algorithms based on Deep Learning. *Frontiers in Computing and Intelligent Systems*, 4(2), 17–20
- Darılmaz, G., Özdemirel, T. Ş., Duru, S., Ertürk, A., & Bahadır, A. (Eds.). (2024). *Geriatrik akciğer hastalıkları: Güncel tanı ve tedavi yaklaşımları*. Duru Yayıncılık.
- Doe, J. (2025, August). YOLOv11 explained: Next level object detection with enhanced speed and accuracy. *Medium*.
- Ferreira, F. R. T., & do Couto, L. M. (2025). Using deep learning on microscopic images for white blood cell detection and segmentation to assist in leukemia diagnosis. *The Journal of Supercomputing*, 81(2), 410.
- Horry, M. J., Chakraborty, S., Paul, M., Ulhaq, A., Pradhan, B., Saha, M., & Shukla, N. (2020). COVID-19 detection through transfer learning using multimodal imaging data. *IEEE Access*, 8, 149808–149824.
- Hussain, M., & Khanam, R. (2024). In-depth review of YOLOv1 to YOLOv10 variants for enhanced photovoltaic defect detection. *Solar*, 4(1), 351–386. MDPI.
- Ji, Z., Zhao, J., & Ganchev, I. (2023). *ELCT-YOLO: An efficient one-stage model for automatic lung tumor detection based on CT images. Mathematics*, 11(10), Article 2344.
- Khanam, R., & Hussain, M. 2024, October 23. *YOLOv11: An overview of the key architectural enhancements*, arXiv:2410.17725
- Kiran, A., et al. (2023, September). Advanced object detection: A general overview of YOLO variants and their performances. In *Proceedings of the 4th International Conference on Smart Electronics and Communication (ICOSEC)* pp. 1018–1024.
- Mehra, A. (2024, September). Understanding YOLOv8 architecture, applications & features. *Labellerr*. Retrieved August 13, 2025, from <https://www.labellerr.com/blog/understanding-yolov8-architecture-applications-features/>

- Ornoba, T. R., Roy, G., & Hassan, E. (2023). CovidExpert: A Triplet Siamese Neural Network framework for the detection of COVID-19. *Informatics in Medicine Unlocked*, 37, Article 101156.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Ball, R. L., Langlotz, C., Shpanskaya, K., Lungren, M. P., & Ng, A. Y. (2017). *CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning*
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Ball, R. L., Langlotz, C., Shpanskaya, K., Lungren, M. P., & Ng, A. Y. (2017). *CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning*. *arXiv preprint arXiv:1711.05225*.
- Rath, S. (2023, January 10). Ultralytics YOLOv8: Comprehensive guide to state-of-the-art object detection. *LearnOpenCV*. Retrieved August 13, 2025, from <https://learnopencv.com/ultralytics-yolov8/>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. 2016. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779–788). IEEE.
- Ren, C., Hou, S., Hou, J., & Pang, Y. (2024). SwiF-YOLO: A deep learning method for lung nodule detection. *International Journal of Biology and Life Sciences*, 5(2), 20–27.
- Ren, C., Hou, S., Hou, J., & Pang, Y. (2024). SwiF-YOLO: A deep learning method for lung nodule detection. *International Journal of Biology and Life Sciences*, 5(2), 20–27.
- Sameer, H. A., Mutlag, A. H., & Gharghan, S. K. (2022). CT-Scan method-based artificial neural network for diagnosis of COVID-19. *Journal of Techniques*, 4(4), 24–32.
- Santone, A., Mercaldo, F., & Brunese, L. (2024). *A method for real-time lung nodule instance segmentation using deep learning*. *Life*, 14(9), 1192.
- Tang, C., Zhou, F., Sun, J., & Zhang, Y. (2025). Lung-YOLO: Multiscale feature fusion attention and cross-layer aggregation for lung nodule detection. *Biomedical Signal Processing and Control*, 99, Article 106815.
- Wang, H., Sui, C., Jiang, F., & Wang, A. (2024). Value-guided adaptive data augmentation for imbalanced small object detection. *The Journal of Supercomputing*, 81(2), 410.
- Wang, L., Lin, Z. Q., & Wong, A. (2020). *COVID-Net: A tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images*. *Scientific Reports*, 10(1), 19549.
- Wang, X., Wu, H., Wang, L., Chen, J., Li, Y., He, X., Chen, T., Wang, M., & Guo, L. (2025). Enhanced pulmonary nodule detection with U-Net, YOLOv8, and Swin Transformer. *BMC Medical Imaging*, 25(1), Article 247.
- Wu, X., Zhang, H., Sun, J., Wang, S., & Zhang, Y. (2024). *YOLO-MSRF for lung nodule detection*. *Biomedical Signal Processing and Control*, 94, Article 106318.
- Y. Li, Q. Fan, H. Huang, Z. Han, and Q. Gu. A modified yolov8 detection network for uav aerial image recognition. *Drones*, 7(5):304, 2023.
- Yao, S., Chen, Y., Tian, X., Jiang, R., & Ma, S. (2020). An improved algorithm for detecting pneumonia based on YOLOv3. *Applied Sciences*, 10(5), 1818.
- Yaseen, M. 2024, August 28. *What is YOLOv8: An in-depth exploration of the internal features of the next-generation object detector*, arXiv:2408.15857
- Yaseen, M. 2024, September 12. *What is YOLOv9: An in-depth exploration of the internal features of the next-generation object detector*, arXiv:2409.07813

Yasin, M. (2024, August). YOLOv8 Nedir: Yeni nesil nesne algılayıcının dahili özelliklerinin derinlemesine incelenmesi (12 sayfa). *arXiv*, arXiv:2408.15857v1

Zhao, Z.-Q., Zheng, P., Xu, S.-T., & Wu, X. (2019). Object detection with deep learning: A review. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3212–3232.



ÖZGEÇMİŞ

Murat Kaan Akar, Gülşen Batar Anadolu Lisesi'ni bitirdikten sonra Gaziantep İslam Bilim ve Teknoloji Üniversitesinden 2023 yılında mezun oldu. 2023 yılında Gaziantep İslam Bilim ve Teknoloji Üniversitesi Elektrik Elektronik Mühendisliği Ana Bilim Dalına Girdi. İyi/ Orta derecede İngilizce bilmektedir. Temel ilgi alanları; Görüntü işleme, Yapay Zeka (Aralık, 2025)

Yayınlanmış Çalışmalar

1. Proceedings of ICCESN-2024 Performance Evaluation and Design of Solar Energy Systems in Antalya Province Antalya-TURKEY 25-28 October 2024
2. 9th International Symposium on Multidisciplinary Studies and Innovative Technologies Disease Detection and Classification from Lung Images Using Deep Learning Methods TURKEY, Nov14,2025- Nov16,2025.

Sertifikalar

1. Turkcell Geleceği Yazarlar Python Sertifika / 2021
2. C Kodlama Dili / 2021
3. Deneyap Kart Eğitimi T3 Vakfı / 2023
4. Genel Veri Tabanı Tasarımı / 2023
5. Java ile Programlamaya Giriş / 2024

Bilgisayar Bilgileri

1. Microsoft Office Programları
2. Matlab
3. C++
4. Ardunio
5. Python
6. PVSOL
7. Java

