



**DERİN ÖĞRENME MİMARİLERİ KULLANILARAK ABDOMEN
BÖLGESİ İÇİN HASTALIK TESPİTİ**

Neslihan AYAZ

**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

OCAK 2026

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Neslihan AYAZ

20/01/2026

DERİN ÖĞRENME MİMARİLERİ KULLANILARAK ABDOMEN BÖLGESİ İÇİN
HASTALIK TESPİTİ
(Yüksek Lisans Tezi)

Neslihan AYAZ

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2026

ÖZET

Karın bölgesine ait acil bilgisayarlı tomografi (BT) görüntülerinde görülen patolojilerin hızlı ve doğru biçimde saptanması, özellikle acil servis koşullarında klinik karar sürecini doğrudan etkileyen kritik bir gereksinimdir. Bu tür sistemler, acil servis dışında da rutin klinik pratikte radyologlara yardımcı bir tanı destek aracı olarak kullanılabilir ve gözden kaçabilecek bulguların azaltılmasına katkı sağlayabilir. Bu çalışmada, akut kolesistit, akut pankreatit, böbrek/üreter taşı ve abdominal aort anevrizması/diseksiyonu bulgularının BT kesitleri üzerinden otomatik olarak tespiti ve sınıflandırılması için derin öğrenme tabanlı bir nesne tespit yöntemi önerilmektedir. Çalışmada, Teknofest Sağlıkta Yapay Zekâ Yarışması kapsamında yayımlanan veri seti kullanılmıştır. Veri setinin farklı hastaneler, farklı BT cihazları ve farklı çekim protokollerinden kaynaklanan heterojen yapısını azaltmak amacıyla giriş görüntülerine yoğunluk dönüşümü ve pencereleme, gürültü azaltma ve geometrik standardizasyon adımlarını içeren çok aşamalı bir ön işleme hattı uygulanmıştır. Nesne tespiti için YOLOv11 tabanlı mimari ile model eğitilmiş ve başarımlar hem rastgele görüntü bazlı hem de klinik genellenebilirliği daha iyi temsil eden hasta bazlı veri kullanımı senaryoları altında değerlendirilmiştir. Görüntü bazlı veri kullanımı senaryosunda genel başarımlar mAP@0.5 değeri 0,94 ve mAP@0.5:0.95 değeri 0,67 olarak elde edilirken, hasta bazlı veri kullanımında bu değerler sırasıyla 0,77 ve 0,44 olarak bulunmuştur. Sınıf bazında en yüksek başarımlar AAA/AAD sınıfında gözlenmiştir; böbrek/üreter taşı sınıfı ise küçük lezyon yapısı ve sınırlı örnek sayısı nedeniyle en zor sınıf olarak öne çıkmıştır. Gerçekçi bir klinik senaryoyu yansıtmak amacıyla hasta bazlı veri kullanımı benimsenmiş ve bu kapsamda mimari EMA, SimAM ve CA dikkat mekanizmaları ile geliştirilmiştir. Bu mimaride dikkat modülleri, omurga üzerindeki C3k2 bloklarına kademeli olarak entegre edilerek modelin özellikle küçük ve düşük kontrastlı patolojilere odaklanma yeteneği artırılmıştır. Geliştirilen model, aynı veri seti üzerinde raporlanan mevcut çalışmalarla karşılaştırıldığında, hasta bazlı değerlendirmede tutarlı ve rekabet edebilir bir performans sergilemiştir. Elde edilen sonuçlar, önerilen yaklaşımın abdominal acil patolojilerin hızlı ön değerlendirilmesi için kullanılabileceğini göstermektedir.

Bilim Kodu : 93436
Anahtar Kelimeler : Bilgisayarlı tomografi, abdomen, YOLOv11, derin öğrenme, hastalık tespiti, dikkat mekanizmaları
Sayfa Adedi : 87
Danışman : Doç. Dr. Ayşe DEMİRHAN

DISEASE DETECTION IN THE ABDOMINAL REGION USING DEEP LEARNING ARCHITECTURES

(M. Sc. Thesis)

Neslihan AYZA

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2026

ABSTRACT

Rapid and accurate detection of pathologies observed in emergency abdominal computed tomography (CT) images is a critical requirement that directly affects the clinical decision-making process, particularly under emergency department conditions. Such systems can also be used as computer-aided diagnostic support tools in routine clinical practice outside emergency settings, contributing to the reduction of overlooked findings. In this study, a deep learning-based object detection method is proposed for the automatic detection and classification of acute cholecystitis, acute pancreatitis, kidney/ureter stones, and abdominal aortic aneurysm/dissection findings from CT slices. In this study, the dataset published within the scope of the TEKNOFEST Health Artificial Intelligence Competition was used. To reduce the heterogeneity of the dataset arising from different hospitals, different CT scanners, and different acquisition protocols, a multi-stage preprocessing pipeline was applied to the input images, including intensity transformation and windowing, noise reduction, and geometric standardization. For object detection, a model was trained using a YOLOv11-based architecture, and its performance was evaluated under both random image-based and patient-based data usage scenarios, the latter of which better represents clinical generalizability. In the image-based data usage scenario, overall performance was achieved with an mAP@0.5 value of 0.94 and an mAP@0.5:0.95 value of 0.67, while in the patient-based data usage scenario these values decreased to 0.77 and 0.44, respectively. Class-wise evaluation showed that the highest performance was observed in the AAA/AAD class, whereas the kidney/ureter stone class emerged as the most challenging due to its small lesion size and limited number of samples. To reflect a realistic clinical scenario, patient-based data usage was adopted, and within this framework the architecture was enhanced using EMA, SimAM, and CA attention mechanisms. In this architecture, attention modules were gradually integrated into the C3k2 blocks of the backbone, thereby improving the model's ability to focus particularly on small and low-contrast pathologies. The developed model exhibited a consistent and competitive performance in patient-based evaluation when compared to existing studies reported on the same dataset. The results indicate that the proposed approach can be used for the rapid preliminary assessment of abdominal emergency pathologies.

Science Code : 93436

Key Words : Computed tomography, abdomen, YOLOv11, deep learning, disease detection, attention mechanisms

Page Number : 87

Supervisor : Assoc. Prof. Dr. Ayşe DEMİRHAN

TEŞEKKÜR

Çalışmalarımın yürütülmesi ve sonuçlandırılmasında desteğini eksik etmeyen değerli danışman hocam Doç. Dr. Ayşe DEMİRHAN'a maddi ve manevi tüm katkılarından dolayı en içten teşekkürlerimi sunarım. Bu zorlu yolculukta benden desteklerini ve sevgilerini hiçbir zaman esirgemeyen, her koşulda yanımda olan sevgili aileme sonsuz teşekkürlerimi sunarım. Bu akademik süreçte varlığıyla beni güçlendiren, destekleri için değerli arkadaşım Onur ADAK'a da minnettarlığımı sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI	7
3. MATERYAL VE METOTLAR.....	13
3.1. BT Görüntüleme Tekniği	13
3.2. Veri Seti	15
3.3. Görüntü Ön İşleme	20
3.3.1. Yoğunluk dönüşümü ve pencereleme.....	21
3.3.2. Gürültü azaltma	21
3.3.3. İlgi alan tespiti	22
3.3.4. Geometrik standardizasyon	23
3.4. YOLOv11.....	24
3.5. Dikkat Mekanizmaları.....	28
3.5.1. Verimli çok ölçekli dikkat mekanizması (efficient multi-scale attention, EMA).....	28
3.5.2. Basit parametresiz dikkat mekanizması (simple, parameter-free attention module, SİMAM).....	30
3.5.3. Koordinat dikkat mekanizması (coordinate attention, CA).....	32
3.5.4. Kayıp fonksiyonları	33

	Sayfa
3.5.5. Optimizasyon algoritmaları	34
3.5.6. Epok, küme boyutu ve öğrenme oranı	36
3.6. Model Performansının Değerlendirilmesi	37
3.6.1. Temel Bileşenlerin Tanımı	38
3.7. Geliştirilen Nesne Tespit Modeli	39
4. DENEYLER VE SONUÇLAR.....	45
4.1. Görüntü Bazlı Veri Kullanımı Deneyleri	46
4.2. Hasta Bazlı Veri Kullanımı Deneyleri	50
4.2.1. SiMAM dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonu.....	55
4.2.2. EMA dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonu ..	61
4.2.3. CA dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonu.....	68
5. SONUÇ VE ÖNERİLER	77
KAYNAKLAR	81
ÖZGEÇMİŞ	87

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Veri seti sınıf dağılımları.....	18
Çizelge 4.1. Model eğitiminde kullanılan hiperparametreler	46
Çizelge 4.2. Veri kümesi sınıf dağılımı	47
Çizelge 4.3. Görüntü bazlı veri kullanımı deney performansı	47
Çizelge 4.4. Hasta bazlı veri kümesi dağılımı	51
Çizelge 4.5. Hasta bazlı veri kullanımı model performans sonuçları.....	51
Çizelge 4.6. SiMAM dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonunun model başarımına etkisi	56
Çizelge 4.7. EMA dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonunun model başarımına etkisi	63
Çizelge 4.8. CA dikkat mekanizmasının kademeli entegrasyonunun model başarımına etkisi.....	69
Çizelge 4.9. Sınıf Bazlı Performans Karşılaştırması	75

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Bilgisayarlı tomografi.....	14
Şekil 3.2. Akut kolesistit veri seti örnek görüntüsü.....	19
Şekil 3.3. Akut pankreatit veri seti örnek görüntüsü	19
Şekil 3.4. Böbrek/üreter taşı veri seti örnek görüntüsü	20
Şekil 3.5. Abdominal aort anevrizması/diseksiyonu veri seti örnek görüntüsü	20
Şekil 3.6. Görüntü ön işleme adımları.....	24
Şekil 3.7. YOLO 11 mimarisi.....	26
Şekil 3.8. YOLOv11 mimarisinde kullanılan temel yapı taşları	27
Şekil 3.9. EMA dikkat mekanizmasının şematik gösterimi	30
Şekil 3.10. SimAM dikkat mekanizmasının şematik gösterimi.....	31
Şekil 3.11. CA dikkat mekanizmasının şematik gösterimi	33
Şekil 3.12. EMA mekanizmasının C3k2 bloklarına entegre edildiği YOLOv11n mimarisi.....	41
Şekil 3.13. SimAM mekanizmasının C3k2 bloklarına entegre edildiği YOLOv11n mimarisi.....	42
Şekil 3.14. CA mekanizmasının C3k2 bloklarına entegre edildiği YOLOv11n mimarisi.....	44
Şekil 4.1. Görüntü bazlı veri kullanımına ait karışıklık matrisi	48
Şekil 4.2. (a) AAA/ Diseksiyon (b) Böbrek/üreter taşı (c) AAA/ Diseksiyon (d) Akut Pankreatit test görüntüleri tahmin başarımları.....	49
Şekil 4.3. Hasta bazlı veri kullanımına ait karışıklık matrisi.....	52
Şekil 4.4. (a) Böbrek/üreter taşı (b) AAA/ Diseksiyon (c) Akut Kolesistit (d) Akut Pankreatit test görüntüleri tahmin başarımları.....	54

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

n	Anizotropik difüzyon filtresinde iterasyon sayısı
κ	Anizotropik difüzyon filtresinde iletkenlik katsayısı
λ	Anizotropik difüzyon filtresinde entegrasyon hızı sabiti
$\odot$	Eleman bazında çarpım
$\mu^{\wedge}$	Kanal geneli piksel ortalaması (SimAM mekanizmasında)
σ^2	Kanal geneli piksel varyansı (SimAM mekanizmasında)

Kısaltmalar

Açıklamalar

3B	Üç boyutlu
AAA	Abdominal Aort Anevrizması
AAD	Abdominal Aort Diseksiyonu
AP	Average Kesinlik – Ortalama Hassasiyet
AR	Average Duyarlılık – Ortalama Geri Çağırma
AUC	Area Under the Curve – Eğri Altı Alan
BiFPN	Bidirectional Feature Pyramid Network
BT	Bilgisayarlı Tomografi
C2f	Cross Stage Partial – Two Convolutions (CSP tabanlı C2f bloğu)
C2PSA	Cross Stage Partial Bottleneck with 2 Convolutions
C3k2	Convolutional Block with Parallel Spatial Attention
CA	Koordinat Dikkati (Coordinate Attention)
CIoU	Complete IoU
CNN	Convolutional Neural Network – Evrimsel Sinir Ağı
COCO	Common Objects in Context (kıyaslama veri seti)
CTA	Computed Tomography Angiography – Bilgisayarlı Tomografi Anjiyografi
DICOM	Digital Imaging and Communications in Medicine

Kısaltmalar	Açıklamalar
DIoU	Distance IoU
EMA	Verimli Çok Ölçekli Dikkat (Efficient Multi-scale Attention)
F1	F1 skoru
FPN	Feature Pyramid Network
GAP	Global Average Pooling – Küresel Ortalama Havuzlama
GFLOPs	Giga Floating Point Operations (hesaplama maliyeti ölçütü)
GIoU	Generalized IoU
Grad-CAM	Gradient-weighted Class Activation Mapping
HU	Hounsfield Unit
ICD-10	International Classification of Diseases (10. Revizyon)
IoU	Intersection over Union – Kesişim Üzerinden Birleşim
IV	İntravenöz (damar içi)
LSTM	Long Short-Term Memory
mAP	mean ortalama kesinlik
mAP@0.5	IoU=0.5 eşliğinde mAP
mFP	mean False Positives (metinde “ortalama yanlış pozitif”)
MPDIoU	kayıp/ölçüt adı – metinde “MPDIoU kayıp fonksiyonu”
MR	Manyetik Rezonans
MRA	Magnetic Resonance Angiography – Manyetik Rezonans Anjiyografi
MRG	Manyetik Rezonans Görüntüleme
MSE	Mean Squared Error – Ortalama Kare Hata
NTS	Ulusal Teleradyoloji Sistemi
OBB	Oriented Bounding Box
PANet	Path Aggregation Network
PET-BT	Pozitron Emisyon Tomografisi – Bilgisayarlı Tomografi
ROI	Region of Interest – İlgi Bölgesi
SGD	Stochastic Gradient Descent
SimAM	Basit Parametresiz Dikkat Modülü (Simple, Parameter-Free Attention Module)
Soft-NMS	Soft Non-Maximum Suppression

Kısaltmalar**Açıklamalar****SPPF**

Spatial Pyramid Pooling Fast

SSDSingle Shot (MultiBox) Detector
(metinde “SSD-FPN-ResNet-50”)**TEKNOFEST**

TEKNOFEST Havacılık, Uzay ve Teknoloji Festivali

**TR_ABDOMEN_RAD
_EMERGENCY**

Veri seti adı

U-Net

(mimari adı)

VGG-16

(mimari adı)

WL

Window Level – Pencere Merkezi

WW

Window Width – Pencere Genişliği

YOLO

You Only Look Once

**YOLOv5 / YOLOv7 /
YOLOv11**

YOLO sürümleri

YZ

Yapay Zekâ

1. GİRİŞ

Abdominal bölge (karın bölgesi); karaciğer, böbrekler, dalak, pankreas gibi hayati organları içerdiği için insan vücudunun klinik açıdan önemli bir anatomik bölgesidir. Bu organlar travma, enfeksiyon, tümör, damar tıkanıklığı, taş hastalığı veya iltihaplanma gibi nedenlerden etkilenebilir. Tıbbi görüntüleme yöntemleri ise bu organların ayrıntılı görülmesini sağlar. Görüntüleme sayesinde hastalıkların anatomik yeri, boyutu ve şekli değerlendirilebilir. Bu bilgiler, doğru tanı konulması açısından büyük önem taşır. Abdominal değerlendirmede semptomlara ve klinik şüpheye bağlı olarak çeşitli yöntemler kullanılabilir. Abdominal organların detaylı incelenmesinde bilgisayarlı tomografi (BT) ve manyetik rezonans (MR) görüntüleme en sık başvuru yöntemleridir [1].

Abdominal organlarda meydana gelebilecek hastalıklar, tüm vücut sistemini etkileyen ciddi sağlık sorunlarına yol açabilir. Akut karın ağrısı, acil servis başvurularının yaygın nedenlerinden biridir. Bu ağrıların sebebi insan yaşamını tehdit eden bir durum olabilir. En sık nedenler akut gastroenterit ve belirgin bir nedeni olmayan karın ağrısıdır. Bunları safra taşı hastalığı, böbrek taşı, divertikülit ve apandisit gibi durumlar izlemektedir. Birçok organın bulunması doktorların doğru tanıyı koymasını zorlaştırır. Görüntüleme yöntemi seçilirken ağrının yeri ve klinik şüphe dikkate alınır [2].

BT, abdominal bölgeden organları kesitsel olarak ayrıntılı biçimde gösteren bir görüntüleme yöntemidir. Özel X-ışını tüpü ve dedektörler kullanılarak abdominalden çok sayıda kesit halinde görüntü alınır. Bu kesitler bilgisayar ortamında yeniden işlenerek karaciğer, böbrek, pankreas, dalak, bağırsaklar ve damar yapıları net bir şekilde görüntülenir. BT, farklı dokuların X-ışını soğurma özelliklerini algıladığı için, doku yoğunluğundaki küçük farkları ortaya çıkarabilir. Böylece tümörler, kistler, taşlar, apseler, kanamalar, inflamatuvar değişiklikler ve travmaya bağlı hasarlar kolayca değerlendirilebilir. Yüksek uzaysal çözünürlüğe sahip kesitsel görüntüler tüm batını aynı anda gösterdiği için, hem küçük lezyonların hem de hafif yoğunluk değişimlerinin erken dönemde saptanmasına katkı sağlar. Bu özellikler, akut karın ağrısı ile başvuran hastalarda apandisit, bağırsak tıkanıklığı gibi acil durumların hızlı tanısında, travma olgularında iç organ yaralanmalarının değerlendirilmesinde ve kronik hastalıklarda hastalığın izlenmesinde BT'yi vazgeçilmez bir yöntem hâline getirmektedir. BT incelemesi kontrastsız olarak yapılabilirdiği gibi, bazı durumlarda damar yolu ile kontrast madde verilerek yapılabilir. Temel olarak, abdominal

BT dahi geniş bir hastalık yelpazesinin tanı ve tedavi planlamasında doktora güvenilir ve hızlı bilgi sunan bir görüntüleme aracıdır [3].

Akut pankreatit, pankreas dokusunun ani başlayan ve yaşamı tehdit edebilen bir iltihap hastalığıdır. Klinik olarak hastalarda çoğunlukla ani başlayan ve şiddetli üst karın ağrısı, bulantı, kusma ve sistemik inflamatuvar yanıt bulguları görülmektedir. En sık nedenleri arasında safra taşlarına bağlı safra yolu tıkanıklığı ve aşırı alkol kullanımı yer alır. Hiperlipidemi, ilaçlar, endoskopik müdahaleler ve genetik yatkınlık da nedenler arasında sayılabilir. Hastalık şiddetine göre hafif, orta ve ağır akut pankreatit şeklinde sınıflandırılır. Ağır akut pankreatit hastalığında çoklu organ yetmezliği görülebilir ve mortalite oranı %20–40’a ulaşabilir. Bu nedenle hastalığın erken dönemde doğru belirlenmesi büyük önem taşımaktadır. BT, hastalığın tanısında, şiddetinin değerlendirilmesinde ve komplikasyonların saptanmasında temel görüntüleme yöntemlerinden biri olarak önemli bir rol oynamaktadır [4].

Böbrek taşları, dünya genelinde sık karşılaşılan sağlık sorunları arasında yer almakta olup, böbrek kanallarında biriken sert mineral yapıdaki oluşumlarla tanımlanır. Şiddetli ağrı ataklarına yol açmasının yanı sıra, iş gücü kaybına neden olarak önemli bir sosyoekonomik yük oluşturur. Ancak bu hastalığın esas tıbbi önemi, yol açabileceği komplikasyonlardan kaynaklanmaktadır. Özellikle idrar akışını engellemesi durumunda, böbrek dokusunda kalıcı hasar ve buna bağlı olarak böbrek fonksiyon kaybı riski ortaya çıkabilir. Bu nedenle, böbrek taşlarının doğru şekilde tanınması ve uygun şekilde tedavi edilmesi, hem yaşam kalitesinin korunması hem de önlenabilir böbrek hasarlarının engellenmesi açısından kritik öneme sahiptir. Böbrek taşı, böbreklerin toplayıcı sisteminde veya pelvis bölgesinde oluşan, sert mineral birikintileri olarak tanımlanır. Üreter taşı ise böbrekte oluşan taşın zamanla aşağıya doğru ilerleyerek üretere düşmesi veya doğrudan üreter içinde taş oluşması durumudur. Bu taşlar, idrarda çözünmüş minerallerin ve tuzların aşırı doygunluğa ulaşp kristalleşmesi, büyümesi ve bir araya toplanmasıyla ortaya çıkar. Şiddetli akut ağrı, hematüri, bulantı–kusma, enfeksiyon ve obstrüksiyona bağlı böbrek fonksiyon kaybı gibi sonuçlara yol açabilir. Taş hastalığı tekrarlamaya eğilimli olup, yaşam boyu risk erişkinlerde %10'lara ulaşmaktadır. Taş hastalığının doğru ve zamanında tedavisi bu nedenle büyük önem taşır. Böbrek ve üreter taşlarının BT ile doğru ölçümü, düşme olasılığını, müdahale gereksinimini ve seçilecek yöntemi öngörmeye rol oynar. Uygun tedaviyle ağrı ve akut atakların kontrolü,

enfeksiyon, obstrüktif hidronefroz, kalıcı böbrek fonksiyon kaybı gibi komplikasyonların önlenmesiyle hastanın yaşam kalitesi ve böbrek sağlığı korunmuş olur [5-6].

Akut kolesistit, safra kesesinin aniden iltihaplanmasıdır. Bu durumun en büyük nedeni, safra taşının kesenin çıkış yolunu tıkamasıdır. Bu tıkanıklık nedeniyle safra kesesi şişer ve içindeki basınç artar. Zamanında tedavi edilmezse bu durum kan dolaşımını bozarak doku ölümüne veya kesenin delinmesine kadar gidebilir. Bazı durumlarda hastalık bir safra taşı ağrısı veya mide rahatsızlığı ile karıştırılabildiği için tanısı zorlayıcı olabilir. Teşhis için genellikle ilk olarak ultrasona başvurulsa da kesenin duvar yapısını, olası bir delinmeyi veya çevre dokulardaki iltihabı tam olarak görebilmek için BT gibi daha detaylı yöntemlere ihtiyaç duyulur. Özellikle durumu karmaşık olan hastalarda BT, hastalığın ciddiyetini net bir şekilde ortaya koyarak doktorun en doğru tedavi kararını vermesini sağlar [7].

Abdominal aort anevrizması (AAA), abdominal aort çapının 3 cm'nin üzerine çıkması ya da normalden %50 fazla genişlemesiyle tanımlanan, rüptür durumunda yüksek ölüm oranıyla seyreden ciddi bir damar hastalığıdır. Başlıca risk faktörleri arasında ileri yaş, erkek cinsiyet, sigara kullanımı, yüksek tansiyon ve aile öyküsü yer almaktadır. Ancak birçok olgu, rüptür gerçekleşene kadar belirti vermeden ilerleyebilir. Bu nedenle AAA'nın erken teşhis edilmesi ve düzenli takip edilmesi, ölüm riskinin azaltılmasında kritik rol oynar. Mevcut kılavuzlara göre, tarama ve küçük anevrizmaların izleminde ilk basamak yöntem olarak ultrasonografi önerilmektedir. Ancak cerrahi ya da endovasküler müdahale planlanan hastalarda detaylı anatomik değerlendirme için bilgisayarlı tomografi anjiyografi (CTA) altın standart olarak kabul edilir. Böbrek fonksiyon bozukluğu olan hastalarda ise manyetik rezonans anjiyografi (MRA) tercih edilebilecek bir alternatiftir. Son dönemde yapay zekâ destekli analizler, intravasküler ultrason ve PET-BT gibi ileri görüntüleme yöntemlerinin kullanımıyla anevrizma büyüme hızı ve rüptür riski daha doğru biçimde tahmin edilmekte, buna bağlı olarak daha kişiselleştirilmiş tedavi kararları alınabilmektedir [8].

Yapay zekâ (YZ), özellikle derin öğrenme ve evrimsel sinir ağları (CNN) gibi gelişmiş yöntemlerin kullanımıyla, tıbbi görüntülemede yalnızca yardımcı bir araç olmaktan çıkmış; hastalıkların tanı, tedavi planlama ve izlem süreçlerini dönüştüren temel bir bileşen hâline gelmiştir. Radyolojik görüntülerdeki karmaşık örüntüleri analiz ederek lezyon saptama, hastalık sınıflandırma ve organ bölütleme gibi görevlerde klinisyenlere yüksek duyarlılıklı bir ikinci göz desteği sunarken insan gözünün fark edemeyeceği mikroskobik doku

özelliklerini sayısallaştırarak tanısal süreci daha nesnel ve tekrarlanabilir kılmaktadır. YZ, meme kanseri taramalarında yanlış pozitiflerin azaltılmasından akciğer nodüllerinin erken saptanmasına ve kardiyovasküler risklerin öngörülmesine kadar geniş bir yelpazede tanı doğruluğunu artırırken; cerrahi navigasyon gibi alanlarda gerçek zamanlı görüntü analizi sağlayarak operasyonların güvenliğini de desteklemektedir. Bu otomasyon, uzmanların iş yükünü hafifletip raporlama sürelerini kısaltmanın yanı sıra, çelişkili olgularda karar destek mekanizması olarak tıbbi hata riskinin azaltılmasına da katkıda bulunmaktadır. Öte yandan, veri mahremiyeti, algoritmaların şeffaflığı, farklı cihazlar arasında genellenebilirlik ve etik boyutlar gibi tartışmalı alanlar hâlen önemini korumaktadır. Görüntü verilerinin genetik, patolojik ve klinik kayıtlarla birlikte değerlendirildiği çok modlu füzyon yaklaşımları ile veriyi paylaşmadan modeli eğitmeye imkân veren federatif öğrenme yöntemleri ise, gelecekte her hastaya özgü, bütüncül ve kişiselleştirilmiş tedavi planlarının oluşturulmasında YZ'nin vazgeçilmez bir rol üstleneceğini göstermektedir [9–11].

YOLO (You Only Look Once) serisi, tek aşamalı bir nesne tespit yaklaşımı olarak, gerçek zamanlı çalışma kapasitesi ve yüksek doğruluk düzeyi sayesinde tıbbi görüntüleme alanında önemli bir konuma sahip olmuştur. Geleneksel nesne tespit yöntemlerinden farklı olarak, tek bir ileri beslemeli ağ üzerinden hem nesne sınıflandırmasını hem de sınırlayıcı kutu tahminini aynı anda gerçekleştirmesi, özellikle zamanın kritik olduğu klinik senaryolarda belirgin bir hız ve verimlilik avantajı sunmaktadır. Bu sayede YOLO tabanlı modeller; akciğer nodülü tespiti [12], meme kanseri taraması [13], kolorektal lezyonların endoskopik görüntülerden tespiti [14] gibi farklı tıbbi görüntüleme uygulamalarında yaygın biçimde kullanılmaktadır. Nitekim YOLO tabanlı yaklaşımların akciğer BT görüntülerinde nodül tespitinde yüksek doğruluk sağladığı ve özellikle küçük boyutlu nodüllerin saptanmasında etkili sonuçlar verdiği literatürde rapor edilmiştir [12]. Benzer şekilde, YOLOv5 mimarisinin uzun-kısa vadeli bellek (LSTM) ağılarıyla birlikte kullanıldığı çalışmalarda, meme manyetik rezonans görüntüleme (MRG) incelemelerinde yanlış pozitif oranlarının azaldığı ve tarama doğruluğunun arttığı gösterilmiştir [13]. Bu başarıda yalnızca yüksek hız değil, özellik piramit ağı (FPN), çapraz ölçekli özellik entegrasyonu ve dikkat mekanizmaları gibi mimari iyileştirmeler de etkili olmaktadır. Bununla birlikte, küçük yapıları saptamadaki kısıtlar, düşük kontrastlı görüntülerde sınırlı genelleme yeteneği ve modelin yorumlanabilirliğine ilişkin sorunlar gibi zorluklar da mevcuttur. Yine de YOLO'nun hafif sürümlerinin (örneğin YOLOv5s, YOLOv8n) taşınabilir tıbbi cihazlara ve gerçek zamanlı klinik sistemlere entegre edilebilmesi, özellikle acil durumlar ve tele-tıp

uygulamaları açısından dikkate değer bir potansiyel taşımaktadır [15]. Ayrıca, YOLO mimarisinin çok modlu görüntü füzyonu, 3B (3 Boyut) modelleme ve kendi kendine öğrenme gibi yaklaşımlarla birlikte kullanılması, gelecekte tıbbi tanı sistemlerinin doğruluk ve güvenilirliğinin daha da artırılmasına olanak sağlayabilir [15].

Dikkat mekanizmaları, insan görsel sisteminin karmaşık sahnelerdeki belirgin bölgeleri seçme yeteneğinden esinlenerek geliştirilmiş olup, giriş verisindeki özniteliklere dayalı dinamik bir ağırlıklandırma süreci sunmaktadır. Bu mekanizmalar; görüntülerdeki gürültülü alanların baskılanması, özniteliklerin daha hassas çıkarılması ve özellikle tıbbi görüntüleme verilerinde de kullanılmaktadır [16].

Karın bölgesindeki hastalıklar genellikle birbirine benzeyen belirtilerle ortaya çıkar. Bu yüzden doğru ve hızlı tanı koymak, tedavi sürecinin başarılı olması için çok önemlidir. Bu çalışmanın amacı, BT görüntülerinde abdominal patolojileri tespit edip konumlandırarak ikincil bir tanı aracı geliştirmektir. Hastalık bölgelerini belirleyip patolojik bulguları sınıflandırarak, sistemin radyologlara gözden kaçabilecek durumları en aza indirmede ve tanı sürecini hızlandırmada destek olması hedeflenmektedir.

Bu tez çalışmasında, abdominal hastalıkların tespiti ve sınıflandırılmasında doğruluğu artırmak amacıyla derin öğrenme tekniklerinden yararlanılmıştır. Geliştirilen sistemin temelinde, derin öğrenme tabanlı YOLOv11 mimarisi yer almaktadır. Mevcut standart mimari üzerinde yapılan iyileştirmeler kapsamında, modelin görüntü içerisindeki tanısal açıdan önemli bölgelere odaklanabilmesini sağlamak amacıyla farklı dikkat mekanizmaları model omurgasına stratejik olarak entegre edilerek farklı mimariler oluşturulmuştur. Bu sayede modelin hem sınıflandırma hem de sınırlayıcı kutu yerleştirme performansının artırılması hedeflenmiştir.

2. LİTERATÜR ARAŞTIRMASI

Son yıllarda, birçok araştırmacı karın bölgesi hastalıklarını tespit etmek için derin öğrenme yöntemlerini kullanmaktadır. Literatürde farklı modeller ve farklı veriler üzerinde gerçekleştirilmiş birçok çalışma bulunmaktadır.

Chih-Jui Yu ve arkadaşları [17], akut kolesistit ve safra taşı tespiti için ultrason görüntülerinde çalışan derin öğrenme modelleri geliştirmiştir. Taipei Medical University Hospital veritabanından elde edilen 89 000'den fazla abdominal ultrason görüntüsü kullanılmıştır. Görüntülere rastgele kırpmaya, yatay çevirme ve renk değişimi gibi veri artırma teknikleri uygulanmıştır. Çalışmada safra taşı nesne tespiti ve konumlandırması, akut kolesistit tespiti için ise sınıflandırma yapılmıştır. Safra taşı tespiti için SSD-FPN-ResNet-50, akut kolesistit tespiti için ise MobileNet V2 mimarileri kullanılmıştır. Çalışma sonucunda, SSD-FPN-ResNet-50 modeli ile safra taşı tespitinde %92 AUC, MobileNet V2 modeli ile akut kolesistit tespitinde ise %94 AUC oranı elde edilmiştir.

Yang ve arkadaşları [18], akut kolesistit hastalığında abdominal BT kesitlerinde safra kesesini otomatik olarak tanımlayıp ardından hastalığı değerlendirmek üzere VGG-16 ve U-Net tabanlı tam otomatik bir derin öğrenme sistemi geliştirmiştir. Önerilen sistem; VGG-16 ile safra kesesi içeren kesitlerin otomatik seçilmesi, U-Net ile safra kesesi bölgesinin segmentasyonu ve özellik çıkarımı, çıkarılan özelliklerle akut kolesistit varlığının sınıflandırılması olmak üzere üç aşamadan oluşmaktadır. Çalışma, safra kesesi tanıma aşamasında %95,3 doğruluk (accuracy) elde etmiştir. Segmentasyon performansını artırmak için bilateral filtre ile desteklenen U-Net modeli, %72,7 IoU (Intersection over Union) değerine ulaşmıştır. Model, akut kolesistit tespiti aşamasında ise %92,5 doğruluk, %90,4 duyarlılık (duyarlılık), %94,1 özgüllük (specificity) ve 0,97 AUC başarı oranı göstermiştir.

Chen ve arkadaşları [19], akut pankreatitli hastalarda hastalığın gidişatını tahmin etmek için BT temelli radyomik verileri klinik bilgilerle birleştiren bir model geliştirmiştir. 2015–2022 yılları arasında akut pankreatit tanısı almış 344 hastanın kontrastlı BT görüntüleri incelenmiştir. Pankreas ve çevresinden çıkarılan 2 264 radyomik özellikten en anlamlı 14 tanesi seçilerek klinik verilerle birleştirilmiştir. Bu çalışmada beş farklı model test edilmiş, klinik + radyomik birleşik model en yüksek performansı göstermiştir. Modelin AUC değerleri eğitimde 0,9, doğrulamada 0,88 ve testte 0,74 olarak bulunmuştur.

Zhang ve arkadaşları [20], akut pankreatit tanısı için bir model geliştirmiştir. Model, akut pankreatit sınıflandırma ve lezyon segmentasyon modülünden oluşmaktadır. Bu çalışmada, Sichuan Provincial People's Hospital'den 190 akut pankreatit hastasına ait BT görüntüleri kullanılmıştır. Sınıflandırma modülü, BT görüntülerinde akut pankreatiti %99,1 doğruluk ve %100 duyarlılıkla tespit etmiştir. Test setinde modelin AUC değeri 0,99, harici doğrulama setinde ise 0,85 olarak hesaplanmıştır. Segmentasyon modülü ise pankreas ve çevresindeki lezyonların (ödem, inflamatuvar eksüda, efüzyon, abse/nekroz) sınırlarını belirlemiştir. Ortalama IoU değerleri pankreas için %86, inflamatuvar eksüda için %61,8, efüzyon için %57,7 ve abse/nekroz için %66,4 olarak elde edilmiştir.

Asif ve arkadaşları [21], böbrek taşlarının BT görüntülerinde sınıflandırılmasına yönelik StoneNet adını verdikleri derin öğrenme modeli geliştirmiştir. Model, MobileNet mimarisi temel alınarak tasarlanmış ve depthwise separable convolution, küresel ortalama havuzlama (global average pooling, GAP), Batch Normalization ve Dropout katmanlarıyla optimize edilmiştir. Bu yapı sayesinde hafif bir mimari elde edilmiştir. Bu çalışmada, Elazığ Fethi Sekin Şehir Hastanesi'nden alınan 1 799 BT görüntüsü (790 taş, 1.009 normal) kullanılmıştır. Görüntüler radyologlar tarafından etiketlenmiş ve veri artırma teknikleri kullanılmıştır. StoneNet modeli, %97,98 doğruluk, %96,98 duyarlılık, %98,78 kesinlik, %98,91 özgüllük, %97,87 F1-skoru ve %98,83 AUC değerlerine ulaşmıştır.

Almuayqil ve arkadaşları [22], böbrek hastalıklarını sınıflandırmak için KidneyNet adlı derin öğrenme tabanlı bir evrimsel sinir ağı (CNN) modeli geliştirmiştir. KidneyNet, sekiz konvolüsyon katmanı, üç havuzlama katmanı, bir flatten katmanı ve iki tam bağlı katmandan oluşmaktadır. Gradient-weighted class activation mapping (Grad-CAM) tabanlı görselleştirme kullanılarak modelin açıklayıcılığı artırılmıştır. Bu modelde görüntülerden özellik çıkarımı yapılarak böbrek taşı, kist ve tümör ayırt edilmiştir. Sonuçlara göre KidneyNet modeli, %99,88 doğruluk, %99,76 duyarlılık, %99,58 kesinlik, %99,92 özgüllük ve %99,67 F1-skoru değerleriyle üstün performans sergilemiştir.

Tang ve arkadaşları [23], böbrek taşı tespiti için YOLO-C3AC adını verdikleri geliştirilmiş bir derin öğrenme modeli önermiştir. Model, YOLOv5 mimarisi temel alınarak oluşturulmuş ve böbrek taşlarının BT görüntülerinde tespit edilmesi amacıyla tasarlanmıştır. Önerilen modelde dört ana yenilik bulunmaktadır. C3AC modülü ile bağlamsal bilgi algısı artırılmış ve Fusion Block yapısı ile çok ölçekli özelliklerin etkili birleştirilmesi sağlanmıştır.

MPDIoU kayıp fonksiyonu kullanılarak da sınır kutusu tahminlerinin doğruluğu artırılmış, Soft-NMS yöntemiyle de örtüşen kutulardan kaynaklanan yanlış pozitif tespitler azaltılmıştır. Bu modelde, Kaggle platformundan alınan yaklaşık 1 300 BT görüntüsü ve 3 000 taş örneği içeren veri kümesi kullanılmıştır. Çalışma sonucu, YOLO-C3AC modeli mAP@0.5 %80,2 başarı oranı elde etmiştir.

Abdimurotovich ve Cho [24] , böbrek taşı tespiti için YOLOv5m-SE adlı derin öğrenme modeli önermiştir. Bu model, standart YOLOv5m mimarisinin C3 bloğuna Sıkıştırma ve Uyarma (SE, Squeeze-and-Excitation) modülü entegre edilerek oluşturulmuştur. Bu modül özellik haritaları arasındaki ilişkileri güçlendirmiş ve özellikle küçük taşların tespitinde modelin duyarlılığını artırmıştır. YOLOv5m-SE, %81,6 kesinlik, %63,7 duyarlılık ve %66,4 mAP@0.5 performans elde etmiştir.

Xing ve arkadaşları [25], böbrek, üreter ve mesane taşlarını kontrastsız BT görüntülerinden otomatik olarak tespit edebilen bir derin öğrenme sistemi geliştirmiştir. Önerilen model, USm-FPNs (üriner taş haritası-özellik piramit ağı) adı verilen basamaklı bir yapıya sahiptir. Yanlış pozitif oranını azaltmak için üreter mesafe ısı haritası yöntemi kullanılmıştır. Taş tespitinde ortalama 1,18 ortalama yanlış pozitif (mFP) değeri ve %97,7 duyarlılık (sensitivity) oranı elde edilmiştir. Hasta düzeyinde değerlendirildiğinde ise sistem %99,5 duyarlılık ve %99 kesinlik (precision) göstermiştir.

Parakh ve arkadaşları [26], üriner sistem taşları için kademeli iki evreli bir CNN modeli geliştirmiştir. Modelin ilk ağı (CNN-1) üriner sistem bölgesini belirlerken, ikinci ağ (CNN-2) taşı belirlemek amacını taşır. Model, GrayNet adı verilen, CT görüntüleriyle önceden eğitilmiştir. Elde edilen sonuçlara göre, GrayNet-SB modeli, 0,95 AUC, %95 doğruluk, %94 duyarlılık ve %96 özgüllük oranlarına ulaşmıştır. Özellikle 4 mm'den küçük taşlarda yanlış negatif oranı diğer modellere göre belirgin şekilde azalmıştır.

Chatterjee ve arkadaşları [27], abdominal aort anevrizmalarını (AAA) tespit etmek için bir model geliştirmiştir. Bu çalışmada, 66 manuel olarak segmentlenmiş BT taraması kullanılarak eğitilen 3D U-Net tabanlı bir modelle aort segmentasyonu yapılmış ve çapı 3 cm'nin üzerinde olan vakalar AAA pozitif olarak sınıflandırılmıştır. Model, 9.172 semptomsuz hastaya ait BT görüntüleriyle doğrulanmıştır. Model, %96 duyarlılık, %96 özgüllük ve %99 AUC değeriyle yüksek doğruluk göstermiştir. Bu modelle tespit edilen

AAA'ların, abdominal aorttaki kalsiyum skoruyla güçlü şekilde ilişkili olduğu ($p < 0,0001$) bulunmuştur. Sadece plak skoruna dayalı tahminde 0,86 AUC, %82 duyarlılık ve %81 özgüllük değeri görülmüştür.

Baltacı ve arkadaşları [28], tarafından yapılan çalışma, AAA ve abdominal aort diseksiyonu (AAD) hastalıklarının görüntülerinden otomatik olarak tespisi, sınıflandırılması ve segmentasyonu üzerine odaklanmaktadır. Veri kümesi T.C. Sağlık Bakanlığı Teleradyoloji Sistemi'nden alınan 13 294 adet DICOM (Digital imaging and communications in medicine) formatında görüntü içermektedir. Çalışmada önerilen model CNN tabanlı hibrit bir mimaridir. Bu mimari hem anevrizma hem de diseksiyon bölgelerinin tespiti ve sınırlarının belirlenmesi için tasarlanmıştır. Sonuçlar, ResDenseUNet, INet ve C-Net gibi mevcut CNN tabanlı modellerle karşılaştırılmıştır. Önerilen model, %89,64 doğruluk, %87,55 F1 skoru ve %83,76 IoU oranı elde etmiştir.

Bu çalışmada, abdominal BT görüntülerinde birden fazla abdominal bölge hastalığının otomatik olarak tespiti amacıyla YOLOv11 mimarisi temel model olarak seçilmiştir. YOLOv11'in mimarisi önceki YOLO mimarilerine kıyasla sadeleştirilmiştir ve düşük parametre sayısı sayesinde kaynak kısıtlı ortamlarda dahi verimli bir çıkarım sağlamaktadır. Bu özellikleri nedeniyle çalışmada YOLOv11'n sürümü temel model olarak tercih edilmiştir. Literatür incelendiğinde, abdominal BT görüntülerinde patoloji tespitine yönelik çalışmaların önemli bir kısmının tek bir hastalık türüne odaklandığı; çok sınıflı ve konum bilgisi içeren neste tespit yaklaşımlarının ise görece sınırlı sayıda kaldığı görülmektedir. Mevcut çalışmaların çoğunda sınıflandırma veya segmentasyon temelli yöntemler ön planda yer almakta, klinik açıdan kritik olan lezyonun hem tespiti hem de konumlandırılması gereksinimi ise ikincil düzeyde ele alınmaktadır. YOLO tabanlı mimarilerin tıbbi görüntüleme uygulamalarında yaygın biçimde kullanılmasına karşın, abdominal BT'de özellikle küçük boyutlu ve düşük kontrastlı patolojilerin tespitinde temel mimarilerin sınırlı kaldığı; bu kısıtın giderilmesi amacıyla dikkat mekanizmalarının omurga seviyesinde kademeli ve sistematik biçimde entegre edilerek etkilerinin derinlik düzeylerine göre karşılaştırıldığı çalışmaların literatürde yeterince kapsamlı olmadığı anlaşılmaktadır.

Bu tez çalışmasında söz konusu eksiklikler doğrultusunda, abdominal BT görüntülerinde birden fazla acil patolojinin nesne tespit yaklaşımıyla eş zamanlı olarak tespiti hedeflenmiş ve klinik kullanım senaryosuna daha yakın bir değerlendirme sağlamak amacıyla hasta bazlı

veri kullanımı benimsenmiştir. Temel YOLOv11n mimarisinin özellikle küçük boyutlu ve düşük kontrastlı hastalıkların tespitinde sınırlı kaldığı gözlenmiştir. Bu eksikliği gidermek amacıyla, model omurgasına EMA (Efficient Multi-scale Attention), SimAM (Simple, Parameter-Free Attention Module) ve CA (Coordinate Attention) dikkat mekanizmaları entegre edilerek modelin küçük ve düşük kontrastlı patolojiler üzerindeki performansı artırılmıştır. Bu yönleriyle çalışma, hem yöntemsel yaklaşım hem de değerlendirme stratejisi bakımından literatürdeki boşluğu gidermeyi amaçlamaktadır.



3. MATERİYAL VE METOTLAR

Materiyal ve metotlar bölümünde, BT görüntüleme tekniği, kullanılan veri seti, görüntü ön işleme, YOLO11 modelinde kullanılan yöntemler, parametreler ve metotlar hakkında bilgi verilmektedir.

3.1. BT Görüntüleme Tekniği

BT, vücudun iç yapılarının ayrıntılı görüntülerini oluşturmak için X-ışını teknolojisini kullanan tıbbi görüntüleme yöntemidir. Bu işlem sırasında hasta, bir X-ışını tüpü ve dedektör barındıran tarayıcının içine doğru kayan bir masaya yatar. X-ışını tüpü vücuttan farklı açılardan geçen ışınlar yayarken, dedektörler geçen radyasyon miktarını ölçer. Toplanan bu veriler bir bilgisayara gönderilir ve matematiksel algoritmalar kullanılarak kesitsel görüntülere dönüştürülür. Elde edilen bu kesitler tek tek incelenebileceği gibi, birleştirilerek 3B görüntüler de oluşturulabilir. BT cihazının genel görünümü Şekil 3.1’de gösterilmektedir. Modern BT tarayıcıları, yüksek çözünürlüklü görüntüleri saniyeler içinde ve hastaya minimum radyasyon vererek üretebilmektedir [29].

Bu süreçte yer alan X-ışını dedektörü, görüntü oluşturmak için esas bileşendir ve hem elde edilen görüntü kalitesi hem de hastanın maruz kaldığı radyasyon dozu üzerinde önemli etkiye sahiptir. Günümüzde kullanılan BT sistemlerinde çoğunlukla tamamı katı hâl dedektörler kullanılmaktadır. X-ışını tüpü ve dedektör dizisinin birbirine sıkıca bağlı olduğu ve hastanın etrafında birlikte döndüğü üçüncü nesil tasarıma sahiptir. Bu sistemlerde dedektörler, dokulardan geçerek zayıflamış olan X-ışını demetini algılamakta ve elde edilen sinyaller bilgisayar tarafından işlenmek üzere dijital veriye dönüştürülmektedir. Dedektör teknolojilerindeki gelişmeler, foton sayım dedektörleri gibi yeni nesil yaklaşımlar ile görüntü kalitesinin artırılmasına ve radyasyon dozunun azaltılmasına olanak sağlamaktadır [30].



Şekil 3.1. Bilgisayarlı tomografi [31]

Kontrast madde, görüntülemelerde belirli doku ve damar yapılarını çevre dokulardan daha belirgin hâle getirmek amacıyla vücuda intravenöz (damar yolu) yolla verilen bir maddedir. BT incelemelerinde kullanılan intravenöz kontrast maddelerin temel amacı, dokuların X-ışını ile etkileşimini değiştirerek hedef yapıların daha net görünmesini sağlamaktır. Bu işlem şu mekanizmalarla gerçekleşir:

1. X-ışını attenuasyonu (zayıflama): X-ışınları dokulardan geçerken enerji kaybeder. Yoğun yapılar, örneğin kemikler, bu ışınları daha fazla absorbe eder ve görüntüde daha parlak olarak görünür.
2. İyotun Etkisi: Kas, damar ve organ gibi yumuşak dokular benzer yoğunluklara sahiptir. Yüksek atom numarasına sahip iyot içeren kontrast ajanları, X-ışınlarını güçlü bir şekilde emerek bu dokuların birbirinden ayırt edilmesini kolaylaştırır.
3. Kontrast Tutulumu: Damar yoluyla verilen iyotlu madde, dolaşım sistemiyle yayılır ve kanlanan organları geçici olarak yoğunlaştırır. Bu durum, tümörler veya damar yapılarının normal dokulardan ayırt edilerek görüntüde daha parlak görünmesini sağlar [32].

Kontrastlı BT: İntravenöz kontrastlı BT, birçok abdominal patolojide tanısal bilgiyi artırmak için kullanılır ve çoğu senaryoda tek kontrastlı faz ile yeterli tanısal bilgi elde edilebilir. Örneğin; akut pankreatit, akut non-lokalize karın ağrısı ve ateş, divertikülit şüphesi, Crohn hastalığı gibi durumlarda kontrastlı abdomen–pelvis BT endikasyonları listelenmektedir [36].

Kontrastsız BT: İntravenöz kontrast verilemeyen hastalarda (ör. kontrast alerjisi veya böbrek fonksiyon kısıtlılığı) seçilmiş endikasyonlarda tanısal bir alternatif sağlayabilir. Ayrıca bazı klinik durumlarda ilk basamak inceleme olarak tercih edilebilir. Örneğin, akut yan ağrıda ürolitiazis (taş) şüphesinde kontrastsız BT önerilen yaklaşımlar arasındadır [33].

BT sırasında kontrast madde kullanımına, mevcut klinik bulgular, semptomlar ve diğer tanı yöntemlerinin sonuçlarına göre karar verilir. Her hastaya özgü durum değerlendirilerek, kontrastlı veya kontrastsız BT tercih edilir. Bu çalışma kapsamında ise hem kontrastlı hem de kontrastsız BT görüntüleri kullanılmıştır.

Abdominal BT incelemelerinde kontrastsız ve kontrastlı çekimlerin bir arada kullanılması, hastalıkların daha kapsamlı ve doğru şekilde teşhis edilmesini sağlar. Kontrastsız fazlar; özellikle taş, kalsifikasyon ve akut kanama gibi yoğun yapıların kolayca saptanmasına yardımcı olur. Kontrastlı fazlar ise lezyonların damar yapılarıyla olan ilişkisini ve komşu organlara yayılımını daha net bir şekilde gösterir. Bu iki yöntemin birlikte uygulanması, lezyon sınırlarının belirlenmesine ve hastalıkların birbirlerinden ayırt edilmesine önemli katkı sunar [34].

3.2. Veri Seti

Türkiye’de düzenlenen Teknofest Havacılık, Uzay ve Teknoloji Festivali, millî teknolojiye yön veren çok sayıda kamu kurumu, üniversite, özel sektör kuruluşu ve sivil toplum örgütünün desteğiyle gerçekleştirilen, havacılık, uzay ve ileri teknoloji odaklı kapsamlı bir organizasyondur. Teknofest teknoloji yarışmaları, fuar alanları, uçuş gösterileri, seminerler ve atölye çalışmaları gibi etkinlikler düzenleyerek teknolojiye olan ilgiyi artırmayı ve Millî Teknoloji Hamlesi vizyonunu yaygınlaştırmayı amaçlamaktadır. Teknofest kapsamındaki yarışmalar, özellikle gençlerin yenilikçi projeler geliştirmesini teşvik ederek, ülkenin teknolojik yetkinliğinin artmasına ve nitelikli insan kaynağının güçlenmesine önemli katkı sunmaktadır [35].

Bu kapsamda, Teknofest bünyesinde düzenlenen Sağlıkta Yapay Zekâ Yarışması altında, karın bölgesine ait acil durum BT görüntülerini içeren, “TR ABDOMEN RAD EMERGENCY” adlı veri seti Sağlık Bakanlığı tarafından oluşturulmuştur. Bu veri seti, 2022 yılında Ordu’da gerçekleştirilen Teknofest Sağlıkta Yapay Zekâ yarışması için hazırlanmış

olup, acil servise başvuran hastalarda görülen çeşitli abdominal patolojilerin sınıflandırılması ve tespitine yönelik BT kesitleri ile bunlara ait etiketleri içermektedir [36]. Veri seti yarışma sonrasında araştırmacıların kullanımına sunulmak üzere T.C. Sağlık Bakanlığı Açık Veri Portalı üzerinden herkese açık olarak paylaşılmıştır [37].

Veri seti, T.C. Sağlık Bakanlığı'na bağlı e-Nabız Kişisel Sağlık Sistemi ve Ulusal Teleradyoloji Sistemi (NTS) kayıtlarından, 2019–2021 yılları arasını kapsayacak şekilde merkezi olarak toplanmıştır. Veri havuzunu oluşturulurken ICD-10 (Uluslararası Hastalık Sınıflandırması) kodları ve ilgili görüntüleme prosedür kodları kullanılarak filtreleme yapılmıştır [36].

İlk aşamada 16.143 olgu belirlenmiş, bu olgular arasından rastgele seçilen 1.517 vaka, yarışmada kullanılacak çekirdek veri setini oluşturacak şekilde ayrıntılı incelemeye tabi tutulmuştur. Çalışmaya dâhil edilen BT görüntüleri, Türkiye genelinde 459 farklı hastanenin acil radyoloji bölümlerinden elde edilmiştir. Bu geniş kapsam, veri setinin gerçek dünya koşullarındaki hastalık dağılımını yansıtmayı sağlamaktadır [36].

Veri setinin demografik özellikleri incelendiğinde, hastaların yaş dağılımının 10 ile 97 yıl arasında değiştiği ve ortalama yaşın 49,49 olduğu görülmektedir. Cinsiyet dağılımı ise %62 erkek ve %38 kadın olacak şekilde heterojen bir yapıdadır [36].

BT taramalarının yaklaşık yarısı (%49,45) intravenöz (IV) kontrastlı olarak çekilmiş, küçük bir kısmında (%3,99) pozitif oral kontrast kullanılmıştır. Kesit kalınlıkları 0,5 mm ile 5 mm arasında değişmekte, seri başına düşen kesit sayısı ise 51 ile 2.051 arasında geniş bir aralıkta dağılım göstermektedir [36]. Bu teknik çeşitlilik ve farklı patolojilerin birbirine yakın görünüşleri, veri setini yapay zekâ modelleri için oldukça zorlu ve karmaşık bir test ortamı haline getirmektedir.

Veri setinin temel zorluğu, içerdiği patolojilerin BT kesitlerinde birbirine çok yakın radyolojik görünümlere sahip olmasıdır. Performans değerlendirmesinde, yarışmacı algoritmaların tahmin ettiği sınırlayıcı kutular ile yer işaretleri arasındaki kesişim-birleşim oranına (IoU) dayalı olarak farklı eşik değerlerinde (0,25; 0,5; 0,75) F1 skoru hesaplanmıştır. Eşik değeri yükseldikçe F1 skorlarında belirgin bir düşüş gözlenmiştir. Tüm sınıflar 0,5 eşik dikkate alındığında, veri setinin zorluğu daha belirgin hâle gelmektedir. Analizler,

abdominal aort anevrizması/diseksiyonu sınıfının göreceli olarak daha kolay tespit edilebilir olduğunu, akut divertikülitin ise en güç sınıflardan biri olarak öne çıktığını göstermiştir [36].

Veri seti oluşturulurken farklı üretici ve modelde (6 üretici, 55 farklı BT cihaz modeli) cihazların kullanılmış olması, hem görüntü kalitesi hem de parametreler açısından çeşitlilik oluşturmaktadır. Bu teknik çeşitlilik ile farklı patolojilerin BT’de birbirine oldukça benzer görünümlere sahip olması birlikte değerlendirildiğinde, “TR ABDOMEN_RAD_EMERGENCY” veri seti, yapay zekâ tabanlı modeller için oldukça zorlu ve karmaşık bir test ortamı sunmaktadır [36].

Etiketleme süreci, deneyimli on radyologdan oluşan ekip tarafından yürütülmüştür. Tamamen anonimleştirilmiş BT görüntüleri, ulusal teleradyoloji platformu üzerinde geliştirilen özel bir anotasyon arayüzü kullanılarak incelenmiştir. Her bir patolojik bulgu, sınırlayıcı kutu ve buna karşılık gelen sınıf etiketi ile işaretlenmiştir. Radyologlar, akut apandisit, akut kolesistit, akut pankreatit, böbrek/üreter taşı, abdominal aort anevrizması/diseksiyonu, akut divertikülit gibi altı temel abdominal hastalığı temsil eden etiketleri kullanmıştır. [36].

Orijinal veri havuzunda toplam altı sınıf tanımlanmıştır. Bu çalışmada kullanılan veri setinin incelenmesi sonucunda, bazı hastalık sınıflarına ait görüntülere karşılık gelen etiket bilgilerinin eksik olduğu belirlenmiştir. Bu durum, derin öğrenme tabanlı modellerin eğitimi ve performans değerlendirmesinde yanlı ve güvenilir olmayan sonuçlara yol açabileceğinden, analiz sürecinde görüntü-etiket eşleşmesi eksiksiz ve tutarlı olan sınıfların kullanılmasına karar verilmiştir [36]. Bu doğrultuda, veri setinde hem görüntü hem de sınırlayıcı kutu (bounding box) etiketleri tam ve doğrulanabilir nitelikte bulunan akut kolesistit, akut pankreatit, böbrek/üreter taşı ve abdominal aort anevrizması/diseksiyonu sınıfları çalışmaya dâhil edilmiştir. Böbrek/üreter taşı sınıfı, veri setinde eksik görüntü ve eksik/uyumsuz etiketler bulunmasına rağmen, klinik pratikte yüksek prevalansa sahip yaygın bir patoloji olması nedeniyle çalışmaya dâhil edilmiştir.

Çizelge 3.1.’de, her bir hastalık sınıfı için ayrı ayrı olmak üzere, eğitim ve yarışma veri setlerinde yer alan olgu sayıları ve bu olgulara karşılık gelen toplam görüntü sayıları gösterilmektedir [36].


Çizelge 3.1. Veri seti sınıf dağılımları

Veri Seti	İstatistik Türü	Sınıf 1 (Apandisit)	Sınıf 2 (Kolesistit)	Sınıf 3 (Pankreatit)	Sınıf 4 (Böbrek/Üreter Taşı)	Sınıf 5 (Divertikülit)	Sınıf 6 (Aort Anevrizması)	Toplam*
Eğitim	Olgu Sayısı	221	124	146	283	76	159	1 209
Eğitim	Görüntü Sayısı	5 490	5 085	6 668	2 513	1 084	9 793	357 428
Yarışma	Olgu Sayısı	83	34	48	97	16	49	308
Yarışma	Görüntü Sayısı	2 051	1 260	2 173	975	319	2 874	98 101


Çizelge 3.1.'de eğitim veri seti, modelin öğrenme sürecinde kullanılmak üzere daha geniş örnek hacmi sağlarken; yarışma veri seti, yarışma sürecinde performansın ölçülmesine yönelik ayrı bir değerlendirme kümesi olarak tanımlanmıştır [36].

Eğitim verisi, altı farklı hastalık sınıfına ait 1.209 olgu ve toplam 357.428 görüntüden oluşmaktadır. Sınıflar arasında olgu ve görüntü sayıları bakımından klinik gerçekliği yansıtan belirgin bir dengesizlik bulunmaktadır. Veri setindeki bu dengesiz dağılım, model eğitimi sırasında özel önlemler alınmasını ve değerlendirmede sınıf bazlı performans analizlerinin yapılmasını gerekli kılmaktadır. Bununla birlikte, Teknofest kapsamında yayımlanan proje ve sonuç raporlarında değerlendirme çıktılarının eğitim veri seti üzerinden raporlandığı, yarışma veri seti üzerinde ayrıca bağımsız bir test değerlendirmesine yer verilmediği görülmektedir. Bu nedenle, bu tez kapsamında raporlarla tutarlılığı ve karşılaştırılabilirliği korumak amacıyla yarışma veri seti kullanılmamış; tüm deneysel analizler eğitim veri üzerinden gerçekleştirilmiştir. Sınıflar arası örnek sayısı dengesizliği ise model eğitimi sürecinde sınıf dengesizliği problemini gündeme getirmekte ve değerlendirme aşamasında sınıf bazlı performans analizlerinin önemini artırmaktadır. [36].


Bu çalışmada kullanılan veri setine ait örnek görüntüler hastalık sınıflarına göre ayrı ayrı sunulmuştur. Akut kolesistit ve akut pankreatit sınıflarına ait örnek görüntüler sırasıyla Şekil 3.2. ve Şekil 3.3.'te gösterilmektedir. Böbrek/üreter taşı ve abdominal aort anevrizması/diseksiyonu sınıflarına ait örnek görüntüler ise Şekil 3.4. ve Şekil 3.5.'te sunulmuştur.




Şekil 3.2. Akut kolesistit veri seti örnek görüntüsü



Şekil 3.3. Akut pankreatit veri seti örnek görüntüsü



Şekil 3.4. Böbrek/üreter taşı veri seti örnek görüntüsü



Şekil 3.5. Abdominal aort anevrizması/diseksiyonu veri seti örnek görüntüsü

3.3. Görüntü Ön İşleme

Bu çalışmada kullanılan ham BT kesitleri, standart DICOM formatında temin edilmiştir. Ham BT kesitlerinin farklı cihaz, protokol ve hastane kaynaklı heterojen yapısını azaltmak ve derin öğrenme modelinin verimliliğini artırmak amacıyla dört aşamalı sistematik bir ön işleme hattı uygulanmıştır. Ön işleme hattı; yoğunluk dönüşümü ve pencereleme, gürültü azaltma, ilgi alanı tespiti ve geometrik standardizasyon oluşmaktadır. Görüntü ön işleme adımları Şekil 3.6.'da gösterilmiştir.

3.3.1. Yoğunluk dönüşümü ve pencereleme

Veri ön işleme protokolünün ilk ve en kritik aşaması, ham BT görüntülerinin yoğunluk değerlerinin tıbbi görüntüleme standartlarına uygun hale getirilmesidir. Öncelikle, DICOM formatındaki ham piksel değerleri, dokuların X-ışını absorpsiyon katsayılarını nicel olarak ifade eden HU değerlerine dönüştürülmüştür [38].

Bu HU değerleri üzerinde, özellikle abdominal ve pelvik bölgeye ait yumuşak doku, organ sınırları ve olası patolojik bulguların kontrastını ve görünürlüğünü artırmak amacıyla pencereleme (windowing) uygulanmıştır. Pencereleme parametreleri öncelikle DICOM dosyasında tanımlı Pencere Merkezi (Window Level, WL) ve Pencere Genişliği (Window Width, WW) değerlerinden okunmuştur. Bu bilgilerin bulunmadığı durumlarda ise, otomatik bir pencereleme aralığı belirlenmiştir. Bu yaklaşım, hem cihazdan bağımsız bir ön işleme süreci sağlamış hem de aşırı uç değerlerin görüntü kontrastını bozmasını engellemiştir.

Pencereleme işlemi sonrasında elde edilen HU değerleri, 8-bit gri seviye standardına (0–255 aralığı) normalize edilmiştir. Bu normalizasyon, Eş. 3.1.’deki lineer dönüşüm fonksiyonu kullanılarak gerçekleştirilmiştir.

$$\text{Gray} = \frac{HU - (WL - (\frac{WW}{2}))}{WW} \times 255 \quad (3.1)$$

Burada orijinal HU skalasındaki giriş piksel değerini, ise 0–255 aralığındaki çıkış piksel değerini temsil etmektedir. Burada Gray, 0–255 aralığındaki çıktı piksel değerini temsil etmektedir. Bu dönüşümle pencere aralığının alt sınırı 0’a, üst sınırı ise 255’e eşlenmiş; aralık dışındaki değerler alt/üst sınırlara sabitlenmiştir. Böylece model girdileri standartlaştırılırken, klinik açıdan anlamlı kontrast bilgisi korunmuştur.

3.3.2. Gürültü azaltma

BT görüntüleme sürecine içkin olan düşük seviyeli gürültülerin (örneğin, Speckle gürültüsü) baskılanması amacıyla Anizotropik Difüzyon Filtresi [39] uygulanmıştır. Bu tür düşük seviyeli gürültüler, derin öğrenme modelinin doğru öznitelik çıkarımını zorlaştırmaktadır. Geleneksel izotropik (her yönde eşit) pürüzsüzleştirme filtreleri (örneğin Gauss filtreleri)

kenar bilgilerini de bulanıklaştırırken, anizotropik difüzyonun temel avantajı homojen bölgeleri pürüzsüzleştirirken kritik anatomik sınırları ve kenar bilgilerini koruma yeteneğidir.

Bu çalışmada kullanılan anizotropik difüzyon yöntemi, üstel iletkenlik fonksiyonuna dayalı olup aşağıdaki parametrelerle yapılandırılmıştır: iterasyon sayısı $n_{iter} = 3$, iletkenlik katsayısı $\kappa = 30$ ve entegrasyon hız sabiti $\gamma = 0,15$ [40]. Parametreler, görüntülerin aşırı düzleştirilmeden gürültüsünün azaltılması ve patolojik yapıların kenarlarının korunması hedeflenerek deneysel olarak belirlenmiştir. Filtreleme işlemi, modelin daha kararlı ve ayırt edici öz nitelikler öğrenmesini destekleyen bir ön işleme adımı olarak kullanılmıştır.

Filtre parametreleri, deneysel gözlemler doğrultusunda optimal performans elde edilecek şekilde aşağıdaki gibi belirlenmiştir :

- İterasyon sayısı (n_{iter}): 3
- İletkenlik katsayısı (κ): 30
- Entegrasyon hız sabiti (γ): 0,15

Bu konfigürasyon ile doku içi homojenite artırılmış; buna karşın patolojik bulguların tespitinde kritik öneme sahip gradyan geçişleri ve kenar bilgisi başarıyla korunmuştur [41].


3.3.3. İlgi alan tespiti

Bu çalışmada ilgi alanı (Region of Interest, ROI), abdominal BT görüntülerinde tanı açısından kritik bilgileri barındıran pelvik ve abdominal bölgeyi temsil edecek şekilde belirlenmiştir. Ham BT kesitleri, geniş görüş alanı (field of view) nedeniyle tanısal açıdan önemsiz arka plan bölgeleri içerebildiğinden, doğrudan modele verilmesi öğrenme sürecini olumsuz etkileyebilmektedir. Bu nedenle, modelin dikkatini anatomik olarak anlamlı bölgelere yönlendirmek amacıyla ROI tabanlı bir ön işleme adımı uygulanmıştır. ROI tespiti aşamasında, öncelikle görüntülerde hasta anatomisini içeren merkezi bölge hedeflenmiş, masa, hava boşlukları ve tanısal olmayan periferik alanlar dışlanmıştır. Bu işlem, görüntü koordinatları üzerinde önceden tanımlanan sınırlar doğrultusunda kırpma (cropping) uygulanarak gerçekleştirilmiştir. Böylece yalnızca ilgili anatomik yapıları içeren bölge korunmuş, gürültü ve gereksiz piksel bilgisi önemli ölçüde azaltılmıştır. Bu yaklaşım,

özellikle derin öğrenme tabanlı modellerde hesaplama yükünü azaltırken, modelin ayırt edici özelliklere odaklanmasını kolaylaştırmaktadır [42].

3.3.4. Geometrik standardizasyon

Kırpma işleminden sonra elde edilen ilgilenilen bölge (Region of Interest, ROI) görüntüleri, modelin giriş gereksinimlerine uyması amacıyla 512x512 piksel çözünürlüğe yeniden boyutlandırılmıştır. Bu yeniden boyutlandırma işlemi, görüntü kalitesini maksimum düzeyde korumayı hedefler. Yeniden örnekleme algoritması olarak bikübik interpolasyon yöntemi kullanılmıştır. Bu yöntem, çevredeki pikselleri kullanarak yumuşak ve sürekli bir yüzey eğrisi oluşturarak piksel değerlerini ve görüntüdeki ince detayları korur. Bu süreç, pelvik bölgeyi maksimum düzeyde ön plana çıkarırken, görüntünün geometrik bütünlüğünü ve tanısal önem taşıyan morfolojik özelliklerini koruyarak sonraki aşamalarda verimli model eğitimi ve doğru tespiti için sağlam bir temel oluşturmaktadır [43].



Şekil 3.6. Görüntü ön işleme adımları

3.4. YOLOv11

Bu çalışmada, karın bölgesi acil patolojilerinin tespiti ve sınıflandırılması amacıyla, Ultralytics tarafından geliştirilen YOLOv11 (You Only Look Once - Version 11) mimarisi kullanılmıştır. YOLOv11 modeli [44], Ultralytics ekibi tarafından geliştirilmiştir. Literatürdeki en güncel gerçek zamanlı nesne tespit mimarilerinden biridir. Tek bir ağ üzerinden hem sınıflandırma hem de sınırlayıcı kutu kestirimi yapabilen çok görevli (multi-task) yapısıyla nesne tespit problemleri için tasarlanmıştır.


YOLOv11, geleneksel nesne algılamanın ötesinde geniş bir yelpazedeki bilgisayarlı görü görevlerini destekleyen çok yönlü bir araçtır. YOLOv11; nesne algılama, örnek

segmentasyonu, duruş tahmini, yönlendirilmiş nesne algılama (OBB), görüntü sınıflandırma ve nesne takibi gibi temel bilgisayarlı görü görevlerini desteklemektedir [45].

YOLOv11, mimari iyileştirmeleri ve aerodinamik eğitim süreçleri aracılığıyla daha hızlı işlem hızları elde ederken doğruluk ve hesaplama verimliliği arasında bir dengeyi korur. Kıyaslama analizlerinde, YOLOv11 varyantları, COCO veri setinde üstün puanları elde ederken daha hızlı bir çıkarım hızını koruyarak önceki modelleri tutarlı bir şekilde geride bırakmıştır. Ayrıca, verimlilik açısından, YOLOv11m varyantı, YOLOv8m muadilinden %22 daha az parametre kullanırken üstün ortalama hassasiyet (mAP) puanları elde etmiştir. Modelin azaltılmış parametre sayısı, genel doğruluğu önemli ölçüde etkilemeden daha hızlı model performansına katkıda bulunur. Model, nano'dan ekstra büyük boyutlara kadar uzanan farklı model boyutlarında mevcut olup, kaynak kısıtlı uç cihazlardan yüksek performanslı bilgi işlem ortamlarına kadar çeşitli uygulama ihtiyaçlarına cevap verebilen bir ölçeklenebilirlik sunmaktadır. YOLOv11 ailesi, genel performansta tutarlı bir şekilde en iyiler arasında sıralanmıştır [46]. Bu tez çalışmasında en az parametreye ve düşük hesaplama karmaşıklığına sahip olması nedeniyle YOLOv11'in nano sürümü temel model olarak seçilmiştir. Bu özellikleri sayesinde YOLOv11n, kaynak kısıtlı ortamlarda kullanım için oldukça uygun olup, görece yüksek bir tespit verimliliğini korumaktadır [47].

YOLOv11'in bu evrimsel gelişimi, YOLOv3'ten en son YOLOv12'ye kadar olan sürümleri kapsayan kapsamlı bir karşılaştırmalı değerlendirme çalışmasının bir parçası olarak incelenmiştir [48]. Bu çalışmalar, değişen nesne boyutları, farklı en-boy oranları ve küçük nesne tespiti gibi çeşitli zorluk senaryolarında performansı; hassasiyet (kesinlik), geri çağırma (duyarlılık), ortalama hassasiyet (mAP), işlem süresi, işlem karmaşıklığı (GFLOPs) ve model boyutu gibi metrikler üzerinden değerlendirmektedir. Bu kıyaslama çalışmasında, YOLOv11 ailesi, doğruluk ve GFLOPs sayısı açısından birinci sırada yer alarak ve hız ve boyut açısından da en üst sıralarda bulunarak en dengeli model ailesi olarak ortaya çıkmıştır. Genel olarak, YOLOv11 ailesi, YOLOv3, YOLOv5, YOLOv8, YOLOv9 ve YOLOv10 ailelerinden olan muadillerini, değişen boyutlardaki nesnelerin tespitinde hassasiyet ve hız etkili bir şekilde dengeleme yetenekleri açısından önemli ölçüde geride bırakmıştır. YOLOv11'in bu başarısı, daha iyi özellik çıkarma, çıkarım hızı ve doğruluk sunarak YOLOv8'e üstün bir alternatif olarak ortaya çıkmasını sağlamış ve hız ve hassasiyet gerektiren gerçek dünya uygulamaları için ideal bir model olarak yeni bir referans noktası belirlemiştir. Özellikle, YOLOv11 ailesi küçük ve minik nesnelerin tespitinde YOLO ailesinin performansını artırmada ve verimli işlemeyi sağlamada güvenilirliğini ve

sağlamlığını kanıtlamıştır [48]. Bu modelin çok görevli yapısı ve küçük nesne tespitindeki başarımı, abdominal BT görüntülerinde yer alan küçük ve düşük kontrastlı patolojik bulguların tespiti açısından bu çalışma için uygun bir temel oluşturmıştır.



Şekil 3.7. YOLO 11 mimarisi [49]


YOLO mimarisinin temelinde bir omurga (backbone), bir boyun (neck) ve bir kafa (head) bileşeni bulunur. YOLOv11'in omurga yapısı, görüntüden yüksek seviyeli öznetelikleri çıkarmak için optimize edilmiştir. Derin katmanlardan elde edilen anlamsal bilgi ile sığ katmanlardaki doku ve kenar bilgisi, özellikle küçük ve düşük kontrastlı patolojik yapıların temsil edilmesine katkı sunmaktadır [45].

YOLOv11'in boyun kısmı, farklı çözünürlüklerdeki öznetelikleri birleştirerek kafa katmanına aktarır. Bu çok ölçekli birleştirme süreci, küçük patolojik bulguların farklı derinlik seviyelerinde tutarlı biçimde temsil edilmesine olanak tanımaktadır [45].

Kafa bileşeni, rafine edilmiş özellik haritalarına dayanarak nesne lokalizasyonu ve sınıflandırması için nihai çıktıları üreten tahmin mekanizmasıdır. Bu katman, tespit

işleminin gerçekleştiği kısımdır. Bu bölümde, çapasız yaklaşım kullanılmaktadır. Tahmin aşamasında görüntü grid adı verilen hücrelere bölünür ve her grid hücresi, nesnenin merkezine, boyutuna ve sınıfına ait tahminleri doğrudan üretir [50]. Bu yapı, önceki YOLO sürümlerine göre hem eğitim süresini kısaltır hem de küçük nesnelerdeki konum hatalarını azaltır. Çıkış katmanında sigmoid aktivasyon fonksiyonu kullanılarak koordinatlar normalize edilir. Ayrıca, kayıp fonksiyonu olarak Complete IoU (CIoU) veya Generalized IoU (GIoU) tercih edilmektedir [46].

YOLOv11, özellikle YOLOv8'in temelleri üzerine inşa edilmiş ve gelişmiş algılama performansı elde etmek için mimari yenilikler ve parametre optimizasyonları getirmiştir. YOLOv11'deki temel mimari geliştirmeler, modelin özellik çıkarma yeteneklerini geliştiren yeni blokların eklenmesini içerir [45].



Şekil 3.8. YOLOv11 mimarisinde kullanılan temel yapı taşları [45]

YOLOv11 mimarisinde önceki sürümlere kıyasla yapılan başlıca yapısal yenilikler; daha verimli evrişim bloklarının kullanılması, dikkat mekanizmalarının mimariye entegre edilmesi ve çok ölçekli öznitelik birleştirme yapısının optimize edilmesidir. Bu kapsamda, önceki sürümlerde kullanılan C2f bloğu yerine C3k2 bloğu tercih edilmiştir. CSP tabanlı bu yapı, iki küçük evrişim katmanı kullanarak hesaplama maliyetini azaltırken temsil gücünü korumayı hedeflemektedir. Bu sayede model, daha az parametre ile benzer veya daha iyi performans sunabilmektedir [45].

Buna ek olarak, SPPF bloğundan sonra konumlandırılan C2PSA (Parallel Spatial Attention) yapısı, öznelilik haritaları üzerinde uzamsal dikkat mekanizmasını güçlendirerek modelin görüntü içerisindeki ayırt edici bölgelere odaklanmasını sağlamaktadır. SPPF bloğu ise önceki sürümlerde olduğu gibi korunarak çok ölçekli bağlam bilgisinin birleştirilmesine katkı sunmaktadır [46].

Son olarak, YOLOv11 çapasız (anchor-free) ve ayırık (decoupled) tespit kafası yapısını benimsemektedir. Bu yaklaşım, önceden tanımlanmış çapa kutularına olan ihtiyacı ortadan kaldırarak parametre sayısını azaltmakta ve çıkarım hızını artırmaktadır. Sınıflandırma ve konum regresyonu işlemlerinin ayırık katmanlarda ele alınması, bu iki görevin birbirini olumsuz etkilemeden öğrenilmesini sağlamaktadır.

3.5. Dikkat Mekanizmaları

Derin öğrenme tabanlı nesne tespiti modellerinde dikkat mekanizmaları, ağın hangi özelliklere odaklanması gerektiğini öğrenmesini sağlayarak hem temsil gücünü hem de genelleme kabiliyetini artırmayı amaçlamaktadır. Abdominal BT görüntülerinde patolojiler lokal yoğunluk farkları ve çevre dokularla bağlamsal ve uzamsal ilişkileriyle ayırt edildiğinden, dikkat mekanizmaları model performansında kritik rol oynamaktadır [51]. Bu çalışmada, farklı seviyelerde etki gösteren Verimli Çok Ölçekli Dikkat Mekanizması (Efficient Multi-scale Attention, EMA), Basit Parametresiz Dikkat Mekanizması (Simple, Parameter-Free Attention Module, SimAM) ve Koordinat Dikkati (Coordinate Attention, CA) yaklaşımları ele alınmıştır.

3.5.1. Verimli çok ölçekli dikkat mekanizması (efficient multi-scale attention, EMA)

EMA mekanizması, giriş özellik haritası $X \in \mathbb{R}^{(C \times H \times W)}$ üzerindeki uzamsal ve kanal bazlı bağımlılıkları verimli bir şekilde yakalamayı amaçlar. Burada C , H ve W sırasıyla kanal sayısını, yüksekliği ve genişliği temsil etmektedir. Mekanizma, yönlü uzamsal bilgiyi ayrıştırmak ve küresel bağlamı korumak amacıyla paralel özetleme yolları kullanır. Her bir c . kanalda (i, j) konumundaki piksel değeri $x_c(i, j)$ ile gösterilir. Kanal c için yatay doğrultudaki (yükseklik eksenini boyunca) uzamsal dağılım, her satır üzerindeki piksellerin ortalaması alınarak kodlanır. Bu işlem, özellik haritasının yatay yöndeki küresel bağlamını temsil eden bir özet vektör üretir ve Eş. 3.2'deki gibi tanımlanır.

$$z_c^h(h) = \frac{1}{W} \sum_{i=1}^W x_c(h, i), \quad (3.2)$$


Benzer şekilde, kanal c için dikey doğrultudaki (genişlik eksenini boyunca) uzamsal dağılım, her sütun üzerindeki piksellerin ortalaması alınarak elde edilir. Bu temsil, dikey yöndeki uzamsal bağımlılıkları ve konumsal varyasyonları yakalamaya yardımcı olur (Eş. 3.3).

$$z_c^w(w) = \frac{1}{H} \sum_{j=1}^H x_c(j, w) \quad (3.3)$$

Yatay ve dikey eksenler boyunca elde edilen bu iki çıkarım, EMA'nın yön bağımlı uzamsal bilgiyi ayrıştırarak modellemesini sağlar. Bunun yanı sıra, kanal c için tüm uzamsal bölgeyi kapsayan küresel bağlam bilgisini elde etmek amacıyla iki boyutlu global ortalama havuzlama uygulanır. Bu işlem, özellik haritasındaki tüm piksellerin ortalamasını alarak kanal bazlı tek bir küresel temsil üretir (Eş. 3.4).

$$\bar{z}_c = \frac{1}{H \times W} \sum_{j=1}^H \sum_{i=1}^W x_c(i, j) \quad (3.4)$$

Yatay (z_c^h), dikey (z_c^w) ve iki boyutlu küresel (z_c) özet temsillerin birlikte kullanılması, EMA modülünün hem yönlü uzamsal bağımlılıkları hem de tüm görüntüye ait küresel bağlamı eş zamanlı olarak dikkate almasını sağlar [52]. Bu yaklaşım sayesinde, arka plan gürültüsünün baskılanması ve patolojik yapıların bulunduğu bölgelerin daha belirgin hale getirilmesi amaçlanmaktadır. Şekil 3.9'da EMA dikkat mekanizmasının şematik gösterimi verilmiştir.



Şekil 3.9. EMA dikkat mekanizmasının şematik gösterimi [52]

3.5.2. Basit parametresiz dikkat mekanizması (simple, parameter-free attention module, SIMAM)

SimAM, öğrenilebilir parametre içermeyen ve hem uzamsal hem de kanal boyutlarında aynı anda dikkat ağırlıkları üreten bir dikkat modülüdür [53]. İnsan görsel sistemindeki "uzamsal baskılama" olgusundan esinlenerek, bir özellik haritasındaki her bir nöronun (piksel) çevresine kıyasla ne kadar ayırt edici olduğunu ölçer.

Mekanizma, her bir nöron için bir enerji fonksiyonu tanımlar. Bu fonksiyon, hedef nöron ile aynı kanaldaki diğer nöronlar arasındaki doğrusal ayrılabilirliği ölçmeyi amaçlar. İkili etiketler (hedef nöron için +1, diğerleri için -1) ve bir düzenleme terimi kullanılarak enerji fonksiyonu aşağıdaki gibi formüle edilmiştir: (Eş. 3.5)

$$e_t(w_t, b_t, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} (-1 - (w_t x_i + b_t))^2 + (1 - (w_t t + b_t))^2 + \lambda w_t^2 \quad (3.5)$$

Burada t hedef nöronu, x_i aynı kanaldaki diğer nöronları, w_t ve b_t doğrusal dönüşüm parametrelerini, M kanaldaki toplam nöron sayısını ($H \times W$), λ ise düzenleştirme katsayısını temsil eder. Bu enerji fonksiyonunun minimizasyonu kapalı bir form çözümüne sahiptir. Tüm nöronların aynı dağılımdan geldiği varsayımıyla, kanal genelindeki ortalama ($\hat{\mu}$) ve varyans ($\hat{\sigma}^2$) kullanılarak her bir t nöronu için minimum enerji değeri aşağıdaki gibi hesaplanabilir: (Eş. 3.6).


$$e_t^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (3.6)$$

Bu ifadede, paydanın büyük olması (nöronun ortalamadan uzak ve/veya varyansın yüksek olması) enerjiyi düşürür. Düşük e_t^* değeri, o nöronun daha ayırt edici ve önemli olduğunu gösterir.

Nörobilimdeki dikkat temelli ölçeklendirme etkisine dayanarak, bu enerjilerin tersi bir sigmoid fonksiyonundan geçirilerek $[0,1]$ aralığında dikkat ağırlıklarına dönüştürülür. Bu ağırlıklar, orijinal özellik haritası X ile çarpılarak iyileştirilmiş çıktı elde edilir: (Eş. 3.7)

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (3.7)$$

Burada E , tüm nöronlar için hesaplanan e_t^* değerlerini içeren 3B tensördür ve $\odot$ eleman bazında çarpımı ifade eder [53]. Şekil 3.10.'da SimAM dikkat mekanizmasının şematik gösterimi verilmiştir.



Şekil 3.10. SimAM dikkat mekanizmasının şematik gösterimi [53]

3.5.3. Koordinat dikkat mekanizması (coordinate attention, CA)

CA mekanizması, kanal dikkat mekanizmalarında yaygın olan iki boyutlu global ortalama havuzlamanın uzamsal konum bilgisini kaybetmesi sorununa çözüm olarak geliştirilmiş; yön duyarlı ve konum bilinçli bir dikkat modülüdür [54].

CA mekanizmasında giriş özellik haritası Eş.3.8'deki gibi tanımlanır. Burada C kanal sayısını, H özellik haritasının yüksekliğini ve W ise genişliğini ifade eder.

$$X \in \mathbb{R}^{C \times H \times W} \quad (3.8)$$

Kanal bazında ele alınır ve uzamsal bilgi, yükseklik ve genişlik eksenlerinde ayrı ayrı uygulanan bir boyutlu global ortalama havuzlama işlemleri ile kodlanır. Kanal c için yükseklik doğrultusunda (yatay eksen boyunca) elde edilen özet temsil şu şekilde tanımlanır. Burada $x_c(h, i)$, c kanalda (h, i) konumundaki piksel değeridir ve $z_c^h(h)$, h satır boyunca genişlik üzerinden alınan ortalamayı temsil eder (Eş. 3.9).

$$z_c^h(h) = \frac{1}{W} \sum_{i=1}^W x_c(h, i), \quad (3.9)$$

Benzer biçimde, genişlik doğrultusunda (dikey eksen boyunca) elde edilen özet temsil Eş. 3.10'daki gibi tanımlanır. Burada $z_c^w(w)$, w sütun boyunca yükseklik üzerinden alınan ortalamayı gösterir


$$z_c^w(w) = \frac{1}{H} \sum_{j=1}^H x_c(j, w) \quad (3.10)$$

Bu iki özet temsil, özellik haritasındaki bilgiyi yatay ve dikey uzamsal yönler boyunca ayrı ayrı kodlayarak, patolojik yapıların görüntü içerisindeki konum bilgisinin korunmasını sağlar.

Elde edilen yatay (z_c^h) ve dikey (z_c^w) temsiller, öğrenilebilir doğrusal dönüşümlerden geçirilerek kanal bazlı dikkat ağırlıkları g_c^h ve g_c^w üretilir. Son aşamada, giriş özellik haritası bu iki yönlü dikkat ağırlığı ile yeniden ölçeklendirilerek çıktı özellik haritası elde edilir (Eş. 3.11).

$$y_c(i, j) = x_c(i, j) \cdot g_c^h(i) \cdot g_c^w(j) \quad (3.11)$$

Bu yapı, CA'nın uzun menzilli bağımlılıkları yakalarken kesin konum bilgisini korumasını sağlar. Özellikle anatomik konumun kritik olduğu tıbbi görüntü analizi gibi görevlerde, nesnelerin hem kanal ilişkilerini hem de uzamsal yerleşimini aynı anda modelleyerek daha ayırt edici temsiller sunar. Şekil 3.11.'da CA dikkat mekanizmasının şematik gösterimi verilmiştir.



Şekil 3.11. CA dikkat mekanizmasının şematik gösterimi [54]

3.5.4. Kayıp fonksiyonları

Bu bölümde nesne tespiti ve sınıflandırma problemlerinde kullanılan kayıp fonksiyonları tanıtılmıştır. Bu kayıplar, tahmin edilen sınırlayıcı kutunun gerçek konumla ne kadar iyi eşleştiğini ölçer.

Bu çalışmada, YOLOv11 mimarisinin çok bileşenli kayıp fonksiyonu yapısı kullanılmıştır. Model eğitimi sırasında sınırlayıcı kutu regresyonu ve sınıflandırma görevleri eş zamanlı olarak optimize edilmektedir. Sınırlayıcı kutu regresyonunda Complete Intersection over Union (CIoU) kaybı tercih edilmiştir. CIoU, tahmin edilen ve gerçek sınırlayıcı kutular arasındaki örtüşme oranına ek olarak, kutu merkezleri arasındaki öklidyen uzaklığı ve en-

boy oranı uyumsuzluğunu da dikkate alarak konum, ölçek ve şekil uyumunu birlikte optimize etmektedir. Bu özellik, özellikle küçük ve düzensiz şekilli nesnelerin yer aldığı tıbbi görüntülerde daha kararlı ve hızlı yakınsama sağlamaktadır [55].

Buna ek olarak, sınırlayıcı kutu kenarlarının daha hassas tahmin edilebilmesi amacıyla Distribution Focal Loss (DFL) kullanılmıştır. DFL yaklaşımı, kutu koordinatlarını doğrudan tek bir değer olarak tahmin etmek yerine, bunları ayrık bir olasılık dağılımı üzerinden modelleyerek özellikle küçük nesnelerde ve düşük kontrastlı bölgelerde konum doğruluğunu artırmaktadır. Bu yöntem, modern YOLO mimarilerinde (YOLOv8 ve sonrası) standart hâle gelmiş olup, bounding box regresyon performansına önemli katkı sağlamaktadır [56].

Sınıflandırma görevinde ise her bir tahminin ilgili sınıfa ait olma olasılığı Binary Cross Entropy (BCE) tabanlı sınıflandırma kaybı ile optimize edilmiştir. YOLO11 mimarisinde sınıflandırma tarafında Focal Loss kullanılmamakta, bunun yerine DFL ile desteklenen hassas konum tahmini ve dengeli örnekleme stratejileriyle sınıf dengesizliğinin etkisi dolaylı olarak azaltılmaktadır.

Model performansının değerlendirilmesinde ise bir tahminin doğru kabul edilmesi, tahmin kutusu ile gerçek kutu arasındaki IoU değerinin belirli bir eşiği aşmasına dayanır. Bu temelde, Ortalama Kesinlik Değeri (Average Precision) belirli bir IoU eşiğinde ilgili sınıf için kesinlik-duyarlılık eğrisi altındaki alanı ölçer. Genel Ortalama kesinlik değeri (Mean average precision) ise tüm sınıflar için hesaplanan AP değerlerinin ortalamasıdır. COCO gibi protokollerde 0.50'den 0.95'e kadar farklı IoU eşiklerinde AP ortalaması alınarak daha kapsamlı bir değerlendirme yapılır [57].

Bu çalışmada kullanılan CIOU + DFL + BCE bileşenlerinden oluşan kayıp fonksiyonu yapısı, sınıf dağılımı dengesizliği ve küçük lezyon tespiti gibi abdominal BT görüntülerine özgü zorluklar göz önünde bulundurularak tercih edilmiştir.

3.5.5. Optimizasyon algoritmaları

Derin öğrenme modellerinin eğitimi sırasında, modelin başarımı büyük ölçüde seçilen optimizasyon algoritmasına bağlıdır. Bu bağlamda gradyan iniş (gradient descent), kayıp (hata) fonksiyonunu minimize etmek amacıyla model parametrelerinin, kayıp

fonksiyonunun gradyanının ters yönünde iteratif olarak güncellenmesine dayanan en temel yaklaşımdır. Uygulamada gradyan iniş; tüm veri kümesi kullanılarak güncelleme yapılan Batch Gradient Descent (BGD), her adımda tek bir örnek ile güncelleme yapan Stochastic Gradient Descent (SGD) ve küçük örnek gruplarıyla güncelleme yapan Mini-batch Gradient Descent (Mini-Batch GD) biçimlerinde uygulanır; bu yöntemler arasındaki temel fark, her parametre güncellemesinde kullanılan veri miktarıdır [58].

Bununla birlikte, temel gradyan iniş yöntemleri her problemde yeterince hızlı ve kararlı yakınsama sağlayamayabilir. Bu nedenle öğrenme sürecini hızlandırmak, salınımları azaltmak ve farklı ölçeklerdeki parametreler için daha dengeli güncellemeler yapmak amacıyla çeşitli optimizasyon algoritmaları geliştirilmiştir. Örneğin Momentum, gradyanların üstel ağırlıklı ortalamasını kullanarak güncellemeleri atalet etkisiyle hızlandırır ve özellikle dar vadilerdeki zikzak hareketlerini azaltır. Nesterov hızlandırılmış gradyan (NAG), bir sonraki adımı öngörerek gradyanı ileriden hesaplar ve bu sayede daha kontrollü bir yakınsama sağlayabilir. AdaGrad, her parametre için geçmiş gradyanlara bağlı olarak öğrenme oranını uyarlayarak seyrek özelliklerde avantaj sağlayabilir; ancak zamanla öğrenme oranlarının aşırı küçülmesi nedeniyle RMSProp bu sorunu üstel hareketli ortalama ile dengeler. Adam ise Momentum ve RMSProp yaklaşımlarını birleştirerek hem birinci moment (ortalama) hem ikinci moment (varyans) tahminleri üzerinden adaptif bir güncelleme yapar; bu nedenle pratikte geniş bir problem sınıfında güçlü ve yaygın bir varsayılan seçenek olarak kullanılır. Optimizasyon sürecini desteklemek için erken durdurma (early stopping), veri sırasının her epokta yeniden düzenlenmesi (shuffling), batch normalization gibi yöntemler ve bazı senaryolarda gradyana kontrollü gürültü eklenmesi gibi stratejiler de uygulanabilir. Büyük ölçekli veri kümelerinde ve dağıtık eğitim senaryolarında ise Hogwild!, Downpour SGD ve Elastic Averaging SGD gibi paralel/dağıtık SGD türevleri, eğitim süresini kısaltmaya yönelik yaklaşımlar olarak değerlendirilebilir. Sonuç olarak, en uygun optimizasyon algoritması seçimi; veri kümesinin yapısına, model mimarisine, hesaplama kısıtlarına ve hedeflenen yakınsama davranışına bağlıdır. Adam ve benzeri adaptif yöntemler birçok senaryoda güçlü bir başlangıç noktası sunarken, bazı problemlerde SGD tabanlı yöntemlerin daha iyi genelleme performansı sağlayabileceği de dikkate alınmalıdır [58].

Bu tez çalışmasında, YOLO11 tabanlı modelin eğitiminde SGD optimizasyon algoritması kullanılmıştır. SGD, uygun öğrenme oranı planlaması ile birlikte kullanıldığında, adaptif

yöntemlere kıyasla daha güçlü bir genelleme performansı sunabilmekte ve modelin eğitim verisine aşırı uyum göstermesini azaltabilmektedir. Ayrıca momentum terimi, gradyan yönündeki salınımları azaltarak daha kararlı bir yakınsama sağlamaktadır. Bu nedenlerle, sınıf dağılımı dengesizliği ve küçük örneklem kaynaklı aşırı uyum riskinin bulunduğu abdominal hastalık tespiti probleminde, daha dengeli ve genellenebilir bir model eğitimi elde etmek amacıyla SGD tercih edilmiştir.

3.5.6. Epok, küme boyutu ve öğrenme oranı

Derin öğrenme modellerinin eğitim sürecinde, epok, küme (batch) boyutu ve öğrenme oranı birbiriyle ilişkili üç temel kavramdır ve optimizasyonun davranışını doğrudan etkiler.

Epok, eğitim verisinin tamamının ağa bir kez gösterilmesini ifade eder. Eğitim sırasında genellikle birden fazla epok kullanılır ve her epok başında verinin karıştırılması (shuffling), modelin veri sırasından etkilenmesini azaltarak daha sağlıklı bir öğrenme süreci sağlar. Bazı durumlarda ise örneklerin zorluk seviyesine göre sıralandığı “curriculum learning” yaklaşımlarıyla epok yapısı bilinçli olarak düzenlenebilir.

Küme boyutu (batch / mini-batch size), her parametre güncellemesinde kaç örneğin birlikte kullanıldığını belirler. Tüm veri kümesinin kullanıldığı durumda “batch gradyan inişi”, tek bir örneğin kullanıldığı durumda “SGD”, aradaki durumda ise “mini-batch” yaklaşımından söz edilir. Mini-batch yönteminde, küçük kümeler üzerinden güncelleme yaparak hem hesaplama verimliliği artar hem de güncellemelerdeki rastgelelik (varyans) bir miktar azalır. Uygulamada yaygın mini-batch boyutlarının 50–256 aralığında seçildiği ifade edilmektedir.

Öğrenme oranı (learning rate), her güncellemede gradyan yönünde ne kadar büyük adım atılacağını belirleyen en kritik hiperparametrelerden biridir. Çok küçük bir öğrenme oranı, modelin parametrelerini çok yavaş güncellemesine ve yakınsamanın yavaş olmasına yol açarken; çok büyük bir öğrenme oranı, kayıp fonksiyonunun minimum çevresinde dalgalanmasına veya tamamen ıraksamasına neden olabilir. Bu nedenle, zamanla kademeli olarak azaltılan öğrenme oranı çizelgeleri sıkça kullanılır; ancak bu çizelgelerin ve eşik değerlerinin önceden belirlenmesi gerekir ve veri kümesinin özelliklerine kendiliğinden uyum sağlayamaz.

Sonuç olarak, epok sayısı, küme boyutu ve öğrenme oranı birlikte ele alındığında, modelin ne kadar hızlı, ne kadar kararlı ve ne düzeyde genelleyci bir çözüm bulacağını belirleyen temel eğitim ayarlarını oluşturur [58].

Bu tez çalışmasında, YOLO11 tabanlı modelin eğitimi 100 epok boyunca gerçekleştirilmiştir. Epok sayısı, modelin veri setindeki örüntüleri yeterli düzeyde öğrenebilmesini sağlarken aşırı uyum (overfitting) riskini artırmayacak şekilde belirlenmiştir. Eğitim sürecinde mini-toplu gradyan inişi kullanılmış ve küme (batch) boyutu 8 olarak ayarlanmıştır. Küçük batch boyutu ise hem donanım kısıtları hem de tıbbi görüntü veri setlerindeki sınırlı örnek sayısı dikkate alınarak seçilmiştir. Bu hiperparametre kombinasyonu, sınıf dengesizliği ve küçük boyutlu patolojilerin bulunduğu abdominal hastalık tespiti probleminde dengeli ve kararlı bir eğitim süreci sağlamıştır.

Optimizasyon sırasında başlangıç öğrenme oranı (learning rate) 0,01 olarak belirlenmiş, eğitim ilerledikçe daha kararlı bir yakınsama elde edebilmek amacıyla öğrenme oranının etkisi kontrollü biçimde azaltılmıştır. Bu hiperparametre ayarları, sınıf dağılımı dengesizliği ve sınırlı örnek sayısının bulunduğu tıbbi görüntü veri setlerinde genellenebilir bir model eğitimi sağlamak amacıyla tercih edilmiştir.

Tüm model eğitimleri ve deneyler, Google Colab platformu üzerinde gerçekleştirilmiştir. Deneylerde, NVIDIA T4 GPU ile hızlandırılmış bir çalışma ortamı kullanılmıştır. Bu donanım, YOLOv11 tabanlı modellerin eğitimi ve çoklu dikkat mekanizmalarının entegrasyonu için gerekli hesaplama kapasitesini sağlamıştır. Deneysel ortamın tekrarlanabilirliğini sağlamak amacıyla Python 3.10, PyTorch 2.1 ve Ultralytics YOLO kütüphanesi kullanılmıştır.

3.6. Model Performansının Değerlendirilmesi

Bu çalışmada modelin sınıflandırma başarısını değerlendirmek ve elde edilen sonuçları detaylı bir şekilde yorumlamak amacıyla Karmaşıklık Matrisi yöntemi kullanılmıştır. Karmaşıklık Matrisi, makine öğrenimi ve sınıflandırma modellerinin performansını değerlendirmek için kullanılan temel bir araçtır [59]. Model tahminlerinin gerçek sınıflarla karşılaştırmasını yapılandırılmış bir özet hâlinde sunar. Bu matris, yalnızca doğru tahminleri değil, aynı zamanda yanlış sınıflandırmaların niteliğini de yakalayarak Hassasiyet

(Kesinlik), Geri Çağırma (Duyarlılık), F1-skoru ve Doğruluk (Accuracy) gibi geniş bir performans metriği yelpazesinin temelini oluşturur.

3.6.1. Temel bileşenlerin tanımı

İkili (Binary) veya çoklu sınıflandırma senaryolarında, her veri örneği (örneğin pozitif/negatif) tahmin edilen sınıf ile gerçek sınıfın karşılaştırılmasıyla aşağıdaki dört karşılıklı özel ve toplu olarak kapsamlı bölgeye ayrılır:

- Gerçek Pozitif (TP - True Positive): Modelin, pozitif sınıfına ait bir örneği doğru bir şekilde pozitif olarak tahmin etmesidir. Doğru sınıflandırılmış pozitif sınıfı sayısını ifade eder.
- Gerçek Negatif (TN - True Negative): Modelin, negatif sınıfına ait bir örneği doğru bir şekilde negatif olarak tahmin etmesidir. Doğru sınıflandırılmış negatif sınıf sayısını ifade eder.
- Yanlış Pozitif (FP - False Positive): Modelin, negatif sınıfa ait bir örneği yanlış bir şekilde pozitif olarak tahmin etmesidir (Yanlış Alarm). Yanlış sınıflandırılmış pozitif sınıf sayısını ifade eder.
- Yanlış Negatif (FN - False Negative): Modelin, pozitif sınıfa ait bir örneği yanlış bir şekilde negatif olarak tahmin etmesidir (Gözden Kaçırma). Yanlış sınıflandırılan negatif sınıf sayısını ifade eder [59].

Doğruluk ve Performans Metrikleri (TP–TN–FP–FN’ye göre) Bu dört durum (TP, TN, FP, FN) üzerinden ikili sınıflandırma performansı nicel olarak ölçülebilir.

Doğruluk (Accuracy): Modelin tüm örnekler içinde doğru tahmin ettiği örneklerin oranıdır (Eş. 3.12).

$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN) \quad (3.12)$$

Ancak sınıf dengesizliğinin olduğu durumlarda (örneğin pozitif sınıf örneklerinin az olduğu veri setleri) doğruluk değeri tek başına yanıltıcı olabilmektedir. Bu nedenle, özellikle pozitif sınıfa ait örnekleri doğru yakalama ve yanlış alarmları kontrol etme açısından kesinlik ve duyarlılık gibi ölçütler sıklıkla kullanılır.

Kesinlik: Modelin pozitif tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu gösterir (Eş. 3.13).

$$\text{Kesinlik} = TP / (TP + FP) \quad (3.13)$$

Duyarlılık: Gerçek pozitif örneklerin ne kadarının model tarafından doğru biçimde yakalandığını ifade eder (Eş. 3.14).

$$\text{Duyarlılık} = TP / (TP + FN) \quad (3.14)$$

Duyarlılık, özellikle tıbbi uygulamalarda “gözden kaçırma” (FN) maliyetinin yüksek olduğu senaryolarda kritik öneme sahiptir.

Özgüllük (Specificity): Modelin negatif örnekleri doğru belirleme başarısını ölçer (Eş. 3.15).

$$\text{Özgüllük} = TN / (TN + FP) \quad (3.15)$$

F1 Skoru (F1-Score): Kesinlik ve duyarlılık arasında dengeyi tek bir değerle özetlemek amacıyla kullanılır; kesinlik ve duyarlılık’un harmonik ortalamasıdır (Eş. 3.16).

$$\text{F1 Skoru} = (2 * \text{Kesinlik} * \text{Duyarlılık}) / (\text{Kesinlik} + \text{Duyarlılık}) \quad (3.16)$$

Bu metrikler birlikte değerlendirildiğinde, modelin yalnızca genel doğruluğu değil; aynı zamanda yanlış alarm (FP) üretme eğilimi ve pozitif örnekleri kaçırma (FN) riski de daha kapsamlı biçimde analiz edilebilmektedir [59].

Bu çalışmada, model tahminleri ile uzman radyologlar tarafından oluşturulan gerçek (ground truth) anotasyonlar arasındaki uyum, aşağıda tanımlanan ve literatürde yaygın kabul gören metrikler kullanılarak kapsamlı bir şekilde ölçülmüştür. Modelin performans değerlendirmesi için kesinlik, duyarlılık, mAP metrikleri kullanılmıştır.


3.7. Geliştirilen Nesne Tespit Modeli

Bu tez çalışmasında, karın BT görüntülerinde çok sınıflı patoloji tespiti problemi için YOLOv11 tabanlı bir nesne tespit modeli geliştirilmiştir. Seçilen temel mimari, tek aşamalı

yapısı sayesinde yüksek çıkarım hızı sunarken, çok ölçekli özellik çıkarımı sayesinde farklı boyutlardaki patolojik yapıların tespitine olanak sağlamaktadır. Bununla birlikte, abdominal BT görüntülerinde yer alan patolojilerin boyut, kontrast ve görsel belirginlik açısından önemli farklılıklar göstermesi, temel mimarinin doğrudan kullanımında bazı sınırlamaları beraberinde getirmektedir.


Bu doğrultuda, kullanılan model yalnızca standart YOLOv11 mimarisiyle sınırlı tutulmamış; hata bazlı analizler ve hasta bazlı test sonuçları ışığında mimari düzeyde çeşitli iyileştirmeler yapılmıştır. Özellikle küçük ve düşük kontrastlı patolojiler (örneğin böbrek/üreter taşları) ile daha geniş ve belirgin anatomik yapılar (örneğin abdominal aort anevrizması/diseksiyonu) arasında farklı temsil ihtiyaçları olduğu göz önünde bulundurularak, modelin özellik çıkarım kapasitesini artırmaya yönelik düzenlemeler gerçekleştirilmiştir.

Geliştirilen modelin omurgası, YOLOv11 mimarisinde yer alan C3k2 blokları temel alınarak yapılandırılmıştır. Bu bloklar, hesaplama maliyetini sınırlı tutarken yeterli temsil gücü sağlaması nedeniyle tercih edilmiştir. Ancak hasta bazlı deneylerde elde edilen sonuçlar, bazı sınıflarda modelin yerel detayları yeterince vurgulayamadığını ve sınıf bazlı kaçırma (false negative) hatalarının arttığını göstermiştir. Bu bulgular doğrultusunda, dikkat mekanizmaları omurga üzerindeki C3k2 bloklarına kademeli olarak entegre edilmiştir.



Şekil 3.12. EMA mekanizmasının C3k2 bloklarına entegre edildiği YOLOv11'n mimarisi

Tez kapsamında üç farklı dikkat yaklaşımı değerlendirilmiştir: YOLOv11 tabanlı nesne tespit mimarisinde, dikkat mekanizmalarının omurga yapısına entegrasyonunun model performansına etkisi ayrıntılı olarak incelenmiştir. Bu doğrultuda, farklı dikkat yaklaşımlarının mimari üzerindeki konumlandırmaları ve yapısal etkileri görsel olarak sunulmuştur. Şekil 3.12.'de, Verimli Çok Ölçekli Dikkat (EMA) mekanizmasının YOLOv11 mimarisine entegre edildiği yapı gösterilmekte olup, bu mimaride özellikle erken ve orta seviye özellik haritalarında çok ölçekli bağlamsal bilginin güçlendirilmesi hedeflenmiştir. Şekil 3.13.'de ise, parametresiz yapısıyla dikkat çeken SimAM mekanizmasının YOLOv11 omurgasına kademeli olarak entegre edildiği mimari sunulmakta ve nöron seviyesinde önemlendirme yoluyla uzamsal ayrımın artırılması amaçlanmaktadır. Son olarak, Şekil 3.14.'de CA mekanizmasının entegre edildiği YOLOv11 tabanlı mimari yer almakta olup, bu yapıda kanal ve uzamsal bilginin koordinat temelli olarak birlikte modellenmesi sayesinde özellikle küçük ve konumsal hassasiyeti yüksek patolojilerin daha etkin tespit edilmesi hedeflenmiştir. Bu üç farklı mimari yaklaşım, tez kapsamında önerilen nesne tespit modelinin tasarım sürecini ve dikkat mekanizmalarının performansa olan katkısını bütüncül bir şekilde ortaya koymaktadır.




Şekil 3.13. SimAM mekanizmasının C3k2 bloklarına entegre edildiği YOLOv11'nin mimarisi

Dikkat mekanizmalarının entegrasyonu sırasında, modelin genel karmaşıklığının aşırı artmamasına özellikle dikkat edilmiştir. Bu nedenle, tüm omurgaya yayılmış dikkat yerine erken katmanlara odaklanan ve kademeli olarak genişleyen yapıların performans üzerindeki etkisi öncelikli olarak değerlendirilmiştir. Dikkat mekanizmalarının kademeli olarak yerleştirilmesinde birinci aşamada, ilgili dikkat modülü omurganın başlangıcında yer alan ilk C3k2 bloğuna ($C3k2_1$) entegre edilmiştir. Bu düzenleme ile, girişe yakın katmanlarda yoğun olarak bulunan düşük seviyeli özelliklerin daha etkili biçimde vurgulanması ve bu bilgilerin sonraki katmanlara daha ayırt edici bir temsil olarak aktarılması hedeflenmiştir. İkinci aşamada dikkat mekanizmasının kapsamı genişletilerek modül, $C3k2_1$ ve onu takip eden ikinci C3k2 bloğuna ($C3k2_2$) uygulanmıştır. Bu aşama, erken katmanlarda öğrenilen lokal özelliklerin yanı sıra orta seviyede oluşmaya başlayan daha yapılandırılmış ara temsillerin de yeniden ağırlıklandırılmasını sağlayacak biçimde kurgulanmıştır. Böylece hem yerel detayların hem de daha geniş bağlamı yansıtan ara düzey özelliklerin dikkat mekanizması tarafından düzenlenmesi amaçlanmıştır. Üçüncü aşamada dikkat modülü, omurga üzerinde ardışık biçimde konumlanan ilk üç C3k2 bloğunu kapsayacak şekilde ($C3k2_1$ – $C3k2_3$) entegre edilmiştir. Bu senaryo, dikkat mekanizmasının yalnızca girişe yakın

ve ara katmanlarda değil, daha derin temsillerin oluşmaya başladığı seviyelerde de etkisini sürdürmesini sağlayarak, hiyerarşik özellik öğrenimi üzerindeki katkısının daha kapsamlı biçimde incelenmesine imkân tanımaktadır. Dördüncü ve son aşamada dikkat mekanizması, omurga boyunca yer alan tüm C3k2 bloklarına yaygınlaştırılmıştır. Bu aşama, dikkat modüllerinin omurganın her seviyesinde etkinleştirilmesiyle en geniş kapsamlı entegrasyon senaryosunu temsil etmektedir. Sonuç olarak, EMA, SimAM ve CA modüllerinin YOLOv11n omurgasına entegrasyonunda; dikkat mekanizmalarının C3k2 blokları üzerinde konumlandırılma kapsamı adım adım genişletilerek (i) yalnızca C3k2₁, (ii) C3k2₁–C3k2₂, (iii) C3k2₁–C3k2₃ ve (iv) tüm C3k2 blokları olacak şekilde dört farklı yapılandırma tanımlanmıştır. Bu kademeli yaklaşım, dikkat mekanizmalarının modelin farklı derinliklerindeki etkisini kontrollü bir deney tasarımı ile değerlendirmeye olanak tanımaktadır.

Yapılan deneyler, erken katmanlara entegre edilen dikkat mekanizmalarının küçük patolojilerin tespitinde daha belirgin katkı sağladığını, buna karşın dikkat modülünün tüm omurgaya yayılmasının bazı sınıflarda temsil gürültüsünü artırarak performansı sınırlayabildiğini göstermiştir.



Şekil 3.14. CA mekanizmasının C3k2 bloklarına entegre edildiği YOLOv11n mimarisi

Sonuç olarak, bu tez çalışmasında geliştirilen nesne tespit modeli; YOLOv11 tabanlı omurgayı, sınıf bazlı hata analizleriyle yönlendirilen dikkat destekli mimari iyileştirmeler ile birleştiren hibrit bir yapı sunmaktadır. Model, yalnızca yüksek doğruluk değerleri elde etmeyi değil, aynı zamanda hasta bazlı ayırım senaryolarında genellenebilir ve klinik açıdan daha güvenilir sonuçlar üretmeyi hedefleyecek şekilde tasarlanmıştır.

4. DENEYLER VE SONUÇLAR

Bu tez çalışmasında, karın BT görüntülerinde çok sınıflı patoloji tespiti amacıyla geliştirilen YOLOv11n tabanlı nesne tespit modelinin deneysel değerlendirmesi sunulmaktadır. YOLOv11n en az parametreye ve düşük hesaplama karmaşıklığına sahip olması nedeniyle temel model olarak seçilmiştir. Bu özellikleri sayesinde YOLOv11n, kaynak kısıtlı ortamlarda kullanım için oldukça uygun olup, görece yüksek bir tespit verimliliğini korumaktadır.

Bu çalışmada karın BT görüntülerinde çok sınıflı patoloji tespiti amacıyla kullanılan YOLOv11n, farklı veri kullanımı senaryoları altında değerlendirilmiştir. Deneylerin temel amacı, modelin hem ölçülen performansını hem de bu performansın gerçek dünya genelleme kabiliyetini temsil etme düzeyini ortaya koymaktır. Bu nedenle, veri setindeki görüntü bazlı ve hasta bazlı veri kullanımı olacak şekilde iki farklı senaryo ele alınarak hastalık tespiti yapılmıştır ve bu senaryoların model performansı üzerindeki etkileri incelenmiştir.

Daha sonra hasta bazlı veri ayrımı deneylerinde YOLOv11n tabanlı mimari üzerinde EMA, SimAM ve CA dikkat mekanizmalarının etkisi sistematik olarak incelenmiştir. Bu kapsamda her bir dikkat modülünün, omurga üzerindeki C3k2 bloklarına kademeli biçimde Bölüm 3.7’de detayları verilen şekilde entegre edilerek; yalnızca erken seviye bloklara uygulanması, erken–orta seviyeye genişletilmesi ve tüm omurga boyunca yayılması gibi farklı konfigürasyonlar test edilmiştir. Elde edilen sonuçlar, hem veri seti geneline ait metrikler hem de hastalık bazlı ölçütler üzerinden Kesinlik , Duyarlılık , $mAP@0.50$ ve $mAP@0.50-0.95$ kriterleri kullanılarak karşılaştırmalı biçimde değerlendirilmiştir.

Eğitim ve test süreçlerinde aynı mimari, eğitim hiperparametreleri ve değerlendirme metrikleri kullanılmıştır. Modelin başarımı, nesne tespit literatüründe yaygın olarak kullanılan Kesinlik, Duyarlılık $mAP@0.5$ ve $mAP@0.5:0.95$ metrikleri ile raporlanmıştır. Ayrıca sınıf bazlı performans farklılıklarını görebilmek için sınıf bazlı AP değerleri incelenmiştir. Eğitim hiperparametreleri deneysel olarak belirlenmiştir (Çizelge 4.1).

Çizelge 4.1. Model eğitiminde kullanılan hiperparametreler

Parametre	Değer
Epoch Sayısı	100
Küme Boyutu	8
Optimizasyon	SGD
Başlangıç Öğrenme Oranı	0,01

Bu çalışmada kullanılan veri setinin temel zorluğu; patolojilerin küçük boyutlu olabilmesi, kontrast/çekim protokollerinin değişkenliği, anatomik varyasyonlar, artefaktlar ve sınıflar arası görsel benzerlik gibi faktörlerden kaynaklanmaktadır. Bu nedenle, yalnızca tek bir veri kullanımı senaryosu ile elde edilen sonuçların mutlak başarı olarak yorumlanması yerine, görüntü bazlı ve hasta bazlı veri kullanımı senaryolarının sonuçları genelleme üzerindeki etkisi özellikle analiz edilmiştir. Tüm eğitimler Google Colab platformunda GPU destekli oturumlarda gerçekleştirilmiştir. Eğitim/ doğrulama döngüleri Python tabanlı olarak yürütülmüş; kullanılan kütüphane sürümleri ve temel hiperparametreler sabitlenerek deneylerin karşılaştırılabilirliği sağlanmıştır. Eğitim çıktıları (kayıp eğrileri, metrikler ve model ağırlıkları) her deney için ayrı koşu dizinlerinde kaydedilmiştir.

4.1. Görüntü Bazlı Veri Kullanımı Deneyleri

İlk aşamada veri setindeki tüm görüntüler hangi hastaya ait olduğu dikkate alınmadan rastgele olacak şekilde %80 eğitim ve %20 test olarak ayrılmıştır. Bu yaklaşım, hızlı bir ilk değerlendirme sağlaması açısından pratik olsa da medikal görüntüleme problemlerinde önemli bir risk taşımaktadır. BT verilerinde aynı hastaya ait ardışık kesitler, doku yapıları ve patoloji görünüşleri açısından birbirine yüksek derecede benzer olduğundan, görüntü bazlı veri kullanımı sırasında eğitim setine giren kesitlerin çok benzerlerinin test setinde yer alması mümkündür. Bu durum, modelin gerçek anlamda genelleme yapmasından ziyade, eğitimde gördüğü örneklerin çok benzerlerini testte de görmesi sonucunda ölçülen performansın yapay olarak yüksek çıkmasına neden olabilir.

Bu çalışmada görüntü bazlı veri kullanımı ile elde edilen sonuçların belirgin biçimde yüksek olduğu gözlenmiştir. Bu durum, modelin gerçek performansının çok yüksek olduğuna işaret edebileceği gibi; veri sızıntısı veya değerlendirme yanlılığı kaynaklı bir iyimserlik de

oluşturmuş olabilir. Özellikle hasta bazlı bağımsızlık sağlanmadığında, ölçülen başarı gerçek dünya senaryosunu temsil etmeyebilir.

Çalışmada kullanılan veri setinin genel yapısı, toplam görüntü sayıları ve yarışma kapsamında paylaşılan orijinal sınıfsal dağılımı Çizelge 3.1.'de sunulmuştur. Bu tez kapsamında kullanılan görüntü sayıları ve sınıfların detaylı dağılımı Çizelge 4.2'de detaylandırılmıştır.

Çizelge 4.2. Veri kümesi sınıf dağılımı


Bölüm	Görüntü Sayısı	Akut Kolesistit	Akut Pankreatit	Böbrek/Üreter Taşı	AAA Disseksiyon
Eğitim	17 454	3 746	5 143	824	7 741
Test	4 364	936	1 286	206	1 936

Çizelge 4.3. Görüntü bazlı veri kullanımı deney performansı

Sınıf (Class)	Keskinlik	Duyarlılık	mAP@50	mAP@50-95
Tümü	0,93	0,91	0,94	0,67
Akut Kolesistit	0,97	0,97	0,99	0,76
Akut Pankreatit	0,92	0,93	0,96	0,67
Böbrek/Üreter Taşı	0,82	0,76	0,82	0,38
AAA Disseksiyon	0,99	0,99	0,99	0,87

Çizelge 4.3.'te YOLOv11n modeli kullanılara elde edilen sonuçlar verilmiştir. Çizelge 4.3. incelendiğinde, görüntü bazlı veri kullanımı senaryosunda modelin genel başarı metriklerinin oldukça yüksek olduğu görülmektedir. Sınıf bazlı değerlendirmede de benzer şekilde yüksek performans elde edilmiş; özellikle AAA sınıfında hem kesinlik (0,99) hem duyarlılık (0,99) değerleri dikkat çekici seviyede gerçekleşmiştir. Akut kolesistit ve akut

pankreatit sınıfları da yüksek $mAP@0.5$ değerleri ile (sırasıyla 0,99 ve 0,96) güçlü bir tespit başarımı sergilemiştir. Buna karşın, böbrek/üreter taşı sınıfında $mAP@0.5:0.95$ değerinin görece düşük kalması (0,38), bu sınıfın daha küçük hedefler ve daha zor ayırt edilebilir görsel ipuçları içermesi ile ilişkili olabilir.




Şekil 4.1. Görüntü bazlı veri kullanımına ait karışıklık matrisi

Şekil 4.1.'de verilen karışıklık matrisi de genel olarak yüksek doğruluk eğilimini desteklemektedir. Diyagonal üzerindeki değerlerin yüksek olması, modelin sınıfları doğru tahmin etme eğiliminde olduğunu göstermektedir.

Abdominal Aort Anevrizması/Diseksiyonu sınıfı 0,99 $AP@0.5$ ile en yüksek performansı sergilemiştir. Büyük ve belirgin bir anatomik yapı olması ile, belirli kesitlerde daha ayırt edilebilir bir görünüm sunması, modelin bu sınıfı yüksek doğrulukla tespit etmesine katkı sağlamıştır. Akut Kolesistit ve Akut Pankreatit sınıfları sırasıyla 0,99 ve 0,96 $AP@0.5$

değerleri ile güçlü bir performans göstermiştir. Böbrek/Üreter Taşı sınıfı 0,82 AP@0.5 ile diğer sınıflara kıyasla en düşük performansa sahiptir. Bu düşüş; taşların küçük boyutlu olması, düşük kontrastlı bölgelerde yer alabilmesi ve benzer yoğunluk yapılarıyla karışabilmesi gibi faktörlerle ilişkili olabilir. Buna rağmen rastgele görüntü bazlı veri kullanımı senaryosunda elde edilen sonuçlar genel olarak yüksek düzeydedir.

Görüntü bazlı veri kullanımı senaryosunda bağımsız test görüntüleri üzerindeki tahmin başarımı Şekil 4.2.'de akut kolesistit, böbrek ve üreter taşı, abdominal aort anevrizması ve diseksiyonu ve akut pankreatit ait test görüntüsü tahmin başarımı yer almaktadır.



Şekil 4.2. (a) AAA/ Diseksiyon (b) Böbrek/üreter taşı (c) AAA/ Diseksiyon (d) Akut Pankreatit test görüntüleri tahmin başarımı

BT görüntülerinde aynı hastaya ait ardışık kesitler; anatomik yapı, doku yoğunluğu ve patolojik bulgular açısından büyük ölçüde benzerlik göstermektedir. Görüntü bazlı veri

kullanımı senaryosunda, aynı hastaya ait ve görsel olarak neredeyse özdeş olan kesitlerin eğitim ve test kümelerine birlikte dağılması olasıdır. Bu durumda model, test aşamasında yeni örneklerle değil, eğitim sürecinde gördüğü görüntülere çok benzeyen kesitlerle karşılaşmaktadır. Dolayısıyla ölçülen $mAP@0.5 \approx 0,94$ değeri, modelin patolojik bulgulara ait genel ve soyut özellikleri öğrenmesinden çok, eğitim verisindeki görsel örüntülere güçlü biçimde uyum sağladığı görülmektedir.

Bu nedenle, çalışmada görüntü bazlı veri kullanımı sonuçları hızlı bir ön değerlendirme olarak ele alınmış; modelin yeni ve bağımsız hastalar üzerinde daha gerçekçi şekilde test edilebilmesi için sonraki aşamada hasta bazlı veri kullanımı senaryosuna geçilmiştir. Hasta bazlı veri kullanımı uygulanarak, aynı hastaya ait hiçbir görüntünün farklı veri kümelerinde yer almaması sağlanmıştır. Bu kapsamda, bir hastaya ait tüm görüntüler yalnızca eğitim kümesinde ya da yalnızca test veri kümesinde bulunacak şekilde ayrılmıştır. Böylece, modelin eğitim sırasında gördüğü hasta bilgilerini test aşamasında dolaylı olarak kullanmasının (veri sızıntısı) önüne geçilmiş ve elde edilen performans sonuçlarının gerçek klinik genelleme kabiliyetini daha güvenilir biçimde yansıtması amaçlanmıştır.

4.2. Hasta Bazlı Veri Kullanımı Deneyleri

Bu aşamada veri seti, hasta kimliği esas alınarak %80 eğitim ve %20 test olarak ayrılmıştır. Hasta bazlı veri kullanımı yaklaşımında temel amaç, aynı hastaya ait kesitlerin farklı veri alt kümelerine dağılmasını engelleyerek, modelin performansını tamamen bağımsız hastalar üzerinde ölçmektir. Medikal görüntüleme problemlerinde bir hastaya ait ardışık BT kesitleri; anatomik yapı, doku yoğunluğu ve patoloji görünümü açısından birbirine yüksek derecede benzerlik gösterebildiğinden, görüntü bazlı veri kullanımı sırasında aynı hastanın benzer kesitlerinin hem eğitim hem test kümesine düşmesi mümkündür. Bu durum, modelin gerçek genelleme yeteneğinden ziyade benzer örnekleri tekrar görmesine bağlı olarak performansın yapay biçimde yükselmesine yol açabilir.

Hasta bazlı veri kullanımı ile bu risk azaltılmış ve aynı hastaya ait hiçbir görüntünün farklı kümelere yer almaması sağlanarak, modelin yeni hasta varyasyonlarına (farklı anatomik yapı, farklı çekim protokolü, kontrast seviyesi, artefaktlar ve patoloji sunum farklılıkları) karşı genelleme kapasitesi daha güvenilir biçimde değerlendirilmiştir. Bu nedenle hasta bazlı veri kullanımı senaryosunda elde edilen performans değerleri, görüntü bazlı veri kullanımı

senaryosunda elde edilenlere göre daha düşük olsa da, klinik koşullara daha yakın bir değerlendirme sunduğundan tez kapsamında daha temsil edici kabul edilmiştir. Çizelge 4.4.'de hastaların sayıları ve görüntü sayıları gösterilmektedir.

Çizelge 4.4. Hasta bazlı veri kümesi dağılımı


Küme	Görüntü Sayısı	Hasta Sayısı	Akut Kolesistit	Akut Pankreatit	Böbrek/Üreter Taşı	AAA Disseksiyon
Eğitim	17 435	420	3 729	5 147	840	7 719
Test	4 383	105	953	1 282	190	1 958

Çizelge 4.5.Hasta bazlı veri kullanımı model performans sonuçları

Sınıf (Class)	Kesinlik	Duyarlılık	mAP@0.50	mAP@0.50-0.95
Genel	0,77	0,74	0,77	0,44
Akut Kolesistit	0,88	0,85	0,91	0,58
Akut Pankreatit	0,68	0,68	0,71	0,36
Böbrek/Üreter Taşı	0,59	0,53	0,5	0,17
AAA Disseksiyon	0,94	0,89	0,95	0,66

Çizelge 4.5. incelendiğinde, hasta bazlı bölme senaryosunda modelin genel başarımının kesinlik 0,77, duyarlılık 0,74, mAP@0.5 0,77 ve mAP@0.5:0.95 0,44 olduğu görülmektedir. Görüntü bazlı veri kullanımı senaryosuna kıyasla özellikle mAP@0.5:0.95 değerinde belirgin düşüş gözlenmesi, hasta bazlı veri kullanımı senaryosunda modelin kutu lokalizasyon hassasiyetinin daha zorlayıcı bir genelleme problemine dönüştüğünü

göstermektedir. Bu sonuç, hasta bazlı veri kullanımının daha gerçekçi bir değerlendirme sunduğu görüşünü desteklemektedir.




Şekil 4.3. Hasta bazlı veri kullanımına ait karışıklık matrisi

Şekil 4.3.'de verilen karışıklık matrisi, hasta bazlı değerlendirmede sınıflar arası karışıklıkların ve hata tiplerinin (yanlış pozitif/yanlış negatif) daha net incelenmesine imkân vermektedir. Görüntü bazlı veri kullanım senaryosuna göre diyagonal dışı değerlerin artması, modelin daha önce hiç görmediği hastalarda bazı sınıfları ayırt etmede zorlanabildiğini göstermektedir. Bu gözlem, hasta bazlı veri kullanımının modelin klinik genelleme performansını ölçmek için daha güvenilir bir strateji olduğunu teyit etmektedir.

AAA/ Diseksiyon sınıfı 0,95 mAP@0.5 ile hasta bazlı veri kullanımı senaryosunda da en yüksek performansı sergilemiştir. Yüksek kesinlik (0,94) ve yüksek duyarlılık (0,89) değerleri, AAA'nın daha büyük ve daha belirgin anatomik bir yapı olması nedeniyle model

tarafından daha tutarlı tespit edilebildiğini düşündürmektedir. Akut Kolesistit sınıfı 0,91 mAP@0.5 ve 0,58 mAP@0.5:0.95 ile güçlü bir performans göstermiştir. Bu sınıfta hem duyarlılığın (0,85) hem de lokalizasyon hassasiyetinin görece iyi seviyede olması, safra kesesi çevresi bulgularının model tarafından daha iyi yakalanabildiğini göstermektedir. Akut Pankreatit sınıfında 0,71 mAP@0.5 ve özellikle duyarlılığın (0,68) daha düşük olması, bazı olguların kaçırıldığına işaret etmektedir. Pankreas çevresi inflamatuvar bulguların kesitten kesite değişebilmesi ve sınıf içi varyasyonun yüksek olması bu düşüşü açıklayabilir. Böbrek/Üreter Taşı sınıfı 0,50 mAP@0.5 ve 0,17 mAP@0.5:0.95 ile en zorlayıcı sınıf olmuştur. Taşların küçük boyutlu olması, düşük kontrastlı bölgelerde yer alabilmesi ve doğru kutu yerleşimi gerektirmesi nedeniyle modelin lokalizasyon performansı daha fazla etkilenmektedir. Bu durum, veri setinin zorluğunu, eksikliğini ve hasta bazlı genelleme problemini en belirgin biçimde yansıtan sınıfın böbrek/üreter taşı olduğunu göstermektedir. Şekil 4.4.'de, akut kolesistit, böbrek ve üreter taşı, abdominal aort anevrizması ve diseksiyonu ve akut pankreatit ait test görüntüsü tahmin başarımı yer almaktadır.



Şekil 4.4. (a) Böbrek/üreter taşı (b) AAA/ Diseksiyon (c) Akut Kolesistit (d) Akut Pankreatit test görüntüleri tahmin başarımları

Görüntü bazlı veri kullanımı senaryosunda daha yüksek performans değerleri elde edilmesi, aynı hastaya ait benzer kesitlerin eğitim ve test kümelerine dağılılabilmesi nedeniyle değerlendirmeyi iyimserleştirebilir. Buna karşılık hasta bazlı veri kullanımı senaryosu, modelin tamamen yeni hastalar üzerinde sınanmasını sağladığından, klinik kullanım senaryosunu daha iyi temsil eder. Bu çalışmada hasta bazlı sonuçlar, modelin gerçek dünya genelleme kabiliyetini daha güvenilir biçimde yansıttığı için ana değerlendirme çıktısı olarak ele alınmıştır.

Bölüm 4.2.1., 4.2.2. ve 4.2.3'te sırasıyla SimAM, EMA ve CA dikkat mekanizmalarının YOLOv11n tabanlı mimaride omurga üzerinde yer alan C3k2 bloklarına kademeli olarak entegre edilmesinin model başarımı üzerindeki etkileri incelenmiştir. Bu entegrasyon dört

farklı strateji ile test edilmiştir: (i) yalnızca ilk C3k2 bloğuna (C3k2₁), (ii) ilk iki bloğa (C3k2₁₋₂), (iii) ilk üç bloğa (C3k2₁₋₃) ve (iv) tüm C3k2 bloklarına entegrasyon. Bu yaklaşım, dikkat mekanizmasının erken seviye yerel detaylar, orta seviye anlamsal temsiller ve derin seviye bağlamsal bilgi üzerindeki ayrı etkilerinin sistematik analizine olanak tanımıştır.

4.2.1. SiMAM dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonu

SiMAM dikkat mekanizmasının YOLOv11n tabanlı mimaride omurga üzerinde yer alan C3k2 bloklarına kademeli olarak entegre edilmesinin model başarımı üzerindeki etkisi incelenmiştir. Bu kapsamda Bölüm 3.7.'de de anlatıldığı gibi, SiMAM modülü, sırasıyla yalnızca ilk C3k2 bloğuna, ilk ve onu izleyen C3k2 bloklarına, ilk–orta–ileri seviye C3k2 bloklarına ve tüm omurga boyunca yer alan C3k2 bloklarına uygulanarak değerlendirilmiştir. Böylece dikkat mekanizmasının farklı derinlik seviyelerinde uygulanmasının sınıf bazlı ve genel performansa etkisi sistematik olarak analiz edilmiştir. Çizelge 4.6.'de SiMAM dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonunun model başarımına etkisi gösterilmiştir. Bu yapı için genel sınıfta kesinlik 0,79, duyarlılık 0,76, mAP@0.50 0,78 ve mAP@0.50–0.95 0,45 değerleri elde edilmiştir. Bu sonuçlar temel modele kıyasla kesinlikte yaklaşık %2,6, duyarlılıkta %2,7, mAP@0.50'de %1,3 ve mAP@0.50–0.95'te %2,3 oranında iyileşmeye karşılık gelmektedir. Base modele göre mAP@0.50'deki bu sınırlı artış, modelin genel tespit yeteneğinde mütevazı bir güçlenme sağlarken, mAP@0.50–0.95'teki daha belirgin yüzdesel iyileşme, SiMAM'ın konumlandırma hassasiyetini görece daha fazla olumlu etkilediğini düşündürmektedir.

Çizelge 4.6. SiMAM dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonunun model başarımına etkisi

Sınıf	Konfigürasyon	Kesinlik	Duyarlılık	mAP@0.50	mAP@0.50-0.95
Genel	YOLOv11n	0,77	0,74	0,77	0,44
	YOLOv11n + SiMAM (Erken Seviye – C3k2 ₁)	0,79	0,76	0,78	0,45
	YOLOv11n + SiMAM (Erken-Orta Seviye – C3k2 ₁₋₂)	0,78	0,76	0,78	0,45
	YOLOv11n + SiMAM (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,75	0,77	0,77	0,46
	YOLOv11n + SiMAM (Tam Omurga – Tüm C3k2)	0,76	0,76	0,77	0,45
Akut Kolesistit	YOLOv11n	0,88	0,85	0,91	0,58
	YOLOv11n + SiMAM (Erken Seviye – C3k2 ₁)	0,92	0,83	0,92	0,6
	YOLOv11n + SiMAM (Erken-Orta Seviye – C3k2 ₁₋₂)	0,92	0,8	0,9	0,58
	YOLOv11n + SiMAM (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,87	0,86	0,91	0,61
	YOLOv11n + SiMAM (Tam Omurga – Tüm C3k2)	0,91	0,82	0,9	0,6
Akut Pankreatit	YOLOv11n	0,68	0,68	0,71	0,36
	YOLOv11n + SiMAM (Erken Seviye – C3k2 ₁)	0,69	0,68	0,71	0,35
	YOLOv11n + SiMAM (Erken-Orta Seviye – C3k2 ₁₋₂)	0,67	0,67	0,68	0,35
	YOLOv11n + SiMAM (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,65	0,69	0,68	0,34
	YOLOv11n + SiMAM (Tam Omurga – Tüm C3k2)	0,66	0,70	0,7	0,34
Böbrek / Üreter Taşı	YOLOv11n	0,59	0,53	0,5	0,17
	YOLOv11n + SiMAM (Erken Seviye – C3k2 ₁)	0,64	0,64	0,55	0,19
	YOLOv11n + SiMAM (Erken-Orta Seviye – C3k2 ₁₋₂)	0,65	0,66	0,6	0,2
	YOLOv11n + SiMAM (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,59	0,61	0,52	0,19
	YOLOv11n + SiMAM (Tam Omurga – Tüm C3k2)	0,59	0,57	0,53	0,2
AAA / Diseksiyon	YOLOv11n	0,94	0,89	0,95	0,66
	YOLOv11n + SiMAM (Erken Seviye – C3k2 ₁)	0,91	0,91	0,95	0,67
	YOLOv11n + SiMAM (Erken-Orta Seviye – C3k2 ₁₋₂)	0,89	0,89	0,95	0,68
	YOLOv11n + SiMAM (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,91	0,92	0,96	0,69
	YOLOv11n + SiMAM (Tam Omurga – Tüm C3k2)	0,89	0,93	0,96	0,67

Çizelge 4.6. SiMAM dikkat mekanizmasının erken ve orta seviye C3k2 bloklarına kademeli olarak entegre edildiği yapılandırmalarda, tüm omurgaya yaygın biçimde uygulanmasına kıyasla daha dengeli ve kararlı sonuçlar ürettiğini göstermektedir.

Akut Kolesistit sınıfında, tüm metrik değerler birlikte değerlendirildiğinde, SiMAM dikkat mekanizmasının entegrasyon stratejisinin model performansı üzerinde belirleyici ve katman-seviyeli bir etkiye sahip olduğu gözlemlenmiştir. Temel YOLOv11n modeli, 0,88 kesinlik, 0,85 duyarlılık, 0,91 mAP@0.50 ve 0,58 mAP@0.50–0.95 değerleri ile zaten güçlü bir başlangıç performansı sergilemektedir. Ancak, erken seviye (C3k2₁) katmanına SiMAM eklenmesiyle, kesinlik 0,92'ye çıkarak modelin yanlış pozitif oranını minimize etmiş; duyarlılık 0,83'e düşmekle birlikte klinik açıdan kabul edilebilir bir seviyede tutulmuş ve mAP@0.50–0.95 metriği 0,60'a yükselmiştir. Bu durum, erken katmanlarda işlenen düşük seviyeli görsel özniteliklerin akut kolesistit tanısındaki kritik rolü ile tutarlıdır ve SiMAM'ın bu temel ipuçlarına odaklanma kapasitesini kanıtlamaktadır. Dikkat mekanizmasının erken ve orta seviye (C3k2_{1–2}) katmanlarına genişletilmesi ise farklı bir performans profili ortaya koymuştur: kesinlik 0,92 ile yüksek kalırken duyarlılık 0,80'e düşmüş ve mAP@0.50 değeri 0,90'a gerilemiştir. Bu konfigürasyon, modelin daha seçici ve temkinli davranmasına, dolayısıyla daha az yanlış pozitif üretmesine karşın gerçek pozitif vakaların da daha fazla atlanmasına yol açmıştır. İleri seviye katmanların da (C3k2_{1–3}) dahil edildiği konfigürasyonda ise denge ters yönde değişmiş; duyarlılık 0,86'ya yükselirken kesinlik 0,87'ye düşmüş ve mAP@0.50–0.95 en yüksek değer olan 0,61'e ulaşmıştır. Bu sonuçlar, dikkatin ağ geneline yayılmasının lezyon lokalizasyonunu iyileştirebileceğini, ancak sınıflandırma kararlarında istikrarsızlığa neden olabileceğini düşündürmektedir. Son olarak, SiMAM'ın tüm C3k2 katmanlarına uygulandığı konfigürasyon, erken seviye uygulamasına kıyasla daha düşük bir genel performans (0,91 kesinlik, 0,82 duyarlılık, 0,90 mAP@0.50) sergilemiştir. Bu bulgu, dikkat mekanizmasının her katmana eklenmesinin otomatik olarak daha iyi sonuç vermediğini, aksine dikkat kaynağının sulandırılmasının modelin odaklanma yeteneğini azaltabileceğini göstermektedir. Özellikle mAP@0.50–0.95 değerleri incelendiğinde, SiMAM'ın erken katmanlara entegrasyonunun modelin konumlama hassasiyetini artırdığı, ancak bu etkinin sınırlı kaldığı görülmüştür. Temel modelde 0,58 olan mAP@0.50–0.95, erken seviye SiMAM eklenmesiyle 0,60'a, üç seviyeli (erken–orta–ileri) konfigürasyonda ise maksimum 0,61'e yükselmiştir. Bu artış, SiMAM'ın modelin yalnızca nesneyi bulmasını değil, sınırlarını daha isabetli çizmesini de desteklediğini göstermekle birlikte, değerlerin genel olarak 0,58–0,61 bandında kalması, akut kolesistit lezyonlarının

değişken morfolojisi ve komşu dokularla kontrast kaybı gibi doğal zorluklar nedeniyle yüksek IoU eşiklerinde halen zorlayıcı olduğunu ortaya koymaktadır. Dolayısıyla, SiMAM konumlama performansında iyileşme sağlasa da, özellikle yüksek kesinlik gerektiren klinik senaryolarda sınır belirleme doğruluğunun geliştirilmesi için ek mekanizmalara ihtiyaç olduğu sonucuna varılabilir. Sonuç olarak, akut kolesistit tespiti özelinde en yüksek klinik güvenilirliği ve dengeli performansı sağlayan konfigürasyonun erken seviye SiMAM entegrasyonu olduğu ortaya konmuştur. Bu durum, tıbbi görüntü analizinde dikkat mekanizmalarının başarısının yalnızca varlığına değil, patolojinin görsel doğasına uygun katman seviyesine stratejik yerleştirilmesine bağlı olduğunu teyit etmekte ve dikkat tabanlı modellerin optimizasyonunda katman-seviyeli ayarlamaların önemini vurgulamaktadır.

Akut Pankreatit sınıfında, SiMAM'ın ilk C3k2 ve ilk-orta seviye C3k2 bloklarına entegre edildiği yapılandırmalar arasında sınırlı fakat tutarlı bir iyileşme gözlenmiş; base model değeri olan 0,71 ile karşılaştırıldığında, $mAP@0.50$ 'de belirgin bir değişiklik olmadığı, $mAP@0.50-0.95$ değerlerinin ise 0,36'dan 0,34-0,35 seviyelerine hafif bir düşüş gösterdiği görülmektedir. Buna karşılık dikkat mekanizmasının daha derin C3k2 bloklarına ve tüm omurgaya yayılmasıyla bu sınıfta belirgin bir kazanım elde edilememiş, bazı yapılandırmalarda küçük performans düşüşleri meydana gelmiştir. Bu durum, pankreatite ait yaygın ve sınırları belirsiz görsel örüntülerin, aşırı dikkat yoğunlaştırmasından olumsuz etkilenebileceğine işaret etmektedir. Akut Pankreatit sınıfı için elde edilen sonuçlar, SiMAM dikkat mekanizmasının performans üzerindeki etkisinin patolojiye özgü olduğunu ve Akut Kolesistit'te gözlemlenen belirgin iyileşmelerin bu sınıf için geçerli olmadığını ortaya koymaktadır. Temel YOLOv11n modeli, Akut Pankreatit tespitinde 0,68 kesinlik, 0,68 duyarlılık, 0,71 $mAP@0.50$ ve 0,36 $mAP@0.50-0.95$ değerleri ile nispeten düşük bir performans sergilemiştir. Dikkat çekici olan, SiMAM'ın herhangi bir katman konfigürasyonunda uygulanmasının bu metriklerde anlamlı bir iyileşme sağlamamış olmasıdır. Örneğin, erken seviye SiMAM entegrasyonunda kesinlik 0,69'a minimum düzeyde artarken, $mAP@0.50-0.95$ değeri 0,35'e düşmüş; diğer konfigürasyonlar ise benzer şekilde 0,34-0,35 bandında kalmıştır. Bu durumun temel nedeni, Akut Pankreatit'in radyolojik görünümünün doğasından kaynaklanmaktadır. Akut pankreatit bulguları genellikle düşük kontrasta sahip, yaygın ve iyi tanımlanmamış sınırları olan lezyonlardır. Bu özellikler, Akut Kolesistit'teki gibi kesin kenarlara veya belirgin doku yoğunluğu farklarına dayalı erken seviye özneteliklere kıyasla, daha ileri seviyeli, bağlamsal ve şekil-tabanlı özneteliklerin analizini gerektirir. SiMAM'ın erken katmanlarda düşük seviyeli özneteliklere

odaklanma stratejisi, bu nedenle Akut Pankreatit'in karmaşık ve yaygın morfolojisi karşısında sınırlı bir etki göstermiştir. Ayrıca, tüm SiMAM konfigürasyonlarında $mAP@0.50-0.95$ değerlerinin 0,34–0,36 aralığında kalması, modelin lezyon sınırlarını lokalize etmekte ciddi zorluk yaşadığını göstermektedir. Bu, patolojinin doğal olarak yayılım göstermesi ve net bir geometrik şekle sahip olmaması ile tutarlıdır. Sonuç olarak, Akut Pankreatit sınıfındaki bu bulgular, bir dikkat mekanizmasının başarısının genellenemeyeceğini ve hedef patolojinin görsel karmaşıklığına sıkı sıkıya bağlı olduğunu kanıtlamaktadır. SiMAM'ın Akut Kolesistit'teki başarısı, onun erken özniteliklere odaklanma yeteneğinden kaynaklanırken; Akut Pankreatit gibi yapısal olarak daha karmaşık ve düşük kontrastlı patolojilerde, daha ileri veya özelleştirilmiş dikkat stratejilerinin geliştirilmesi gerekliliğini ortaya koymaktadır. Bu durum, tıbbi görüntü analizinde tek tip bir dikkat yaklaşımı yerine, patolojiye özgü mimari adaptasyonların önemini vurgulamaktadır.

Böbrek/Üreter Taşı sınıfındaki sonuçlar, SiMAM dikkat mekanizmasının etkisinin seviyeye bağlı olarak değişen ve optimum bir noktaya sahip olduğunu göstermektedir. Temel YOLOv11n modeli, bu sınıf için 0,59 kesinlik, 0,53 duyarlılık, 0,50 $mAP@0.50$ ve 0,17 $mAP@0.50-0.95$ değerleri ile sınırlı bir başlangıç performansı sergilemiştir. Erken seviye SiMAM entegrasyonu, tüm metriklerde belirgin bir iyileşme sağlamış; kesinlik 0,64'e, duyarlılık 0,64'e, $mAP@0.50$ 0,55'e ve $mAP@0.50-0.95$ 0,19'a yükselmiştir. Bu artış, taşların yüksek yoğunluk ve genellikle iyi tanımlı kenar özelliklerine sahip olmasıyla açıklanabilir. SiMAM'ın erken katmanlarda bu tür düşük seviyeli kontrast ve kenar bilgilerini vurgulaması, modelin küçük ve keskin yapıları tespit etme yeteneğini güçlendirmiştir. En yüksek performans, erken ve orta seviye katmanlara birlikte SiMAM eklenen konfigürasyonda elde edilmiştir. Bu konfigürasyonda kesinlik 0,65, duyarlılık 0,66, $mAP@0.50$ 0,60 ve $mAP@0.50-0.95$ 0,20 değerlerine ulaşarak sınıf özelinde en yüksek seviyeyi temsil etmiştir. Bu durum, böbrek taşı tespitinin yalnızca erken seviye yoğunluk farklarıyla değil, aynı zamanda orta seviye şekil, boyut ve konum bağlamı bilgisiyle de desteklendiğini düşündürmektedir. Örneğin, bir taşın üreter içindeki konumunun anlaşılması veya böbrek pelvisindeki şeklinin değerlendirilmesi, orta seviye özniteliklerin önemini ortaya koyar. Ancak, dikkat mekanizmasının daha fazla katmana yayılması (erken-orta-ileri seviye ve tam omurga) performansın tekrar düşmesine neden olmuştur. Bu konfigürasyonlarda kesinlik 0,59'a, duyarlılık 0,57–0,61 bandına, $mAP@0.50$ 0,52–0,53 seviyelerine gerilerken, $mAP@0.50-0.95$ değerlerinin 0,19–0,20 aralığında kaldığı

görülmüştür. Bu bulgu, $mAP@0.50$ düzeyinde belirgin bir düşüş olmasına karşın, daha sıkı IoU eşikleri içeren $mAP@0.50-0.95$ metriğinde iyileşmenin sınırlı kaldığını göstermektedir. Bu düşüş, aşırı karmaşıklık veya dikkat dağılması olarak yorumlanabilir. Taş tespiti gibi nispeten lokal ve iyi tanımlı bir görevde, ileri seviye soyut özniteliklerin aşırı vurgulanması, modelin asıl hedef olan küçük, yoğun yapılara odaklanmasını zayıflatmış olabilir. Sonuç olarak, Böbrek/Üreter Taşı tespitinde SiMAM'ın en etkili olduğu nokta, erken ve orta seviye katmanların birlikte kullanıldığı dengeli konfigürasyondur. Bu bulgu, taş gibi küçük ve yüksek kontrastlı hedeflerin tespitinde, hem temel yoğunluk/kenar bilgisinin hem de bağlamsal/şekil bilgisinin optimize edilmiş bir şekilde dikkate alınması gerektiğini ortaya koymaktadır. Performansın ileri seviye katmanlarla birlikte düşmesi ise, bu spesifik görev için dikkat mekanizmasının kapsamının sınırlandırılmasının önemini göstermektedir.

AAA/Diseksiyon sınıfına ait sonuçlar, bu patolojinin yüksek kontrast ve belirgin anatomik sınırlara sahip olması nedeniyle tüm modellerde zaten çok yüksek bir temel performans sergilediğini, ancak SiMAM dikkat mekanizmasının entegrasyonunun bu performansı daha da dengeleme ve optimize etme potansiyeli taşıdığını göstermektedir. Temel YOLOv11n modeli, bu sınıf için 0,94 kesinlik, 0,89 duyarlılık, 0,95 $mAP@0.50$ ve 0,66 $mAP@0.50-0.95$ gibi klinik açıdan oldukça güçlü değerlerle başlamaktadır. Erken seviye SiMAM entegrasyonu, kesinlikte hafif bir düşüşe (0,94'ten 0,91'e) neden olurken, duyarlılığı aynı oranda artırarak (0,89'dan 0,91'e) modelin kesinlik-duyarlılık dengesini daha simetrik bir yapıya taşımıştır. Bu konfigürasyonda $mAP@0.50$ değeri 0,95 seviyesinde korunurken, $mAP@0.50-0.95$ değeri 0,67'ye yükselmiştir. Bu artış, SiMAM'ın erken katmanlarda damar duvarı, lümen ve komşu dokular arasındaki keskin yoğunluk geçişlerine odaklanarak, yalnızca varlık tespitini değil, aynı zamanda sınır doğruluğunu da iyileştirdiğini göstermektedir. Dikkat mekanizmasının kapsamı genişletildikçe bu denge farklı biçimlerde değişmiştir. Erken-orta seviye konfigürasyonunda kesinlik ve duyarlılık 0,89 seviyesinde eşitlenmiş, $mAP@0.50$ değeri 0,95 olarak korunmuş, buna karşılık $mAP@0.50-0.95$ değeri 0,68'e yükselmiştir. Bu sonuç, orta seviye özniteliklerin eklenmesiyle birlikte diseksiyon flebinin ve lümen ayrımının daha hassas biçimde lokalize edilebildiğini düşündürmektedir. En dikkat çekici iyileşme, erken-orta-ileri seviye ve tam omurga konfigürasyonlarında gözlemlenmiştir. Bu yapılarda $mAP@0.50$ değeri 0,96'ya, $mAP@0.50-0.95$ değeri ise sırasıyla 0,69 ve 0,67 seviyelerine ulaşmıştır. Özellikle erken-orta-ileri seviye SiMAM entegrasyonu, hem en yüksek $mAP@0.50$ hem de en yüksek $mAP@0.50-0.95$ değerini sağlayarak AAA Diseksiyon sınıfı için en dengeli ve en hassas konfigürasyon olarak öne

çıkıştır. Bu durum, AAA diseksiyonu gibi büyük ve kompleks vasküler yapıların doğru şekilde konumlandırılması ve sınırlarının hassas biçimde çizilebilmesi için, yalnızca erken seviye kenar bilgisinin değil, ileri seviyedeki anatomik bağlam ve şekil bilgisinin de dikkat mekanizması aracılığıyla vurgulanmasının kritik önem taşıdığını göstermektedir. $mAP@0.50$ değerleri özelinde incelendiğinde, AAA Diseksiyonu sınıfının tüm konfigürasyonlarda son derece yüksek ve istikrarlı bir performans sergilediği görülmektedir. Ancak $mAP@0.50-0.95$ metriği, bu sınıf için ayırt edici ve klinik açıdan çok daha anlamlı bir değerlendirme sunmaktadır. Elde edilen 0,66–0,69 aralığındaki $mAP@0.50-0.95$ değerleri, modelin klinik karar süreçlerini etkileyebilecek düzeyde hassas bir konumsal tahmin üretebildiğini göstermektedir. SiMAM'ın ileri seviye katmanlarda sağladığı katkı, bu tür sınır hassasiyeti gerektiren vakalarda modelin güvenilirliğini artıran temel unsurlardan biri olarak değerlendirilebilir. Sonuç olarak, AAA Diseksiyonu için sunulan $mAP@0.50$ sonuçları, modelin ve SiMAM'ın genel tespit gücünü kanıtlamaktadır.

Genel performans açısından değerlendirildiğinde, ilk C3k2 ve ilk–orta seviye C3k2 bloklarına kademeli olarak entegre edilen SiMAM yapılandırmalarının hem sınıf bazlı hem de tüm veri seti genelinde en dengeli sonuçları sunduğu görülmektedir. Buna karşılık SiMAM'ın tüm omurgaya uygulanması, bazı sınıflarda sınırlı kazanımlar sağlasa da genel mAP ve performans stabilitesi açısından anlamlı bir ek avantaj sunmamıştır. Bu nedenle çalışmada, erken katmanlara kademeli olarak entegre edilen SiMAM yaklaşımı tercih edilmiş ve ilk C3k2 bloğunu temel alan yapı, SiMAM için en uygun konfigürasyon olarak belirlenmiştir.

4.2.2. EMA dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonu

Bu çalışmada, YOLOv11n tabanlı mimaride omurga üzerinde yer alan C3k2 bloklarına kademeli olarak entegre edilmesinin model başarımı üzerindeki etkisi incelenmiştir. Bu kapsamda Bölüm 3.7.'de de anlatıldığı gibi, EMA modülü, sırasıyla yalnızca ilk C3k2 bloğuna, ilk ve onu izleyen C3k2 bloklarına, ilk–orta–ileri seviye C3k2 bloklarına ve tüm omurga boyunca yer alan C3k2 bloklarına uygulanarak değerlendirilmiştir. Böylece dikkat mekanizmasının farklı derinlik seviyelerinde uygulanmasının sınıf bazlı ve genel performansa etkisi sistematik olarak analiz edilmiştir. Bu kademeli yapı sayesinde EMA dikkat mekanizmasının, erken seviye yerel detaylar, orta seviye semantik temsiller ve derin seviye bağlamsal bilgiler üzerindeki etkisi ayrı ayrı gözlemlenebilmiştir.

Bu çalışmada YOLO11n tabanlı temel mimari ile birlikte, EMA dikkat mekanizmasının farklı entegrasyon stratejileri değerlendirilmiştir. Bu stratejiler, dikkat modülünün yalnızca erken seviye özellik çıkarım aşamalarında uygulanması, kademeli olarak orta seviye temsillere genişletilmesi ve tüm omurga boyunca yayılması şeklinde tasarlanmıştır. Bu yaklaşım sayesinde dikkat mekanizmasının hem yerel detaylara hem de küresel bağlama olan etkisi sistematik olarak incelenmiştir. Temel model ile karşılaştırıldığında, yalnızca erken seviye C3k2 bloğuna uygulanan EMA entegrasyonu genel performans açısından en dengeli sonuçları üretmiştir. Bu yapı için genel sınıfta precision 0,79, recall 0,75, mAP@0.50 0,79 ve mAP@0.50–0.95 0,45 değerleri elde edilmiştir. Bu sonuçlar temel modele kıyasla precision’da yaklaşık %2,6, recall’da %1,4, mAP@0.50’de %2,6 ve mAP@0.50–0.95’te %2,3 oranında iyileşmeye karşılık gelmektedir. Elde edilen kazanımlar, EMA’nın erken seviye özellik haritalarını yeniden ağırlıklandırarak hem tespit doğruluğunu hem de genel dengeyi artırdığını göstermektedir (Çizelge 4.7.).

Çizelge 4.7. EMA dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonunun model başarımına etkisi

Sınıf	Konfigürasyon	Kesinlik	Duyarlılık	mAP@0,5	mAP@0,5-0,95
Genel	YOLOv11n	0,77	0,74	0,77	0,44
	YOLOv11n + EMA (Erken Seviye – C3k2 _i)	0,79	0,75	0,79	0,45
	YOLOv11n + EMA (Erken-Orta Seviye – C3k2 ₁₋₂)	0,76	0,75	0,78	0,45
	YOLOv11n + EMA (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,78	0,76	0,78	0,46
	YOLOv11n + EMA (Tam Omurga – Tüm C3k2)	0,74	0,72	0,77	0,44
Akut Kolesistit	YOLOv11n	0,88	0,85	0,91	0,58
	YOLOv11n + EMA (Erken Seviye – C3k2 _i)	0,9	0,8	0,89	0,58
	YOLOv11n + EMA (Erken-Orta Seviye – C3k2 ₁₋₂)	0,88	0,82	0,9	0,58
	YOLOv11n + EMA (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,91	0,81	0,9	0,59
	YOLOv11n + EMA (Tam Omurga – Tüm C3k2)	0,8	0,86	0,89	0,55
Akut Pankreatit	YOLOv11n	0,68	0,68	0,71	0,36
	YOLOv11n + EMA (Erken Seviye – C3k2 _i)	0,7	0,69	0,73	0,36
	YOLOv11n + EMA (Erken-Orta Seviye – C3k2 ₁₋₂)	0,64	0,69	0,7	0,35
	YOLOv11n + EMA (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,69	0,68	0,71	0,36
	YOLOv11n + EMA (Tam Omurga – Tüm C3k2)	0,66	0,66	0,68	0,34
Böbrek / Üreter Taşı	YOLOv11n	0,59	0,53	0,5	0,17
	YOLOv11n + EMA (Erken Seviye – C3k2 _i)	0,68	0,62	0,61	0,21
	YOLOv11n + EMA (Erken-Orta Seviye – C3k2 ₁₋₂)	0,63	0,59	0,58	0,2
	YOLOv11n + EMA (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,63	0,65	0,55	0,19
	YOLOv11n + EMA (Tam Omurga – Tüm C3k2)	0,64	0,46	0,55	0,2
AAA / Diseksiyon	YOLOv11n	0,94	0,89	0,95	0,66
	YOLOv11n + EMA (Erken Seviye – C3k2 _i)	0,91	0,91	0,95	0,66
	YOLOv11n + EMA (Erken-Orta Seviye – C3k2 ₁₋₂)	0,9	0,92	0,95	0,68
	YOLOv11n + EMA (Erken-Orta-İleri Seviye – C3k2 ₁₋₃)	0,91	0,9	0,95	0,68
	YOLOv11n + EMA (Tam Omurga – Tüm C3k2)	0,87	0,9	0,95	0,66

Hastalık bazlı deęerlendirmede Akut Kolesistit sınıfında precision deęeri %2,3 oranında artarak 0,9'a yükselmiş, buna karşın recall deęeri yaklaşık %5,9 oranında azalarak 0,80 seviyesine gerilemiştir; mAP@0.50 deęeri ise deęeri ise 0,91'den 0,89'a hafif düşmüştür. Akut kolesistit sınıfına ait sonuçlar, EMA (Efficient Multi-scale Attention) dikkat mekanizmasının bu patoloji üzerinde genel olarak kesinlik-duyarlılık dengesini yeniden ayarlayan, ancak temel modelin zaten yüksek olan başarımı nedeniyle sınırlı kazanım üreten bir etkiye sahip olduğunu göstermektedir. Akut kolesistit, BT görüntülerinde safra kesesi duvar kalınlaşması, perikolesistik sıvı ve çevre yağ dokusunda inflamatuvar deęişiklikler gibi hem lokal hem de çevresel bulgular içerdüğinden, modelin yalnızca kenar/yoğunluk farklarını deęil, aynı zamanda komşu anatomik yapılara ilişkin bağlamsal ipuçlarını da doğru biçimde kullanması gerekir. Temel YOLOv11n modeli bu sınıfta 0,88 kesinlik, 0,85 duyarlılık, 0,91 mAP@0.50 ve 0,58 mAP@0.50–0.95 deęerleriyle güçlü bir başlangıç performansı sergilemiştir; bu da kolesistit bulgularının çoğu vakada yeterince belirgin olması ve modelin bu örüntüleri etkili şekilde öğrenebilmesiyle uyumludur. EMA'nın erken seviye katmanlara (C3k2₁) entegre edildięi konfigürasyonda, kesinliğin 0,90'a yükselmesi buna karşılık duyarlılığın 0,80'e düşmesi, modelin daha seçici hâle geldiğini ve yanlış pozitifleri azaltırken bazı gerçek vakaları kaçırabildiğini düşündürmektedir. Bu yapı altında mAP@0.50'nin 0,89'a düşmesi, erken seviye EMA'nın düşük seviyeli özellikleri daha güçlü vurgulamasına rağmen kolesistit gibi heterojen sınır karakteristiğine sahip bir problemde tespit başarımının her zaman artmadığını göstermektedir. Buna karşın mAP@0.50–0.95'nin 0,58'de korunması, lokalizasyon hassasiyeti açısından belirgin bir kayıp oluşmadığını, ancak kazanımın da sınırlı kaldığını işaret etmektedir. Erken–orta seviye EMA entegrasyonunda kesinliğin 0,88, duyarlılığın 0,82, mAP@0.50'nin 0,90 ve mAP@0.50–0.95'nin 0,58 olması, erken seviyeye göre duyarlılığın kısmen toparlandığını ancak temel modele kıyasla net bir üstünlük oluşmadığını göstermektedir. Dikkat mekanizmasının erken–orta–ileri seviyeye genişletildięi konfigürasyonda kesinlik 0,91, duyarlılık 0,81, mAP@0.50 0,90 ve mAP@0.50–0.95 0,59 deęerleri elde edilmiştir. Burada mAP@0.50–0.95'te görülen sınırlı artış, EMA'nın daha derin katmanlarda anatomik bağlam ve şekil bilgisini güçlendirerek sınır hassasiyetine küçük bir katkı sağlayabildiğini düşündürmektedir; ancak mAP@0.50 düzeyinde belirgin bir artış oluşmaması, kazanımın daha çok ince ayar düzeyinde kaldığını göstermektedir. EMA'nın tüm omurgaya yayıldığı tam konfigürasyonda ise kesinliğin 0,80'e düşmesi ve duyarlılığın 0,86'ya yükselmesi, modelin daha fazla vakayı yakaladığını fakat bunun daha fazla yanlış pozitif pahasına gerçekleştiğini ortaya koymaktadır. Bu yapı altında mAP@0.50'nin 0,89'a, mAP@0.50–0.95'nin 0,55'e gerilemesi özellikle daha sıkı

IoU eşiklerinde lokalizasyon doğruluğunun zayıfladığını göstermektedir. Bu sonuç, EMA'nın çok geniş bir katman aralığına yayılmasıyla modelin safra kesesine özgü ayırt edici sınır ipuçları yerine çevresel inflamatuvar bağlamı aşırı vurgulayarak odak dağılması yaşayabileceği şeklinde yorumlanabilir. Genel olarak akut kolesistit sınıfı özelinde EMA, temel modelin zaten yüksek olan performansını radikal biçimde artırmaktan ziyade, farklı entegrasyon seviyelerinde kesinlik-duyarlılık dengesini değiştirmiştir. $mAP@0.50-0.95$ değerlerinin 0,55–0,59 bandında kalması, akut kolesistitte klinik açıdan kritik olan sınır hassasiyetinin EMA ile sınırlı ölçüde iyileştirilebildiğini göstermektedir.

Akut pankreatit sınıfına ait sonuçlar, EMA (Efficient Multi-scale Attention) dikkat mekanizmasının bu patoloji üzerinde belirgin ve tutarlı bir performans artışı sağlayamadığını, hatta bazı entegrasyon seviyelerinde performans dalgalanmalarına yol açtığını göstermektedir. Akut pankreatit, BT görüntülerinde pankreasın sınırları net olmayan ve çevre dokularla iç içe geçmiş bulgular ile karakterizedir. Bu nedenle, net bir nesne sınırı tanımlamak zor olup, modelin hem lokal yoğunluk değişimlerini hem de geniş çevresel bağlamı birlikte yorumlaması gerekmektedir. Temel YOLOv11n modeli, bu sınıf için 0,68 kesinlik, 0,68 duyarlılık, 0,71 $mAP@0.50$ ve 0,36 $mAP@0.50-0.95$ değerleriyle görece sınırlı bir başlangıç performansı sergilemiştir; bu durum, pankreatitin doğası gereği tespiti zor bir patoloji olduğunu doğrulamaktadır. EMA'nın erken seviye katmanlara entegre edildiği konfigürasyonda, kesinliğin 0,70'e, duyarlılığın 0,69'a yükselmesiyle birlikte $mAP@0.50$ 'nin 0,73 seviyesine çıktığı gözlemlenmiştir. Bu artış, EMA'nın erken seviyede çok ölçekli bağlam bilgisi sunarak pankreas dokusundaki belirgin yoğunluk farklılıklarını daha iyi vurgulayabildiğini düşündürmektedir. Ancak, $mAP@0.50-0.95$ değerinin 0,36 seviyesinde kalması, bu kazanımın daha çok nesnenin kabaca bulunması düzeyinde olduğunu; sınır hassasiyetine anlamlı bir katkı sağlamadığını göstermektedir. Erken–orta seviye EMA entegrasyonunda kesinlik 0,64'e düşerken, duyarlılığın 0,69 seviyesinde korunması ve $mAP@0.50$ 'nin 0,70'e gerilemesi, orta seviye bağlam bilgisinin eklenmesinin pankreatit için net bir avantaj sunmadığını ortaya koymaktadır. Bu yapı altında $mAP@0.50-0.95$ 'nin 0,35 seviyesine düşmesi, özellikle daha sıkı IoU eşiklerinde lokalizasyon doğruluğunun zayıfladığını göstermektedir. Dikkat mekanizmasının erken–orta–ileri seviye katmanlara genişletildiği konfigürasyonda kesinlik 0,69, duyarlılık 0,68, $mAP@0.50$ 0,71 ve $mAP@0.50-0.95$ 0,36 değerleri elde edilmiştir. Bu sonuçlar, EMA'nın derin katmanlara yayılmasının performansı istikrarlı biçimde artırmadığını; kazanımın erken seviye ile sınırlı kaldığını düşündürmektedir. EMA'nın tüm omurgaya uygulandığı tam konfigürasyonda ise

kesinlik ve duyarlılığın 0,66 seviyesine gerilemesi, $mAP@0.50$ 'nin 0,68'e, $mAP@0.50-0.95$ 'nin 0,34'e düşmesi, dikkat mekanizmasının aşırı yayılması sonucunda modelin pankreasa özgü ayırt edici örüntüler yerine geniş inflamatuvar bağlamı fazla vurguladığını ve bu durumun tespit doğruluğunu olumsuz etkilediğini göstermektedir. Genel olarak akut pankreatit sınıfı için EMA dikkat mekanizması, erken seviye entegrasyonda sınırlı bir $mAP@0.50$ artışı sağlamış olsa da, $mAP@0.50-0.95$ metriği açısından anlamlı ve sürdürülebilir bir iyileşme üretmemiştir.

Klinik açıdan en zorlayıcı sınıflardan biri olan Böbrek/Üreter Taşı için EMA entegrasyonu en belirgin kazanımları sunmuştur. EMA dikkat mekanizmasının bu patoloji üzerinde özellikle erken seviye entegrasyonda anlamlı katkı sağladığını, ancak daha derin katmanlara yayılmasıyla birlikte bu etkinin zayıfladığını göstermektedir. Temel YOLOv11n modeli bu sınıf için 0,59 kesinlik, 0,53 duyarlılık, 0,5 $mAP@0.50$ ve 0,17 $mAP@0.50-0.95$ değerleriyle oldukça sınırlı bir başlangıç performansı sergilemiştir; bu durum, küçük boyutlu hedeflerin ve sınırlı bağlamsal ipuçlarının tespit sürecini zorlaştırdığını göstermektedir. EMA'nın erken seviye katmanlara entegre edildiği konfigürasyonda, performansın tüm metriklerde belirgin biçimde iyileştiği görülmektedir. Bu yapı altında kesinlik 0,68, duyarlılık 0,62, $mAP@0.50$ 0,61 ve $mAP@0.50-0.95$ 0,21 değerlerine ulaşılmıştır. Özellikle $mAP@0.50$ ve $mAP@0.50-0.95$ 'deki artış, EMA'nın erken katmanlarda sağladığı çok ölçekli bağlam bilgisinin, taşların yüksek yoğunluklu ve keskin kenarlı yapısını daha net biçimde öne çıkardığını düşündürmektedir. Bu sonuç, EMA'nın erken seviyede küçük ve kontrastı yüksek yapıların tespitinde etkili olabildiğini ortaya koymaktadır. EMA'nın erken-orta seviye katmanlara genişletildiği konfigürasyonda ise kesinlik 0,63, duyarlılık 0,59, $mAP@0.50$ 0,58 ve $mAP@0.50-0.95$ 0,2 değerleri elde edilmiştir. Erken seviye konfigürasyona kıyasla tüm metriklerde gözlemlenen düşüş, orta seviye bağlamsal özniteliklerin taş tespiti için sınırlı fayda sağladığını ve hatta bazı durumlarda modelin odağını dağıtabildiğini göstermektedir. Bu yapı altında taşın kendisine özgü yoğunluk ipuçları yerine, böbrek parankimi veya çevre yumuşak dokuların gereksiz biçimde dikkate alınması, tespit doğruluğunu olumsuz etkilemiş olabilir. Dikkat mekanizmasının erken-orta-ileri seviye katmanlara yayılmasıyla birlikte kesinliğin 0,63, duyarlılığın 0,65, $mAP@0.50$ 'nin 0,55 ve $mAP@0.50-0.95$ 'nin 0,19 seviyelerine gerilemesi, EMA'nın daha derin temsillerinin taş gibi lokal ve küçük hedefler için avantaj sağlamadığını açıkça ortaya koymaktadır. EMA'nın tüm omurgaya uygulandığı tam konfigürasyonda ise kesinlik 0,64, duyarlılık 0,46, $mAP@0.50$ 0,55 ve $mAP@0.50-0.95$ 0,2 değerleri elde edilmiştir. Özellikle

duyarlılıktaki belirgin düşüş, modelin çok sayıda gerçek taşı kaçırdığını ve aşırı bağlamsal dikkat nedeniyle lokal yoğunluk sinyallerinin bastırıldığını düşündürmektedir. Genel olarak böbrek/üreter taşı sınıfı için EMA dikkat mekanizması, yalnızca erken seviye entegrasyonda anlamlı ve klinik açıdan yorumlanabilir bir katkı sunmuştur. EMA'nın daha derin katmanlara yayılması, taş tespiti gibi lokal ve yüksek kontrastlı bir görevde performansı artırmak yerine, dikkat dağılmasına ve lokalizasyon doğruluğunun zayıflamasına yol açmıştır. $mAP@0.50-0.95$ değerlerinin tüm EMA konfigürasyonlarında 0,19–0,21 aralığında kalması, sınır hassasiyetinin EMA ile sınırlı ölçüde iyileştirilebildiğini göstermektedir. Bu bulgular, böbrek taşı tespitinde çok ölçekli bağlamdan ziyade erken seviye yoğunluk/kenar vurgusunun kritik olduğunu ve EMA gibi dikkat mekanizmalarının kontrollü ve sınırlı derinlikte uygulanmasının daha uygun bir strateji olduğunu ortaya koymaktadır.

AAA/Diseksiyon sınıfına ait sonuçlar, EMA dikkat mekanizmasının bu patoloji için temel modelde zaten yüksek olan tespit başarımını koruduğunu, ancak özellikle daha hassas yer belirleme açısından sınırlı fakat tutarlı katkılar sağlayabildiğini göstermektedir. Temel YOLOv11n modeli bu sınıf için 0,94 kesinlik, 0,89 duyarlılık, 0,95 $mAP@0.50$ ve 0,66 $mAP@0.50-0.95$ değerleriyle oldukça güçlü bir başlangıç performansı sergilemiştir. Bu durum, AAA diseksiyonunun BT görüntülerinde geniş, yüksek kontrastlı ve anatomik olarak belirgin bir yapı olarak yer almasıyla uyumludur. EMA'nın erken seviye katmanlara entegre edildiği konfigürasyonda, kesinliğin 0,91'e düşmesine karşılık duyarlılığın 0,91'e yükselmesi, modelin daha dengeli bir yapı sergilediğini göstermektedir. Bu yapı altında $mAP@0.50$ değeri 0,95 seviyesinde korunmuş, $mAP@0.50-0.95$ ise 0,66 olarak değişmeden kalmıştır. Bu sonuç, EMA'nın daha fazla vakayı yakalamaya yardımcı olduğunu, ancak yer belirleme hassasiyetinde ek bir kazanım oluşturmadığını düşündürmektedir. EMA'nın erken–orta seviye katmanlara genişletildiği konfigürasyonda duyarlılığın 0,92'ye yükselmesi, $mAP@0.50-0.95$ değerinin ise 0,68'e çıkması, bu sınıf için elde edilen en iyi yer belirleme performansını temsil etmektedir. Bu artış, EMA'nın orta seviye özellikler sayesinde damardaki anormal bölgeyi çevresinden daha net ayırt etmeye yardımcı olduğunu göstermektedir. Buna karşın $mAP@0.50$ değerinin 0,95'te sabit kalması, kazanımın nesnenin bulunmasından ziyade, konumunun daha doğru çizilmesine yönelik olduğunu ortaya koymaktadır. Dikkat mekanizmasının erken–orta–ileri seviye katmanlara yayılması durumunda $mAP@0.50-0.95$ değerinin 0,68 seviyesinde korunması, ancak daha ileri bir artış göstermemesi, EMA'nın bu noktadan sonra ek fayda üretmediğini

düşündürmektedir. EMA'nın tüm omurgaya uygulandığı tam konfigürasyonda ise kesinliğin 0,87'ye gerilemesi ve $mAP@0.50-0.95$ 'nin tekrar 0,66 seviyesine düşmesi, dikkat mekanizmasının aşırı yayılmasının performansı artırmak yerine dengeyi bozabildiğini göstermektedir. Genel olarak AAA/Diseksiyon sınıfında EMA, zaten çok yüksek olan $mAP@0.50$ performansını artırmamış, ancak erken-orta seviye entegrasyonda $mAP@0.50-0.95$ metriği üzerinden daha hassas yer belirleme sağlamıştır. Bu bulgu, EMA'nın bu patoloji için kontrollü ve sınırlı derinlikte kullanıldığında en etkili sonuçları verdiğini, tüm omurgaya yayılmasının ise gerekli olmadığını göstermektedir.

Genel olarak değerlendirildiğinde, EMA dikkat mekanizmasının erken seviye C3k2 bloklarına odaklanan entegrasyon stratejisi hem genel metriklerde hem de hastalık bazı değerlendirilmelerde temel modele kıyasla en tutarlı ve klinik açıdan anlamlı iyileştirmeleri sağlamıştır. Özellikle küçük lezyonlarda elde edilen yüksek yüzdesel kazanımlar, bu yaklaşımın klinik kullanım açısından önemini vurgulamakta; bu nedenle çalışmada EMA için referans yapı olarak erken seviye özellik odaklı entegrasyon tercih edilmiştir.

4.2.3. CA dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonu

CA dikkat mekanizmasının YOLOv11n tabanlı mimaride omurga üzerinde yer alan C3k2 bloklarına kademeli olarak entegre edilmesinin model başarımı üzerindeki etkisi incelenmiştir. Bu kapsamda Bölüm 3.7.'de de anlatıldığı gibi, CA modülü, sırasıyla yalnızca ilk C3k2 bloğuna, ardından ilk ve onu izleyen C3k2 bloklarına, daha sonra ilk-orta-ileri seviye C3k2 bloklarına ve son olarak omurgadaki tüm C3k2 bloklarına uygulanarak değerlendirilmiştir. Bu yaklaşım sayesinde koordinat tabanlı dikkat mekanizmasının erken, orta ve derin seviye temsiller üzerindeki katkısı sistematik biçimde analiz edilmiştir. Çizelge 4.8.'de CA dikkat mekanizmasının C3k2 bloklarına kademeli entegrasyonunun model başarımına etkisi gösterilmiştir.

Çizelge 4.8. incelendiğinde, akut kolesistit sınıfında, CA mekanizmasının erken ve orta seviye C3k2 bloklarına uygulanmasıyla base modele kıyasla performans artışı sağlandığı görülmektedir. Temel modelde $mAP@0.50$ değeri 0,91 iken, CA'nın ilk C3k2 ve ilk-orta seviye C3k2 bloklarına entegre edildiği yapılarda bu değerin 0,9-0,92 aralığında korunduğu; $mAP@0.50-0.95$ metriğinin ise 0,58 seviyesinden bazı konfigürasyonlarda 0,6 seviyesine

yükseldiği gözlenmiştir. Bu durum, safra kesesi çevresindeki konumsal bilginin, CA mekanizması sayesinde daha etkin biçimde temsil edilebildiğini göstermektedir.

Çizelge 4.8. CA dikkat mekanizmasının kademeli entegrasyonunun model başarımına etkisi

Sınıf	Konfigürasyon	Kesinlik	Duyarlılık	mAP@0,5	mAP@0,5–0,95
Genel	YOLOv11n	0,77	0,74	0,77	0,44
	YOLOv11n + CA (Erken Seviye – C3k2 ₁)	0,77	0,75	0,78	0,45
	YOLOv11n + CA (Erken–Orta Seviye – C3k2 _{1–2})	0,77	0,75	0,78	0,45
	YOLOv11n + CA (Erken–Orta–İleri Seviye – C3k2 _{1–3})	0,78	0,76	0,79	0,46
	YOLOv11n + CA (Tam Omurga – Tüm C3k2)	0,78	0,74	0,78	0,45
Akut Kolesistit	YOLOv11n	0,88	0,85	0,91	0,58
	YOLOv11n + CA (Erken Seviye – C3k2 ₁)	0,9	0,84	0,92	0,6
	YOLOv11n + CA (Erken–Orta Seviye – C3k2 _{1–2})	0,89	0,81	0,9	0,58
	YOLOv11n + CA (Erken–Orta–İleri Seviye – C3k2 _{1–3})	0,9	0,81	0,9	0,6
	YOLOv11n + CA (Tam Omurga – Tüm C3k2)	0,86	0,81	0,89	0,57
Akut Pankreatit	YOLOv11n	0,68	0,68	0,71	0,36
	YOLOv11n + CA (Erken Seviye – C3k2 ₁)	0,67	0,7	0,72	0,35
	YOLOv11n + CA (Erken–Orta Seviye – C3k2 _{1–2})	0,66	0,69	0,71	0,35
	YOLOv11n + CA (Erken–Orta–İleri Seviye – C3k2 _{1–3})	0,7	0,7	0,7	0,36
	YOLOv11n + CA (Tam Omurga – Tüm C3k2)	0,67	0,7	0,71	0,37
Böbrek / Üreter Taşı	YOLOv11n	0,59	0,53	0,5	0,17
	YOLOv11n + CA (Erken Seviye – C3k2 ₁)	0,61	0,58	0,53	0,19
	YOLOv11n + CA (Erken–Orta Seviye – C3k2 _{1–2})	0,64	0,62	0,58	0,21
	YOLOv11n + CA (Erken–Orta–İleri Seviye – C3k2 _{1–3})	0,63	0,59	0,6	0,22
	YOLOv11n + CA (Tam Omurga – Tüm C3k2)	0,71	0,54	0,58	0,21
AAA / Diseksiyon	YOLOv11n	0,94	0,89	0,95	0,66
	YOLOv11n + CA (Erken Seviye – C3k2 ₁)	0,91	0,88	0,94	0,67
	YOLOv11n + CA (Erken–Orta Seviye – C3k2 _{1–2})	0,9	0,88	0,94	0,66
	YOLOv11n + CA (Erken–Orta–İleri Seviye – C3k2 _{1–3})	0,92	0,92	0,96	0,67
	YOLOv11n + CA (Tam Omurga – Tüm C3k2)	0,93	0,89	0,95	0,66

Akut kolesistit tespitinde, CA dikkat mekanizmasının bu patoloji üzerinde özellikle erken ve erken-orta seviye entegrasyonlarda sınırlı fakat tutarlı iyileştirmeler sağladığını, ancak daha derin katmanlara yayılmasıyla birlikte bu kazanımın sürdürülemediğini göstermektedir. Temel YOLOv11n modeli bu sınıf için 0,88 kesinlik, 0,85 duyarlılık, 0,91 mAP@0.50 ve 0,58 mAP@0.50–0.95 değerleriyle güçlü bir başlangıç performansı sunmaktadır. Bu yüksek temel seviye, akut kolesistitin BT görüntülerinde çoğu vakada belirgin duvar kalınlaşması ve çevresel inflamatuvar bulgular oluşturmasıyla uyumludur. CA'nın erken seviye katmanlara entegre edildiği konfigürasyonda, kesinliğin 0,9'a yükselmesi ve mAP@0.50'nin 0,92'ye çıkması, dikkat mekanizmasının safra kesesi çevresindeki yapısal ipuçlarını daha seçici biçimde vurguladığını göstermektedir. Buna karşılık duyarlılığın 0,84'e gerilemesi, modelin daha temkinli davranarak bazı gerçek vakaları kaçırabildiğini düşündürmektedir. Bu yapı altında mAP@0.50–0.95'nin 0,60'a yükselmesi, yalnızca nesnenin bulunmasında değil, sınırların daha hassas çizilmesinde de sınırlı bir kazanım elde edildiğini ortaya koymaktadır. Erken-orta seviye CA entegrasyonunda kesinliğin 0,89, duyarlılığın 0,81, mAP@0.50'nin 0,9 ve mAP@0.50–0.95'nin 0,58 olması, erken seviye konfigürasyona kıyasla performansın dengelendiğini ancak ek bir iyileşme sağlanamadığını göstermektedir. Bu sonuç, kolesistit gibi heterojen ve sınırları kısmen belirsiz patolojilerde, orta seviye konumsal bilginin tek başına belirleyici olmadığını düşündürmektedir. CA'nın erken-orta-ileri seviye katmanlara yayılması durumunda kesinliğin tekrar 0,9 seviyesinde korunmasına karşın duyarlılığın 0,81'de kalması, mAP@0.50'nin 0,9 ve mAP@0.50–0.95'nin 0,6 değerlerinde sabitlenmesi, dikkat mekanizmasının daha derin katmanlarda ek bir fayda üretmediğini göstermektedir. CA'nın tüm omurgaya uygulandığı tam konfigürasyonda ise kesinliğin 0,86'ya düşmesi, mAP@0.50'nin 0,89'a, mAP@0.50–0.95'nin 0,57'ye gerilemesi, dikkat mekanizmasının aşırı yayılmasıyla birlikte modelin safra kesesine özgü ayırt edici sınır ipuçları yerine daha geniş bağlamsal bilgiyi vurguladığını ve bunun performansı olumsuz etkilediğini düşündürmektedir. Genel olarak akut kolesistit sınıfı için CA dikkat mekanizması, erken seviye entegrasyonda mAP@0.50 ve mAP@0.50–0.95 metriklerinde sınırlı fakat anlamlı bir artış sağlamış, ancak daha derin katmanlara yayılması durumunda bu kazanımı koruyamamıştır. Bu bulgular, kolesistit gibi orta ölçekli ve çevre dokularla sınır ilişkisi karmaşık olan patolojilerde, CA'nın kontrollü ve sınırlı derinlikte uygulanmasının daha uygun bir strateji olduğunu göstermektedir.

Akut pankreatit sınıfına ait sonuçlar, CA dikkat mekanizmasının bu patoloji üzerinde belirgin bir performans artışı sağlamadığını, ancak bazı konfigürasyonlarda sınırlı ve yönlü etkiler oluşturduğunu göstermektedir. Akut pankreatit, net sınırları olmayan ve çevre dokularla iç içe geçmiş bir yapıya sahiptir. Bu özellikler, nesne tespiti temelli yaklaşımlar için zorlu bir problem oluşturmaktadır. Temel YOLOv1 1n modeli bu sınıf için 0,68 kesinlik, 0,68 duyarlılık, 0,71 mAP@0.50 ve 0,36 mAP@0.50–0.95 değerleriyle görece sınırlı bir başlangıç performansı sergilemiştir. CA'nın erken seviye katmanlara entegre edildiği konfigürasyonda, duyarlılığın 0,70'e yükselmesine karşılık kesinliğin 0,67'ye düşmesi, modelin daha fazla vakayı yakalayabildiğini ancak yanlış pozitiflerin arttığını göstermektedir. Bu yapı altında mAP@0.50'nin 0,72'ye çıkması, CA'nın erken seviyede pankreas dokusundaki kaba yoğunluk farklılıklarını daha görünür hâle getirdiğini düşündürmektedir. Buna karşın mAP@0.50–0.95'nin 0,35'e gerilemesi, bu kazanımın sınır hassasiyetine yansımadığını ve yer belirleme doğruluğunun zayıf kaldığını göstermektedir. Erken–orta seviye CA entegrasyonunda kesinliğin 0,66, duyarlılığın 0,69, mAP@0.50'nin 0,71 ve mAP@0.50–0.95'nin 0,35 olması, erken seviye konfigürasyona kıyasla ek bir iyileşme sağlanamadığını ortaya koymaktadır. CA'nın erken–orta–ileri seviye katmanlara yayılması durumunda kesinlik ve duyarlılığın 0,70 seviyesinde dengelenmesi, modelin daha stabil bir davranış sergilediğini göstermektedir. Ancak bu yapı altında mAP@0.50'nin 0,70'e düşmesi ve mAP@0.50–0.95'nin 0,36 seviyesinde kalması, dikkat mekanizmasının daha derin katmanlarda pankreatit için anlamlı bir kazanım üretmediğini düşündürmektedir. CA'nın tüm omurgaya uygulandığı tam konfigürasyonda ise mAP@0.50–0.95'nin 0,37'ye hafifçe yükselmesi, sınır hassasiyetinde çok sınırlı bir artışa işaret etse de, mAP@0.50'nin 0,71 seviyesinde kalması, bu kazanımın pratik açıdan sınırlı olduğunu göstermektedir. Genel olarak akut pankreatit sınıfı için CA dikkat mekanizması, nesnenin bulunması açısından sınırlı katkı sağlamış, ancak yüksek IoU eşiklerinde ölçülen yer belirleme hassasiyetini anlamlı biçimde iyileştirememiştir. mAP@0.50–0.95 değerlerinin tüm CA konfigürasyonlarında 0,35–0,37 bandında kalması, pankreatitin diffüz ve sınırları belirsiz yapısının, konum bilgisine odaklanan CA mekanizmasıyla yeterince ayrıştırılamadığını göstermektedir.

Böbrek/Üreter Taşı sınıfına ait sonuçlar, CA dikkat mekanizmasının bu patoloji üzerinde özellikle orta ve orta–ileri seviye entegrasyonlarda belirgin bir katkı sağladığını, ancak duyarlılık–kesinlik dengesi açısından dikkatli yorumlanması gerektiğini göstermektedir. Böbrek ve üreter taşları BT görüntülerinde genellikle küçük boyutlu, yüksek yoğunluklu ve

keskin sınırlı yapılar olarak görülse de, çevre anatomik yapıların karmaşıklığı ve taşın üreter içindeki konumu tespiti zorlaştırabilmektedir. Temel YOLOv11n modeli bu sınıf için 0,59 kesinlik, 0,53 duyarlılık, 0,50 mAP@0.50 ve 0,17 mAP@0.50–0.95 değerleriyle sınırlı bir başlangıç performansı sergilemiştir. CA'nın erken seviye katmanlara entegre edildiği konfigürasyonda, kesinliğin 0,61'e, duyarlılığın 0,58'e, mAP@0.50'nin 0,53'e ve mAP@0.50–0.95'nin 0,19'a yükselmesi, dikkat mekanizmasının taşlara ait konumsal ipuçlarını kısmen daha iyi yakalayabildiğini göstermektedir. Ancak bu artış, henüz güçlü ve istikrarlı bir kazanım düzeyine ulaşmamıştır. Erken–orta seviye CA entegrasyonunda kesinliğin 0,64, duyarlılığın 0,62, mAP@0.50'nin 0,58 ve mAP@0.50–0.95'nin 0,21 değerlerine ulaşması, bu sınıf için elde edilen en dengeli performanslardan birini temsil etmektedir. Bu sonuç, CA'nın konumsal bilgiyi yönlü biçimde kodlayabilen yapısı sayesinde, taşın böbrek ya da üreter içindeki yerinin daha doğru ayırt edilebildiğini düşündürmektedir. CA'nın erken–orta–ileri seviye katmanlara yayılmasıyla birlikte mAP@0.50'nin 0,60'a, mAP@0.50–0.95'nin ise 0,22'ye yükselmesi, yer belirleme hassasiyeti açısından tablodaki en yüksek değerlerin elde edildiğini göstermektedir. Bu yapı, CA'nın özellikle küçük ve lokal hedeflerde, konum bilgisini koruyarak daha doğru sınırlar çizebildiğini ortaya koymaktadır. Buna karşılık duyarlılığın 0,59'a gerilemesi, modelin daha seçici hâle geldiğini ve bazı gerçek vakaların kaçırılabilirdiğini göstermektedir. CA'nın tüm omurgaya uygulandığı tam konfigürasyonda ise kesinliğin 0,71'e yükselmesine karşın duyarlılığın 0,54'e düşmesi, modelin yanlış pozitifleri ciddi ölçüde azalttığını ancak çok sayıda gerçek taşı kaçırdığını göstermektedir. Bu yapı altında mAP@0.50'nin 0,58, mAP@0.50–0.95'nin 0,21 seviyelerinde kalması, aşırı derin dikkat entegrasyonunun böbrek/üreter taşı gibi küçük ve lokal hedefler için ek bir fayda sağlamadığını ortaya koymaktadır. Genel olarak böbrek/üreter taşı sınıfı için CA dikkat mekanizması, özellikle erken–orta ve erken–orta–ileri seviye entegrasyonlarda lokalizasyon hassasiyetini artırmış, mAP@0.50–0.95 metriği üzerinden anlamlı kazanımlar sağlamıştır. Buna karşılık, tüm omurgaya yayılan CA yapısı duyarlılığı düşürerek performans dengesini bozmuştur. Bu bulgular, böbrek taşı tespitinde CA'nın kontrollü ve sınırlı derinlikte uygulanmasının daha uygun olduğunu; konumsal bilginin güçlendirilmesinin, küçük ve yüksek kontrastlı hedeflerin doğru şekilde yerleştirilmesinde kritik rol oynadığını göstermektedir.

AAA/Diseksiyon sınıfına ait sonuçlar, CA dikkat mekanizmasının bu patoloji için zaten yüksek olan temel performansı büyük ölçüde koruduğunu, bazı entegrasyon seviyelerinde ise yer belirleme hassasiyeti açısından sınırlı fakat anlamlı kazanımlar sağlayabildiğini

göstermektedir. AAA diseksiyonu, BT görüntülerinde geniş çaplı, yüksek kontrastlı ve anatomik olarak belirgin sınırlara sahip bir vasküler yapı olarak yer aldığından, modelin bu patolojiyi nesne düzeyinde tespit etmesi görece daha kolaydır. Temel YOLOv11n modeli bu sınıf için 0,94 kesinlik, 0,89 duyarlılık, 0,95 mAP@0.50 ve 0,66 mAP@0.50–0.95 değerleriyle oldukça güçlü bir başlangıç performansı sergilemiştir. CA'nın erken seviye katmanlara entegre edildiği konfigürasyonda, kesinliğin 0,91'e, duyarlılığın 0,88'e gerilemesi ile mAP@0.50'nin 0,94'e düşmesi, dikkat mekanizmasının erken seviyede ek bir avantaj sağlayamadığını göstermektedir. Buna karşın mAP@0.50–0.95'nin 0,67'ye yükselmesi, CA'nın konumsal bilgiyi kodlayan yapısı sayesinde diseksiyon bölgesinin sınırlarının daha tutarlı biçimde çizilebildiğini düşündürmektedir. Bu sonuç, kazanımın nesnenin bulunmasından ziyade yerinin daha hassas belirlenmesi yönünde olduğunu ortaya koymaktadır. Erken–orta seviye CA entegrasyonunda kesinlik 0,90, duyarlılık 0,88, mAP@0.50 0,94 ve mAP@0.50–0.95 0,66 değerleri elde edilmiştir. Bu yapı, erken seviye konfigürasyona kıyasla ek bir iyileşme sunmamış ve performansın temel modele yakın seyrettiğini göstermiştir. Buna karşılık CA'nın erken–orta–ileri seviye katmanlara yayılması durumunda kesinliğin 0,92'ye, duyarlılığın 0,92'ye yükselmesi ve mAP@0.50'nin 0,96'ya çıkması, nesnenin daha kararlı biçimde tespit edildiğini göstermektedir. Bu yapı altında mAP@0.50–0.95'nin 0,67 seviyesinde korunması, sınır hassasiyetinde ek bir sıçrama olmasa da, genel performansın dengeli biçimde iyileştiğini düşündürmektedir. CA'nın tüm omurgaya uygulandığı tam konfigürasyonda ise kesinliğin 0,93, duyarlılığın 0,89, mAP@0.50'nin 0,95 ve mAP@0.50–0.95'nin 0,66 seviyelerine gerilediği görülmektedir. Bu durum, CA'nın aşırı derinlikte uygulanmasının AAA/Diseksiyon gibi zaten belirgin sınırlara sahip bir patolojide ek bir fayda sağlamadığını, hatta performansı temel modele yaklaştırdığını göstermektedir. Genel olarak AAA/Diseksiyon sınıfı için CA dikkat mekanizması, mAP@0.50 açısından sınırlı değişimler üretmiş, buna karşılık mAP@0.50–0.95 metriği üzerinden yer belirleme hassasiyetini erken ve erken–orta–ileri seviye entegrasyonlarda koruyabilmiştir. Bu bulgular, CA'nın bu patoloji için kontrollü ve sınırlı katman derinliğinde kullanıldığında daha dengeli sonuçlar verdiğini, tüm omurgaya yayılmasının ise gerekli olmadığını ortaya koymaktadır. Genel performans değerlendirildiğinde, base modelin 0,77 mAP@0.50 ve 0,44 mAP@0.50–0,95 değerleri, erken–orta–ileri seviye C3k2 bloklarına uygulanan CA entegrasyonu ile sırasıyla 0,79 ve 0,46 seviyelerine yükselmiştir. Buna karşın CA mekanizmasının tüm omurga boyunca yer alan C3k2 bloklarına uygulanması, hesaplama maliyetini artırmasına rağmen anlamlı bir ek

performans kazancı sunmamıştır. Bu durum, CA mekanizmasının özellikle erken ve orta seviye temsillerde daha etkili olduğunu ortaya koymaktadır.

Sonuç olarak, CA mekanizmasının ilk–orta–ileri seviye C3k2 bloklarına kademeli olarak entegre edilmesi, hem küçük lezyonların (böbrek/üreter taşı) hem de büyük patolojilerin (AAA diseksiyon) birlikte ele alındığı çok sınıflı senaryoda en dengeli ve en yüksek performansı sağlayan yapı olarak belirlenmiştir. Bu nedenle tez kapsamında CA için nihai yapılandırma olarak kademeli C3k2 entegrasyonu tercih edilmiştir.

Bu çalışmada geliştirilen dikkat mekanizmalı modellerin klinik geçerliliği aynı veriyi kullanan ve yarışmada dereceye girmiş MedicAI ve itsALL-AI modelleri ile Çizelge 4.9’da karşılaştırılmıştır. Akut kolesistit, akut pankreatit, böbrek/üreter taşı ve AAA/diseksiyon sınıflarının tespit performansı kesinlik, duyarlılık, $mAP@0.50$ ve $mAP@0.50-0.95$ metrikleri kullanılarak için yapılmıştır.

Çizelge 4.9. Sınıf Bazlı Performans Karşılaştırması

Hastalık	Kaynak	Kesinlik	Duyarlılık	mAP@0,50	mAP@0,50–0,95
Akut Kolesistit	MedicAI	0,77	0,87	0,90	0,59
	itsALL-AI (Safra)	0,71	0,9	–	–
	YOLOv11n	0,88	0,85	0,91	0,58
	YOLOv11n + SiMAM (C3k2 ₁)	0,92	0,83	0,92	0,6
	YOLOv11n + EMA (C3k2 ₁)	0,9	0,8	0,89	0,58
	YOLOv11n + CA (C3k2 ₁₋₃)	0,9	0,81	0,9	0,6
Akut Pankreatit	MedicAI	0,75	0,7	0,74	0,37
	itsALL-AI (Pankreas)	0,82	0,96	–	–
	YOLOv11n	0,68	0,68	0,71	0,36
	YOLOv11n + SiMAM (C3k2 ₁)	0,69	0,68	0,71	0,35
	YOLOv11n + EMA (C3k2 ₁)	0,7	0,69	0,73	0,36
	YOLOv11n + CA (C3k2 ₁₋₃)	0,7	0,7	0,7	0,36
Böbrek / Üreter Taşı	MedicAI (Üreter)	0,71	0,85	0,85	0,34
	MedicAI (Böbrek)	0,58	0,60	0,57	0,24
	itsALL-AI	0,78	0,93	–	–
	YOLOv11n	0,59	0,53	0,5	0,17
	YOLOv11n + SiMAM (C3k2 ₁)	0,64	0,64	0,55	0,19
	YOLOv11n + EMA (C3k2 ₁)	0,68	0,62	0,61	0,21
AAA / Diseksiyon	YOLOv11n + CA (C3k2 ₁₋₃)	0,63	0,59	0,6	0,22
	MedicAI (Anevrizma)	0,95	0,95	0,98	0,73
	MedicAI (Diseksiyon)	0,45	0,2	0,25	0,05
	itsALL-AI (Aorta)	0,99	0,99	–	–
	YOLOv11n	0,94	0,89	0,95	0,66
	YOLOv11n + SiMAM (C3k2 ₁)	0,91	0,91	0,95	0,67
	YOLOv11n + EMA (C3k2 ₁)	0,91	0,91	0,95	0,66
	YOLOv11n + CA (C3k2 ₁₋₃)	0,92	0,92	0,96	0,67

Yarışmada birinci olan MedicAI [60] YOLOv5 tabanlı bir nesne tespit yaklaşımı kullanmış, DICOM formatındaki BT görüntülerini öncelikle HU değerlerine dönüştürmüştür. Ardından, görüntü kontrastını standartlaştırmak ve hedef dokuların daha belirgin hâle gelmesini sağlamak amacıyla pencereleme işlemi uygulanmıştır. YOLOv5x modeliyle yapılan eğitimler sonucunda, model tüm sınıflar genelinde %51,40 mAP@0,5 ve %55,20 duyarlılık (duyarlılık) elde etmiştir. Örnek sayısı daha yüksek olan sınıflarda daha yüksek başarı gözlenmiş; örneğin abdominal aort anevrizması sınıfında %97,90 mAP@0,5 değerine ulaşılırken, örnek sayısı düşük sınıflarda performansın belirgin biçimde azaldığı görülmüştür.

MedicAI modeli görsel olarak belirgin patolojilerde dengeli bir performans sergilerken, yarışmada ikinci olan itsALL-AI ensemble modeli [61] tüm sınıflarda çok yüksek duyarlılık değerleri raporlamış, ancak mAP değerlerinin eksikliği lokalizasyon doğruluğunun karşılaştırılmasını kısıtlamıştır. itsALL-AI kapsamlı bir model karşılaştırması ve birleştirme

(ensemble) yaklaşımı sunmuştur. Veri setini %80 eğitim ve %20 test olacak şekilde bölmüş ve MMDetection platformu kullanılarak Faster R-CNN, RetinaNet, FCOS, YOLOv3 ve Deformable DETR gibi 12 farklı nesne tespit modeli eğitmişlerdir. Veri setindeki sınıf dengesizliğinin model performansı üzerindeki olumsuz etkisini azaltmak amacıyla, bu modellerin tahminleri birleştirilerek ensemble bir yapı oluşturulmuştur. Elde edilen birleştirilmiş model, %64,50 mAP@0,5 başarımına ulaşmış ve bu değer, tekil modeller arasında en yüksek performansı gösteren Deformable DETR modelinin %59,70 mAP@0,5 skorunun üzerinde rapor edilmiştir.

Yarışmada üçüncü olan GAIa-TECH [62] veri setindeki görüntüleri bilateral filtresi, döndürme, bulanıklaştırma ve parlaklık/kontrast değişimi gibi veri artırma teknikleri kullanarak artırmıştır. Mish aktivasyon fonksiyonunun başarısı dolayısıyla YOLOv4 modeli tercih edilmiştir. Kullanılan YOLOv4 modeli, %82,56 doğruluk ve %84,56 doğrulama doğruluğu elde etmiştir. Sonuçlar diğer çalışmalardaki gibi keskinlik, duyarlılık, mAP@0,5 ve mAP@0,50-0,95 metrikleri ile verilmediği için Tablo 9'da yer verilmemiştir.

Temel YOLOv11n modeli, özellikle akut kolesistit ve AAA/diseksiyon sınıflarında MedicAI ile rekabet edebilen yüksek mAP değerleri elde etmiştir. Dikkat mekanizmalarının entegrasyonu bu performansı daha da iyileştirmiş; SimAM ile akut kolesistit sınıfında mAP@0.50 değeri 0.92'ye çıkarak MedicAI'e göre yaklaşık %2,2'lik bir üstünlük sağlanmış, CA mekanizması ile AAA/diseksiyon sınıfında mAP@0.50 0.96'ya yükselerek temel modele göre %1,1'lik bir iyileşme kaydedilmiştir. Böbrek/üreter taşı sınıfında bu çalışmada kullanılan tüm modeller görece düşük performans göstermiştir. Yarışmada dereceye giren çalışmalarda YOLOv3, YOLOv4 ve YOLOv5x gibi daha düşük YOLO versiyonları kullanılmasına rağmen bu çalışmada YOLOv11n modeli ile daha düşük performans elde edilmesinin nedeni kamuya açık hale getirilen veri setinde bulunan etiketleme eksiklikleridir. Sonuç olarak, ensemble modelleri yüksek duyarlılık sunarken, tek mimarili ve dikkat mekanizmalı modeller üstün lokalizasyon doğruluğu (mAP) ve denge sağlamış; dikkat mekanizmalarının stratejik entegrasyonunun, kritik metriklerde ölçülebilir iyileşmeler (%1,1-2,2) ile yarışma modelleriyle rekabet edebilen, pratik ve yüksek performanslı sistemler geliştirmeye katkıda bulunduğu gösterilmiştir.

5. SONUÇ VE ÖNERİLER

Bu tez kapsamında, acil servis koşullarında sık karşılaşılan abdominal patolojilerin BT kesitleri üzerinden otomatik tespiti ve sınıflandırılması için derin öğrenme tabanlı bir nesne tespit yaklaşımı geliştirilmiştir. TEKNOFEST Sağlıkta Yapay Zekâ Yarışması kapsamında paylaşılan TR_ABDOMEN_RAD_EMERGENCY veri seti üzerinde yürütülen deneylerde, veri setinin farklı hastaneler, BT cihazları ve çekim protokollerinden kaynaklanan heterojen yapısının modele olumsuz etkisini azaltmak amacıyla çok aşamalı bir ön işleme hattı uygulanmıştır. Yoğunlu dönüşümü ve pencereleme ile yumuşak doku kontrastı artırılmış; gürültü azaltma ve geometrik standardizasyon adımlarıyla görüntüler arası dağılım farkları azaltılarak model girişinde daha tutarlı bir temsil elde edilmiştir. Bu sayede, YOLOv11n tabanlı mimarinin abdominal patolojilerde yüksek doğrulukla çalışabildiği ve sınırlayıcı kutu tabanlı tespit yaklaşımının klinik açıdan anlamlı bölgesel işaretleme sağlayabildiği görülmüştür.

Model başarımı iki farklı veri kullanımı senaryosu altında değerlendirilmiştir. Görüntü bazlı veri kullanımı, veri setindeki benzer örneklerle performansı olduğundan yüksek gösterebilmektedir. Buna karşın hasta bazlı veri kullanımı, aynı hastaya ait kesitlerin farklı kümelerinde yer almasını engelleyerek klinik genellenebilirliği daha gerçekçi biçimde temsil etmektedir. Elde edilen sonuçlar, görüntü bazlı veri kullanımında genel mAP@0.5 değerinin 0,94 ve mAP@0.5:0.95 değerinin 0,67 olduğunu göstermiştir. Hasta bazlı veri kullanımında ise bu değerler sırasıyla 0,77 ve 0,44'e düşmüştür. Sınıf bazında ise akut kolesistitte mAP@0.5 0,91, akut pankreatitte 0,71, böbrek/üreter taşında 0,5 ve AAA/Diseksiyon sınıfında 0,95 olarak ölçülmüştür. Bu düşüş, abdominal BT'de cihaz, protokol ve hasta kaynaklı değişkenliğin model genellemesine doğrudan etki ettiğini; dolayısıyla klinik kullanıma yakın değerlendirme için hasta bazlı bölmenin kritik olduğunu ortaya koymaktadır.

Sınıf bazında değerlendirmelerde, abdominal aort anevrizması/diseksiyonu sınıfı daha belirgin anatomik yapı ve daha yüksek örnek sayısı gibi etkenler nedeniyle göreceli olarak daha yüksek performans sergilemiştir. Böbrek/üreter taşı sınıfı ise küçük lezyon karakteri, düşük kontrast ve örnek sayısı gibi nedenlerle en zor sınıflardan biri olarak öne çıkmıştır. Bu bulgu, küçük hedeflerde hem öznetelik çıkarımının hem de sınır kutusu regresyonunun

daha kırılgan olduğunu ve tespit performansının veri dengesizliğine daha duyarlı hale geldiğini göstermektedir.

Çalışmanın ana katkısı, EMA, SimAM ve CA dikkat mekanizmalarının model omurgasına kademeli entegrasyon stratejilerinin sistematik olarak araştırılması ve bu mekanizmaların performansa olan etkisinin nicellenmesidir. Her bir mekanizma için optimize edilmiş entegrasyon derinliği belirlenmiş; SimAM ve EMA için erken katmanda, CA için ise ilk üç katmanda kademeli entegrasyonun en etkili olduğu gösterilmiştir. Dikkat mekanizmaları, temel modelin genel performansını %2-3 oranında iyileştirirken, özellikle böbrek/üreter taşı gibi klinik açıdan zorlu sınıflarda %22'ye varan önemli mAP artışları sağlamıştır. Bu bulgu, dikkat mekanizmalarının modelin küçük ve düşük kontrastlı hedeflere odaklanma yeteneğini belirgin şekilde güçlendirdiğinin göstergesidir. Genel olarak, geliştirilen yaklaşımın abdominal acil patolojiler için hızlı bir ön değerlendirme sunabildiği; özellikle zaman baskısının yüksek olduğu klinik senaryolarda karar destek bileşeni olarak kullanılabilecek bir potansiyel taşıdığı değerlendirilmektedir. Dikkat mekanizmalarının entegrasyonu, modelin hem genel doğruluğunu hem de klinik açıdan zorlu sınıflardaki tespit başarısını anlamlı ölçüde iyileştirmiştir.

Geliştirilen modellerin klinik geçerliliği, aynı veri setini kullanan diğer çalışmalarla karşılaştırmalı analizle desteklenmiştir. Önerilen modeller, yüksek duyarlılık odaklı ensemble yöntemlerine kıyasla, üstün lokalizasyon doğruluğu (mAP) ve dengeli bir kesinlik-duyarlılık profili sergilemiştir. Örneğin akut kolesistit sınıfında, SimAM ile güçlendirilmiş model 0,92 mAP@0.50 değeri ile diğer yöntemlerden %2,2 oranında daha yüksek performans sergilemiştir.

Bu tez çalışmasının başlıca sınırlılığı, kullanılan veri setindeki etiketleme eksikliklerinden kaynaklanmaktadır. Veri seti orijinal olarak altı farklı abdominal patoloji sınıfı içermesine rağmen, akut apandisit ve akut divertikülit sınıflarına ait etiketlerdeki tutarsızlıklar ve eksiklikler nedeniyle bu iki sınıf çalışma kapsamına alınamamıştır. Dolayısıyla çalışma, mevcut dört sınıf (akut kolesistit, akut pankreatit, böbrek/üreter taşı, AAA/AAD) ile sınırlı kalmıştır. Ayrıca, çalışmaya dahil edilen böbrek/üreter taşı sınıfında da belirli sayıda görüntüde etiket eksikliği tespit edilmiş; bu durum, modelin bu sınıfa özgü öğrenme kapasitesini kısıtlayarak, özellikle duyarlılık ve ortalama kesinlik (mAP) metriklerinin beklenen seviyelerin altında kalmasına neden olmuştur. Ancak, böbrek taşı hastalığının

klirik pratikteki yaygınlığı ve acil tanıdaki kritik önemi göz önünde bulundurularak, mevcut kısmi etiketlerle birlikte bu sınıfın analize dahil edilmesi uygun görülmüştür. Bu sınırlılıklar, elde edilen sonuçların değerlendirilmesi ve genellenmesi noktasında dikkate alınmalıdır.

Sonuç olarak, bu çalışma stratejik olarak entegre edilen dikkat mekanizmalarının, tek ve verimli bir nesne tespit mimarisinin abdominal patoloji tespitindeki performansını ve güvenilirliğini anlamlı ölçüde artırabileceğini ortaya koymaktadır. Sunulan yaklaşım, acil radyoloji ve klinik karar destek sistemleri için hızlı bir ön değerlendirme aracı olarak potansiyel taşımaktadır. Gelecek çalışmalar, farklı dikkat mekanizmalarının hibrit kullanımını, kesitler arası bağlamı yakalayan 3B mimarileri ve bu sistemlerin gerçek zamanlı klinik iş akışlarına entegrasyonunu araştırmayı hedeflemelidir.



KAYNAKLAR

1. Hu, P., Li, J., Wang, Y., ve Kong, D. (2025). Deep learning in abdominal organ segmentation: A review. *Intelligent Oncology*, 1(4), 277–289.
2. Yew, K. S., George, M. K., ve Allred, H. B. (2023). Acute abdominal pain in adults: Evaluation and diagnosis. *American Family Physician*, 107(6), 585–596.
3. Kumari, S., Verma, A., Pratap, A., Chouhan, S., Tiwari, A., Singh, V., Karn, E. (2024). Effectiveness of contrast-enhanced computed tomography in whole abdominal disease identification: A review. *International Journal of Medical Science in Clinical Research and Review*, 7(4), 700–709.
4. Hu, J. X., Zhao, C. F., Wang, S. L., Tu, X. Y., Huang, W. B., Chen, J. N., Xie, Y., Chen, C. R. (2023). Acute pancreatitis: A review of diagnosis, severity prediction and prognosis assessment from imaging technology, scoring system and artificial intelligence. *World Journal of Gastroenterology*, 29(37), 5268–5291.
5. Bargagli, M., Scoglio, M., Howles, S. A., ve Fuster, D. G. (2021). Kidney stone disease: risk factors, pathophysiology and management. *Nature Reviews Nephrology*, 17(12), 794–808.
6. Yoon, M. S., Jang, D. H., Lee, J., Jeong, J., Kim, D. G., Lim, H., Lee, D. K., Oh, J. (2025). Comparison of actual and automated CT measurements of urinary stone size: a phantom study. *Urolithiasis*, 53(1), 71.
7. Patel, R., Tse, J. R., Shen, L., Bingham, D. B., ve Kamaya, A. (2024). Improving diagnosis of acute cholecystitis with US: New paradigms. *RadioGraphics*, 44(12), e240032.
8. Wanhainen, A., Van Herzele, I., Bastos Goncalves, F., Bellmunt Montoya, S., Berard, X., Boyle, J. R., ... Yeung, K. K. (2024). Editor's Choice – European Society for Vascular Surgery (ESVS) 2024 Clinical practice guidelines on the management of abdominal aorto-iliac artery aneurysms. *European Journal of Vascular and Endovascular Surgery*, 67(2), 192–331.
9. Yang, Y., Ye, L., ve Feng, Z. (2025). Application of artificial intelligence in medical imaging: Current status and future directions. *iRADIOLOGY*, 3, 144–151.
10. Keni, S. (2024). Evaluating artificial intelligence for medical imaging: a primer for clinicians. *British Journal of Hospital Medicine*, 85(7), 1–13.
11. Sezdi, M., ve Artuğ, N. T. (2024, Eylül 26-28). *The Impact of Artificial Intelligence on Medical Imaging Technologies*. Paper presented at the TIPTEKNO 2024 - Medical Technologies Congress, Muğla, 1-4.
12. Wu, X., Zhang, H., Sun, J., Wang, S., ve Zhang, Y. (2024). YOLO-MSRF for lung nodule detection. *Biomedical Signal Processing and Control*, 94, 106318.

13. Jing, X., Dorrius, M. D., Zheng, S., Wielema, M., Oudkerk, M., Sijens, P. E., ve van Ooijen, P. M. A. (2024). Localization of contrast-enhanced breast lesions in ultrafast screening MRI using deep convolutional neural networks. *European Radiology*, 34(3), 2084–2092.
14. Pacal, I., Karaman, A., Karaboga, D., Akay, B., Basturk, A., Nalbantoglu, U., ve Coskun, S. (2022). An efficient real-time colonic polyp detection with YOLO algorithms trained by using negative samples and large datasets. *Computers in Biology and Medicine*, 141, 105031.
15. Cai, Z., Zhou, K., ve Liao, Z. (2025). A systematic review of YOLO-Based object detection in medical imaging: Advances, challenges, and future directions. *Computers, Materials & Continua*, 85(2), 2255-2303.
16. Guo, M. H., Xu, T. X., Liu, J. J., Liu, Z. N., Jiang, P. T., Mu, T. J., Zhang, S.H., Martin, R. R., Cheng, M. M., Hu, S. M. (2022). Attention mechanisms in computer vision: A survey. *Computational Visual Media*, 8(3), 331-368.
17. Yu, C. J., Yeh, H. J., Chang, C. C., Tang, J. H., Kao, W. Y., Chen, W. C., Su, E. C. Y. (2021). Lightweight deep neural networks for cholelithiasis and cholecystitis detection by point-of-care ultrasound. *Computer Methods and Programs in Biomedicine*, 211, 106382.
18. Yang, C., Kao, H., Chen, Y. C., Kuo, C., Liu, C. H., ve Liu, S. (2025). Automated CT image prescription of the gallbladder using deep learning: Development, evaluation, and health promotion. *Acute Medicine & Surgery*, 12(1), e70049.
19. Chen, H., Wen, Y., Li, X., Li, X., Su, L., Wang, X., Wang, F., Liu, D. (2025). Integrating CT-based radiomics and clinical features to better predict the prognosis of acute pancreatitis. *Insights into Imaging*, 16(1), 8.
20. Zhang, C., Peng, J., Wang, L., Wang, Y., Chen, W., Sun, M. W., ve Jiang, H. (2024). A deep learning-powered diagnostic model for acute pancreatitis. *BMC Medical Imaging*, 24(1), 154.
21. Asif, S., Zhao, M., Chen, X., ve Zhu, Y. (2023). StoneNet: An efficient lightweight model based on depthwise separable convolutions for kidney stone detection from CT images. *Interdisciplinary Sciences: Computational Life Sciences*, 15(4), 633–652.
22. Almuayqil, S. N., Abd El-Ghany, S., Abd El-Aziz, A. A., ve Elmogy, M. (2024). KidneyNet: A novel CNN-based technique for the automated diagnosis of chronic kidney diseases from CT scans. *Electronics*, 13(24), 4981.
23. Tang, J., Li, Y., ve Wang, J. (2025, Haziran 14-16). *YOLO-C3AC: An efficient deep learning method for CT image detection of kidney stones*. Paper presented at the BDCTA 2025 - International Conference on Big Data, Communication Technology and Computer Applications, Malaysia, 28-35.
24. Abdimurotovich, K. A., ve Cho, Y. I. (2024). Optimized YOLOv5 architecture for superior kidney stone detection in CT scans. *Electronics*, 13(22), 4418.

25. Xing, Z., Zhu, Z., Jiang, Z., Zhao, J., Chen, Q., Xing, W., Liu, A., Ding, J. (2024). Automatic urinary stone detection system for abdominal non-enhanced CT images reduces the burden on radiologists. *Journal of Imaging Informatics in Medicine*, 37(2), 444–454.
26. Parakh, A., Lee, H., Lee, J. H., Eisner, B. H., Sahani, D. V., ve Do, S. (2019). Urinary stone detection on ct images using deep convolutional neural networks: Evaluation of model performance and generalization. *Radiology: Artificial Intelligence*, 1(4), e180066.
27. Chatterjee, D., Shen, T. C., Mukherjee, P., Lee, S., Garrett, J. W., Zacharias, N., Pickhardt, P. J., Summers, R. M. (2024). Automated detection of incidental abdominal aortic aneurysms on computed tomography. *Abdominal Radiology*, 49(2), 642–650.
28. Baltacı, H., Yalcin, S., Yildirim, M., ve Bingol, H. (2023). Automatic diagnosis, classification, and segmentation of abdominal aortic aneurysm and dissection from computed tomography images. *Diagnostics*, 13(15), 2476.
29. Noor, M. (2023). An Overview of Computed Tomography: What it is and how it works? Applications of computed tomography. *Imaging in Medicine*, 15(5), 93–94.
30. Shaji, A., Fidha, A., Kumari, S., Dabholkar, A. D., ve Gaonkar, O. U. (2024). Recent advancements in CT aetectors: A comprehensive review. *Journal of Clinical and Diagnostic Research*, 18(12), TE01-TE05.
31. Akkaş, A., Kavak, A. G., Demir, H., Kaya, M. A., Çatlı Dinç, S., ve Nur, S. (2024). *Radyasyon uygulamaları ve radyasyondan korunma* (1. Baskı). İstanbul: Özgür Yayınları, 21-22.
32. Rogers, D. C., ve Tadi, P. (2025). *Intravenous contrast* (1. Baskı). Treasure Island (FL): StatPearls Publishing, 215-220.
33. Rastogi, S., Singh, R., Borse, R., Valkovic Zujic, P., Segota, D., Diklic, A., Jurkovic, S., Ali, A., Mohammed Kharita, H., Al-Naemi, H. M., Alkalbani, J., Al-Rasbi, A., Gershan, V., Galic, S., Yusuf, M., Avramova-Cholakova, S., Zulkipli, I. M. B. H., Shein, N., Teferi, S., Rehani, M. M., Vassileva, J., Kalra, M. K. (2021). Use of multiphase CT protocols in 18 countries: Appropriateness and radiation doses. *Canadian Association of Radiologists Journal*, 72(3), 381–387.
34. Esen, K., ve Apaydın, F. D. (2020). Abdominal incelemelerde ileri BT teknikleri ve protokolleri. *Türk Radyoloji Seminerleri Dergisi*, 8(1), 21–37.
35. İnternet: Teknofest. (t.y.). *Hakkımızda*. URL: <https://www.teknofest.org/tr/corporate/about/>, Son Erişim Tarihi: 18.11.2025
36. Koç, U., Sezer, E. A., Özkaya, Y. A., Yarbay, Y., Beşler, M. S., Taydaş, O., Yalçın, A., Evrimler, Ş., Kızıloğlu, H. A., Kesimal, U., Atasoy, D., Oruç, M., Ertuğrul, M., Karakaş, E., Karademir, F., Sebik, N. B., Topuz, Y., Aktan, M. E., Sezer, Ö., Aydın, Ş., Varlı, S., Akdoğan, E., Ülgü, M. M., Birinci, Ş. (2024). Elevating healthcare through artificial intelligence: analyzing the abdominal emergencies data set (TR_ABDOMEN_RAD_EMERGENCY) at TEKNOFEST-2022. *European Radiology*, 34(6), 3588–3597.

37. İnternet: T.C. Sağlık Bakanlığı. (2022). *TR_Abdomen Rad_Emergency veriseti (Teknofest 2022)*. URL: <https://acikveri.saglik.gov.tr/Home/DataSetDetail/2>, Son Erişim Tarihi: 16.11.2025
38. Kalender, W. A. (2011). *Computed tomography: fundamentals, system technology, image quality, applications* (3rd Ed.). Weinheim: Wiley-VCH, 200-250.
39. Perona, P., ve Malik, J. (1990). Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(7), 629–639.
40. Thakur, N., Khan, N. U., ve Sharma, S. D. (2021). A review on performance analysis of PDE based anisotropic diffusion approaches for image enhancement. *Informatica*, 45(6), 87-112.
41. Kaur, R., ve Juneja, M. (2022). A hybrid approach for enhancement of abdominal CT images. *Computers and Electrical Engineering*, 102, 108291.
42. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88.
43. Gong, L., Liu, L., Liu, G., Bai, H., Wang, D., ve Wang, H. (2026). PLNM-YOLO: Pelvic lymph node metastasis detection algorithm in gynaecological tumours based on edge-aware and multi-scale feature fusion. *Biomedical Signal Processing and Control*, 112, 108358.
44. İnternet: Ultralytics. (t.y.). *YOLOv7 vs. YOLO11: Evolution of real-time object detection*. URL: <https://docs.ultralytics.com/compare/yolov7-vs-yolo11/#model-performance-comparison>, Son Erişim Tarihi: 22.06.2025
45. İnternet: Khanam, R., ve Hussain, M. (2024). *Yolov11: An overview of the key architectural enhancements*. URL: arXiv preprint arXiv:2410.17725, Son Erişim Tarihi: 22.10.2025
46. İnternet: Emergent Mind. (t.y.). *YOLOv11 object detection*. URL: <https://www.emergentmind.com/topics/yolov11-object-detection>, Son Erişim Tarihi: 22.10.2025
47. Gong, X., Yu, J., Zhang, H., ve Dong, X. (2025). AED-YOLO11: A small object detection model based on YOLO11. *Digital Signal Processing*, 166, 105411.
48. Murat, A. A., ve Kiran, M. S. (2025). A comprehensive review on YOLO versions for object detection. *Engineering Science and Technology, an International Journal*, 70, 102161.
49. Chen, F., Zhang, Y., Fu, L., Hua, R., Zhang, Q., ve Bi, S. (2025). A comparative review of the next-generation YOLO models: YOLOv10 and YOLO11. *Journal of Computer Science and Artificial Intelligence*, 3(2), 1-6.

50. İnternet: Jegham, N., Koh, C. Y., Abdelatti, M., ve Hendawi, A. (2024). *YOLO evolution: A comprehensive benchmark and architectural review of YOLOv12, YOLO11, and their previous versions*. URL: arXiv preprint arXiv:2411.00201, Son Erişim Tarihi: 22.10.2025.
51. Li, X., Li, M., Yan, P., Li, G., Jiang, Y., Luo, H., ve Yin, S. (2023). Deep learning attention mechanism in medical image analysis: Basics and beyonds. *International Journal of Network Dynamics and Intelligence*, 2(1), 93–116.
52. Ouyang, D., He, S., Zhang, G., Luo, M., Guo, H., Zhan, J., ve Huang, Z. (2023, Haziran 4-10). *Efficient multi-scale attention module with cross-spatial learning*. Paper presented at the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Rhodes Island, 1-5.
53. Yang, L., Zhang, R. Y., Li, L., ve Xie, X. (2021, Temmuz 18-24). *SimAM: A simple, parameter-free attention module for convolutional neural networks*. Paper presented at the 38th International Conference on Machine Learning, PMLR, Virtual, 139, 11863-11874.
54. Hou, Q., Zhou, D., ve Feng, J. (2021, Temmuz 19-25). *Coordinate attention for efficient mobile network design*. Paper presented at the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Nashville, 13708-13717.
55. Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R., ve Ren, D. (2020, Şubat 7-12). *Distance-IoU loss: Faster and better learning for bounding box regression*. Paper presented at the AAAI Conference on Artificial Intelligence, New York, 34(7), 12993-13000.
56. Li, X., Wang, W., Wu, L., Chen, S., Hu, X., Li, J., Tang, J., Yang, J. (2020, Aralık 6-12). *Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection*. Paper presented at the Advances in Neural Information Processing Systems (NeurIPS), Vancouver, 33, 21002-21012.
57. Terven, J., Cordova-Esparza, D. M., Romero-González, J. A., Ramírez-Pedraza, A., ve Chávez-Urbiola, E. A. (2025). A comprehensive survey of loss functions and metrics in deep learning. *Artificial Intelligence Review*, 58(7), 195.
58. İnternet: Ruder, S. (2016). *An overview of gradient descent optimization algorithms*. URL: arXiv preprint arXiv:1609.04747, Son Erişim Tarihi: 22.10.2025.
59. İnternet: Grandini, M., Bagli, E., ve Visani, G. (2020). *Metrics for multi-class classification: An overview*. URL: arXiv preprint arXiv:2008.05756, Son Erişim Tarihi: 22.10.2025.
60. İnternet: Türkiye Sağlık Enstitüleri Başkanlığı (TÜSEB). (2022). *TEKNOFEST 2022 Sağlıkta Yapay Zekâ Yarışmaları: Bilgisayarlı Görüyle Abdomen (Karın) Bölgesi için Hastalık Tespiti Kategorisi – Proje Detay Raporu*. URL: <https://www.teknofest.org/tr/yarismalar/saglikta-yapay-zeka-yarismasi/>, Son Erişim Tarihi: 16.06.2025.

61. İnternet: itsALL-AI Takımı. (2022). *TEKNOFEST 2022 Sağlıkta Yapay Zekâ Yarışmaları: Bilgisayarlı Görüyle Abdomen (Karın) Bölgesi için Hastalık Tespiti Kategorisi – Proje Detay Raporu*. URL: <https://www.teknofest.org/tr/yarismalar/saglikta-yapay-zeka-yarismasi/>, Son Erişim Tarihi: 16.06.2025
62. İnternet: Türkiye Sağlık Enstitüleri Başkanlığı (TÜSEB). (2022). *TEKNOFEST 2022 Sağlıkta Yapay Zekâ Yarışmaları: Bilgisayarlı Görüyle Abdomen (Karın) Bölgesi için Hastalık Tespiti Kategorisi – Proje Detay Raporu*. URL: <https://www.teknofest.org/tr/yarismalar/saglikta-yapay-zeka-yarismasi/>, Son Erişim Tarihi: 16.06.2025





Gazili olmak ayrıcalıktır