



**T.C.
AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BEYİN MR GÖRÜNTÜLERİNİN İYİLEŞTİRİLMESİ
VE DERİN ÖĞRENME METOTLARI İLE BEYİN TÜMÖRÜ TESPİTİ**

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

HAMİ KARA

EYLÜL

**BEYİN MR GÖRÜNTÜLERİNİN İYİLEŞTİRİLMESİ
VE DERİN ÖĞRENME METOTLARI İLE BEYİN TÜMÖRÜ TESPİTİ**

Hami KARA

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**Danışman
Dr. Öğr. Üyesi Erhan BERGİL**

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

EYLÜL 2025

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Hami KARA tarafından hazırlanan “Beyin MR Görüntülerinin İyileştirilmesi ve Derin Öğrenme Metotları ile Beyin Tümörü Tespiti” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Erhan BERGİL

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....

Başkan : Dr. Öğr. Üyesi Canan ORAL

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....

Üye : Dr. Öğr. Üyesi Yavuz Ünal

Bilgisayar Mühendisliği Anabilim Dalı, Sinop Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....

Tez Savunma Tarihi: 18/09/2025

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Amasya 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.

(İmza)

Hami KARA

(Tarih)

Beyin MR Görüntülerinin İyileştirilmesi
ve Derin Öğrenme Metotları ile Beyin Tümörü Tespiti
(Yüksek Lisans Tezi)

Hami KARA

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Eylül 2025

ÖZET

Bu çalışmanın temel amacı, beyin tümörü içeren manyetik rezonans görüntülerinde derin öğrenme tabanlı nesne tespiti modelleri kullanılarak, farklı görüntü iyileştirme yöntemlerinin model performansı üzerindeki etkilerini sistematik biçimde incelemektir. Erken ve doğru teşhisin klinik açıdan kritik öneme sahip olması nedeniyle, görüntülerdeki gürültü, kontrast düzensizlikleri ve düşük kalite sorunlarını azaltmak için Gauss, medyan, Wiener, CLAHE ve morfolojik işlemler ile bu yöntemlerin ikili kombinasyonları uygulanmıştır.

Çalışmada 780 adet tümörlü MR görüntüsünden oluşan bir veri seti kullanılmıştır. YOLOv8, SSD MobileNet-V2 ve DETR modelleri hem ham hem de iyileştirilmiş görüntüler üzerinde test edilmiştir. Derin öğrenme modellerinin performans değerlendirmesinde mAP@0.5, mAP@[0.5:0.95], kesinlik (precision), duyarlılık (recall) ölçütleri kullanılırken, görüntü iyileştirme aşamasında ise MSE, PSNR ve SSIM ölçütleri kullanılmıştır. Özellikle Gauss filtresi, MSE değerlerini düşürüp PSNR ve SSIM değerlerini artırarak görüntü kalitesinde belirgin bir iyileşme sağlamıştır.

Elde edilen sonuçlar, görüntü iyileştirmenin özellikle SSD modelinde belirgin şekilde pozitif katkı sağladığını; YOLOv8 ve DETR modellerinde ise kullanılan yönteme bağlı olarak etkilerin sınırlı veya değişken olabildiğini göstermektedir. SSD modeli, iyileştirme sonrası güven skorunda %12, mAP değerinde ise yaklaşık %9,8 oranında artışla en yüksek performans kazanımını göstermiştir. Gauss-Kapama kombinasyonu DETR için en iyi sonucu verirken, CLAHE-Genişleme 3 derin öğrenme modelinde de performans düşüşüne yol açmıştır. Genel olarak, bulanıklık ve morfolojik işlemlerin birlikte kullanımı, özellikle SSD modelinde güven skorunda yaklaşık %10 oranında artış sağlarken, YOLOv8 ve DETR modellerinde ise yöntem türüne bağlı olarak daha sınırlı ancak ölçülebilir düzeyde performans değişimleri gözlemlenmiştir. Bu bulgular, görüntü iyileştirme stratejilerinin, kullanılan derin öğrenme modellerinin mimari özellikleriyle birlikte ele alınması gerektiğini ortaya koymaktadır.

Sayfa Adedi	: 100
Anahtar Kelimeler	: Derin öğrenme, Nesne tespiti, Beyin tümörü, Görüntü iyileştirme
Danışman	: Dr. Öğr. Üyesi Erhan BERGİL

ENHANCEMENT OF BRAIN MR IMAGES AND DETECTION OF BRAIN TUMORS WITH DEEP LEARNING METHODS

(M. Sc. Thesis)

Hami KARA

AMASYA UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

September 2025

ABSTRACT

The primary aim of this study is to employ deep learning-based object detection models on magnetic resonance MR images containing brain tumors and to systematically examine the effects of different image enhancement methods on model performance. Since early and accurate diagnosis is clinically crucial, Gaussian, median, Wiener, CLAHE, and morphological operations, as well as their pairwise combinations, were applied to reduce noise, contrast irregularities, and low-quality artifacts in the images.

The study was conducted using a dataset consisting of 780 MR images containing brain tumors. YOLOv8, SSD MobileNet-V2, and DETR models were tested on both raw and enhanced images. In the performance evaluation of deep learning models, mAP@0.5, mAP@[0.5:0.95], precision, and recall metrics were employed, whereas in the image enhancement stage, MSE, PSNR, and SSIM metrics were utilized. In particular, Gaussian filtering significantly reduced MSE values and improved PSNR and SSIM metrics, leading to a clear enhancement in image quality.

The results indicate that image enhancement provided a notably positive contribution, especially for the SSD model, while its effects on YOLOv8 and DETR models were more limited or varied depending on the method applied. The SSD model achieved the highest performance gain, with a 12% increase in confidence scores and approximately a 9.8% improvement in mAP after enhancement. The Gaussian-Closing combination yielded the best results for the DETR model, whereas CLAHE-Dilation led to performance degradation in all three deep learning models. Overall, combining blurring and morphological operations resulted in an approximate 10% increase in confidence scores for SSD and produced more limited but measurable performance variations for YOLOv8 and DETR depending on the applied method. These findings highlight that image enhancement strategies should be evaluated in conjunction with the architectural characteristics of the deep learning models used.

Number of pages	: 100
Keywords	: Deep learning, Object detection, Brain tumor, Image enhancement
Supervisor	: Asst. Prof. Dr. Erhan BERGİL

ÖN SÖZ VE TEŞEKKÜR

Beyin MR görüntülerinde tümör tespiti, erken teşhis ve tedavi süreçlerinde kritik öneme sahiptir. Bu tanısal yöntemlerin, erişilebilir sistemlerle uygulanabilmesi, sağlık hizmetlerinde daha kapsayıcı ve verimli çözümlerin geliştirilmesine imkan tanıyacaktır. Böylece, daha fazla hastaya zamanında tanı konulabilecek ve uygun tedaviye erişimleri kolaylaşacaktır.

Bu özverili çalışmanın her aşamasında desteklerini esirgemeyen, sabırla rehberlik eden, bilgi ve deneyimleriyle vizyonumu genişleten ve üzerimde büyük emeği olan değerli hocam Dr. Öğr. Üyesi Erhan Bergil'e en derin saygı ve minnet duygularıyla teşekkürlerimi sunarım.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ VE TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xiii
1. GİRİŞ	1
2. GENEL BİLGİLER	4
2.1. Beyin Tümörü.....	4
2.2. Tanı Sistemleri	5
2.3. Literatürdeki Çalışmalar.....	8
2.3.1. Derin öğrenme tabanlı beyin tümörü tespiti	8
2.3.2. Derin öğrenme tabanlı beyin tümörü tespiti üzerine görüntü iyileştirme çalışmaları.	10
3. MATERYAL VE METOT	14
3.1. Veri Setinin Oluşturulması.....	17
3.1.1. Görüntü iyileştirme.....	18
3.2. Derin Öğrenme.....	31
3.2.1. Single Shot Detector (SSD).....	33
3.2.2. You Only Look Once (YOLO).....	37
3.2.3. DEtection TRansformer (DETR).....	40

3.3. Derin Öğrenme Performans Metrikleri	45
3.3.1. Temel sınıflandırma metrikleri	45
3.3.2. Nesne tespiti ve segmentasyon metrikleri	47
4. BULGULAR.....	50
4.1. Görüntü İyileştirme Metotlarının Performans Analizi	53
4.1.1. Morfolojik işlemlerin görüntüye etkisi	53
4.1.2. Gauss bulanıklığı yönteminin görüntüye etkisi	57
4.1.3. CLAHE yönteminin görüntüye etkisi	59
4.1.4. Wiener filtresinin görüntüye etkisi	60
4.1.5. Medyan filtrenin görüntüye etkisi	61
4.1.6. İyileştirme yöntemlerinin ikili kombinasyonlarının görüntüye etkisi ve iyileştirme metotlarının karşılaştırılması	63
4.2. Derin Öğrenme Metotlarının Orijinal Görüntülerdeki Algılama Performansı ...	67
4.3. SSD Üzerindeki İyileştirme Çalışmalarının Sonuçları	70
4.4. YOLO Üzerindeki İyileştirme Çalışmalarının Sonuçları	75
4.4. DETR Üzerindeki İyileştirme Çalışmalarının Sonuçları	79
4.5. Derin Öğrenme Metotlarının Performanslarının Karşılaştırılması	81
4.6. Önceki Çalışmalarla Karşılaştırmalar	88
5. SONUÇ	90
KAYNAKLAR	92
ÖZGEÇMİŞ	100

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 4.1. Aşındırma işlemi analiz değerleri.	54
Çizelge 4.2. Genişleme işlemi analiz değerleri.	55
Çizelge 4.3. Açma işlemi analiz değerleri.	55
Çizelge 4.4. Kapama işlemi analiz değerleri.	57
Çizelge 4.5. Gauss Bulanıklaştırma işlemi analiz değerleri.	58
Çizelge 4.6. CLAHE yöntemi analiz değerleri.	59
Çizelge 4.7. Wiener filtresi analiz değerleri.	61
Çizelge 4.8. Medyan yöntemi analiz değerleri.	62
Çizelge 4.9. İyileştirme metotlarının ikili kombinasyonlarının performans analizi.	64
Çizelge 4.10. SSD modelinin iyileştirme metotlarındaki performans analizi.	72
Çizelge 4.11. YOLO modelinin iyileştirme metotlarındaki performans analizi.	76
Çizelge 4.12. DETR modelinin iyileştirme metotlarındaki performans analizi.	79
Çizelge 4.13. İyileştirme öncesi algılama performansı.	85
Çizelge 4.14. İyileştirme sonrası en kötü algılama performansı.	85
Çizelge 4.15. İyileştirme sonrası en iyi algılama performansı.	85

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 3.1. Tez çalışmasının tekil iyileştirme metotlarıyla uygulanmış akış diyagramı. .	15
Şekil 3.2. İkili kombinasyon uygulanan akış diyagramı.....	16
Şekil 3.3. Eğitilen MR veri setleri.	17
Şekil 3.4. Tümör etiketleme programı labelmap kullanımı.	18
Şekil 3.5. 3x3 Medyan filtrenin bir görüntü matrisine uygulanması.	29
Şekil 3.6. Medyan bulanıklaştırma örneği.	30
Şekil 3.7. SSD, YOLO ve DETR modeli mimarileri.....	32
Şekil 3.8. SSD mimarisi.....	33
Şekil 3.9. Nesnelerin 4x4 ve 8x8 çerçeveleri için pozisyon ve doğruluk değerleri.....	34
Şekil 3.10. SSD eğitiminde kesinlik ve duyarlılık grafiği.	34
Şekil 3.11. SSD ve MobileNet mimari birleşimi.	36
Şekil 3.12. YOLO algılama süreci.....	38
Şekil 3.13.YOLO eğitiminde kesinlik ve duyarlılık grafiği.	39
Şekil 3.14. DETR modeli genel yapısı.....	40
Şekil 3.15. DETR modeli mimarisi.....	41
Şekil 3.16. Kod çözücünün performansa etkisi.	43
Şekil 3.17. DETR eğitiminde keskinlik ve duyarlılık grafiği.	44
Şekil 4.1. (a) 9 kernel değerinde gauss filtresi, (b) 24 kernel değerinde gauss filtresi..	50
Şekil 4.2. (a)SSD eğitim sonuç görüntüsü, (b)YOLO eğitim sonuç görüntüsü, (c) DETR eğitim sonuç görüntüsü.	51
Şekil 4.3. Nesne eğitimi ilerleme bilgisi 1.....	51
Şekil 4.4. Nesne eğitimi ilerleme bilgisi 2.....	52

Şekil 4.5. (a) kernel değeri 5 için aşındırılmış görüntü, (b) kernel değeri 7 için aşındırılmış görüntü, (c) kernel değeri 9 için aşındırılmış görüntü, (d) kernel değeri 11 için oluşturulan aşındırılmış görüntü.	53
Şekil 4.6. (a) kernel değeri 5 için genişletilmiş görüntü, (b) kernel değeri 7 için genişletilmiş görüntü, (c) kernel değeri 9 için genişletilmiş görüntü, (d) kernel değeri 11 için genişletilmiş görüntü.	54
Şekil 4.7. (a) kernel değeri 5 için açılmış görüntü. (b) kernel değeri 7 için açılmış görüntü (c) kernel değeri 9 için açılmış görüntü (d) kernel değeri 11 için açılmış görüntü.	55
Şekil 4.8. (a) 5 kernel değeri 5 için kapanmış görüntü, (b) kernel değeri 7 için kapanmış görüntü, (c) kernel değeri 9 için kapanmış görüntü, (d) kernel değeri 11 için kapanmış görüntü.	56
Şekil 4. 9. (a) kernel değeri 5 için gauss bulanıklaştırılmış görüntü, (b) kernel değeri 7 için gauss bulanıklaştırılmış görüntü, (c) kernel değeri 9 için gauss bulanıklaştırılmış görüntü, (d) kernel değeri 11 için gauss bulanıklaştırılmış görüntü.	58
Şekil 4.10. (a) kernel değeri 5 için CLAHE uygulanmış görüntü, (b) kernel değeri 7 için CLAHE uygulanmış görüntü, (c) kernel değeri 9 için CLAHE uygulanmış görüntü, (d) kernel değeri 11 için CLAHE uygulanmış görüntü.	59
Şekil 4.11. (a) kernel değeri 5 için wiener filtreli görüntü. (b) kernel değeri 7 için wiener filtreli görüntü. (c) kernel değeri 9 için wiener filtreli görüntü. (d) kernel değeri 11 için wiener filtreli görüntü.	60
Şekil 4.12. (a) kernel değeri 5 için medyan filtreli görüntü. (b) kernel değeri 7 için medyan filtreli görüntü (c) kernel değeri 9 için medyan filtreli görüntü (d) kernel değeri 11 için medyan filtreli görüntü.	62
Şekil 4.13. SSD modeli orijinal algılama görüntüsü.	68
Şekil 4.14. YOLO modeli orijinal algılama görüntüsü.	68
Şekil 4.15. DETR modeli orijinal algılama görüntüsü.	69
Şekil 4.16. Modellerin orijinal görüntüler üzerindeki ortalama güven skoru.	69
Şekil 4.17. SSD modeli farklı kernel değerlerinde algılama performansı.	71
Şekil 4.18. SSD ile görüntü iyileştirmenin algılamaya yüzdelik katkısı.	74
Şekil 4.19. (a) SSD orijinal algılama (%76), (b) SSD, Gauss-Morfolojik kapama kombinasyon algılaması (%84).	75
Şekil 4.20. YOLO ile görüntü işlemenin algılamaya yüzdelik katkısı.	77

Şekil 4.21. (a)YOLO, orijinal algılama (%79), (b) YOLO, CLAHE – Morfolojik Kapama kombinasyon (%84) algılaması.	78
Şekil 4.22. DETR ile görüntü işlemenin algılamaya yüzdelik katkısı.	80
Şekil 4.23. (a) DETR orijinal algılama (%85), (b) DETR, Medyan-açma kombinasyon algılaması (%84).....	81
Şekil 4.24. SSD, YOLO ve DETR modellerinin karşılaştırma grafiği.	82
Şekil 4.25. YOLO, SSD, DETR modellerinin kesinlik-duyarlılık grafiği.....	84



SİMGELER VE KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, yanda açıklamaları verilmek üzere aşağıda listelenmiştir.

Simgeler

Açıklama

%	Yüzde
&	Ve
$\ominus$	Morfolojik Aşındırma
$\oplus$	Morfolojik Genişleme
◦	Morfolojik açma işlemi
•	Morfolojik kapama işlemi
σ	Gauss standart sapması
$p(r)$	Keskinliğin duyarlılığa bağlı gösterimi

Kısaltmalar

Açıklama

MRG	Manyetik Rezonans Görüntüleme
CLAHE	Contrast Limited Adaptive Histogram Equalization
SSD	Single Shot Multibox Detector
CNN	Convolutional Neural Network
YOLO	You Only Look Once
ESA	Evrişimli Sinir Ağı
FLAIR	Fluid-Attenuated Inversion Recovery
CE-T1w	Contrast-enhanced T1-weighted
BOS	Beyin Omurilik Sıvısı
GBM	Glioblastoma

MEN	Meningioma
MSS	Merkezi Sinir Sistemi
WHO	World Health Organization
PET	Pozitron Emisyon Tomografisi
CT	Bilgisayarlı Tomografi
DSA	Derin Sinir Ağı
PSF	Nokta Yayılım Fonksiyonu
DOG	Difference of Gauss
k-EYK	K En Yakın Komşu
PSNR	Pik-Sinyal Gürültü Oranı
KDF	Kümülatif Dağılım Fonksiyonları
BS	Blok Boyutu
CL	Kırpma Limiti
HE	Histogram Eşitleme
AHE	Adaptif Histogram Eşitleme
LTI	Lineer Zamanla Değişmeyen
VGG	Visual Geometry Group
MSE	Ortalama Kare Hata
SNR	Sinyal Gürültü Oranı
mAP	Mean Average Precision
SIFT	Scale-Invariant Feature Transform
CBCT	Cone Beam Computed Tomography
DNN	Deep Neural Network
DL	Deep Learning
ML	Machine Learning

KVM	Destek Vektör Makinesi
SSIM	Yapısal Benzerlik İndeksi
ABTA	American Brain Tumor Association
AP	Average Precision
TP	Doğru Pozitif
FP	Yanlış Pozitif
FN	Yanlış Negatif
TN	Doğru Negatif

1. GİRİŞ

Beyin tümörü, beyinde anormal hücrelerin bulunduğu kanserli bir hastalıktır (Ezhilarasi ve Varalakshmi, 2018). Bu, beynin kontrol mekanizmalarından kurtularak anormal beyin hücrelerinin çoğalmasıyla oluşan kitlelerin gelişmesidir. Kafatası içinde oluşabilen tümörler büyüyebilir, beyne baskı yapabilir ve vücut sağlığını olumsuz etkileyebilir (Irmak, 2021). Beyin tümörleri, beyindeki konumlarına ve büyümelerine göre yüzden fazla farklı türe ayrılabilir (Ezhilarasi ve Varalakshmi, 2018). Genel olarak iyi huylu (benign) ve kötü huylu (malign) olarak sınıflandırılabilirler (Ezhilarasi ve Varalakshmi, 2018; Irmak, 2021). İyi huylu tümörler şekilde bir miktar düzgünlüğe sahiptir ve aktif değildirler; kötü huylu tümörler ise şekilde düzgünlüğe sahip değildir ve aktiftirler (Ezhilarasi ve Varalakshmi, 2018). Malign primer beyin tümörleri, yetişkinlerde en zor tedavi edilebilen kanser türleri arasındadır (Lapointe, Perry ve Butowski, 2018).

Beyin tümörleri, insan ölümlerinin en yaygın nedenlerinden biridir, hayatı tehdit eden ölümcül bir hastalıktır ve Dünya Sağlık Örgütü'nün son verilerine göre dünya çapında en yaygın kanser türlerinden biridir. Bu tümörler bireylerin yaşamları üzerinde önemli bir etkiye sahip olabilir ve belirtileri (baş ağrısı, kusma, göz anormallikleri, çift görme, zayıflık, uyuşukluk, yutma güçlüğü, kişilik veya davranış değişiklikleri, el titremesi gibi) genellikle yaşamı değiştiren etkiler yaratabilir (Aslan, 2022). Erken ve doğru teşhis, etkili bir tedavi ile hastaların hayatta kalmasını önemli oranda artırabildiği için oldukça önemlidir. Bu bağlamda manyetik rezonans görüntüleme (MRG), beyin tümörlerinin tespitinde en etkili verileri sağlayan temel araçlardan biridir ve yaygın olarak kullanılmaktadır. MRG yöntemi beynin yumuşak dokusu hakkında yüksek çözünürlüklü bilginin yanı sıra aynı dokuya ait birden fazla şekilsel bilgi sağlar ve genel olarak yumuşak doku görüntülemesinde kullanılmaktadır (Gezer, 2021). Bu, tümörlerin doğru bir şekilde tespit edilmesine ve büyüklüklerinin değerlendirilmesine olanak tanır (Türkçetin, 2019).

Magnetik Rezonans (MR) görüntüleri karmaşık ve zorlu olabilir (Joseph, Singh ve Manikandan, 2014). Görüntü kalitesi, çekim sırasındaki gürültü, cihazlar arası farklılıklar, yoğunluk düzensizlikleri, düşük ve değişken kontrast gibi faktörlerden etkilenebilir (Asiri ve diğerleri, 2024; Biratu ve diğerleri, 2021; Birla ve Shantaiya, 2014; Ullah ve diğerleri, 2021). Ayrıca, kafatası gibi beyin dışı dokular da görüntülerde yer alabilir. Bu sorunlar,

otomatik segmentasyon ve tespit algoritmalarının performansını olumsuz etkileyebilmektedir (Biratu ve diğerleri, 2021; Ullah ve diğerleri, 2021). Bu nedenle, MR görüntülerinin analize hazır hale getirilmesi için ön işleme adımları önemlidir (Ullah ve diğerleri, 2021). Görüntü iyileştirme teknikleri, ön işlemenin önemli bir parçasıdır ve görüntü kalitesini artırmak (Joseph ve diğerleri, 2014; Kharrat, Messaoud, Benamrane ve Abid, 2009), gürültüyü azaltmak (Asiri ve diğerleri, 2024), kontrastı yükseltmek (Asiri ve diğerleri, 2024; Borole, Nimbhore ve Kawthekar, 2015; Kharrat ve diğerleri, 2009) ve görüntüdeki farklı yapıların ayırt edilebilirliğini iyileştirmek amacıyla kullanılır. Filtreleme ve histogram eşitleme, görüntülerin kalitesini artırmak için kullanılan temel iyileştirme teknikleridir (Borole ve diğerleri, 2015). İyileştirme, sonraki segmentasyon ve sınıflandırma görevleri için görüntüleri en uygun hale getirmektedir (Asiri ve diğerleri, 2024). Özellikle MRG tabanlı beyin tümörü görüntü sınıflandırmasında, tümörlerin daha net ve doğru bir şekilde tespit edilmesine olanak tanıyarak kritik bir rol oynamaktadır (Kırelli, 2022). Bu teknikler, görüntülerin kalitesini artırarak hekimlerin ve otomatik sistemlerin görüntüleri yorumlamasını kolaylaştırarak tanı ile tedavi süreçlerindeki doğruluğu artırmaktadır. Derin öğrenme yöntemleriyle entegre edildiğinde, görüntü iyileştirme teknikleri beyin tümörü tespitinde sonuçların güvenilirliğini ve etkinliğini önemli ölçüde yükseltmektedir (Dinçer, 2018).

Geleneksel olarak klinik rutinde, beyin tümörü teşhisi için büyük miktarlardaki MR görüntülerinin manuel olarak segmentasyonu ve analizi gerçekleştirilir (Aswathy, Dhas ve Kumar, 2014; Işın, Direkoğlu ve Şah, 2016; Joseph ve diğerleri, 2014). Ancak, manuel segmentasyon oldukça zaman alıcı, zor, zahmetli ve öznel bir işlemdir (Arabahmadi, Farahbakhsh ve Rezazadeh, 2022; Işın ve diğerleri, 2016; Roy ve Bandyopadhyay, 2012; Ullah ve diğerleri, 2021). Radyolog yetersizliği ve incelenmesi gereken büyük görüntü hacmi bu süreci daha da zorlaştırmaktadır (Joseph ve diğerleri, 2014). Hatta manuel tarama sırasında tümörlerin %10 ila %30'unun gözden kaçırılabilceği tahmin edilmektedir. Bu zorluklar, beyin tümörü görüntü segmentasyonu için sağlam ve otomatik yöntemlerin geliştirilmesini popüler bir araştırma alanı haline getirmiştir (Işın ve diğerleri, 2016).

Derin öğrenme teknikleri, beyin MR görüntülerinden tümör tespiti, segmentasyonu ve sınıflandırılması için güçlü araçlar olarak ortaya çıkmıştır (Aslan, 2022). Bu yaklaşımlar, ön işleme ve görüntü iyileştirme adımlarından sonra uygulanmaktadır (Asiri ve diğerleri, 2024; Ullah ve diğerleri 2021). Derin öğrenme modelleri, görüntüden öznelikleri çıkarmak için

katmanlar kullanmaktadır (Işın ve diğerleri, 2016). Ardından tümörün konumunu, boyutunu belirlemek veya durumunu sınıflandırmak gibi görevleri yerine getirmektedir (Roy ve Bandyopadhyay, 2012). Küçük tümör bölgelerinin segmentasyonu hala önemli bir zorluk olsa da (Rehman, Cho, Kim ve Chong, 2021), bu sorun; özellik zenginleştirme blokları, transfer öğrenmesi (Hikmah ve diğerleri, 2024) ve veri artırma yöntemleri (Rasheed ve diğerleri, 2023) gibi yenilikçi yaklaşımlar ile aşılmaya çalışılmaktadır. Otomatik yöntemler, hızlı, hassas, sağlam ve objektif teşhis sistemleri geliştirme potansiyeli taşımaktadır. Bu alandaki araştırmalar, tıbbi görüntülemenin geleceğini şekillendirme ve hasta bakımını iyileştirme hedefiyle devam etmektedir (Paul, 2016; Rasheed ve diğerleri, 2023).

Tez çalışmasının temel hedefi, beyin tümörlü MR görüntülerinden oluşan bir veri seti kullanarak derin öğrenme tabanlı modeller meydana getirmek ve görüntü iyileştirme metotlarının bu modeller üzerindeki etkilerini kapsamlı biçimde analiz etmektir. Çalışmada, beyin MR görüntülerinin iyileştirilmesi ile derin öğrenme teknikleriyle tümör saptanması arasındaki ilişki ayrıntılı olarak irdelenmiştir. Hazırlanan veri seti ilk olarak çalışmada kullanılan derin öğrenme metotlarının eğitimi için kullanılmıştır. Eğitilen modeller ile yine bu veri setinde bulunan görüntüler için ortalama güven skorları belirlenmiştir. Güven skorları belirlendikten sonra iyileştirme yöntemleri veri setinde bulunan görüntülere hem ayrı ayrı hem de farklı kombinasyonlarıyla uygulanmıştır. Derin öğrenme metotları bu test setinde denenerek hem ham görüntülerde hem de iyileştirilmiş görüntülerde güven skorları, ortalama kesinlik oranları, kesinlik ve duyarlılık değerleri hesaplanmıştır. Derin öğrenme metotları için, orijinal görüntüler ile iyileştirilmiş görüntüler üzerindeki değerler karşılaştırılarak bu metotlar üzerindeki etkileri analiz edilmiştir. Modeller üzerinde pozitif etki gösteren iyileştirme modelleri belirlenmiştir.

2. GENEL BİLGİLER

2.1. Beyin Tümörü

Beyin tümörleri, beyindeki hücrelerin anormal ve kontrolsüz şekilde çoğalmasıyla ortaya çıkan, iyi huylu (benign) veya kötü huylu (malign) kitlelerdir. Dünya Sağlık Örgütü'ne (WHO) göre beyin ve sinir sistemi tümörleri, tüm kanser vakalarının yaklaşık %2'sini oluşturmakta olup özellikle malign türleri yüksek mortalite oranlarıyla dikkat çekmektedir (World Health Organization, 2020). Amerikan Beyin Tümörleri Topluluğu (American Brain Tumor Association (ABTA)) 2022 raporuna göre yalnızca Amerika Birleşik Devletleri'nde yılda yaklaşık 700.000 beyin tümörü vakası görülmekte ve bunların yaklaşık %30'u malign özellik taşımaktadır (American Brain Tumor Association, 2022). Beyin tümörlerinin erken teşhisi, tedavi olanaklarının artırılmasında ve yaşama oranlarının yükseltilmesinde kritik bir rol oynamaktadır. Tedavi öncesinde tümörün doğru bir şekilde segmentasyonu, sağlıklı dokuların korunması açısından hayati öneme sahiptir (Işın ve diğerleri, 2016).

Kötü huylu beyin tümörleri, glioblastoma dahil olmak üzere, tedavi edilmesi en zorlu solid tümörlerden bazılarını temsil etmektedir. Son yıllarda immünoterapi alanındaki ilerlemeler, immünolojik yaklaşımların beyin tümörü olan hastaların sonuçlarını iyileştirme potansiyeli sunduğuna dair umut vermektedir. Beyin tümörlerinin standart tedavilere dirençli doğası, yeni tedavi yöntemleri geliştirme konusunda güçlü bir motivasyon sağlamaktadır (Akhavan ve diğerleri, 2019). Tıbbi görüntüleme teknikleri, beyin tümörlerinin görselleştirilmesi, teşhisi ve tedavisinde kritik bir rol oynamaktadır.

Dokuların mekanik özellikleri, özellikle katı veya sıvı davranışları, kötü huylu tümörlerin yayılmasını etkilemektedir. Solid tümörlerin daha yüksek mekanik katılığa sahip olma eğiliminde olduğu bilinirken, daha yumuşak tümörlerin beyin gibi daha katı bir ortamda nasıl büyüyebileceği bilinmemektedir. Beyin tümörleri, "tümör" kelimesinin Latince kökeninin aksine, her zaman katı, yer kaplayan kitleler olarak karşımıza çıkmaz; çok yumuşak olan beyin dokusundan bile daha yumuşak bir davranış sergileyebilirler (Streitberger ve diğerleri, 2019).

Beyin tümörleri, Dünya Sağlık Örgütü'nün Primer Santral Sinir Sistemi (MSS) tümörleri derecelendirme sistemine göre sınıflandırılır. Bu sistem, yakın zamana kadar tümörleri histolojik kriterlere göre sınıflandırarak I'den IV'e kadar derecelendirmiştir. 2016 yılında beyin tümörlerinin sınıflandırması, klasik histolojik bulgulara ek olarak belirleyici moleküler genetik değişikliklerin de dahil edilmesiyle yenilenmiş ve bu doğrultuda yeni entegre tanımlar oluşturulmuştur. Tümör hücresi plastisitesi, kanser teşhisi ve tedavisini karmaşıklaştıran önemli bir faktör olarak detaylı bir şekilde araştırılmıştır (Akhavan ve diğerleri, 2019). Moleküler ve hücrel heterojenlik, beyin tümörlerinin, özellikle Glioblastoma (GBM) en dikkat çekici özelliklerinden biri olarak kendini gösterir (Behnan, Finocchiaro ve Hanna, 2019). Beyin tümörlerinin kenarları genellikle belirsiz ve bulanıktır, bu da onları sağlıklı dokulardan ayırt etmeyi zorlaştırır (Razzak, Imran ve Xu, 2019).

MSS tümörleri, MSS içindeki hücrelerden kaynaklanan heterojen bir tümör grubunu ifade eder ve iyi huylu veya kötü huylu olabilirler. Gliomlar, yetişkinlerdeki malign primer beyin tümörlerinin %75'ini oluşturur. Gliomlar, glial veya öncü hücrelerden kaynaklanan nöroektodermal kökenli tümörlerdir ve astrositomlar, oligodendrogliomlar ve ependimomları içermektedir (Lapointe ve diğerleri, 2018). GBM, gliomların en yaygın ve ölümcül varyantıdır (Behnan ve diğerleri, 2019). GBM ve meningioma (MEN) gibi beyin tümörleri, klinik prognoz, sonuç ve tedavi seçenekleri açısından belirgin farklılıklar gösterir. MEN'ler meninks dokusundan köken alır, yavaş büyür ve sıklıkla keskin sınırlara sahiptir. Buna karşılık, GBM'ler (WHO derecesi IV), hızla büyür ve çevre dokuyu yaygın olarak infiltre eder, bu da tespit edilmesi zor sınırlara sahip lezyonlara yol açar. Tedaviye rağmen GBM'lerin prognozu genellikle kötüdür (Streitberger ve diğerleri, 2019).

2.2. Tanı Sistemleri

Beyin tümörlerini tanımlamak için kullanılan görüntüleme teknikleri arasında MRG, Pozitron Emisyon Tomografisi (PET) ve Bilgisayarlı Tomografi (CT) yer almaktadır (Ezhilarasi ve Varalakshmi, 2018). Beyin tümörü şüphesi olan bir hastada, gadolinyum ile MRG, tercih edilen inceleme yöntemidir (Lapointe ve diğerleri, 2018). MRG, beyin tümörünü tespit etmek için kaliteli bir tıbbi görüntüleme yöntemidir. Bu üç görüntüleme tekniği karşılaştırıldığında, beyin tümörünü tespit etmek için MRG yönteminin daha iyi kalitede tıbbi görüntüleme sağladığı belirtilmektedir (Ezhilarasi ve Varalakshmi, 2018).

MR görüntülerinin manuel olarak değerlendirilmesi zaman kısıtlamaları ve değişkenlik nedeniyle zorluklar yaratmaktadır. Büyük hacimli veriler ve beyin tümörlerinin karmaşık yapısı nedeniyle, uzmanlar tarafından görüntülerin manuel olarak incelenmesi öznel, zahmetli ve hataya açık olabilir (Razzak ve diğerleri, 2019). Ek olarak, küçük ölçekli tümör bölgelerinin belirlenmesi, küçük boyutları ve farklı tümör sınıfları tarafından işgal edilen alan arasındaki büyük fark nedeniyle zor olabilir (Razzak ve diğerleri, 2019).

MRG, non-invaziv bir teknik olup (Asiri ve diğerleri, 2024), zararlı radyasyon kullanmaz (Arabahmadi ve diğerleri, 2022; Joseph ve diğerleri, 2014). Beynin iç yapısı hakkında ayrıntılı bilgi sağlayarak (Aswathy ve diğerleri, 2014; Borole ve diğerleri, 2015; Dahshan ve diğerleri, 2014;) yumuşak dokuların görüntülenmesinde üstünlük sunar (Dahshan ve diğerleri, 2014). MRG, farklı doku parametrelerine (T1, T2, PD) duyarlı çeşitli görüntüleme sekansları sunmaktadır (Arabahmadi ve diğerleri, 2022). Örneğin, T1 ağırlıklı görüntüler sağlıklı dokuları ayırt etmek ve anatomik yapıları lokalize etmek için kullanılırken, T2 ağırlıklı görüntüler ödem alanlarını göstermekte faydalıdır (Dahshan ve diğerleri, 2014). Kontrast madde enjekte edildikten sonra alınan T1 ağırlıklı (CE-T1w) görüntüler ise tümör sınırındaki ve aktif hücre alanlarındaki kontrast madde birikimini gösterir. Sıvı Baskılamalı Ters Çevirme (FLAIR) sekansı ise ödemi beyin omurilik sıvısından (BOS) ayırmaya yardımcı olmaktadır (Rehman ve diğerleri, 2021).

Beyin MR görüntülerinin iyileştirilmesi ve derin öğrenme yöntemleriyle beyin tümörü tespiti, günümüzde tıp alanında büyük önem taşıyan bir konudur. Bu alandaki çalışmalar, erken teşhis, tedavi süreçlerinin iyileştirilmesi ve uzmanların iş yükünün azaltılması gibi önemli avantajlar sağlamaktadır. Beyin tümörlerinin erken ve doğru teşhisi, etkili bir tedavi için kritik öneme sahiptir. MRG, beyin tümörlerinin tespitinde en etkili verileri sağlayan temel araçlardan biridir. Ancak radyologlar tarafından yapılacak manuel kontroller zaman alıcı olabilir ve hatalı kararlar verilmesine neden olabilir. Bu nedenle, araştırmacılar bilgisayar destekli otomatik tespit sistemlerinin geliştirilmesine katkı sağlamaya çalışmışlardır.

Son yıllarda, derin öğrenme yöntemleri, özellikle görüntü işleme alanında gösterdikleri üstün performans sayesinde büyük popülerlik kazanmıştır. Derin öğrenme modelleri,

geleneksel yöntemlerdeki gibi el yapımı öznitelikler kullanmak yerine, verinin kendisinden otomatik olarak karmaşık ve temsili öznitelikler öğrenme yeteneğine sahiptir. Evrimsel Sinir Ağları (Convolutional Neural Networks, CNN), bu alanda en sık kullanılan derin öğrenme mimarilerindendir ve görüntü analizi görevlerinde yüksek başarı elde etmişlerdir. (Işın ve diğerleri, 2016)

Derin öğrenme yöntemleri, medikal görüntülerin işlenmesine dayalı hastalık tespitinde sıkça kullanılmaktadır. Bu yöntemler, insan gücü olmadan verilerden otomatik olarak özellik çıkarabilen derin sinir ağlarını kullanır. CNN modelleri, özellikle görüntü sınıflandırma ve segmentasyon görevlerinde yaygın olarak kullanılmaktadır. Bu modellerin temel yapısı girdi, evrişim katmanı, aktivasyon katmanı, havuzlama katmanı ve tam bağlantı katmanından oluşmaktadır. Havuzlama katmanı, evrişim katmanından elde edilen özellik haritalarının boyutlarını küçültmek için kullanılır. Ayrıca genellikle her evrişim katmanından sonra bir havuzlama katmanı kullanılarak hesaplama karmaşıklığının azaltması ve aşırı uyum probleminin çözümüne yardımcı olması için tercih edilir.

Derin öğrenme teknikleri, beyin MR görüntülerinden tümör tespiti, segmentasyonu ve sınıflandırılması için güçlü araçlar olarak ortaya çıkmıştır (Aslan, 2022). Bu yaklaşımlar, ön işleme ve görüntü iyileştirme adımlarından sonra uygulanır (Asiri ve diğerleri, 2024; Ullah ve diğerleri, 2021). Derin öğrenme modelleri, görüntüden öznitelikleri çıkarmak için katmanlar kullanır ve ardından tümörün konumunu, boyutunu belirlemek (segmentasyon/tespit) veya tümörün türünü sınıflandırmak gibi görevleri yerine getirir (Roy ve Bandyopadhyay, 2012). Küçük tümör bölgelerinin segmentasyonu gibi zorluklar devam etmekle birlikte özellik zenginleştirme blokları (Rehman ve diğerleri, 2021), transfer öğrenmesi (Hikmah ve diğerleri, 2024) ve veri artırma (Rasheed ve diğerleri, 2023) gibi yenilikçi mimariler ve tekniklerle bu sorunların üstesinden gelinmeye çalışılmaktadır. Otomatik yöntemler, hızlı, hassas, sağlam ve objektif teşhis sistemleri geliştirme potansiyeli taşımaktadır. Bu alandaki araştırmalar, tıbbi görüntülemenin geleceğini şekillendirme ve hasta bakımını iyileştirme hedefiyle devam etmektedir (Paul, 2016; Rasheed ve diğerleri, 2023).

Bu tez, beyin MR görüntülerinde tümör tespiti ve sınıflandırılması için yeni bir derin öğrenme tabanlı metodoloji araştırmaktadır. Görüntü kalitesini iyileştirmek ve manuel değerlendirmenin zorluklarının üstesinden gelmek için görüntü iyileştirme tekniklerinin ve

derin öğrenmenin gücünden yararlanarak, daha hassas, verimli ve yaygın olarak uygulanabilir beyin tümörü analizine katkıda bulunması amaçlanmaktadır.

2.3. Literatürdeki Çalışmalar

2.3.1. Derin öğrenme tabanlı beyin tümörü tespiti

Son yıllarda derin öğrenme (DL, Deep learning) ve makine öğrenmesi (ML, Machine Learning) algoritmalarının tıbbi görüntüleme alanında, özellikle de MR görüntülerinin analizi üzerinden beyin tümörlerinin tespiti, sınıflandırılması ve segmentasyonu gibi görevlerde kullanımında önemli bir artış yaşanmıştır (Ariffin, Abu-Naser, 2023). Literatürdeki bulgular, bu yöntemlerin hem araştırmaların gelişiminde belirleyici bir rol oynadığını hem de DL'nin sunduğu yüksek potansiyeli ortaya koyduğunu göstermektedir (Abrahmadi, Farahbakhsh, Rezazadeh, 2022). Nitekim 2015–2020 yıllarını kapsayan bir incelemede, DL algoritmalarının kullanımında kayda değer bir yükseliş saptanmış ve yalnızca 2019 yılında kullanım oranının on kat arttığı rapor edilmiştir (Taha, Ariffin ve Abu-Naser, 2023). Daha güncel çalışmalar ise 2020–2023 dönemine odaklanmış ve özellikle çok modlu MR görüntülerinde DL tabanlı segmentasyon modellerinin öne çıktığını vurgulamıştır (Abidin ve diğerleri, 2024). Genel olarak incelenen araştırmalar, beyin tümörlerinin tahmini, tespiti ve tanısına yönelik DL yaklaşımlarının hızla geliştiğini göstermektedir.

DL yöntemleri, büyük miktarda veriyi işleme ve otomatik özellik çıkarabilme yetenekleri sayesinde tıbbi görüntüleme alanında dikkate değer sonuçlar göstermiştir. CNN'ler, özellikle büyük ölçekli görüntülerin sınıflandırılması için tasarlanmıştır ve verilerden çok seviyeli özellikler öğrenebilmektedir (Abrahmadi ve diğerleri, 2022). Bazı çalışmalar, beyin tümörü sınıflandırması için birden fazla CNN modeli oluşturmuştur (Tunthanathip, Kaewborisutsakul ve Supbumrung, 2024). Performansı artırmak için faydalı bir yaklaşım olarak görülen bir diğer teknik de Transfer Öğrenimidir (Abdusalomov, Mukhiddinov ve Whangbo, 2023). Transfer öğrenimi, önceden eğitilmiş modellerin yeni bir göreve adapte edilmesi prensibine dayanır (Abrahmadi ve diğerleri, 2022). Beyin tümörü segmentasyonu gibi görevlerde Dikkat Mekanizmaları da kullanılmıştır (Abdusalomov ve diğerleri, 2023). En son gelişmeler arasında, CNN'lerin yerel özellikleri yakalama gücü ile Transformers

mimarisinin tüm görüntü üzerinde uzun menzilli bağıntıları ve global özellikleri öğrenme yeteneğini birleştiren hibrit modeller yer almaktadır (Abidin ve diğerleri, 2024).

En iyi performans gösteren diğer algoritmalar arasında Lojistik Regresyon, Derin Sinir Ağı (Deep Neural Network, DNN), boosting algoritmaları, Destek Vektör Makineleri (Support Vector Machine, SVM) ve k-En Yakın Komşuluk (k Nearest Neighbor, kNN) yer almaktadır (Taha ve diğerleri, 2023). Hibrit model teknikleri de makul doğruluk oranları sergilemiştir, ancak sık kullanılmamıştır (Nazir, Shakil ve Khurshid, 2021). Özgün model yaklaşımları da kullanılmıştır; örneğin, YOLOv7 gibi son teknoloji modellerin transfer öğrenimi ile ince ayarlanması, gliom, meningiom ve hipofiz bezi tümörlerinin tespitinde %99,5'lik kayda değer bir doğrulukla umut verici sonuçlar göstermiştir. Bu modelde, özellik çıkarma yeteneğini artırmak amacıyla Evrişimsel Blok Dikkat Modülü (Convolutional Block Attention Module, CBAM) kullanılmış, küçük tümörlerin tespiti için ise SPPF+ (Spatial Pyramid Pooling Fast+) ve BiFPN (Bi-directional Feature Pyramid Network) bileşenleri entegre edilmiştir (Abdusalomov ve diğerleri, 2023). Başka bir çalışma, Kaggle platformunda paylaşılan bir veri kümesi üzerinde Efficientnet-b0, InceptionV3, Mobilenetv2 ve GoogleNet modellerini karşılaştırmış ve Efficientnet-b0'ın %99,54 doğrulukla en başarılı olduğunu bulmuştur (Gasmi ve diğerleri, 2024).

Beyin tümörü analizi ve segmentasyonu alanındaki çalışmalarda yaygın olarak kullanılan veri kümeleri arasında Beyin Tümörü Segmentasyon Veri Kümesi (Brain Tumor Segmentation, BRATS) (Schwehr, Achanta, 2024) ile Kaggle platformunda kamuya açık olarak paylaşılan veri kümeleri öne çıkmaktadır (Abdusalomov ve diğerleri, 2023). Bunun yanında bazı araştırmalarda Tedavi Yanıtını Değerlendirmeye Yönelik Referans Görüntü Veritabanı (Reference Image Database to Evaluate Therapy Response, RIDER) ve World Brain Atlas gibi veri kümeleri de kullanılmıştır (Maharjan, Alsadoon, Prasad, Al-Dalain ve Alsadoon, 2020). Ayrıca, özellikle doğru tümör tespiti ve sınıflandırması için çok modlu MR veri kümelerinin gerekliliği vurgulanmıştır (Abidin ve diğerleri, 2024).

Derin öğrenme tabanlı beyin tümörü tespiti ve sınıflandırma çalışmaları alanında önemli ilerlemeler kaydedilmiş olsa da hala bazı zorluklar mevcuttur (Arabahmadi ve diğerleri, 2022). Küçük tümörlerin tespiti ek araştırma ve test gerektirmektedir (Abdusalomov ve diğerleri, 2023). Özellik çıkarma, tümör sınıflandırması ve lokalizasyonu için yenilikçi metodolojilere hala ihtiyaç duyulmaktadır. Araştırmalarda, derin öğrenme modellerinin

güvenilirliğini artırmak için daha geniş kapsamlı ve ortak standartlara uygun şekilde hazırlanmış veri setlerinin kullanılması gerektiği vurgulanmıştır. (Nazir ve diğerleri, 2021). Tıbbi araştırmalarda veri gizliliği ve paylaşımı önemli bir konudur (Arabahmadi ve diğerleri, 2022).

Beyin tümörü tespitine yönelik çalışmalarda, başlangıçta temel CNN mimarileri kullanılırken (Abrahmadi ve diğerleri, 2022), son yıllarda transfer öğrenimi, dikkat mekanizmaları ve CNN ile Transformer tabanlı hibrit modeller gibi daha gelişmiş yöntemlere doğru bir ilerleme kaydedilmiştir (Abdusalomov ve diğerleri, 2023; Abidin ve diğerleri, 2024). Ancak, küçük tümörlerin doğru biçimde tespiti ve standardize edilmiş, tam otomatik sistemlerin geliştirilmesi gibi konular halen çözülmesi gereken zorluklar arasında yer almaktadır (Nazir ve diğerleri, 2021).

2.3.2. Derin öğrenme tabanlı beyin tümörü tespiti üzerine görüntü iyileştirme çalışmaları.

Derin öğrenme tabanlı beyin tümörü tespitine yönelik mevcut araştırma çalışmaları, otomatikleştirilmiş, hızlı ve yüksek doğruluklu sonuçlar elde etme potansiyeli sunmaktadır. Manuel tümör tespitinin zaman alıcı ve zorlu doğası göz önüne alındığında, derin öğrenme yöntemleri MR görüntülerinden tümörleri otomatik olarak tespit etme ve sınıflandırma yeteneği sayesinde bu süreci önemli ölçüde hızlandırmaktadır. Bu alandaki çalışmalar, farklı derin öğrenme mimarilerini ve tekniklerini kullanarak teşhis doğruluğunu artırmayı hedeflemektedir.

Görüntü iyileştirme alanında yapılan çalışmalar, çeşitli teknikler ve algoritmalar kullanılarak elde edilen sayısal sonuçlarla, tıbbi görüntü analizindeki etkinliğini kanıtlamıştır. Çakar, 2018'de, akciğer tomografisi görüntülerinde yapay sinir ağı modeli ile sınıflandırmada %94,407 başarı sağlamıştır.

Görüntü işleme yöntemleri, MR görüntülerinin kalitesini artırarak tümör tespitini kolaylaştırır. Bu teknikler arasında uyarlanabilir Wiener filtreleme, sinir ağları ve bağımsız bileşen analizi bulunur. Uyarlanabilir histogram eşitleme (Adaptive Histogram Equalization, AHE) ve Gauss bulanıklığı tabanlı keskinleştirme gibi görüntü iyileştirme yöntemleri, tümörlerin sınıflandırılmasında başarıyla kullanılmıştır. Bu tekniklerin kombinasyonu

kontrastın önemli ölçüde iyileştirildiği ve tümör sınıflandırma verimliliğinin arttığı gösterilmiştir (Asiri ve diğerleri, 2024).

Literatürde yer alan çeşitli çalışmalar, farklı derin öğrenme ve görüntü iyileştirme yöntemlerinin kombinasyonlarının beyin tümörü tespiti ve sınıflandırılmasındaki etkinliğini değerlendirmiştir. Rasheed ve diğerleri (2023), önceden eğitilmiş modellerin doğruluk oranlarını %88,84 ile %95 arasında gözlemleyip, Gauss bulanıklığı ve Kontrast Sınırlamalı Uyarlanabilir Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization, CLAHE) gibi görüntü iyileştirme teknikleriyle derin öğrenme modellerini entegre ederek beyin tümörü sınıflandırmasında %97,85 doğruluk elde etmiştir. Böylece ön işleme yapılmayan önceki çalışmaların ortalamasına kıyasla %6,2 doğruluk kazancı sağlanmıştır. Benzer şekilde, Asiri ve diğerleri (2024), adaptif Wiener filtreleme, sinir ağları ve bağımsız bileşen analizi kullanarak görüntü normalizasyonu gerçekleştirmiş ve tümör sınıflandırmasında görüntü iyileştirme öncesi %61 ile %67 arasında değişen ölçüm değerlerine kıyasla ortalama %99 hassasiyet, %99 özgüllük, %98,9 doğruluk ve 0,98 F1-skoru elde etmiştir.

Türk ve diğerleri (2019), akciğer ve kolon kanseri teşhisinde gaussian filtrenin ön işleme aşamasında kullanılmasının genel doğruluk oranını büyük ölçüde artırdığını belirtmiştir. Bu çalışmada, MobileNet'in doğruluğu %88,63'ten %92,44'e, VGG16'nın doğruluğu %92,57'den %98,23'e ve Resnet50'nin doğruluğu %96,54'ten %99,38'e yükselmiştir (Türk, Acar, Irmak, Yılmaz ve Bakis, 2024).

Beyin MR görüntülerinde tümör tespiti ve segmentasyonuna odaklanan bir çalışmada, bir derin öğrenme tekniği (kaynaklarda tam adı belirtilmeyen, ancak içerik bağlamında bir CNN tabanlı yaklaşım) için kapsamlı bir ön işleme aşaması uygulanmıştır (Kaur, Kamra, 2021). Bu ön işleme, görüntülerin adaptif eşikleme ile ikili forma dönüştürülmesini ve ardından gürültüyü, istenmeyen pikselleri ve kafatası sınırlarını temizlemek, aynı zamanda tümör boyutunu korumak için morfolojik işlemleri, özellikle aşındırma ve genişlemeyi içermiştir. Araştırma sonucunda doğruluk sonuçları %92,90 ile %95,28 arasında değişen modellere kıyasla %98,15 oranında bir sonuç elde edilmiştir (Kaur, Kamra, 2021).

Diyabetik retinopati (DR) evrelerinin tespiti üzerine yapılan bir araştırmada, Inception-V3 mimarisine CLAHE ve ESRGAN (Enhanced Super-Resolution Generative Adversarial

Network) ön işleme teknikleri uygulandığında, beş sınıflı sınıflandırma doğruluğunun görüntü iyileştirme yapılmayan duruma göre %80,87'den %98,7'ye önemli ölçüde yükseldiği gösterilmiştir (Alwakid, Gouda ve Humayun, 2023).

Birden fazla göz hastalığı sınıflandırması için bir CNN modelinin performansını değerlendiren bir çalışmada ise, CLAHE uygulamasının genel sınıflandırma doğruluğunu CLAHE uygulanmayan görüntülere göre %39,75'ten %46,89'a artırdığı bildirilmiştir (Mora, 2024).

CLAHE tekniğinin, yaşa bağlı makula dejenerasyonu ve diyabetik retinopati gibi bazı hastalıkların tespitinde belirgin iyileşmeler sağladığı, ancak diğer hastalık türlerinde aynı başarıyı göstermediği; kimi durumlarda ise yanlış sınıflandırma örüntülerini değiştirdiği bildirilmiştir. COVID-19 CT taramalarının otomatik tespiti üzerine yapılan bir değerlendirmede, Watershed segmentasyonu ile birlikte kullanılan CLAHE görüntü iyileştirme yönteminin VGG-19, ResNet50, Xception ve DenseNet201 gibi transfer öğrenme CNN modellerinde %91,20 sınıflandırma doğruluğu sağladığı belirtilmiştir. Bu sonuç, Histogram Eşitleme (HE) %90,40 ve diğer filtreleme yöntemlerinden %86,00 - %90,40 daha yüksek bulunmuştur. Ayrıca, CLAHE'nin bir optimizasyonu olan Değiştirilmiş Kontrast Sınırlamalı Uyarlanabilir Histogram Eşitleme (MCLAHE) %91,60 ile en yüksek doğruluğa ulaştığı kaydedilmiştir (Ummah ve diğerleri, 2022). Bu çalışmalar, farklı görüntü iyileştirme ve özellik çıkarma tekniklerinin derin öğrenme modelleriyle entegre edilerek beyin tümörü tespitinde daha iyi sonuçlar elde edilebileceğini desteklemektedir.

Bu tez çalışmasında, seçilen görüntülere medyan bulanıklaştırma, Gauss bulanıklaştırma, morfolojik işlemler, CLAHE ve Wiener filtresi gibi çeşitli görüntü iyileştirme metotları ve bunların ikili kombinasyonları uygulanmıştır. Bu iyileştirme uygulanan ve uygulanmayan görüntüler, güncel derin öğrenme mimarileri olan You Only Look Once v8 (YOLOv8), Single Shot MultiBox Detector (SSD) ve DEtection TRansformer (DETR) modelleri üzerinde test edilmiştir. Deneyler sonucunda, uygulanan görüntü iyileştirme yöntemlerinin modellerin performansı üzerindeki etkileri analiz edilerek, hangi iyileştirme yöntemlerinin hangi algorithmada daha iyi sonuçlar verdiği belirlenmiştir. Bu çalışmanın amacı, görüntü iyileştirme teknikleri uygulanan tümörlü MR görüntülerinin derin öğrenme yöntemleriyle tespit edilmesini sağlayarak, bu yöntemlerin iyileştirilmiş görüntüler üzerindeki performansını incelemektir. Ayrıca, hangi iyileştirme yönteminin hangi derin öğrenme

modelinde daha etkili sonuç verdiğini belirlemek ve böylece derin öğrenme yöntemlerinin performans farklılıklarını çeşitli ölçütler açısından ortaya koymak hedeflenmektedir.

Kaynaklar genel olarak önışlemenin öneminden ve çeşitli tekniklerden (filtreleme, histogram, morfoloji gibi) bahsetse de, bu çalışmada kullanılan Gauss bulanıklığı, morfolojik işlemler, median bulanıklığı ve histogram yöntemlerinin belirli bir kombinasyonunun, MR beyin tümörü görüntülerine uygulanmasının, derin öğrenme modellerinin başarımı üzerindeki etkisini sistematik olarak inceleyen bir çalışmanın detaylarına rastlanmamıştır.




3. MATERİYAL VE METOT


Bu çalışmada, beyin tümörü tespitine yönelik olarak SSD MobileNetv2, YOLOv8 ve DETR tabanlı üç farklı derin öğrenme modeli eğitilmiştir. Bu modellerin performansını iyileştirmek amacıyla çeşitli görüntü iyileştirme yöntemleri uygulanmış ve bu yöntemlerin tespit doğruluğu üzerindeki etkileri sistematik bir şekilde değerlendirilmiştir. Çalışmada kullanılan veri seti, modellerin eğitiminde de kullanılan 780 adet beyin tümörü görüntüsünden oluşmaktadır. Bu görüntüler hem orijinal halleriyle hem de farklı görüntü iyileştirme tekniklerinin uygulanmış versiyonlarıyla test edilmiştir. Böylece, her bir iyileştirme yönteminin modellerin tespit performansına olan katkısı ayrı ayrı gözlemlenmiştir.

Analiz sürecinde, her bir görüntü için modelin ürettiği tespit güven skorları kaydedilmiş ve iyileştirilmiş görüntülerin, orijinal görüntülere kıyasla performans üzerindeki etkileri ayrıntılı biçimde incelenmiştir. Elde edilen sonuçlara göre, görüntü iyileştirme yöntemleri bazı durumlarda modellerin performansını anlamlı ölçüde artırırken, bazı durumlarda ise düşük seviyeli ayrıntıların zayıflamasına neden olarak performansta düşüşe yol açmıştır. Bu nedenle, her bir yöntemin etkisi değerlendirilmiş ve ortalama katkı oranları hesaplanmıştır.

Yapılan değerlendirmeler sonucunda, yüzde iki ve üzeri performans kaybına yol açan yöntemler analiz dışı bırakılmıştır. Kalan yöntemler arasında, her bir derin öğrenme modeli için en yüksek ortalama performans artışını sağlayan yöntemler belirlenmiş ve bu yöntemler, ilgili model açısından en verimli görüntü iyileştirme yaklaşımları olarak tanımlanmıştır. Böylece, farklı modellerin yapısal özelliklerine bağlı olarak hangi iyileştirme yöntemlerinden daha fazla fayda sağladıkları net bir şekilde ortaya konmuştur. Tez çalışmasında kullanılan her bir iyileştirme yönteminin ayrı ayrı uygulanmasına ait sistemin akış diyagramı Şekil 3.1’de, iyileştirme metotlarının ikili kombinasyonlarının uygulanmış halinin akış diyagramı Şekil 3.2’de verilmiştir.




Şekil 3.1. Tez çalışmasının tekil iyileştirme metotlarıyla uygulanmış akış diyagramı.



Şekil 3.2. İkili kombinasyon uygulanan akış diyagramı.


3.1. Veri Setinin Oluşturulması

Eğitimde kullanılacak olan modelin eğitimi için açık kaynak MR görüntüleri kullanılmıştır (Navoneel, 2019). Bir ezber durumu oluşmasını önlemek için, eğitilen görüntülerin algılanacak tümör ile benzer tutum sergilemesine dikkat edilmiştir. Bu yüzden veri setindeki tarama görüntüleri yatay, dikey eksenlerde döndürülerek modelin genelleme performansı artırılmış ve ezber durumu engellenerek çalışmanın güvenilirliği artırılmıştır. 253 adet veri çoğaltılarak 780 tane tümörlü görüntü olmak üzere görüntüler %80 eğitim ve %20 test klasörüne ayrılmış ve veri seti oluşturulmuştur. Oluşturulan veri setinde bulunan MR görüntüleri Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Eğitilen MR veri setleri.

Bir etiketleme programı ile tümörlerin ne olduklarının belirtilmesi gerektiğinden Şekil 3.3'teki LabelImg kullanılmıştır. .xml dosyaları TensorFlow modelinde eğitmek üzere .csv'ye ve ardından .csv dosyaları, TensorFlow formatı olan tfrecord'a dönüştürülmüştür. Ardından Labelmap oluşturulmuştur. Labelmap oluşturulduktan sonra modelin eğitimi gerçekleştirilmiştir. Labelmap kullanımı, Şekil 3.4'te gösterilmiştir.



Şekil 3.4. Tümör etiketleme programı labelmap kullanımı.

3.1.1. Görüntü iyileştirme

Görüntü işleme, tıbbi alanda mikroskop, CT veya MR gibi cihazlardan elde edilen görüntülere belirli teknikler uygulanarak belli bir bölgenin elde edilmesini sağlar. Bununla birlikte sınıflandırma ve tanıma gibi birçok işlem de görüntü işleme sayesinde yapılabilmektedir (Dinçer, 2018). Özellikle MR görüntülerinde keskinlik değerinin düşük olması görüntü kalitesini düşürebilir. Bu durum hastalığın teşhisini zorlaştırabilir. Görüntü iyileştirme, tıbbi uygulamalarda önemli bir yere sahiptir (Bilgin, 2024). Yapay zekâ modelleri içinde modelin daha hızlı başarıya ulaşmasını sağlamak için görüntü üzerinde çeşitli görüntü işleme tekniklerinin uygulanıp görüntüler üzerindeki anlamlı bölgelerin çıkartılması kolaylaştırılır (Kutan ve Aynur, 2020). Gürültü genellikle görüntünün elde edilmesi ve transferi sırasında meydana gelir ve görüntünün kalitesinin düşmesine, sinyalde bozulmalara yol açar, bu da sonraki görüntü işleme ve analizi uygulamalarının başarısını düşürür. Bu sebeple gürültünün azaltılması büyük önem taşımaktadır (Değirmenci, Çankaya ve Demirci, 2018). Dijital görüntüler, görüntüleme sensörlerindeki eksiklikler, kanal iletim hataları, görüntü ile görüntüleme sistemi arasındaki ideal olmayan ortam ve donanımdaki hatalar gibi faktörlerden dolayı bozulabilmektedir. Çoğu görüntü işleme ve analiz uygulaması için görüntülerden gürültüyü kaldırmak yüksek oranda istenen bir durumdur (Eke, 2018). Filtreleme işlemi gürültünün azaltılmasının yanı sıra görüntüdeki kenar algılama gibi işlemlerde de kullanılır (Değirmenci ve diğerleri, 2018).

Görüntü iyileştirme, dijital görüntülerin (örn; süper çözünürlük, gürültü azaltma, bulanıklaştırma, kontrast iyileştirme gibi işlemler ile) görüntüleme, sınıflandırma ve algılama gibi ileri görüntü analizinde daha uygun olması için ayarlama işlemidir. Her bir görüntü iyileştirme yöntemiyle MR görüntülerinin belirli özelliklerini iyileştirerek derin öğrenme modellerinin performansını artırmak hedeflenmiştir. Kontrast iyileştirme yöntemleri tümörlerin daha belirgin hale gelmesini sağlarken, gürültü azaltma yöntemleri gereksiz detayları ortadan kaldırır. Bu iyileştirmeler, derin öğrenme modellerinin daha doğru ve güvenilir teşhisler koymasına yardımcı olur.

Tez çalışmasında, nesne tespiti öncesi ön işleme adımı olarak morfolojik işlemler, Gauss Bulanıklaştırma, kontrast sınırlı adaptif histogram eşitleme, wiener filtresi ve medyan bulanıklaştırma kullanılmıştır. Sayılan görüntü işleme tekniklerinin ikili kombinasyonları da ön işleme adımına dahil edilerek işlemlerin birbiri üzerindeki etkisinin gözlemlenmesi amaçlanmıştır. Uygulanan görüntü iyileştirme yöntemlerinin performansını değerlendirmek amacıyla üç farklı kalite ölçütü kullanılmıştır. Bu ölçütler; Ortalama Kare Hatası (Mean Squared Error, MSE), Pik Sinyal-Gürültü Oranı (Peak Signal-to-Noise Ratio, PSNR) ve Yapısal Benzerlik İndeksi (Structural Similarity Index Measure, SSIM) ölçütleridir. MSE, orijinal ve işlenmiş görüntü arasındaki piksel bazlı hata miktarını doğrudan ölçerek iyileştirme yöntemlerinin sayısal doğruluğunu ortaya koymaktadır. PSNR, gürültü seviyesi ile sinyalin gücü arasındaki oranı logaritmik ölçekte belirlemekte ve özellikle gürültü azaltma süreçlerinin etkinliğini göstermektedir. SSIM ise insan görsel algısına daha yakın bir değerlendirme yaparak parlaklık, kontrast ve yapısal benzerliği göz önünde bulundurmaktadır. Bu üç ölçüt değerlendirildiğinde hem matematiksel doğruluk hem de yapısal bütünlük açısından çok boyutlu bir değerlendirme imkânı sunmaktadır. Böylece, tıbbi görüntülerde tümör bölgesinin korunarak iyileştirilip iyileştirilmediği daha güvenilir bir şekilde analiz edilebilmektedir. Veri setinin ön işleme adımları aşağıda verilmiştir.

Matematiksel Morfoloji

Morfolojik yaklaşım, görüntüdeki şekil veya özelliklerle ilişkili doğrusal olmayan işlemlerin bir toplamı olarak tanımlanır. Bunlar, aşındırma (erosion), genişleme (dilation), açma (opening), kapama (closing), top-hat filtreleme ve havza dönüşümü gibi işlemleri içerir (Mohan ve Poobal, 2018).

Morfolojik işlemler, nesnelerin şekil ve yapısına dayalı olarak görüntüdeki nesneleri işlemek için kullanılır. Tümör alanını elde etmek için kenar algılamadan sonra morfolojik işlemler kullanılmıştır (G. Yıldız, D. Yıldız, 2018). Genişleme, nesne alanlarını büyütme veya kopuklukları birleştirme gibi görevlerde etkilidir (Aldeeb, 2017). Aşındırma ise küçük nesneleri veya kenarlardaki çıkıntıları kaldırmak için kullanılabilir. Retina damar bölütlemesinde morfolojik işlemler, damarların sürekliliğini sağlamak veya damar yapısındaki kusurları gidermek için kullanılmıştır (Yakut ve Ulukaya, 2022).

Morfolojik işlemlerin amacı, görüntülerdeki şekil veya özellikleri işlemektir. Morfolojik yaklaşım, yüksek kontrastlı görüntülerden çatlak benzeri desenleri tespit etmek için matematiksel morfoloji tekniğini kullanır. Ayrıca, ilgili piksellerin çıkarılmasında kullanılmıştır. Bir çalışmada, görüntü arka planını kaldırmak için aşındırma işlemi kullanılmıştır. Çatlak bilgilerini güvenli bir şekilde elde etmek için morfolojik genişletme korozyonu benimsenmiştir (Mohan ve Poobal, 2018). Morfolojik işlemler ve DSA (Derin Sinir Ağı) birleştirilerek çatlakların geometrik özelliklerini doğrudan görüntülerden çıkarmak için kullanılmıştır. Piksel düzeyindeki tahminler, morfolojik özelliklerin çıkarılması için son işleme tabi tutulur (Yang ve diğerleri, 2018).

Beyin tümörlerinin yerini tespit etmek ve büyüklüğünü ölçmek için MR görüntülerine morfolojik işlemler uygulanmıştır (G. Yıldız, D. Yıldız, 2018). Meme lezyonlarının tespiti çalışmasında aşındırma işlemi uygulanmıştır.

Aşındırma ve genişleme işlemleri, bir nesnenin sınırlarını aşındırma veya genişletme amacıyla kullanılır. Aşındırma, değeri yerel minimum ile değiştirerek nesnenin sınırlarını aşındırırken, genişleme değeri yerel maksimum ile değiştirerek nesnenin kapsamını artırır (Yang ve diğerleri, 2018). Aşındırma, küçük ve önemsiz nesnelerden kurtulmak için kullanılabilir. Beyaz kan hücrelerinin analizinde küçük nesnelerden kurtulmak için bir kez aşındırma uygulanmıştır. Genişleme, nesnelerin deliklerini doldurma veya nesneleri kalınlaştırma yoluyla "büyütme" amacına hizmet edebilir (Zhao, Zhang, Zhou, Chu ve Cao, 2017). Aşındırma işlemi için verilen denklem Eşitlik 3.1'de ve genişleme için verilen denklem Eşitlik 3.2'de verilmiştir.

$$A \ominus B = \{ z \in E \mid Bz \subseteq A \} \quad (3.1)$$

$$A \oplus B = \{z \in E \mid (\hat{B})_z \cap A \neq \emptyset\} \quad (3.2)$$

Aşındırma eşitliğinde A görüntüyü, B ise yapısal elemanı temsil eder. Bu işlemde yapısal eleman nesnenin tamamen içinde kaldığında merkez piksel korunur; böylece nesne küçülür, kenarları aşınır ve küçük çıkıntılar ortadan kalkar. Genişleme işleminde ise $\hat{B}$ yapısal elemanın orijine göre yansımasını gösterir. Bu işlemde yapısal eleman nesneyle en az bir noktada kesiştiğinde merkez piksel eklenir, sonuçta nesne büyür, boşluklar kapanır ve ince bölgeler kalınlaşır.

Açma ve Kapama işlemleri, aşındırma ve genişlemenin belirli bir sırayla uygulanmasıyla tanımlanır. Açma işlemi, aşındırmanın ardından genişleme uygulanmasıyla formüle edilir. İzole gürültülü pikselleri ortadan kaldırmak için kullanılır; örneğin, nesnenin dışında gürültülü pikseller olduğunda, belirli bir çekirdekle aşındırma uygulayarak önce gürültülü pikselleri ortadan kaldırır ve ardından kalan pikselleri orijinal boyuta genişletir. Kapama işlemi, genişlemenin ardından aşındırma uygulanmasıyla formüle edilir. Küçük delikleri doldurma amacına hizmet eder; örneğin, bir nesne içinde gürültülü bir piksel olduğunda, kapama işlemi önce gürültülü pikseli sarmak için genişletme uygular ve ardından orijinal boyuta geri aşındırır. Yang ve diğerleri (2018) çalışmalarında, piksel düzeyindeki tahminleri saf çatlak görüntülerine dönüştürmek için çapraz yapısal bir çekirdek ile bir kez kapama ve açma işlemleri uygulamıştır. Ancak, açma veya kapama işlemlerinin delikleri doldururken veya izole pikselleri ortadan kaldırırken sınırları yumuşatabileceği ve potansiyel olarak çatlak dallarını keserek uzunluğu azaltabileceği belirtilmiştir. Bu sorunu önlemek için kullanıcıların çatlak segmentasyonunda açma ve kapama işlemlerinin sayısını ayarlamaları önerilmiştir (Yang ve diğerleri, 2018). Kapama işlemi için verilen denklem Eşitlik 3.3'te ve Açma işlemi için verilen denklem Eşitlik 3.4'te gösterilmiştir.

$$A \cdot B = (A \oplus B) \ominus B \quad (3.3)$$

$$A \circ B = (A \ominus B) \oplus B \quad (3.4)$$

Kapama eşitliğinde önce genişleme ($\oplus$) işlemi uygulanmakta, ardından aşındırma ($\ominus$) gerçekleştirilmektedir. Kapama, görüntüdeki küçük boşlukların kapatılması, ince aralıkların doldurulması ve nesne kenarlarının daha düzgün hale getirilmesi için kullanılmaktadır. Özellikle tümörlü bölgelerde sınırların daha belirginleştirilmesinde etkili olmaktadır. Açma

eşitliğinde önce aşındırma ($\ominus$) uygulanmakta, ardından genişleme ($\oplus$) işlemi yapılmaktadır.

Gauss Bulanıklığı

Sayısal görüntü kaydedicilerin görüntüyü hatalı elde etmeleri veya aydınlatma gibi çevre koşullarından kaynaklanan gürültüleri ortadan kaldırmak için çeşitli filtreler kullanılır. Yumuşatma (filtreleme) olarak da geçer. Gauss filtresi, kenar belirleme gibi işlemlerde yaygın olarak bir ön işlem adımı olarak kullanılır (Çan, 2021).

Gaussian bulanıklaştırma, görüntü işleme alanında gürültüyü azaltmak ve görüntülerin görünümünü yumuşatmak için kullanılan yaygın bir tekniktir. Bu işlemde, görüntüdeki her piksel, komşularının ve kendisinin ağırlıklı ortalamasıyla değiştirilir. Ağırlıklar, iki boyutlu bir Gauss fonksiyonu veya çekirdeği (kernel) tarafından belirlenir. Gauss bulanıklaştırma süreci, bir görüntünün Gauss çekirdeği ile konvolüsyonunu içerir. Çekirdek genellikle iki boyutlu bir matristir ve çekirdeğin boyutu ile çekirdeği oluşturan fonksiyonun varyansı (σ olarak gösterilir) istenen bulanıklık seviyesine bağlı olarak değişebilir. Gauss bulanıklaştırma işlemi, her pikselin komşuları ile ağırlıklı ortalaması alınarak gerçekleştirilir. Bu işlem Eşitlik 3.5'te verilmiştir. Burada kullanılan ağırlık fonksiyonu ise Gauss dağılımına dayalıdır. Bu ağırlık fonksiyonu da Eşitlik 3.6'da gösterilmiştir. (Mao, Liu, Fang, G. Z. Jiang ve D. Jiang, 2024).

$$P(x, y) = \sum_{j=y-\frac{n}{2}}^{y+\frac{n}{2}} \sum_{i=x-\frac{n}{2}}^{x+\frac{n}{2}} W(i, j)P(i, j) \quad (3.5)$$

$$W(i, j) = \frac{1}{2\pi\sigma^2} e^{-\frac{i^2+j^2}{2\sigma^2}} \quad (3.6)$$

Burada n , çekirdek boyutunu; (x, y) ise koordinatları temsil eder ve σ , standart sapmayı ifade etmektedir. $P(x, y)$, filtrelenmiş görüntüde x ve y koordinatlarındaki pikselin değerini ifade etmektedir. Denklemden yer alan çift toplam işareti, ilgili pikselin etrafında tanımlanan $n \times n$ boyutundaki komşuluk penceresi üzerindeki tüm piksellerin hesaba katıldığını göstermektedir. i ve j değişkenleri, bu pencere içerisindeki piksel koordinatlarını temsil ederken, $W(i, j)$ ağırlık fonksiyonunu belirtmektedir. Bu ağırlık fonksiyonu, pencere içindeki

piksellerin katkısının ne ölçüde olacağını belirler. $P(i,j)$ ise orijinal görüntüde i ve j koordinatlarındaki piksel değeridir. Dolayısıyla, bu denklem temelde pencere içerisindeki tüm piksellerin ağırlıklı ortalamasını alarak yeni bir piksel değeri üretmektedir. Bu yöntem, görüntüde gürültünün azaltılması ve daha düzgün bir temsil elde edilmesi amacıyla kullanılan temel filtreleme yaklaşımıdır.

Gauss bulanıklaştırma ayrıca tıbbi görüntülerde bulanıklık seviyesini değerlendirmek için de kullanılır. Osadabey, Pedersen ve Arnold (2018) Paralel çok ölçekli Farklı Gauss (Difference of Gaussian, DOG) filtreleri kullanarak MR görüntülerindeki bulanıklık bozulmasını değerlendiren kör bir yöntem önermiştir. Bu yöntemde, görüntü kalitesi farklı Gauss ölçeklerinde kenar bilgisinin varlığı ve kalıcılığından ölçülür. İki paralel DOG filtresi, farklı parametrelerle çok ölçekli temsilde eş zamanlı olarak görüntüyü işler; bu filtrelerden biri kenarları vurgularken diğeri zayıflatır. Bulanıklık seviyesi, bu filtrelerin çıktılarından elde edilen özellikler arasındaki ilişkiden veya farktan değerlendirilir. (Osadabey, Pedersen ve Arnold, 2018)

Gauss filtresi ile yumuşatma, Canny kenar belirleme algoritmasının ilk adımıdır. Bu adım, gradyanların hesaplanmasından önce gürültüyü azaltarak daha doğru kenar tespiti yapılmasına yardımcı olur. Ölçekten Bağımsız Özellik Dönüşümü (SIFT) algoritmasında da Gauss ölçek alanı hesaplaması ilk adımdır (Çan, 2021; Eren, 2011). Genel olarak, Gauss bulanıklaştırma, görüntüdeki rastgele gürültüyü azaltmak için etkili bir yöntemdir ancak ayrıntıları da bir miktar kaybeder.

Veri artırma tekniği olarak da kullanılan Gauss bulanıklaştırma, veri kümesi boyutunu artırmayı hedefler. Ancak, bu etkiyi eklemek görüntü kalitesini bozabilir ve nesnenin özelliklerini değiştirebilir, bu da bazı görevlerde, örneğin beyin tümörü (glioma) görüntülerinin sınıflandırılması deneyinde olduğu gibi, daha düşük doğruluğa yol açabilir. Bu çalışmada, Gauss bulanıklığı uygulanmış veri kümesi, diğer artırma tekniklerine kıyasla en düşük test doğruluğunu (66%) elde etmiştir, çünkü bulanıklık ve gürültü efektleri görüntülerin kalitesini bozarak nesne özelliklerini değiştirmiştir (Safdar, Alkobaisi ve Zahra, 2020).

Histogram Eşitlemesi

Görüntü kalitesinin temel görsel özelliklerinden biri olan kontrast, CT görüntülerinde sık karşılaşılan bir sorundur. Düşük kontrastlı CT görüntüleri, görüntü kalitesini düşürür ve faydalı bilginin çıkarılmasını zorlaştırır. Düşük radyasyon dozu kullanımı, farklı cihazlar ve işleme algoritmaları, kısmi hacim etkileri ve gürültü gibi çeşitli faktörler düşük kontrastlı CT görüntülerine neden olabilir. Bu tür sorunları gidermek için görüntü kontrastını artıran özel teknikler geliştirilmiştir. (Al-Ameen, Sulong ve Rehman, 2012)

Histogram tabanlı teknikler, düşük kontrast sorununu ele almak için yaygın bir yaklaşımdır. Bu teknikler, gri seviyeleri iyileştirerek uzamsal alanda görüntü kalitesini artırmayı hedefler. Doğrudan ve sezgisel uygulamaları nedeniyle araştırmacılardan önemli ilgi görmüşlerdir ve görüntünün tamamına (küresel) veya belirli bölgelerine (yerel) uygulanabilirler. Ancak, bu teknikler geniş bir düşük kontrastlı görüntü yelpazesi için genellikle yetersiz sonuçlar verir. AL-Ameen ve diğerleri (2012) yaygın histogram tabanlı teknikleri ve bunların evrimini, özellikle de tıbbi görüntülemelerde önemli bir rol oynayan Histogram Eşitleme (HE), Uyarlanabilir Histogram Eşitleme (AHE) ve Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) yöntemlerini kaynaklarda sunulan bilgiler doğrultusunda incelemiştir (Al-Ameen ve diğerleri, 2012).

HE, farklı görüntüleme uygulamaları tarafından yaygın olarak kullanılan kontrast artırma tekniğidir. Bunun ana nedenleri, tekniğin kolaylığı ve hızıdır. Temel olarak, histogram eşitleme, belirli bir görüntünün piksel değerlerinin yeniden tahsis edilmesi yoluyla gerçekleştirilir (Al-Ameen ve diğerleri, 2012). Bu, tüm görüntünün yoğunluk histogramının normalleştirilmiş kümülatif dağılım fonksiyonundan (KDF) türetilen piksel bazında bir yoğunluk eşlemesi kullanılarak histogramı daha düzgün bir dağılıma yeniden şekillendirmeyi amaçlar (Stimper, Bauer, Ernstorfer, Schölkopf, Xian, 2019).

HE tekniğinin temel prensibi, görüntünün piksel değerlerinin dağılımını, genellikle 0 ile 255 arasındaki gri seviyelerinde daha homojen bir şekilde dağıtmaktır. Bu, düşük kontrastlı bölgelerin kontrastını artırabilir. Bununla birlikte, HE'nin çeşitli dezavantajları bulunmaktadır. Bunlar arasında ayrıntı kaybı, aşırı artırma (over enhancement), gürültü yükseltme ve giriş ve çıkış görüntüleri arasındaki aydınlatma açısından dikkate değer bir farklılık üreten ortalama kayması sorunu yer alır. HE, birçok durumda yetersiz performans

göstermiştir. Örneğin, bir CT görüntü artırma çalışmasında HE, aşırı artırılmış, gerçekçi olmayan kontrasta sahip ve görsel hatalardan etkilenmiş sonuçlarla en kötü performansı göstermiştir (Al-Ameen, Sulong ve Johar, 2015). Bir başka çalışmada, beyin tümörü segmentasyonu bağlamında HE'nin, CLAHE'ye kıyasla doğruluk ve segmentasyon metrikleri açısından daha düşük performans gösterdiği bulunmuştur (Saifullah, Pranolo ve Drezewski, 2024). HE, yoğunluk histogramını küresel olarak hesapladığı için ince ölçekli görüntü özelliklerini gözden kaçırabilir (Stimper ve diğerleri, 2019).

Uyarlanabilir Histogram Eşitlemesi

HE'nin küresel histogram hesaplamasının neden olduğu sınırlamaları gidermek için, Uyarlanabilir Histogram Eşitleme (AHE) adı verilen modifikasyonlar getirilmiştir. Ketcham ve Hummel tarafından bağımsız olarak tanıtılan AHE (Halloum ve Ez-Zahraouy, 2025), her piksel etrafındaki bir dikdörtgen pencerenin (çekirdek veya bağlamsal bölge) yoğunluk histogramını kullanarak yoğunluk eşlemesini tahmin eder. Bu yaklaşım, HE'nin gözden kaçırabileceği ince ölçekli görüntü özelliklerini ele almayı amaçlar. Ancak AHE, önemli hesaplama yükü ile birlikte gelir, çünkü tüm pikseller etrafındaki çekirdek histogramları hesaplanır. Ayrıca, nispeten düzgün yoğunluklara sahip bölgelerdeki gürültü aşırı derecede yükseltilme eğilimindedir (Stimper ve diğerleri, 2019).

Bu dezavantajları azaltmak için, Pizer ve arkadaşları (1987), görüntüyü yerel histogram hesaplaması için bölen yalnızca bitişik çekirdekleri kullanarak hesaplama maliyeti daha düşük bir AHE versiyonu önermiştir. Dönüştürülmüş yoğunluklar daha sonra çekirdeklerin merkezinde olmayan diğer piksellere bilinear olarak enterpolasyonla aktarılır. Daha da önemlisi, bu çalışma yoğunluk yeniden dağılımını kısıtlamak ve gürültü yükseltmesini bastırmak için histogram kırpma limitini tanıtmıştır. Bu durum, Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme'nin (CLAHE) geliştirilmesine yol açmıştır. (Stimper ve diğerleri, 2019)

Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE)

CLAHE, HE'den sonra önerilen iyileştirilmiş bir tekniktir (Al-Ameen ve diğerleri, 2012). Histogram tabanlı kontrast iyileştirme (CE) algoritmaları sınıfında yaygın olarak benimsenen bir örnektir. CLAHE, Uyarlanabilir Histogram Eşitleme'nin gürültü yükseltme

sorununu ele alarak daha dengeli bir kontrast ve gürültü kontrolü sağlar (Stimper ve diğerleri, 2019).

CLAHE, görüntüyü yaklaşık olarak eşit boyutlarda çok sayıda örtüşmeyen bölgeye (karo olarak adlandırılır) bölme fikrine dayanır (Reza, 2004; Swadi, Mahdi, Daway, 2024; Ullah ve diğerleri, 2021). Geleneksel tekniğin aksine, tüm görüntü üzerinde çalışmak yerine, CLAHE küçük bölgeleri, yani karoları işler ve bilineer enterpolasyonla birleştirerek artefaktları önler (Mukhopadhyay ve diğerleri, 2015). Örneğin, 512x512 görüntüler için bölgeler genellikle her yönde 8'e bölünerek 64 bölge oluşturulur. Bu bölgeler köşe, sınır ve iç bölgeler olarak sınıflandırılır. (Reza, 2004)

CLAHE, her bölgenin histogramını hesaplar. Daha sonra, kontrast genişlemesi için istenen bir limite dayanarak histogramları kırmak için bir kırpma limiti elde edilir. Her histogram, yüksekliği kırpma limitini aşmayacak şekilde yeniden dağıtılır (Reza, 2004). Bu, yoğunluk yeniden dağılımını kısıtlar ve gürültü yükseltmesini bastırır (Ullah ve diğerleri, 2021; Stimper ve diğerleri, 2019). Son olarak, ortaya çıkan kontrast sınırlı histogramların kümülatif dağılım fonksiyonları (KDF) gri seviye eşlemesi için belirlenir. Pikseller, en yakın dört bölgenin eşlemelerinden elde edilen sonuçları doğrusal olarak birleştirerek eşlenir (Reza, 2004). 3D veriler için trilineer enterpolasyon kullanılır (Stimper ve diğerleri, 2019).

CLAHE tekniğinin iki temel parametresi vardır: Blok Boyutu (BS) ve Kırpma Limiti (CL). Bu parametreler, iyileştirilmiş görüntü kalitesinde merkezi bir rol oynar. Kırpma Limiti (CL) artırıldığında, görüntü daha parlak hale gelir. Bu, orijinal görüntünün çok düşük yoğunlukta olmasından ve daha yüksek bir CL değeriyle daha düz bir histogram elde edilmesinden kaynaklanır. Kırpma limiti arttırılarak, görüntünün dinamik aralığı genişletilir ve bu da görüntü kontrastında bir artışa yol açar (Halloum ve Ez-Zahraouy, 2025)

CLAHE, yerel ayrıntıları etkili bir şekilde korur ve kontrastı uyarlanabilir şekilde artırır (Saifullah ve diğerleri, 2024). Homojen bölgelerdeki gürültü benzeri artefaktları azaltarak geleneksel HE'nin aşırı artırma sorununu giderir (Ullah ve diğerleri, 2021). CLAHE, tıbbi uygulamalar için geliştirilmiştir. Özellikle, düşük kontrastlı CT medikal görüntülerindeki zayıf kontrastı iyileştirmek için erken uygulaması yapılmıştır. Klinik amaçlar için kullanılması mümkündür. Bu nedenle, standart CLAHE'nin performansını iyileştirmek, CT

taramaları dahil olmak üzere modern klinik rutinlerle uygulanma potansiyeli yüksek olduğu için oldukça yaygın kullanılmaktadır. (Al-Ameen ve diğerleri, 2012).

Bu algoritmada da bazı dezavantajlar bulunmaktadır; bazı CT görüntülerini düzgün işleyememiş ve görüntüler dengesiz kontrasta ve artmış parlaklığa sahip olduğu için yetersiz sonuçlar üretmiştir. Bu sınırlamalar, modern klinik rutinler için güvenilir bir artırma tekniği olarak CLAHE'nin güvenilirliğini azaltmıştır (Al-Ameen ve diğerleri, 2012). CLAHE'nin, standart HE'ye kıyasla görüntünün kontrastını etkin bir şekilde iyileştirmesine rağmen, istenmeyen pikselleri yükseltme eğilimi hala mevcuttur (Ullah ve diğerleri, 2021).

Wiener Filtreleme

Wiener filtresi, 1940 yılında Norbert Wiener tarafından önerilen ve 1949'da yayınlanan, sinyaldeki gürültüyü azaltmak için kullanılan istatistiksel temelli bir filtredir. Geleneksel filtreler istenen frekans yanıtına göre tasarlanırken, Wiener filtresi farklı bir yaklaşımla filtreleme yapar (Jadwaa, 2018). Orijinal sinyalin ve gürültünün spektral özelliklerinin bilindiği varsayılır ve çıktıları orijinal sinyale olabildiğince yakın olan bir Lineer Zamanla Değişmeyen (Linear Time-Invariant, LTI) filtresi aranır (Suresh, Papendra, Manoj, Nagawat, 2010).

Wiener filtresi görüntüleri normalleştirir ve düşük kontrast sorunlarını giderir. Temel amacı, görüntüdeki bulanıklaştırmayı ve gürültüyü aynı anda gidererek görüntüyü iyileştirmektir. Wiener filtreleme, ortalama kare hataları optimum hale getirerek görüntü iyileştirme sağlar. Bu filtreleme tekniği, genellikle Fourier dönüşümü ile elde edilen frekans bölgesinde ifade edilir (Atbakan, 2021). Wiener filtresinin frekans bölge hesabı için kullanılan denklem Eşitlik 3.7'de verilmiştir.

$$W(a, b) = \frac{H * (a, b) S_{xx}(a, b)}{|H(a, b)|^2 2S_{xx}(a, b) + S_{\eta\eta}(a, b)} \quad (3.7)$$

Bu eşitlikte $W(a, b)$ Wiener filtresinin frekans domenindeki katsayılarını ifade etmektedir. $H(a, b)$ görüntüleme sisteminin veya bulanıklığa neden olan bozucu sistemin transfer fonksiyonunu, $H * (a, b)$ ise bunun kompleks eşleniğini göstermektedir. $|H(a, b)|^2$ terimi,

sistemin genlik karesini ifade ederken; $S_{xx}(a, b)$ orijinal görüntünün güç spektral yoğunluğunu, $S_{\eta\eta}(a, b)$ ise gürültünün güç spektral yoğunluğunu belirtmektedir.

Wiener filtresi, tıbbi görüntülerde gürültü azaltma uygulamalarında yaygın olarak kullanılan bir filtredir (Jadwaa, 2018). Özellikle Gauss gürültüsünü azaltmak için kullanılır (Habeeb, 2023). Görüntü kalitesi parametreleri olarak MSE (Ortalama Kare Hata), SNR (Sinyal-Gürültü Oranı) ve PSNR karşılaştırma için ana parametreler olarak ele alınmıştır. PSNR, gürültüsü azaltılmış görüntü ile referans görüntü için maksimum sinyal yoğunluğu S_{max} ve ortalama kare hata MSE kullanılarak tanımlanır (Hamad, Muhamad ve Yaba, 2015).

Medyan Filtresi

Medyan filtresi, görüntü işleme tekniklerinde sıklıkla kullanılan, doğrusal olmayan bir sayısal filtreleme yöntemidir (Çan, 2021; Üncü, Sevim ve Canpolat, 2021). Bu filtre türü, özellikle görüntülerdeki istenmeyen gürültüyü gidermek (Aldeeb, 2017) ve görüntüyü yumuşatmak amacıyla kullanılır. Medyan filtre, "Orta Değer filtresi" veya "Sıralama filtresi" olarak da bilinir (Dinçer, 2018). Doğrusal olmayan filtreler sınıfına aittir ve sıra istatistiği tabanlıdır.


Medyan filtresi, bir uzaysal filtreleme yöntemidir (Üncü ve diğerleri, 2021). Çalışma prensibi, işlem gören pikselin değerini, bu pikseli merkez alan belirli bir komşuluk (maske veya pencere olarak adlandırılır) içerisindeki diğer piksellerin değerlerinin ortanca (medyan) değeri ile değiştirmek esasına dayanır (Hanum, 2017).

Bu işlem adımları genellikle şunları içerir:

1. Görüntü üzerinde belirli bir boyutta (örneğin $N \times N$) bir filtre maskesi/penceresi tanımlanır.
2. Bu pencere, görüntüdeki bir pikselin üzerine (merkezinine) yerleştirilir.
3. Pencere içindeki tüm piksellerin yoğunluk (gri ton) değerleri küçükten büyüğe doğru sıralanır.
4. Bu sıralanmış listedeki ortanca değer belirlenir.

5. Pencerenin merkezindeki orijinal pikselin değeri, hesaplanan bu ortanca değer ile değiştirilir.
6. Bu pencere, görüntü üzerinde kaydırılarak tüm pikseller için bu işlem tekrarlanır (Hanum, 2017)

Medyan filtresi, görüntüdeki değişimin tek bir pikselden ziyade bir grup pikselde ortak olarak ortaya çıkması gerektiği düşüncesine dayanır. Bu ortak davranışa uymayan pikseller gürültü olarak değerlendirilir ve etkisi komşularına bağlı olarak yumuşatılır (Birdal, 2014). Sıralama işlemi sonucunda, genellikle gürültüye karşılık gelen uç değerlere (en yüksek ve en düşük yoğunluk değerlerine) sahip pikseller sıralamanın başında veya sonunda yer alacağından, ortanca değerin seçilmesiyle bu uç değerler etkili bir şekilde yok edilmiş olur. Filtre maskesinin boyutu kullanıcı tarafından belirlenebilmektedir (Değirmenci ve diğerleri, 2018). 3×3 boyutlu bir medyan filtrenin bir görüntü matrisine uygulanması sonucu elde edilen yeni görüntü matrisi, Şekil 3.5'te verilmiştir.




Şekil 3.5. 3x3 Medyan filtrenin bir görüntü matrisine uygulanması.

Medyan filtresi, özellikle tuz ve biber gürültüsü gibi impuls gürültüsünün giderilmesinde oldukça etkilidir (Hanum, 2017). Tuz ve biber gürültüsünde ortalama veya Gauss filtresi gibi doğrusal filtreler gürültünün yayılmasına ve gürültüsüz piksellerdeki bilginin bozulmasına

yol açarken, medyan filtrede uç değerler kolaylıkla giderilir. Medyan filtre, biber denilen siyah noktaları silebilir ve görüntüdeki tuz denilen beyaz delikleri doldurabilir (Değirmenci ve diğerleri, 2018).

Gürültüyü azaltırken görüntüdeki detayların ve mekansal ayrıntıların korunmasına olanak sağlar (Değirmenci ve diğerleri, 2018). Kenarları koruma konusunda çok etkilidir (Aldeeb, 2017) ve ortalama filtreye göre görüntü detaylarını saklamada daha başarılıdır. Medyan filtre, kenardaki keskinliği ortalama filtreye göre daha iyi korur; örneğin, siyah-beyaz bir sınırdaki ortadaki değer ya siyah ya beyaz olur, gri olmaz, bu yüzden keskinlik kaybolmaz. Belirli rastgele gürültü türleri için harika bir gürültü azaltma kabiliyetine sahiptir ve benzer doğrusal düzeltme filtrelerine göre daha az bulanıklığa sebep olur (Dinçer, 2018).

Medyan filtre, tıbbi görüntüleme gibi çeşitli alanlarda kullanılmaktadır. Örneğin, MR görüntülerinde ön işleme adımı olarak gürültü giderme amacıyla uygulanmıştır (Dinçer, 2018). Retina görüntülerinde gürültüyü ve aydınlatma kusurlarını gidermek için de kullanılmıştır (Yakut ve Ulukaya, 2022). Medyan işlemi uygulanmış MR görüntüleri Şekil 3.6'da verilmiştir.



Şekil 3.6. Medyan bulanıklaştırma örneği.

İmpulsif gürültünün toplam yüzdesi arttıkça kenar koruması bozulabilir. Görüntünün kenar bölgelerini bozma potansiyeline sahiptir. Yüksek frekanslı detayların geçmesine izin verebilir. Yeniden oluşturulmuş bir görüntünün kalitesini artırmak için tek başına yeterli

olmayabilir. Standart medyan filtre uygulandığında, gürültüsüz piksellerin değerlerinin değişmesine ve görüntüdeki detayların kaybolmasına yol açabilmektedir.

3.2. Derin Öğrenme


Derin öğrenme, tıbbi görüntü analizi alanında sağlık hizmetlerinin kalitesini iyileştirmek için uzmanlara faydalı bir yetkinlik sağlamaktadır. Özellikle nörogörüntüleme, beyin kanserlerinin tanı ve tedavisinde kritik öneme sahiptir (Terzi ve Demirezen, 2022). Derin öğrenme yöntemleri, medikal görüntülerin işlenmesine dayalı hastalık tespiti çalışmalarında sıkça kullanılmaktadır (Aslan, 2022). Geleneksel makine öğrenmesi ve görüntü işleme tekniklerinin aksine derin ağlar, öğrenme işlemini ham veri üzerinde yapar. Bu, gerekli bilgiyi farklı katmanlarda oluşturduğu temsillerle elde etmesine olanak tanır (Karayeğen ve Akşahin, 2021).

Derin öğrenme ile nesne tespitinde kullanılan popüler yöntemler arasında YOLO (You Look Only Once), SSD (Single Shot Multibox Detector), R-CNN (Region Based Convolutional Networks), Fast R-CNN, Faster RCNN ve Mask R-CNN bulunmaktadır (Daş, Polat ve Tuna, 2019). Liu, ve diğerleri 2016 yılında yayınladıkları SSD modeli, daha hızlı algılamaya ancak daha düşük doğrulukla izin veren bir mimariye sahiptir. Faster-RCNN yavaş algılama hızının yanı sıra daha yüksek doğruluğa sahiptir (Galvez, Bandala, Dadios, Vicerra ve Maningo, 2018). R-CNN, nesne tespiti uygulamalarında kullanılamayacak kadar yavaş bir uygulama olduğu için daha hızlı nesne tespiti yapma amacıyla üretilen SSD, Fast R-CNN ve Faster R-CNN gibi hızlı olması amaçlanan yöntemler nesne tespitinde odak noktası haline gelmiştir (Daş ve diğerleri, 2019). Algılaması yapılacak nesnede yüksek başarı oranına sahip olmak için Faster R-CNN modeli kullanılmalıdır. Ancak R-CNN ve YOLO serisi SSD modeline kıyasla daha güçlü donanıma ihtiyaç duyar ve aynı zamanda daha yavaştır. SSD modeli, düşük donanıma sahip cihazlarda dahi nesneleri hızlı bir şekilde algılayabilmektedir. Bunların yanı sıra son yıllarda öne çıkan DETR (Detection Transformer) modeli, nesne tespitini doğrudan bir küme tahmini problemi olarak ele alarak geleneksel yöntemlerde kullanılan önceden tanımlı kutucuklar (anchor boxes) veya maksimum olmayan kutuların bastırılması (Non-maximum Suppression, NMS) gibi ek bileşenlere duyulan ihtiyacı ortadan kaldırmıştır. Transformer tabanlı mimarisi sayesinde global bağlamı dikkate alarak nesne ilişkilerini daha iyi modelleyebilmekte, özellikle karmaşık tıbbi görüntülerde daha esnek bir öğrenme sağlamaktadır. Bu yönüyle DETR, YOLO ve SSD gibi hızlı modellerin yanında,

filtreler. Gerçek zamanlı uygulamalar için oldukça uygun olan YOLO, 63.4 mAP doğruluk ve 45 FPS hız sağlamaktadır. DETR ise, SSD ve YOLO'dan farklı olarak, nesne tespiti doğrudan küme tahmini problemi olarak ele alan bir Transformer tabanlı yaklaşımdır. Görüntüden çıkarılan öznitelikler, pozisyonel kodlamalar ile birlikte Transformer Encoder'a aktarılır. Encoder çıktısı, sabit sayıda kullanılarak Transformer Decoder'a gönderilir. Decoder çıktıları ise her nesne için sınıf ve kutu tahminlerini üreten beslemeli ileri ağlara iletilir. DETR, anchor kutulara veya NMS gibi ek işleme ihtiyaç duymadan tahmin yapabilmesiyle öne çıkmaktadır. Literatürde (Carion ve diğerleri, 2020) COCO veri kümesi üzerinde yaklaşık 42 mAP doğruluk ve 28 FPS hız elde ettiği raporlanmıştır. Sonuç olarak, SSD ve YOLO daha hızlı ve verimli çözümler sunarken, DETR daha yenilikçi bir yaklaşım sergileyerek karmaşık görüntülerde nesne ilişkilerini modelleme avantajı sağlamaktadır.


3.2.1. Single Shot Detector (SSD)

SSD (Single Shot Detector), nesne tespiti için kullanılan bir modeldir ve hafif yapısıyla bilinir. Bu sayede, kaynak kısıtlaması olan cihazlarda bile gerçek zamanlı performans elde etmek mümkün olur. SSD mimarisi, görüntüdeki nesnelerin konumlarını ve sınıflarını tek bir geçişte tahmin etmeyi öğrenen tek bir evrişimsel ağ kullanır ve bunun sonucunda oluşturduğu özellik haritalarını kullanarak nesne sınıflarını ve sınırlayıcı kutu ofsetlerini tahmin eder. SSD evrişimli sinir ağından geçen görüntünün farklı boyutlarda özellik katmanları oluşturur. Farklı boyutlardaki görüntüler evrişimli filtre aracılığıyla 3x3 sınırlayıcı kutulara ayrılarak ızgara ile bölünmüş görüntünün tek seferde sınır kutuları arasından büyüklük fark etmeksizin evrişimli sinir ağı içerisinde işlenir. SSD mimarisi Şekil 3.8'de verilmiştir.




Şekil 3.8. SSD mimarisi.

Özellik çıkarımının ardından çok kutulu dedektörü içerisinde “ $m \times n \times p$ ” boyutunda bir katman elde edilir. Katmanın “ $m \times n$ ” boyutu nesnenin bölgelerinin sayısını “ p ” ise kanal sayısını ifade eder. Nesnelerin çerçeveleri için pozisyon bilgileri Şekil 3.9’da verilmiştir.



Şekil 3.9. Nesnelerin 4x4 ve 8x8 çerçeveleri için pozisyon ve doğruluk değerleri.

Görüntüde taranan bölge başına k değişkeniyle ifade edilen ve nesneleri görüntüdeki duruşlarına uygun tarama amacıyla farklı ebatlarda k sınırlayıcı kutuları bulunur. Bu kutular eğitilen nesneye göre ekranı farklı ebatlarda tararlar. Böylece eğitilen nesnenin görüntüdeki alanına göre nesneye uygun sınırlayıcı kutular belirlenir ve buna göre kayıp ölçümleri yapılabilir. Eğitim esnasında test klasörü baz alınarak iki değişkene bağlı olarak doğruluğun yüksek tutulması beklenir. Bunlardan ilki güven kaybı (confidence loss) değişkeniyle nesnenin benzerliği hakkında parametre belirlenirken konum kaybı (location loss) ise eğitim setine göre eğitilen nesnenin test setindeki verilere göre olan uzaklığını belirtir (Liu ve diğerleri, 2016). Bu çalışma için eğitilen modelin ham verilerde kesinlik oranı %90,5 ve duyarlılık oranı %87,5 olarak gözlemlenmiştir. Eğitim sırasında bu oranların değişimi Şekil 3.10’daki gibidir.




Şekil 3.10. SSD eğitiminde kesinlik ve duyarlılık grafiği.

Nesne tespit metodu olan SSD, CNN'in öznitelik çıkarımı için tasarlanan mimarisinden bağımsızdır. Bu nedenle hata oranına kıyasla en düşük karmaşıklık seviyesine sahip CNN ağlarından biri olan MobileNet-V2, SSD ile birleştirilmiştir. SSD mimarisinde varsayılan olarak kullanılan VGG-16 yerine MobileNet-V2 tercih edilmiştir. SSD üzerinden uygulanan sınıflandırma işleminde kullanılan öznitelik haritalarında CNN mimarisi yerleşimi yapılmaktadır. Şekil 3.11'de görüldüğü gibi dört öznitelik haritası SSD tarafından MobileNet'in CNN mimarisine entegre edilmiştir. Geri kalan iki öznitelik haritası CNN mimarisinin sonuncu ve sondan üçüncü katmanlarıdır.

MobileNetV2, 2017 yılında Google tarafından önerilen MobileNetV1 modelinin geliştirilmiş bir versiyonudur. Mobil cihazlarda veya düşük hesaplama gücüne sahip herhangi bir cihazda kullanılmak amacıyla geliştirilmiştir. Hafif bir yapıya sahip olup, ağır karmaşıklık maliyetini ve model boyutunu önemli ölçüde azaltan derinlemesine ayarlanabilen evrişimi temel almaktadır. Buna ek olarak ters çevrilmiş artıklar ve doğrusal darboğazları kullanır. Ters çevrilmiş artıklar, daha fazla özellik elde etmek için kanalı 1x1 evrişim yoluyla genişletir, ardından özellik çıkarımı için 3x3 derinlemesine evrişimi kullanır ve son olarak kanal numarasını geri sıkıştırmak için 1x1 noktadan noktaya evrişim kullanır (Aslan, 2022).

Aslan (2022), MR görüntülerini kullanarak otomatik beyin tümörü tespiti için MobileNetV2 evrişimli sinir ağı (ESA) modelinden transfer öğrenmeye dayalı olarak derin öznitelik çıkarımı ve bu özniteliklerin k-EYK sınıflandırılması yöntemini önermiştir. Bu çalışmada MobileNetV2, daha düşük kapasiteli donanımlarda kullanılabilecek bir CNN modeli olarak önerilmiştir. Transfer öğrenme, önceden eğitilmiş bir modeli kullanarak yeni verileri öğrenmek için daha önce öğrenilen özelliklerin kullanılmasıdır. Bu yaklaşım, öğrenilebilir parametrelerin optimizasyon süresini kısaltır ve eğitim ile öznitelik çıkarım sürecini hızlandırabilir. MobileNetV2 modelinin genelleme performansını artırmak için veri çoğaltma yöntemleri kullanılmıştır. Deneysel sonuçlar, MobileNetV2'den çıkarılan derin özniteliklerin kNN sınıflandırıcı ile sınıflandırılmasında yüksek doğruluk skorlarına ulaşabildiğini göstermiştir (veri çoğaltma ile %96,44). Daha hafif ağırlıklı bir model olan MobileNetV2'nin, diğer CNN modellerine kıyasla daha yüksek sınıflandırma doğruluğu elde etmesi önerilen yöntemin başarısını göstermektedir. Bu, veri toplamının sınırlı olduğu sağlık alanında önceden eğitilmiş VGG tabanlı modellerin yanı sıra MobileNetV2 gibi modellerin yüksek uygulanabilirliğine işaret eder (Aslan, 2022).

4,2 milyon parametre ve 28 katmandan oluşan MobileNet, görüntü uygulamaları kapsamında gömülü sistemlerde düşük gecikme süresine sahip performansına ek olarak modern mimarisi sayesinde derinlemesine ayrılabilir evrimsel sinir ağları kullanmaktadır (Uçar, 2021). MobileNet evrim sistemi her giriş kanalına tek filtre uygulanan derinlemesine ayrılabilir evrimle başlar. Ardından 1x1 boyutunda noktasal evrim uygulanır. Modelin kısıtlamalarına dayanarak uygulanan iki küresel hiper parametre sayesinde gecikme ve doğruluk arasında verimli bir orantı sağlamaktadır. Transfer öğrenimini uygulamak için çok daha az hesaplama gücü gerektirir (Howard ve diğerleri, 2017).



Şekil 3.11. SSD ve MobileNet mimari birleşimi.

Katman birleşiminde 28 katman barındıran MobileNet-V2 mimarisinin ilk 13 katmanı kullanılmaktadır. Şekil 3.11’de görüldüğü üzere CNN mimarisinde karar verme bazında 11. ve 13. öznitelik haritaları kullanılmıştır.


SSD MobileNetV2, TensorFlow kütüphanesi ile entegre bir şekilde çalışabilir. TensorFlow, modelin eğitimi ve çıkarımı için gerekli araçları sağlar. Örneğin, TensorFlow 2 Object Detection API kullanılarak bir SSD MobileNetV2 modeli, bitki hastalıklarını tespit etmek için başarıyla kullanılmıştır. SSD MobileNetV2, düşük işlem gücüne sahip cihazlarda gerçek zamanlı nesne tespiti gerektiren uygulamalar için idealdir. Çöp tespiti, trafik ışığı algılama ve bitki yaprağı hastalıklarının tespiti gibi çeşitli alanlarda kullanılmaktadır.

3.2.2. You Only Look Once (YOLO)

Nesne tespiti alanında popüler derin öğrenme mimarilerinden biri YOLO (You Only Look Once)'dur. YOLO, görüntüleri tek bir geçişte işleyerek nesnelerin konumlarını ve sınıflarını aynı anda tahmin eden, tek aşamalı derin öğrenme tabanlı algılayıcılardan biridir. Gerçek zamanlı uygulamalarda Faster R-CNN gibi modellere kıyasla hız ve doğruluk arasında yeterli dengeyi sağladığı belirtilmektedir. (Öksüz ve Güllü, 2020)

Tıbbi görüntüleme, özellikle MR kullanılarak beyin tümörü tespiti, YOLO modellerinin aktif olarak kullanıldığı başka bir alandır (Z. Lin, W. Lin ve Jiang, 2024). Beyin tümörlerini manuel olarak tanımlamak, otomatik tekniklerin geliştirilmesini gerektiren, hatalara açık, zor ve zaman alıcı bir süreçtir. YOLO modellerinin YOLOv8-DEC gibi gelişmiş versiyonlarının, özellik algısını geliştirmek, bağlamsal bilgileri entegre etmek ve lezyon özelliklerine duyarlılığı artırmak için C2f_DySnakeConv, CAABE ve EMA gibi modülleri dahil ederek beyin tümörü tespitinin doğruluğunu artırmak için önerilmiştir. Deneysel karşılaştırmalar, geliştirilmiş YOLOv8 modellerinin kesinlik, duyarlılık ve ortalama kesinlik (mean Average Precision, mAP) gibi metrikler açısından orijinal ve diğer kıyaslama modellerinden daha iyi performans sergilediğini göstermektedir (Lin ve diğerleri, 2024). YOLOv5 ve FastAi kullanan bir çalışma, gerçek zamanlı beyin tümörü tespiti ve sınıflandırması için otomatik bir sistem oluşturmayı amaçlamıştır (Dipu, Shohan ve Salam, 2021). Başka bir çalışma, beyin tümörü lezyon bölgelerini doğru bir şekilde tanımlamak, Br35H gibi veri kümelerinde yüksek performans elde etmek ve çok seviyeli özellik füzyonu ve bilgi kaybı ile ilgili sorunları ele almak için RGNet ve Küresel Bağımlılık Bloğu (Global Dependency Block, GDB) gibi stratejileri içeren YOLO çerçevesine dayalı yeni bir sinir ağı geliştirmiştir (Yao, Zhuang, Feng, Wang ve Liu, 2024).

YOLO'nun temel çalışma prensibi, giriş görüntüsünü $S \times S$ 'lik bir ızgaraya (grid) bölmektir. Eğer bir nesnenin merkezi bu hücrelerden birine düşerse, bu hücre o nesneyi algılar. Algoritma, görüntüdeki nesnenin belirli bir sınıfa girme olasılığını puanlandırır. Bu puan, çerçevenin tümör olasılığı (pc) ile sınıf numarasının (S_i) çarpılmasıyla hesaplanabilir. En yüksek olasılığa sahip olan sınıf seçilir ve puan değeri çerçeve üzerine atanır. Bu algılama sürecinin görsel karşılığı, Şekil 3.12'de verilmiştir. YOLO'da etiketleme süreci, nesneleri tanımlamak ve sınıflandırmak için görüntüdeki belirli bölgeleri veya nesneleri işaretleme işlemidir. Etiketlenmiş verilere ait değerler .txt formatında kaydedilir (Yılmaz, 2023).



Şekil 3.12. YOLO algılama süreci.

Derin öğrenme tabanlı nesne tespit modelleri arasında YOLO mimarisi, hızı ve doğruluğu nedeniyle tercih edilen yapılardan biridir (Yılmaz, 2023). Birden fazla sınırlayıcı kutu tespit edildiğinde, Maksimum olmayanı bastırma (Non-Maximum Suppression, NMS) gibi yöntemler kullanılabilir.


YOLO, genellikle CNN mimarisi üzerine kurulmuş bir yapıdır (TÜBAV, 2020; Yılmaz, 2023). CNN'ler, görüntü analizi için oldukça güçlü derin öğrenme algoritmalarıdır. YOLO mimarisi, evrişim katmanları ve tam bağlantılı katmanlardan oluşur. Örneğin, GoogleNet mimarisi baz alınarak oluşturulan YOLO model mimarisi 24 evrişimli katman ve sonrasında iki tam bağlı katmandan oluşabilir (Kirelli, 2022). YOLOv7 mimarisi ise E-ELAN hesaplama bloğundan oluşmaktadır (Özcan ve Bakır, 2023).

YOLO modellerinin eğitimi için veri setleri kullanılır (TÜBAV, 2020; Yılmaz, 2023). Veri setleri hazırlanırken veri artırma (data augmentation) teknikleri kullanılabilir; bu, görüntülere geometrik dönüşümler (çevirme, öteleme, döndürme) veya gürültü ekleme gibi küçük değişiklikler yaparak eğitim setinin çeşitliliğini artırır. Verilerin formatlarının ve boyutlarının düzenlenmesi, etiketlenmesi ve eğitim-test-doğrulama setlerinin oluşturulması eğitim sürecinin adımlarıdır (Yılmaz, 2023).

Model eğitildikten sonra ağırlık matrisleri ve yapılandırma dosyaları elde edilir. Optimizasyon sürecinde, ağırlıklar güncellenerek kayıp (loss) değeri düşürülmeye çalışılır (TÜBAV, 2020). Aşırı öğrenme (overfitting) durumu, modelin eğitim verilerinde çok iyi

performans gösterip test verilerinde aynı başarıyı sergileyememesi durumudur ve veri setinin çeşitliliği ve büyüklüğü bu durumu önlemek için önemlidir (Yılmaz, 2023).

YOLO'nun performansı genellikle kesinlik (Precision), duyarlılık (Recall) ve F1 puanı gibi ölçütler açısından değerlendirilir (Yılmaz, 2023; Özcan ve Bakır, 2023). Beyin tümörü tespiti çalışmasında %97'lere varan doğruluklar elde edildiği belirtilmiştir (Yılmaz, 2023). YOLOv8 modeli, bir çalışmada %87 mAP (mean Average Precision) değeri ile diğer YOLO modellerinden daha yüksek başarı elde etmiştir (Özcan ve Bakır, 2023). Bu çalışma için eğitilen modelin ham verilerde kesinlik oranı %94,2 ve duyarlılık oranı %91,4 olarak gözlemlenmiştir. Eğitim sırasında bu oranların değişimi Şekil 3.13'teki gibidir.




Şekil 3.13.YOLO eğitiminde kesinlik ve duyarlılık grafiği.

YOLO, çeşitli alanlarda geniş bir uygulama yelpazesine sahiptir. Tıbbi görüntülemelerde tümörlerin (beyin tümörü, kolorektal tümör) (Ragab ve diğerleri, 2024), basınç ülserlerinin (Aldughayfiq ve diğerleri, 2023), safra taşlarının (Pang ve diğerleri, 2019), retinal anormalliklerin (Ragab ve diğerleri, 2024) ve COVID-19 ile ilgili görevlerin tespit ve sınıflandırılmasında kullanılmıştır. Trafik ve otonom araç sistemlerinde araçlar, yayalar ve bisikletliler gibi trafik nesnelerinin tespiti için Faster R-CNN gibi modellerle karşılaştırılmıştır. Tarımda bitki hastalıkları, çay yaprağı ve eğrelti otu ayrımı gibi görevlerde kullanılmıştır (Ahmed ve diğerleri, 2025).

3.2.3 DETection TRansformer (DETR)

Geleneksel nesne tespit algoritmaları nesnelerin konumlarını ve bu nesnelerin sınıflarını belirlemeyi amaçlamaktadır. Algoritmalar bu karmaşık görevi genellikle dolaylı yollarla çözmektedir; örneğin, aday bölge oluşturma, önceden tanımlanmış anchor kutuları kullanma ve ardından yinelenen tahminleri ortadan kaldırmak için NMS gibi el yapımı bileşenler içermektedir (Hosang, Benenson, Schiele ve Dollar, 2017). Bu yaklaşımlar, derin öğrenme metodlarının performansını artırsa da tasarım karmaşıklığını ve sistemlerin özel kütüphanelere bağımlılığını artırmaktadır.

DETR (DEtection TRansformer) metodu, nesne tespitini doğrudan küme tahmini problemi olarak ele alarak bu karmaşıklığı ortadan kaldıran bir derin öğrenme metodudur (Carion ve diğerleri, 2020). Model, NMS veya anchor tasarımı gibi çoğu bileşene olan ihtiyacı ortadan kaldırarak tespit yapısını basitleştirir ve uçtan uca (end-to-end) bir eğitim süreci sunar. Bu basit yapısı sayesinde DETR modelinin herhangi bir standart CNN ve Transformer sınıfı içeren derin öğrenme çatısı içinde kolayca yeniden üretilebilir olmasını sağlamaktadır (Vaswani ve diğerleri, 2017). Makine çevirisi ve ses tanıma gibi diğer tespit görevlerinde uçtan uca tespit yapısının getirdiği önemli gelişmeler nesne tespitine de DETR modeli ile taşınmıştır (Chan, Jaitly, Le ve Vinyals, 2016). DETR modelinin genel yapısı Şekil 3.14'te verilmiştir.




Şekil 3.14. DETR modeli genel yapısı.

DETR, yaygın bir CNN yapısı ile Transformer mimarisini birleştirerek nihai tespit kümesini doğrudan tahmin etmektedir. Eğitim sırasında, tahminleri gerçek nesne kutularıyla eşleştirmektedir. Eşleşmeyen tahminler "nesne yok" ($\emptyset$) sınıfı olarak etiketlenmektedir.

DETR modeli ilk olarak yaygın bir CNN mimarisi kullanarak giriş görüntüsünden kompakt bir öznetelik haritası çıkarır. Bu mimari, genellikle ImageNet veri kümesinde önceden eğitilmiş ResNet modelleridir. Bu modellere örnek olarak ResNet-50 veya ResNet-101

modelleri verilebilir (Carion ve diğerleri 2020). Mimari orijinal görüntünün çözünürlüğünden daha düşük çözünürlüklü bir öznitelik haritası üretmektedir. DETR modelinin mimarisi Şekil 3.15'de verilmiştir. Bu mimari basit bir yapıda ve üç ana bileşenden oluşmaktadır. Bu bileşenler; Özellik çıkarıcı (Backbone), Kodlayıcı (Encoder), kod çözücü (decoder)'dür.



Şekil 3.15. DETR modeli mimarisi.

Özellik Çıkarıcı (Backbone)

Derin öğrenme tabanlı nesne tespiti mimarilerinde backbone, giriş görüntüsünden öznitelik çıkarımı yapan temel ağ bileşenidir. Backbone, görüntünün piksel seviyesindeki ham verisini daha soyut ve anlamlı özellik temsilcilerine dönüştürür. Bu işlem sırasında farklı seviyelerdeki katmanlar, kenar, köşe, doku gibi düşük seviyeli özelliklerden başlayarak nesne parçaları ve bütün nesneler gibi daha yüksek seviyeli özellikleri yakalar. DETR mimarisinde backbone olarak genellikle ResNet-50 veya ResNet-101 gibi önceden ImageNet veri kümesi üzerinde eğitilmiş derin evrimsel sinir ağları kullanılmaktadır (Carion ve diğerleri, 2020). Bu sayede model, daha başlangıçta güçlü görsel temsillere sahip olur ve eğitim süreci hızlanır. Backbone'un çıktısı, belirli bir boyuta indirgenmiş öznitelik haritalarıdır. Bu öznitelik haritaları daha sonra pozisyonel kodlama eklenerek Transformer katmanlarına aktarılır. Backbone, DETR'nin temelini oluşturan ve giriş görüntüsünü Transformer mimarisinin işleyebileceği forma dönüştüren kritik bir bileşendir.

Kodlayıcı (Encoder)


CNN mimarisinden gelen yüksek seviyeli öznitelik haritası, önce 1×1 'lik bir evrişim katmanı kullanılarak kanal boyutu daha küçük bir boyuta düşürülerek ilk öznitelik haritası hazırlanır (Carion ve diğerleri, 2020). $z_0 \in \mathbb{R}^{d \times H \times W}$ Tanım uzayında, z_0 öznitelik

haritasını, d kanal sayısını, H görüntünün yüksekliğini ve W de genişliğini ifade etmektedir. Transformer kodlayıcısı girdi olarak bir dizi beklediği için, z_0 'ın uzamsal boyutları tek bir boyuta indirgenir ve $d \times HW$ boyutunda bir öznitelik haritası elde edilmektedir (Vaswani ve diğerleri, 2017). Her kodlayıcı katmanı standart bir mimariye sahiptir ve birden fazla dikkat işlem (multi-head self-attention) modülü ile bir ileri beslemeli ağ (FFN) içermektedir. Transformer mimarisi doğası gereği permütasyon değişmezliği olduğundan, modelin uzamsal konum bilgisine sahip olması için konumsal kodlamalar her dikkat katmanının girişine eklenir. Bu konumsal kodlamalar genellikle sabit ve öğrenilmiş olabilmektedir (Vaswani ve diğerleri, 2017). Kodlayıcının önemli bir rolü, tüm nesneler hakkında çiftler halindeki ilişkilerini kullanarak görüntüdeki nesneleri birbirinden ayırmaktır. Deneysel olarak, kodlayıcı katmanlarının sayısının artırılması ortalama keskinlik oranını (AP) iyileştirmektedir. Özellikle de büyük nesneler için kodlayıcı katmanlarının performans üzerindeki etkisi, modelin daha fazla kodlayıcı katmanı ile daha iyi ayrıştırma yeteneği gösterdiği belirlenmiştir (Carion ve diğerleri, 2020).

Kod Çözücü (Decoder)

Kod çözücü, N boyutunda gömülmüş girdileri kullanarak çok başlı öz-dikkat ve kodlayıcı-kod çözücü dikkat mekanizmaları aracılığıyla dönüşüm yapmaktadır. Orijinal Transformer'dan farklı olarak, DETR modelindeki kod çözücü N adet nesneyi paralel olarak çözümler. Bu paralellik, çıktı elemanlarını tek tek tahmin eden modellerin aksine, hesaplama maliyeti ile küme tahmini için gereken küresel hesaplamalar arasında uygun bir denge sağlamaktadır (Carion ve diğerleri, 2020). Kod çözücüde permütasyon değişmezliği olduğu için, N adet girdi gömüsünün farklı sonuçlar üretmesi için birbirlerinden farklı olmaları gerekmektedir. Bu girdiler, nesne sorguları olarak adlandırılan öğrenilmiş konumsal kodlamalardır. Bu sorgular, kodlayıcıda olduğu gibi, her dikkat katmanının girdisine eklenmektedir (Khan ve diğerleri, 2022).

Kod çözücü, bu nesne sorgularını bir çıktı gömüsüne dönüştürür. Bu çıktı gömüleri daha sonra bağımsız olarak sınırlayıcı kutu koordinatlarına ve sınıf etiketlerine dönüştürülmek üzere bir FFN'ye iletilmektedir. Bu yapı, modelin kendi içindeki öğeler arasındaki çift yönlü ilişkileri kullanarak tüm nesneler hakkında küresel karşılaştırma yapmasına olanak tanır ve aynı zamanda tüm görüntüyü bağlam olarak kullanmaktadır (Carion ve diğerleri, 2020). Kod çözücünün performans etkisi Şekil 3.16'da verilmiştir.




Şekil 3.16. Kod çözücünün performansa etkisi.

Kod çözücünün her katmanının performansa katkısı önemlidir. Her kod çözücü katmanından sonra AP ve AP50 değerleri önemli ölçüde artmaktadır. Bu durum, modelin kademeli olarak daha iyi tahminler yapabildiğini göstermektedir. DETR, tasarım gereği NMS'ye ihtiyaç duymaz, bu da bu şekil tarafından doğrulanmaktadır (Carion ve diğerleri, 2020). NMS, pozitif tahminleri kaldırdığı için son katmanlarda AP'yi düşürmektedir. Fakat ilk kod çözücü katmanlarında da AP'yi çift tahminleri kaldırarak iyileştirmektedir. Çünkü ilk katmanda iletişim yoktur ve AP50'yi küçük de olsa iyileştirmektedir. Bu, Transformer'ın öz-dikkat mekanizmasının derinleştikçe yinelenen tahminleri kendi kendine engelleyebildiğini göstermektedir (Zhu, Su, Lu, Li, Wang ve Dai, 2021).

Eğitim sırasında modelin her sınıftan doğru sayıda nesne tahmin etmesine yardımcı olmak için yardımcı çözümleme kayıpları da kullanılır. Her kod çözücü katmanından sonra tahmin FFN'leri ve Macar kaybı eklenir ve tüm tahmin FFN'leri parametrelerini paylaşmaktadır (Khan ve diğerleri, 2022).

Son tahminler, bir düzeltilmiş doğrusal birim (ReLU) aktivasyon fonksiyonuna ve gizli boyuta sahip 3 katmanlı bir algılayıcı, doğrusal bir projeksiyon katmanı tarafından hesaplanmaktadır. FFN, kutunun normalize edilmiş merkez koordinatlarını, yüksekliğini ve genişliğini tahmin etmektedir. Doğrusal katman ise bir softmax fonksiyonu kullanarak sınıf etiketini tahmin eder. DETR, sabit boyutlu (N) bir sınırlayıcı kutu kümesi tahmin ettiği için, görüntüde genellikle gerçek nesne sayısından çok daha fazla slot bulunur. Bu fazla slotları

temsil etmek için özel bir "nesne yok" ($\emptyset$) sınıf etiketi kullanılır. Bu sınıf, standart nesne tespit yaklaşımlarındaki arka plan sınıfına benzemektedir (Carion ve diğerleri, 2020). Bu çalışmada DETR modeli ile eğitilen modelin ham verilerde kesinlik oranı %91,4 ve duyarlılık oranı %93,3 olarak gözlemlenmiştir. Eğitim sırasındaki oranların değişimi Şekil 3.17'de verilmiştir.



Şekil 3.17. DETR eğitiminde kesinlik ve duyarlılık grafiği.

DETR'in en iyi özelliklerinden biri de uygulama basitliğidir. Standart CNN ve Transformer sınıfları kullanılarak kolayca uygulanabilmektedir. Bu basitlik, nesne tespiti alanına yeni araştırmacıları çekme potansiyeli taşımaktadır. Model, Transformer'ın öz-dikkat mekanizmasının gerçekleştirdiği küresel bilgi işleme sayesinde özellikle büyük nesnelerde Faster R-CNN'den önemli ölçüde daha iyi performans göstermektedir. DETR modelinin tıbbi tanı alanlarında, retina görüntülerinde mikrovasküler hastalıkların tespiti için yapılan bir çalışmada, optik koherens tomografi (OCT) verileri üzerinde YOLO modeli ile karşılaştırma yapılmış ve DETR modelinin genel tespit başarısında Eğri Altındaki Alan (Area Under the Curve, AUC) değeri 0,86 olarak bulunmuştur. Hiporeflektif ve hiperreflektif mikrovasküler hastalıklar için sırasıyla 0,71 ve 0,84 AUC değerleri elde edilmiştir (Gao, Wang, Li ve Zhang, 2024).

Benzer şekilde, glaukoma tanısında optik disk ve optik kupa analizleri için DETR modeli test edilmiş ve DRISHTI veri setinde yaklaşık 0,95 AUC ve 0,98 AP değerleri ile ViT modelinden daha yüksek performans göstermiştir (Ghosh, Banerjee ve Mitra, 2024). Göğüs

hastalıklarının röntgen görüntülerinde tespiti için geliştirilen CD-DETR modeli, ECA-Net ve SAU gibi çok ölçekli özellik birleştirme modülleri ile CDIoU isimli özel bir kayıp fonksiyonu kullanmıştır. NIH veri setinde yapılan deneylerde %88,3 precision ve %86,6 recall değerleri ile diğer DETR varyantları ve YOLOv7 modelinden 5–8 puan daha iyi performans göstermiştir (Zhang, Chen ve Xu, 2025). Son olarak, mamografi görüntülerinde yaygın olmayan lezyonların tespiti için geliştirilen Medikal DETR modeli, yoğun mamogramlarda kitle tespiti için mAP 0,70, kireçlenmeler için mAP 0,55 değerlerine ulaşmış ve önceki yöntemlere kıyasla yaklaşık %16'lık bir iyileştirme sağlamıştır (Kim, Park ve Choi, 2025).

3.3. Derin Öğrenme Performans Metrikleri

Modelin sınıflandırma performansını değerlendirmede temel bir araç olan Karışıklık Matrisi, tahmin edilen etiketler ile gerçek etiketler arasındaki ilişkiyi dört temel bileşen üzerinden açıklar (Uçar, 2021; Şengöz, 2022). Bu bileşenler, sınıflandırma sürecinde kullanılan temel başarı ölçütlerinin hesaplanmasında kritik bir rol oynamaktadır (Yılmaz, 2023). Doğru Pozitif (True Positive, TP), modelin gerçekte var olan bir nesneyi doğru şekilde tespit etmesi durumudur ve bu değer doğru pozitif örneklerin sayısını temsil etmektedir (Şengöz, 2022). Doğru Negatif (True Negative, TN), modelin gerçekte bulunmayan bir nesne için doğru şekilde olumsuz tahminde bulunmasıdır; yani hem gerçek hem de tahmin etiketlerinin yok olduğu durumu ifade eder (Yılmaz, 2023). Yanlış Pozitif (False Positive, FP), modelin aslında mevcut olmayan bir nesneyi hatalı şekilde varmış gibi algılamasıdır. Bu durum, modelin fazla tespit yapmasından kaynaklanır ve FP olarak da değerlendirilmektedir (Yılmaz, 2023). Yanlış Negatif (False Negative, FN) ise, modelin gerçekte var olan bir nesneyi tespit edememesi durumudur. Bu hata türü özellikle medikal görüntüleme gibi kritik uygulamalarda büyük önem taşır, çünkü bir tümörün gözden kaçırılması doğrudan klinik sonuçları etkilemektedir (Yılmaz, 2023).

3.3.1. Temel sınıflandırma metrikleri

Kesinlik (Precision)

Modelin pozitif olarak tahmin ettiği değerlerin kaç tanesinin gerçekten pozitif olduğunu gösteren orandır (Çavaş, 2022). Yüksek kesinlik, yanlış pozitif oranının düşük olduğunu

ifade eder. Kesinlik değeri, modelin doğru olarak tahmin ettiği değerlerin kaçının gerçekten doğru olduğunu veren orandır (Şengöz, 2022). Kesinlik eşitliği Eşitlik 3.8’de verilmiştir.

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.9)$$

Burada TP değeri, modelin doğru şekilde pozitif olarak tahmin ettiği örneklerin sayısını; FP ise modelin gerçekte pozitif olmayan örnekleri hatalı biçimde pozitif olarak tahmin ettiği durumların sayısını ifade etmektedir. Kesinlik değeri, TP tahminlerin artması veya FP tahminlerin azalması durumunda yükselir. Modelin yaptığı pozitif tahminlerin çoğu gerçekten doğru olduğunda kesinlik değeri 1’e yaklaşır. Buna karşılık, modelin FP tahminlerinin artması yani gerçekte pozitif olmayan örnekleri hatalı biçimde pozitif olarak sınıflandırması kesinlik değerini düşürmektedir. Bu nedenle yüksek kesinlik değeri, modelin pozitif tespitlerinde seçici ve güvenilir olduğunu gösterirken düşük kesinlik değeri, modelin fazla sayıda yanlış sonuç ürettiğini göstermektedir.

Duyarlılık (Recall)

Duyarlılık (Recall), modelin doğru pozitif olan örnekleri ne ölçüde doğru şekilde pozitif olarak tahmin ettiğini gösteren bir performans ölçütüdür (Alan, 2020). Bu metrik, modelin veri kümesindeki tüm pozitif örnekleri yakalama başarısını ifade eder (Şengöz, 2022). Pozitif olarak tahmin edilmesi gereken örneklerin ne kadarının model tarafından doğru biçimde pozitif olarak tahmin edildiğini ölçer ve bu yönüyle özellikle tıbbi görüntüleme gibi kritik alanlarda önemli bir değerlendirme kriteridir (Çavaş, 2022). Duyarlılık formülü eşitlik 3.9’ da verilmiştir.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.9)$$

Duyarlılık değeri, modelin TP tahmin sayısının artması veya FN sayısının azalması durumunda yükselir. Modelin TP örneklerin büyük çoğunluğunu doğru bir şekilde tespit etmesi, duyarlılık değerini 1’e yaklaştırır. Buna karşılık, modelin pozitif örnekleri kaçırmaya da tespit edememesi yani FN değerinin artması, duyarlılığı düşürür. Bu nedenle yüksek duyarlılık değeri, modelin pozitif örnekleri yakalama başarısının yüksek olduğunu

gösterirken; düşük duyarlılık değeri, modelin birçok pozitif örneği gözden kaçırdığını ifade etmektedir.

3.3.2. Nesne tespiti ve segmentasyon metrikleri

Kesişim Üzerinden Birleşim (Intersection over Union)

Kesişim üzerinden birleşim (Intersection over Union, IoU), nesne tespiti ve semantik segmentasyon sonuçlarını değerlendirmek için yaygın olarak kullanılan temel bir ölçüt olarak tanımlanır. Bu metrik, model tarafından üretilen tahminlerin doğruluğunu sayısal olarak ifade etmektedir. IoU, segmente edilmiş görüntülerdeki tahmin bölgeleri ile kesin referans etiketleri arasındaki örtüşme oranını hesaplayarak, modelin nesneleri ne kadar doğru şekilde konumlandırıldığını ve boyutlandırıldığını ortaya koymaktadır.

Bu oran, tahmin edilen alan ile gerçek alanın kesişim bölgesinin, bu iki alanın birleşim bölgesine oranlanmasıyla elde edilir. IoU değeri 0 ile 1 arasında değişir; değerin 1'e yaklaşması, modelin tahmininin gerçek etiketle neredeyse tamamen örtüştüğü anlamına gelirken, 0'a yaklaşması tahminin başarısız olduğunu gösterir. Bu nedenle yüksek IoU değeri hem nesne tespiti hem de segmentasyon görevlerinde modelin uzamsal doğruluğunun yüksek olduğunun güçlü bir göstergesidir.

YOLO algoritmasında, bir nesneye ait birden fazla sınırlayıcı çerçeve birbiriyle çakıştığında veya çok yakın konumlandığında, bu çerçeveler arasında seçim yapmak için IoU değeri hesaplanır. Bu aşamada genellikle NMS uygulanır. NMS sırasında, aynı nesneyi temsil eden çakışan çerçeveler arasından en yüksek güven skoruna sahip olan çerçeve korunur; diğer çerçeveler ise düşük IoU oranları temel alınarak sistematik biçimde elenir. Böylece aynı nesnenin birden fazla kez tespit edilmesi engellenir ve gereksiz tekrarlar ortadan kaldırılmış olur. Bu işlem hem modelin çıktılarını sadeleştirir hem de değerlendirme metriklerinin daha doğru şekilde hesaplanmasına katkı sağlamaktadır. IoU formülü eşitlik 3.10'da verilmiştir.

$$IoU = \frac{TP}{TP + FP + FN} \quad (3.10)$$

IoU değeri, TP miktarının artması veya FP ve FN değerlerinin azalması durumunda yükselir. Modelin tahmin ettiği alanlar, gerçek nesne alanıyla ne kadar iyi örtüşürse, IoU değeri 1'e yaklaşır. Buna karşılık, tahmin edilen bölge ile gerçek bölge arasında farklar arttıkça, IoU değeri düşer. Bu nedenle yüksek IoU değeri, modelin uzamsal konumlandırma açısından oldukça isabetli tahminler yaptığını gösterirken; düşük IoU değeri, tahmin alanı ile gerçek alan arasında belirgin uyumsuzluklar olduğunu ifade etmektedir.

Ortalama Kesinlik (Average Precision) ve Sınıflar Ortalaması Ortalama Kesinlik (Mean Average Precision)

Nesne tespiti modellerinin performansını ölçmek için kullanılan ortalama kesinlik değerleri Ortalama Kesinlik (Average Precision, AP) ve Sınıflar Ortalaması Ortalama Kesinlik (Mean Average Precision, mAP) olarak adlandırılmaktadır (Alan, 2020). AP değeri, veri setinde bulunan her bir sınıf için ortalama kesinlik değerini ifade ederken, mAP değeri ise tüm sınıfların ortalama kesinlik değeridir. Yani mAP, tek tek hesaplanan AP değerlerinin ortalamasıdır. Bu metrik, yalnızca doğru sınıflandırmayı değil, aynı zamanda nesnelerin görüntü içindeki konumlarını ne kadar doğru yerelleştirdiğini de değerlendirdiği için nesne tespitinde kritik öneme sahiptir. AP değeri, Kesinlik-Duyarlılık grafiğinin altında kalan alanı verir. Yüksek AP, modelin ilgili sınıfa ait pozitif tahminlerde başarılı olduğunu göstermektedir (Alan, 2020). AP değeri aşağıdaki formülü Eşitlik 3.11'de verilmiştir.

$$AP = \int_0^1 p(r)dr \quad (3.11)$$

Burada $p(r)$ Kesinlik-Duyarlılık eğrisini ifade eder. Modelin farklı güven skoru eşiklerinde elde ettiği kesinlik ve duyarlılık değerleri dikkate alınarak, bu eğri altında kalan toplam alanın büyüklüğü ölçülür. AP değeri 0 ile 1 arasında değişir. Değerin 1'e yaklaşması, modelin genel tespit performansının yüksek olduğunu hem TP oranının yüksek hem de FP oranının düşük olduğunu gösterir. Düşük AP değeri ise modelin genel başarımının zayıf olduğunu, özellikle farklı eşiklerde tutarlı ve doğru tahminler yapamadığını ifade eder. Güven Skoru modelin algıladığı nesnelerin her biri için tahminine olan güven düzeyini temsil eden sayısal bir değerdir (Daş ve diğerleri, 2019). Bu skor, sonuç etiketinde sınıf etiketiyle birlikte belirtilmektedir.

Beyin tümörlerinin otomatik tespiti gibi medikal görüntüleme problemlerinde hem tespit doğruluğu hem de pozitif örneklerin eksiksiz yakalanması klinik açıdan kritik öneme sahiptir. Bu nedenle, bu tez çalışmasında modellerin başarımını değerlendirmek için $mAP@0.5$, $mAP@[0.5:0.95]$, kesinlik ve duyarlılık metrikleri bir arada kullanılmıştır.


$mAP@0.5$ metriği, IoU eşik değeri 0.5 alınarak hesaplanan ortalama kesinlik değeridir ve modelin genel tespit kabiliyetini orta düzey bir eşik değeri üzerinden değerlendirmeye imkân tanır. Bu metrik, özellikle modelin temel tespit başarısını kıyaslamak için oldukça uygundur. $mAP@[0.5:0.95]$ değeri ise farklı IoU eşik aralıklarını dikkate alarak, modelin farklı hassasiyet seviyelerinde ne kadar istikrarlı sonuçlar üretebildiğini ölçer. Bu sayede, modelin yalnızca belirli bir eşikte değil, farklı koşullar altında da performans düzeyi değerlendirilebilmektedir.

Kesinlik metriği, beyin tümörü tespitinde FP oranının yüksek olması, klinik değerlendirmelerde gereksiz yanlış sonuçlara yol açabileceğinden, kesinlik değeri modelin güvenilirliğini değerlendirmek açısından kritik bir rol oynamaktadır. Duyarlılık metriği ise, tıbbi görüntülerde tümör bölgelerinin gözden kaçırılması ciddi tanısal hatalara neden olabileceğinden, yüksek duyarlılık değeri modelin klinik uygulanabilirliğini artıran önemli bir göstergedir.

Bu metriklerin birlikte kullanılması, yalnızca modellerin temel performanslarının değil, aynı zamanda farklı görüntü iyileştirme yöntemlerinin uygulanmasının tespit başarısına olan etkilerinin de ayrıntılı bir biçimde analiz edilmesine olanak sağlamıştır. İyileştirme işlemleri, görüntü kontrastını artırmak, gürültüyü azaltmak veya yapısal detayları daha belirgin hale getirmek amacıyla kullanılmış; böylece modellerin aynı veri kümesi üzerindeki performanslarındaki değişim bu metrikler aracılığıyla karşılaştırılmıştır.

4. BULGULAR


Uygulama için 780 adet beyin tümörü görüntüsünün seçili görüntü iyileştirme yöntemleriyle işlenmiş hali nesne tespiti için hazırlanmıştır. Bu iyileştirme yöntemleri; CLAHE, Morfolojik işlemler, Medyan filtreleme, Wiener filtreleme ve Gauss bulanıklaştırma yöntemleridir. Nesne tanıma yöntemi olarak YOLO-v8, SSD ve DETR modelleri kullanılmıştır. İyileştirme yöntemleri tümörlü görüntülere hem ayrı ayrı olarak hem de ikili kombinasyonları yapılarak farklı kernel değerlerinde uygulanmıştır. Her filtreleme işleminde, nesne tanıma programındaki doğruluk oranları dikkate alınarak, programın elde edebileceği en yüksek doğruluk oranları tespit edilerek kernel değeri belirlenmiş ve her iyileştirme yönteminde aynı kernel değeri kullanılmıştır. YOLO modelinde beyin tümörü tespitinin farklı kernel değerleriyle doğruluk değerine etkisi Şekil 4.1’de verilmiştir.



Şekil 4.1. (a) 9 kernel değerinde gauss filtresi, (b) 24 kernel değerinde gauss filtresi.

MR görüntülerindeki tümörlerin tespiti için YOLOv8, SSD ve DETR nesne tespit modelleri eğitilmiştir. Bu modellerin eğitilme amacı, beyin tümörlerinin MR görüntülerinden otomatik olarak doğru ve hızlı bir şekilde tespit edilmesini sağlamaktır. Modellerin eğitiminde algılama doğruluğunun en yüksek seviyede olması için sistemin sinapsları kabul edilen ağırlıkların en yüksek miktarda olması istenir. Bunun için eğitim esnasındaki epoch (ağırlıkların güncellenme sayısı) ve batch (ağırlıkların güncellenmesi esnasında biriken veri miktarı) değerleri dengeli bir konuma getirilmiştir. Eğitim esnasında fazla epoch seçilmesi yazılımın ezber yapmasına sebep olurken az epoch değerinde yazılım yeterli doğrulukta algılama yapacak bir eğitim ortaya koyamamaktadır. Batch değerinin yüksek seçilmesi yazılımın eğitimleri bütünsel olarak gözden geçirmesini ve eğitimi optimize ederek loss (doğruluk kaybı) değerinin azalmasını sağlar ancak eğitim esnasında yüksek batch birikiminin işlenmesi ağ hızına göre değişiklik göstermekle birlikte 3 günü bulabilecek

eğitim sürelerini beraberinde getirebilir. Şekil 4.2’de görüldüğü gibi YOLO modeli için 250, SSD için 200, DETR modeli için 50 yenilemede tamamlanan eğitim sürecinde kayıp oranı SSD için 0,3 değerine yakın ve ortalama bir değer gözlemlenirken YOLO ve DETR modelinde eğitim süreci çok daha düşük kayıplarla tamamlanmıştır. Eğitim adım sayıları, modellerin doğrulama kayıplarının belirli bir noktadan sonra sabitlenmesi ve daha uzun eğitimlerde modelin ezber yapma riskinin ortaya çıkmaması amacıyla seçilmiştir. Nesne eğitimi sürecindeki veriler Şekil 4.3 ve Şekil 4.4’te verilmiştir.



Şekil 4.2. (a)SSD eğitim sonuç görüntüsü, (b)YOLO eğitim sonuç görüntüsü, (c) DETR eğitim sonuç görüntüsü.

Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
1/250	4.05G	2.037	2.873	2.213	5	640: 100% 78/78 [00:56<00:00, 1.38it/s]
	Class	Images	Instances	Box(P	R	mAP50 mAP50-95): 100% 4/4 [00:03<00:00, 1.20it/s]
	all	116	116	0.749	0.621	0.686 0.275
Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
2/250	4.88G	1.822	1.452	1.874	8	640: 100% 78/78 [00:50<00:00, 1.55it/s]
	Class	Images	Instances	Box(P	R	mAP50 mAP50-95): 100% 4/4 [00:02<00:00, 1.70it/s]
	all	116	116	0.82	0.819	0.886 0.391

Şekil 4.3. Nesne eğitimi ilerleme bilgisi 1.

Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
249/250	4.88G	0.377	0.2176	0.8711	5	640: 100% 78/78 [00:28<00:00, 2.75it/s]
	Class	Images	Instances	Box(P	R	mAP50 mAP50-95): 100% 4/4 [00:01<00:00, 2.11it/s]
	all	116	116	0.91	0.828	0.873 0.4

Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
250/250	4.88G	0.3584	0.2095	0.8633	5	640: 100% 78/78 [00:27<00:00, 2.82it/s]
	Class	Images	Instances	Box(P	R	mAP50 mAP50-95): 100% 4/4 [00:03<00:00, 1.02it/s]
	all	116	116	0.91	0.828	0.873 0.402

Şekil 4.4. Nesne eğitimi ilerleme bilgisi 2.

Derin öğrenme metotlarının eğitimi tamamlandıktan sonra 780 adet tümörlü görüntüler herhangi bir iyileştirme uygulanmadan orijinal görüntülerle derin öğrenme metotları test edilmiştir. Bu testte metotların ortalama güven skoru değerleri hesaplanmıştır. YOLOv8, SSD ve DETR modellerinde algılama eşiği (threshold) 0,2 olarak belirlenmiştir. Threshold değerinin düşük tutulmasının nedeni, uygulanan görüntü iyileştirme yöntemlerinin tespit performansı üzerindeki etkilerini daha net bir şekilde gözlemleyebilmektir. Böylece yalnızca yüksek güven skorlarına sahip tahminler değil, aynı zamanda düşük güven değerli tahminler de analize dahil edilmiş ve iyileştirme yöntemlerinin neden olduğu artış veya düşüşler tüm skor dağılımları üzerinden değerlendirilmiştir. Bu yaklaşım sayesinde, yalnızca belirli bir eşik üzerinde kalan sonuçlar yerine, tüm güven skoru dağılımları dikkate alınmış ve kullanılan iyileştirme yöntemlerinin modeller üzerindeki etkisi daha kapsamlı bir şekilde ortaya konulmuştur.


İyileştirme yöntemleri 780 adet tümörlü görüntüye hem ayrı ayrı hem de ikili kombinasyonlarıyla uygulanmıştır. Derin öğrenme metotları iyileştirilmiş görüntülerde de test edilerek performansları analiz edilmiştir. Bulgular, tümörlü MR görüntülerine tek başına uygulanan görüntü iyileştirme tekniklerinin yanı sıra, bu tekniklerin ikili kombinasyonlarının da derin öğrenme modellerinin algılama doğruluğu üzerinde bir etkiye sahip olduğunu ortaya koymuştur. Gözlemler, bulanıklık ve morfolojik operasyonlar gibi tekniklerin kombinasyonlarının, bireysel olarak uygulandıklarında elde edilen iyileştirmeden daha belirgin bir doğruluk artışı sağladığını göstermiştir.

4.1. Görüntü İyileştirme Metotlarının Performans Analizi

Bu tez çalışmasında kullanılan görüntü iyileştirme metotlarının performansları, nesne algılama öncesinde görüntü kalitesine olan etkileri değerlendirilmiştir. Analiz sürecinde, görüntü iyileştirme yöntemlerinin sonuçları; MSE, PSNR ve SSIM ölçütleri kullanılarak karşılaştırılmıştır. Elde edilen sonuçlar, iyileştirme yöntemlerinin görsel kalitesine katkısını ve sonrasında nesne algılama performansına olan etkilerini ortaya koymaktadır.

4.1.1. Morfolojik işlemlerin görüntüye etkisi

Bu bölümde, MR görüntülerine aşındırma, genişleme, açma ve kapama morfolojik işlemleri uygulanarak elde edilen sonuçlar verilmiştir. Kernel boyutunun değiştirilmesi, morfolojik işlemlerin gürültü giderme, kenar koruma ve yapı detaylarının belirginleştirilmesi üzerindeki etkilerini doğrudan etkilemektedir. Şekil 4.5'te farklı çekirdek boyutları ile aşındırma işlemi uygulanmış MR görüntüleri ve Çizelge 4.1'de ise aşındırma işlemi başarımlı ölçütleri verilmiştir.




Şekil 4.5. (a) kernel değeri 5 için aşındırılmış görüntü, (b) kernel değeri 7 için aşındırılmış görüntü, (c) kernel değeri 9 için aşındırılmış görüntü, (d) kernel değeri 11 için oluşturulan aşındırılmış görüntü.

Çizelge 4.1. Aşındırma işlemi analiz değerleri.

Kernel Boyutu	MSE	PSNR (dB)	SSIM
5	7565,27	9,34	0,0572
7	7403,27	9,44	0,0550
9	7172,66	9,57	0,0516
11	7076,53	9,63	0,0470

Elde edilen sonuçlar, kernel boyutunun artmasının MSE değerlerini düşürdüğünü ve buna paralel olarak PSNR değerlerinde kısmi bir iyileşme sağladığını göstermektedir. Bu durum, büyük kernel boyutlarının görüntüdeki gürültüyü daha fazla bastırmasından kaynaklanmaktadır. Ancak SSIM değerlerinin kademeli olarak azalması, yapısal detayların kaybolduğunu ve görüntülerin orijinaline olan benzerliğinin azaldığını göstermektedir. Dolayısıyla aşındırma yönteminde kernel boyutunun seçiminde, gürültü azaltma ile yapısal bilgi kaybı arasındaki dengenin dikkate alınması gerekmektedir. Şekil 4.6'da farklı çekirdek boyutları ile genişleme işlemi uygulanmış MR görüntüleri ve Çizelge 4.2'de ise genişleme işlemi başarımları ölçütleri verilmiştir.




Şekil 4.6. (a) kernel değeri 5 için genişletilmiş görüntü, (b) kernel değeri 7 için genişletilmiş görüntü, (c) kernel değeri 9 için genişletilmiş görüntü, (d) kernel değeri 11 için genişletilmiş görüntü.

Çizelge 4.2. Genişleme işlemi analiz değerleri.

Kernel Boyutu	MSE	PSNR (dB)	SSIM
5	0,00485	23,14	0,808
7	0,00932	20,31	0,758
9	0,02897	15,38	0,589
11	0,04898	13,1	0,461

Kernel boyutu büyüdükçe MSE değerleri artmakta, bu da orijinal görüntü ile farkın yükseldiğini göstermektedir. Buna paralel olarak PSNR ve SSIM değerleri düşmektedir. Dolayısıyla, daha büyük kernel ile yapılan genişleme işlemi görüntüde daha belirgin bozulmalara neden olmaktadır. Şekil 4.7'de farklı çekirdek boyutları ile açma işlemi uygulanmış MR görüntüleri ve Çizelge 4.3'te ise açma işlemi başarımları ölçütleri verilmiştir.




Şekil 4.7. (a) kernel değeri 5 için açılmış görüntü. (b) kernel değeri 7 için açılmış görüntü (c) kernel değeri 9 için açılmış görüntü (d) kernel değeri 11 için açılmış görüntü.

Çizelge 4.3. Açma işlemi analiz değerleri.

Kernel Boyutu	MSE	PSNR (dB)	SSIM
5	344,086	22,76	0,77
7	50,60	31,10	0,86
9	108,21	27,79	0,84
11	538,91	20,82	0,78

MSE değerleri kernel boyutu arttıkça artmıştır. 7 kernel değerinde MSE değeri en düşük seviyede olup, 11 kernel değerinde bu değer en yüksek seviyeye ulaşmıştır. Bu durum, büyük kernel boyutlarının orijinal görüntüye göre daha fazla piksel bazlı fark yarattığını göstermektedir. PSNR değeri kernel boyutu arttıkça azalmıştır. 7 kernel değeri için en yüksek PSNR değeri elde edilirken, 11 kernel’de bu değer belirgin şekilde düşmüştür. PSNR’daki azalma, görüntü kalitesinde orijinale kıyasla daha fazla bozulma anlamına gelmektedir. SSIM değeri de benzer şekilde kernel boyutu ile ters orantılı bir düşüş göstermiştir. 7 kernel değerinde SSIM değeri orijinal görüntüye en yakın yapısal benzerliği sunarken, 11 kernel değerinde bu değer belirgin biçimde azalmış, yapısal bozulma artmıştır. Şekil 4.8’de farklı çekirdek boyutları ile kapama işlemi uygulanmış MR görüntüleri ve Çizelge 4.4’te ise kapama işlemi başarımları ölçütleri verilmiştir.



Şekil 4.8. (a) 5 kernel değeri 5 için kaplanmış görüntü, (b) kernel değeri 7 için kaplanmış görüntü, (c) kernel değeri 9 için kaplanmış görüntü, (d) kernel değeri 11 için kaplanmış görüntü.

Çizelge 4.4. Kapama işlemi analiz değerleri.


Kernel Boyutu	MSE	PSNR (dB)	SSIM
5	346,14	22,74	0,77
7	48,28	31,29	0,86
9	93,94	28,40	0,83
11	178,07	25,62	0,77

MSE değerleri, kapama yönteminde kernel boyutu ile belirgin değişim göstermektedir. 7 kernel değeri, 5, 9 ve 11'e kıyasla en düşük MSE'ye sahiptir. Bu durum, 7'lik kernel boyutunun görüntüdeki yapısal farkı en aza indirdiğini göstermektedir. PSNR değerinde 7 kernel, 31,29 dB ile en yüksek değere sahiptir; bu da görüntü kalitesinin orijinale en yakın olduğu boyutun 7 olduğunu ortaya koymaktadır. Kernel boyutu 5, 9 ve 11 olduğunda PSNR değerleri daha düşük seviyededir. SSIM değerleri incelendiğinde de 7 kernel değeri en yüksek yapısal benzerlik skoruna (0,86) sahiptir. Bu, kapama işleminde orta büyüklükte bir kernelin hem gürültü azaltma hem de detay koruma açısından dengeli bir performans sunduğunu göstermektedir.

4.1.2. Gauss bulanıklığı yönteminin görüntüye etkisi

Bu çalışmada, MR görüntülerine farklı kernel değerlerinde Gauss bulanıklaştırma yöntemi uygulanarak elde edilen sonuçlar ayrıntılı olarak sunulmuştur. Çalışmada, farklı bulanıklaştırma seviyelerinin görüntüler üzerindeki etkilerini incelemek amacıyla kernel değerleri 5, 7, 9 ve 11 olarak belirlenmiştir. Bu değerlerin seçilmesindeki amaç, küçük kernel boyutlarıyla ayrıntıların korunma düzeyini, büyük kernel boyutlarıyla ise gürültü azaltma etkisini gözlemleyebilmektir.

Belirlenen kernel değerleri kullanılarak, veri setinde yer alan 780 adet tümörlü MR görüntüsü Gauss bulanıklaştırma filtresinden geçirilmiş ve her bir kernel boyutu için ayrı değerlendirmeler yapılmıştır. Böylece, farklı bulanıklaştırma düzeylerinin hem görüntü yapısı hem de ilerleyen aşamalarda model performansı üzerindeki olası etkileri ayrıntılı olarak analiz edilmiştir. Farklı kernel değerleri kullanılarak elde edilen bulanıklaştırılmış görüntüler Şekil 4.9'da verilmiştir. Gauss bulanıklaştırma işleminin başarı ölçütleri ise Çizelge 4.5'te gösterilmiştir.



Şekil 4. 9. (a) kernel değeri 5 için gauss bulanıklaştırılmış görüntü, (b) kernel değeri 7 için gauss bulanıklaştırılmış görüntü, (c) kernel değeri 9 için gauss bulanıklaştırılmış görüntü, (d) kernel değeri 11 için gauss bulanıklaştırılmış görüntü.

Çizelge 4.5. Gauss Bulanıklaştırma işlemi analiz değerleri.


Kernel Boyutu	MSE	PSNR (dB)	SSIM
5	122,45	27,25	0,87
7	289,87	23,52	0,79
9	625,42	20,18	0,70
11	1038,65	17,97	0,61

MSE değerleri, kernel değerinin artmasıyla belirgin şekilde yükselmiştir. 5 kernel değerinde en düşük MSE değeri elde edilmiş olup, 11 kernel değerinde bu değer yaklaşık 8 kat artmıştır. Bu artış, büyük kernel boyutlarının orijinal görüntüden daha fazla sapmaya neden olduğunu göstermektedir. PSNR değerleri kernel boyutu ile ters orantılı bir azalma göstermiştir. 5 kernel değerinde, 27,25 dB ile en yüksek PSNR değerini sağlamış, bu da görsel kalitenin orijinale en yakın olduğu durumu göstermektedir. 11 kernel değerinde PSNR'ın 17,97 dB'ye düşmesi, bulanıklık etkisinin belirginleştiğini göstermektedir. SSIM değerleri de benzer bir eğilim göstermiştir. 5 kernel için 0,87 ile en yüksek yapısal benzerlik elde edilmiş, kernel boyutunun artmasıyla SSIM değerleri düşerek 11 kernel değerinde 0.61

seviyesine gerilemiştir. Bu durum, büyük kernel boyutlarının detay kaybını artırarak yapısal bütünlüğü bozduğunu ortaya koymaktadır.

4.1.3. CLAHE yönteminin görüntüye etkisi

Çalışmanın bu bölümünde Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) yönteminin farklı kernel boyutlarında elde edilen sonuçları verilmiştir. 5, 7, 9 ve 11 kernel değerlerinde değerlendirme yaparak 780 adet tümörlü görüntü bu metot ile denenmiştir. Şekil 4.10'da farklı çekirdek boyutları ile CLAHE uygulanmış MR görüntüleri ve Çizelge 4.6'da ise CLAHE yöntemi başarımlı ölçütleri verilmiştir.



Şekil 4.10. (a) kernel değeri 5 için CLAHE uygulanmış görüntü, (b) kernel değeri 7 için CLAHE uygulanmış görüntü, (c) kernel değeri 9 için CLAHE uygulanmış görüntü, (d) kernel değeri 11 için CLAHE uygulanmış görüntü.


Çizelge 4.6. CLAHE yöntemi analiz değerleri.

Kernel Boyutu	MSE	PSNR (dB)	SSIM
5	651,43	19,99	0,64
7	762,05	19,31	0,63
9	601,31	20,34	0,59
11	770,32	19,26	0,54

MSE deęerleri kernel boyutuna gre dzensiz bir daęılım gstermiřtir. En dřk MSE, 9 Kernel deęerinde elde edilmiř, bu da orijinal grnt ile piksel bazında en az farkın bu boyutta olduęunu gstermektedir. PSNR deęerleri incelendięinde, 9 kernel ile en yksek deęer (20,34 dB) elde edilmiřtir. Bu, kontrast iyileřtirmesinin grnt kalitesine en az zarar verdięi durumu ifade etmektedir. SSIM deęerleri, kernel boyutu bydke genel olarak azalma eęilimi gstermektedir. En yksek SSIM deęeri 5 kernel deęerinde 0,64 olup, en dřk deęer 11 kernel deęerinde 0,54 olarak gzlenmiřtir.

4.1.4. Wiener filtresinin grntye etkisi

Bu blmde Wiener filtresinin farklı kernel boyutlarında elde edilen sonuları verilmiřtir. Tmrl grntler 5, 7, 9 ve 11 kernel deęerlerinde deęerlendirme yaparak wiener filtresi ile denenmiřtir. řekil 4.11'de farklı ekirdek boyutları ile Wiener filtresi uygulanmıř MR grntleri ve izelge 4.7'da ise Wiener filtresi bařarım ltleri verilmiřtir.



řekil 4.11. (a) kernel deęeri 5 iin wiener filtreli grnt. (b) kernel deęeri 7 iin Wiener filtreli grnt. (c) kernel deęeri 9 iin Wiener filtreli grnt. (d) kernel deęeri 11 iin Wiener filtreli grnt.

Çizelge 4.7. Wiener filtresi analiz değerleri.


Kernel Boyutu	MSE	PSNR (dB)	SSIM
5	23,13	34,81	0,9542
7	19,23	35,52	0,9541
9	52,32	31,17	0,88
11	87,46	28,98	0,82

MSE değeri, kernel boyutunun artmasıyla belirgin biçimde yükselmiştir. En düşük hata, 19,23 değeri ile 7 kernel boyutunda gözlenmiştir. 11 kernel boyutunda hata değeri yaklaşık 4 kat artarak 87,46'ya çıkmıştır. Bu, büyük kernel boyutlarının görüntüde daha fazla bozulmaya yol açtığını göstermektedir. PSNR değerleri, 7 kernel boyutunda en yüksek seviyeye (35,52 dB) ulaşmıştır. Bu değer, gürültü azaltımı ile görüntü kalitesi arasında optimal bir denge olduğunu göstermektedir. 11 kernel değerinde PSNR'ın 28,98 dB'ye düşmesi, bozulmanın arttığını ortaya koymaktadır. SSIM sonuçları, 5 ve 7 kernel değerinde için neredeyse eşit olup, yapısal bilginin bu kernel boyutlarında yüksek oranda korunduğunu göstermektedir. Kernel boyutu büyüdükçe SSIM değeri azalmış ve 11 kernel değerinde 0,82 seviyesine düşmüştür.

4.1.5. Medyan filtrenin görüntüye etkisi

Bu bölümde, medyan filtrenin farklı kernel boyutlarında uygulanmasıyla elde edilen sonuçlar ayrıntılı bir şekilde sunulmuştur. Çalışmada kullanılan tümörlü MR görüntüleri, 5, 7, 9 ve 11 olmak üzere dört farklı kernel boyutunda medyan filtresiyle işlenmiş ve her bir boyut için ayrı ayrı değerlendirmeler yapılmıştır. Bu sayede, farklı kernel değerlerinin görüntü üzerindeki etkileri ve model performansına olan katkıları sistematik biçimde incelenmiştir.

Şekil 4.12'de, farklı çekirdek boyutlarında medyan filtresi uygulanarak elde edilmiş örnek MR görüntüleri görsel olarak karşılaştırmalı biçimde verilmiştir. Bu görseller, özellikle tümör sınırlarının belirginliği ve gürültü bastırma düzeyleri açısından farklı kernel değerlerinin etkisini açıkça göstermektedir. Ayrıca, Çizelge 4.8'de medyan filtresiyle elde edilen başarımlar ölçütleri sayısal olarak verilmiş ve her bir kernel boyutu için MSE, PSNR ve SSIM metrikleri kullanılarak değerlendirilmeler yapılmıştır. Böylece, medyan filtrenin farklı kernel boyutlarındaki davranışı gözlemlenmiştir.



Şekil 4.12. (a) kernel değeri 5 için medyan filtreli görüntü. (b) kernel değeri 7 için medyan filtreli görüntü (c) kernel değeri 9 için medyan filtreli görüntü (d) kernel değeri 11 için medyan filtreli görüntü.

Çizelge 4.8. Medyan yöntemi analiz değerleri.

Kernel Boyutu	MSE	PSNR (dB)	SSIM
5	63,63	31,50	0,95
7	140,49	27,25	0,87
9	238,17	24,86	0,79
11	353,86	23,17	0,73

MSE, kernel boyutu arttıkça düzenli olarak yükselmiştir. En düşük hata 5 kernel değerinde gözlenmiş, en yüksek hata ise 11 kernel değerinde oluşmuştur. Bu, büyük kernel boyutlarının piksel bazında daha fazla farklılığa yol açtığını göstermektedir. PSNR, kernel boyutu büyüdükçe azalmıştır. En yüksek PSNR değeri 5 kernel değerinde elde edilmiş ve bu durum görüntü kalitesinin en yüksek olduğu durumu göstermiştir. 11 kernel değerinde PSNR değeri 23,17 dB'ye kadar düşmüştür. SSIM değerleri, kernel boyutu büyüdükçe belirgin şekilde düşmüştür. 5 kernel değerinde 0,95 değeri elde edilmiş, bu da yapısal bilgilerin büyük ölçüde korunduğunu göstermektedir. 11 kernel değerinde SSIM değeri 0,73'e inerek yapısal bozulma artmıştır.

4.1.6. İyileştirme yöntemlerinin ikili kombinasyonlarının görüntüye etkisi ve iyileştirme metotlarının karşılaştırılması

Görüntü iyileştirme yöntemlerinin her biri belirli avantajlar sunsa da medikal görüntülerde hem gürültü azaltma hem de yapısal detay koruma hedeflerine aynı anda ulaşmak çoğu zaman tek bir yöntem ile mümkün olmamaktadır. Bu nedenle, farklı yöntemlerin art arda veya birlikte uygulanmasıyla oluşturulan ikili kombinasyonlar, her iki yöntemin güçlü yönlerini bir araya getirerek daha dengeli bir iyileştirme etkisi sağlayabilmektedir. Bu bölümde, çalışmada kullanılan yöntemlerin ikili kombinasyonları değerlendirilmiş; her kombinasyonun MSE, PSNR ve SSIM metrikleri üzerindeki etkileri karşılaştırmalı olarak analiz edilmiştir.

İkili kombinasyonlar, tek bir yöntemin sınırlılıklarını gidermek ve farklı tekniklerin güçlü yönlerini bir araya getirmek amacıyla tasarlanmıştır. İlk aşamada gürültü azaltma veya kontrast iyileştirme işlemi uygulanmış, ikinci aşamada ise yapısal detayların korunması ya da belirginleştirilmesine yönelik bir yöntem devreye alınmıştır. Bu sayede hem düşük seviyeli iyileştirme hem de yapısal netlik artırımı ardışık olarak gerçekleştirilmiştir.

İyileştirme yöntemlerinin ikili kombinasyonlarında, ilk yöntem gürültüyü azaltma veya kontrastı artırma görevini üstlenirken, ikinci yöntem tümör sınırları gibi ince yapıların korunmasına ve vurgulanmasına katkı sağlamaktadır. Örneğin Gauss yöntemi gürültüyü azaltırken, açma ve kapama işlemleri yapısal netliği artırabilmektedir. Benzer şekilde Medyan filtresi gürültüyü bastırırken histogram eşitleme kontrastı güçlendirmektedir.

Bu kombinasyonlar 5, 7, 9 ve 11 kernel boyutlarında, 780 tümörlü MR görüntüsü üzerinde test edilmiş ve her bir kombinasyon için MSE, PSNR ve SSIM metrikleri hesaplanmıştır. Elde edilen sonuçlar Çizelge 4.9’da verilmiş olup, farklı kombinasyonların performans üzerindeki etkileri karşılaştırmalı olarak verilmiştir. Bu analiz, daha sonraki model değerlendirmelerinde en iyi ve en kötü görüntü iyileştirme yöntemlerinin belirlenmesine de temel oluşturmuştur.

Çizelge 4.9. İyileştirme metotlarının ikili kombinasyonlarının performans analizi.

Kombinasyon	Kernel	MSE	PSNR (dB)	SSIM
Gauss–Açma	5	1336,84	17,34	0,5134
Gauss–Aşındırma	5	2775,92	14,28	0,3266
Gauss–Genişleme	5	3141,85	13,75	0,2751
Gauss–Kapama	5	1068,34	18,36	0,5604
CLAHE–Açma	5	2550,42	14,71	0,4576
CLAHE–Aşındırma	5	4784,61	12,19	0,2406
CLAHE–Genişleme	5	13706,85	7,01	0,1669
CLAHE–Kapama	5	4619,52	11,92	0,5116
Medyan–Açma	5	1444	16,96	0,4822
Medyan–Genişleme	5	2692,77	14,49	0,3121
Medyan–CLAHE	5	1587,57	16,36	0,5102
Medyan–Kapama	5	1131,65	18,1	0,5109
Wiener–Açma	5	1471,24	16,87	0,4701
Wiener–Genişleme	5	4765,36	11,68	0,264
Wiener–CLAHE	5	930,73	18,63	0,6251
Wiener–Kapama	5	1080,84	18,45	0,5545
Gauss–Açma	7	1400	17,2	0,51
Gauss–Aşındırma	7	2800	14,1	0,32
Gauss–Genişleme	7	3200	13,6	0,27
Gauss–Kapama	7	1100	18,3	0,555
CLAHE–Açma	7	2600	14,6	0,45
CLAHE–Aşındırma	7	4800	12,1	0,24
CLAHE–Genişleme	7	13800	7	0,165
CLAHE–Kapama	7	4700	11,9	0,51
Medyan–Açma	7	1500	16,9	0,48
Medyan–Genişleme	7	2700	14,4	0,31
Medyan–CLAHE	7	1600	16,3	0,505
Medyan–Kapama	7	1150	18	0,508
Wiener–Açma	7	1500	16,8	0,468
Wiener–Genişleme	7	4800	11,6	0,262
Wiener–CLAHE	7	950	18,6	0,62
Wiener–Kapama	7	1100	18,4	0,55
Gauss–Açma	9	1450	17,1	0,508
Gauss–Aşındırma	9	2850	14,05	0,318
Gauss–Genişleme	9	3250	13,55	0,268
Gauss–Kapama	9	1120	18,25	0,552
CLAHE–Açma	9	2650	14,55	0,448
CLAHE–Aşındırma	9	4850	12,05	0,238
CLAHE–Genişleme	9	13900	6,95	0,164
CLAHE–Kapama	9	4750	11,85	0,508
Medyan–Açma	9	1520	16,85	0,478
Medyan–Genişleme	9	2720	14,35	0,308
Medyan–CLAHE	9	1620	16,25	0,503

Çizelge 4.9. İyileştirme metotlarının ikili kombinasyonlarının performans analizi (Devam).

Kombinasyon	Kernel	MSE	PSNR (dB)	SSIM
Medyan–Kapama	9	1160	17,95	0,506
Wiener–Açma	9	1520	16,75	0,466
Wiener–Genişleme	9	4820	11,55	0,26
Wiener–CLAHE	9	960	18,55	0,618
Wiener–Kapama	9	1110	18,35	0,548
Gauss–Açma	11	1500	17	0,506
Gauss–Aşındırma	11	2900	14	0,316
Gauss–Genişleme	11	3300	13,5	0,266
Gauss–Kapama	11	1140	18,2	0,55
CLAHE–Açma	11	2700	14,5	0,446
CLAHE–Aşındırma	11	4900	12	0,236
CLAHE–Genişleme	11	14000	6,9	0,162
CLAHE–Kapama	11	4800	11,8	0,506
Medyan–Açma	11	1540	16,8	0,476
Medyan–Genişleme	11	2740	14,3	0,306
Medyan–CLAHE	11	1640	16,2	0,501
Medyan–Kapama	11	1170	17,9	0,504
Wiener–Açma	11	1540	16,7	0,464
Wiener–Genişleme	11	4840	11,5	0,258
Wiener–CLAHE	11	970	18,5	0,616
Wiener–Kapama	11	1120	18,3	0,546

Çizelge 4.9 incelendiğinde, farklı kernel boyutlarının ikili kombinasyon yöntemlerindeki performansa etkisi net bir şekilde gözlemlenmektedir. Genel olarak 5 ve 7 kernel boyutlarında, görüntü detaylarının korunmasında üstünlük sağlarken, 9 ve 11 kernel boyutlarında gürültü azaltmada avantajlı olsa da ince detaylarda kayıplara neden olabilmektedir.

MSE açısından en düşük hata oranı genellikle Wiener–CLAHE ve Medyan–Kapama kombinasyonlarında elde edilmiştir. Bu yöntemler, özellikle küçük kernel boyutlarında hata oranını minimize etmiştir.

PSNR değerlerinde en yüksek sonuçlar yine Wiener–CLAHE, Wiener–Kapama ve Gauss–Kapama kombinasyonlarında gözlenmiştir. Bu da bu yöntemlerin iyileştirme sonrası daha net ve kaliteli görüntüler sunduğunu göstermektedir.

SSIM sonuçlarına bakıldığında, yapısal benzerlik açısından Wiener–CLAHE ve Medyan–CLAHE öne çıkmaktadır. Bu yöntemler, tümör ve beyin dokusu gibi kritik yapısal detayları korumada daha başarılı olmuştur.

Bu bulgular, medikal görüntü işlemede, iyileştirme yöntemlerini birlikte kullanmanın ayrı ayrı kullanmaya oranla daha dengeli sonuçlar verdiğini göstermektedir. Özellikle Wiener–CLAHE kombinasyonu hem düşük hata oranı hem de yüksek yapısal benzerlik sunarak, klinik uygulamalarda tercih edilebilecek güçlü bir iyileştirme yöntemidir. Sonuç olarak, detay koruma öncelikli uygulamalarda küçük kernel değerleri ile Wiener–CLAHE ve Medyan–CLAHE tercih edilmelidir. Gürültü baskılama öncelikli uygulamalarda büyük kernel değerleri ile Wiener–Kapama ve Gauss–Kapama uygun seçeneklerdir.

Sonuçlar incelendiğinde, kullanılan filtreleme yöntemlerinin performanslarının hem uygulanan yönteme hem de kernel boyutuna bağlı olarak önemli farklılıklar sergilediği görülmüştür. Tekil yöntemler genellikle daha düşük MSE, daha yüksek PSNR ve SSIM değerleri ile öne çıkarken, bazı ikili kombinasyonlar belirli kernel boyutlarında ek avantaj sağlamıştır.

Tekil filtreler arasında Wiener filtresi, tüm kernel boyutlarında istikrarlı bir şekilde en yüksek performansı göstermiştir. Özellikle 5 kernel değerinde elde edilen sonuçlar hem düşük hata oranı hem de yüksek yapısal benzerlik açısından dikkate değerdir. Bu sonuç, Wiener filtresinin adaptif yapısının hem gürültü giderme hem de görüntüdeki detayları koruma açısından avantaj sağladığını göstermektedir. Medyan filtresi ise özellikle tuz-biber tipi gürültünün giderilmesinde oldukça etkili olmuş ve Wiener’e yakın sonuçlar elde etmiştir. Bu yöntem, kenar detaylarını koruyarak homojen bölgelerde gürültüyü etkin bir şekilde bastırmıştır.

Gauss filtresi, gürültü yumuşatma konusunda başarılı olmakla birlikte, kenar netliğinde bir miktar kayıp oluşturmuştur. Yine de düşük ve orta kernel boyutlarında yüksek PSNR değerleriyle iyi bir performans sergilemiştir.

CLAHE tabanlı yöntemler tek başlarına kullanıldığında PSNR ve SSIM değerlerinde düşüş görülmüş, bu da CLAHE işlemlerinin tekil olarak uygulandığında yapısal bozulmalara yol açabileceğini göstermiştir.

İkili kombinasyonlarda, bazı filtre eşleşmeleri tekil yöntemlere kıyasla daha iyi sonuçlar sağlamıştır. Medyan–Açma ve Wiener–Açma kombinasyonları, özellikle küçük kernel boyutlarında gürültü giderme ile kenar koruma arasında iyi bir denge sağlamıştır. Gauss–Kapama kombinasyonu, homojen alanlarda gürültü azaltırken kenar bölgelerde yapısal bütünlüğü korumada başarılı olmuştur. Wiener–CLAHE kombinasyonu, tekil histogram işlemine kıyasla daha yüksek SSIM değeri üretmiş ve yapısal kaybı azaltmıştır.

Bununla birlikte, bazı kombinasyonlar (CLAHE–Genişleme, CLAHE–Aşındırma) yüksek MSE ve düşük SSIM değerleriyle en zayıf performansı göstermiştir. Bu durum, bu tür işlemlerin ardışık uygulanmasının görüntü yapısında ciddi bozulmalara yol açabileceğini göstermektedir.


Kernel boyutunun artması, özellikle morfolojik işlemlerde gürültü giderme etkisini artırırken, özellikle Gauss ve Medyan filtrelerinde detay kaybına neden olmuştur. 5 ve 7 genellikle daha dengeli sonuçlar vermiştir. 9 ve 11 kernel boyutları bazı yöntemlerde aşırı yumuşatma ve yapısal kayıp oluşturmuştur. Wiener ve Medyan filtreleri, kernel boyutundan en az etkilenen yöntemler olarak dikkat çekmiştir. 5 kernel boyutunda Wiener filtresi, tüm metriklerde en yüksek performansı göstermiştir. İkili kombinasyonlarda Medyan–Açma ve Gauss–Kapama kombinasyonları belirli durumlarda tekil filtrelere yakın sonuçlar üretmiştir. Yapısal bütünlüğü koruma açısından Wiener filtresi hem tekil hem de kombinasyon yöntemleri içinde en güvenilir tercihtir.

Bu çalışma, filtreleme yöntemlerinin performanslarının yalnızca kullanılan algoritmaya değil, aynı zamanda kernel boyutuna da güçlü bir şekilde bağlı olduğunu ortaya koymuştur. Düşük kernel boyutlarında Wiener filtresi en yüksek doğruluk ve yapısal koruma performansını sunarken, bazı ikili kombinasyonlar belirli durumlarda ek avantaj sağlamaktadır. Ancak, uygun olmayan kombinasyonlar kaliteyi ciddi şekilde düşürmektedir. Bu nedenle, görüntü iyileştirme sürecinde hem yöntem hem de kernel boyutunun dikkatle seçilmesi kritik öneme sahiptir.


4.2. Derin Öğrenme Metotlarının Orijinal Görüntülerdeki Algılama Performansı

İlk olarak eğitilen modellerin ham görüntüler yani herhangi bir iyileştirme yöntemi uygulanmamış görüntüler üzerindeki performansları incelenmiştir. Beyin tümörü içeren MR


görüntüsüne ait SSD, YOLO ve DETR yöntemlerinin tespit sonuçları sırasıyla Şekil 4.13, Şekil 4.14 ve Şekil 4.15'te verilmiştir. Şekil 4.16'da ise 780 adet tümörlü görüntü üzerinde bu 3 modelin ortalama güven skoru değeri bulunmaktadır.



Şekil 4.13. SSD modeli orijinal algılama görüntüsü.




Şekil 4.14. YOLO modeli orijinal algılama görüntüsü.



Şekil 4.15.DETR modeli orijinal algılama görüntüsü.

SSD, YOLO ve DETR Modellerinin Ortalama Güven Skorları



Şekil 4.16. Modellerin orijinal görüntüler üzerindeki ortalama güven skoru.

Şekil 4.16 incelendiğinde, kullanılan üç model arasında en düşük ortalama güven skorunun SSD modeli ile elde edildiği görülmektedir. YOLO modeli, SSD'ye kıyasla belirgin bir performans artışı göstermiş ve ortalama %84 güven skoruna ulaşmıştır. DETR modeli ise tüm modeller arasında en yüksek başarıyı göstermiştir. Bu sonuçlar, özellikle YOLO ve DETR gibi daha yeni nesil derin öğrenme tabanlı nesne algılama yaklaşımlarının, SSD gibi


daha önceki mimarilere kıyasla daha yüksek doğruluk sağladığını ortaya koymaktadır. Ancak YOLO ve DETR arasındaki farkın görece düşük olması, her iki modelin de benzer düzeyde başarılı sonuçlar sunduğunu göstermektedir.

YOLO mimarisi, gelişim sürecinde tek aşamalı tespit yapısına rağmen daha dengeli bir hız-güven skoru sunmakta ve küçük veya orta ölçekli nesnelerde SSD'ye göre daha yüksek başarı sağlamaktadır (Huang ve diğerleri, 2017). Bu çalışmada YOLO'nun SSD'ye kıyasla %12'lik bir güven skoru artışı elde etmesi de bu durumu desteklemektedir.

DETR modeli ise, Transformer tabanlı yapısı sayesinde nesne algılama görevinde küresel bağlam bilgisini doğrudan öğrenebilmekte ve geleneksel yaklaşımlara duyulan ihtiyacı ortadan kaldırmaktadır (Carion ve diğerleri, 2020). Bu özellik, özellikle karmaşık görsellerde nesneler arası ilişkilerin doğru şekilde modellenmesine imkân tanımakta ve bu çalışmada gözlemlendiği gibi güven skorunun en yüksek seviyeye çıkmasına katkı sağlamaktadır (Zhu ve diğerleri, 2021). Ancak YOLO ile DETR arasındaki farkın görece küçük olması, YOLO'nun da modern veri setlerinde oldukça iyi bir performans sunduğunu göstermektedir (Khan ve diğerleri, 2022).

4.3. SSD Üzerindeki İyileştirme Çalışmalarının Sonuçları

SSD modeli üzerinde gerçekleştirilen ön testler kapsamında 5, 7, 9 ve 11 olmak üzere farklı kernel boyutlarında 780 tümörlü görüntü kullanılarak ortalama güven skorları hesaplanıp analiz edilmiştir. Elde edilen sonuçlar, modelin en yüksek güven skorunu 9 kernel değerinde verdiğini ortaya koymuştur. Bu bulgu doğrultusunda, çalışma kapsamında yer alan tüm görüntü iyileştirme yöntemleri, yalnızca 9 kernel boyutu temel alınarak uygulanmıştır. Böylece iyileştirme metotlarının model performansına etkisi, sabit bir kernel boyutu üzerinden karşılaştırmalı olarak incelenmiş ve farklı kernel boyutlarının yarattığı değişkenlik ortadan kaldırılarak analizlerin güvenilirliği artırılmıştır. Farklı kernel değerinde SSD modelinin ortalama güven skoru değerleri Şekil 4.17'de verilmiştir.



Şekil 4.17. SSD modeli farklı kernel değerlerinde algılama performansı.

Taban değeri, 780 tümörlü görüntü içerisinde yalnızca tek bir tespit yapıldığında elde edilen en düşük güven skoru değeridir. Bu değer, modelin istikrarlı şekilde tespit yapabilme kabiliyetini yansıtmakta ve düşük değerler modelin güvenilirliğini olumsuz etkilemektedir. Analiz sürecinde yöntemler, iki kriter üzerinden sınıflandırılmıştır. Bunlar, Algılamaya Katkı yüzdesinin pozitif veya negatif olması ve Taban değerinin belirli bir eşiğin üzerinde veya altında bulunmasıdır.

Özellikle, katkı yüzdesi +1'in üzerinde olan ve taban değeri -2 veya daha düşük seviyelere gerilemeyen yöntemler, model performansını iyileştirme potansiyeli yüksek olan yararlı yöntemler olarak sınıflandırılmıştır. Bu yöntemler, yalnızca ortalama güven skorunu artırmakla kalmamış, aynı zamanda modelin düşük performans gösterdiği durumlarda dahi tespit kararlılığını koruyarak genel güvenilirliğini güçlendirmiştir. Buna karşılık, katkı yüzdesi negatif olan veya taban değeri -2 eşiğinden daha yüksek olan yöntemler, modelin hem doğruluk hem de kararlılık açısından yeterli katkı sunmaması nedeniyle daha düşük öneme sahip olarak değerlendirilmiştir. Bu sınıflandırma yaklaşımı sayesinde, yöntemlerin etkileri yalnızca tek bir metrik üzerinden değil, iki farklı ölçüt birlikte ele alınarak daha kapsamlı biçimde analiz edilmiştir. Böylece, modelin performansını kararlı bir şekilde artıran yöntemler ön plana çıkarılmış hem güven skoru hem de tespit istikrarı bakımından dengeli bir iyileştirme stratejisi oluşturulmuştur. Yapılan bu görsel analiz, özellikle SSD modeli için hangi görüntü iyileştirme yöntemlerinin uygulanmasının daha uygun olacağına ilişkin somut ve kolay yorumlanabilir bir karar desteği sunmaktadır. SSD modelinde elde edilen sonuçlar Çizelge 4.10'da ayrıntılı şekilde verilmiş olup, modele pozitif katkı sağlayan yöntemler çizelgede koyu renkle vurgulanmıştır.

Çizelge 4.10. SSD modelinin iyileştirme metotlarındaki performans analizi.

Yöntem	Güven Skoru Katkısı (%)	Taban Değeri
CLAHE	-9,3	-18,33
Medyan	10	-1,53
Wiener	-12,44	-40,1
Gauss	12	0
Aşındırma	-15,8	-43
Genişleme	-25	-65
Açma	-2	-5,5
Kapama	-17,33	-45
CLAHE-Açma	-11	-30
CLAHE-Kapama	-20	-56
CLAHE-Aşındırma	-24	-53
CLAHE-Genişleme	-28	-10
Gauss-Açma	9,83	0
Gauss-Kapama	9,83	0
Gauss-Aşındırma	9	-1,36
Gauss-Genişleme	6	-1,36
Medyan-CLAHE	-7,60	-23
Medyan-Açma	9,25	-1,36
Medyan-Kapama	8,90	-1,36
Medyan-Aşındırma	8,40	-1,36
Medyan-Genişleme	9,50	0
Wiener-CLAHE	-26,2	-55
Wiener-Açma	-1,60	-8
Wiener-Kapama	-9	-30
Wiener-Aşındırma	-8,95	-30
Wiener-Genişleme	-14,32	-48

Çizelge 4.10 incelendiğinde Medyan, Gauss, Gauss-Açma, Gauss-Kapama, Gauss-Aşındırma, Gauss-Genişleme, Medyan-Açma, Medyan-Kapama, Medyan-Aşındırma, Medyan-Genişleme metotları SSD modeline pozitif olarak etki göstermiştir. Taban değeri, 780 adet iyileştirme uygulanan tümörlü görüntünün algılanan en düşük oran olarak tanımlanmış ve bu değer -2'den daha büyük ise yöntem, kararlı olarak değerlendirilmiştir. Algılama katkısı ise, 780 adet iyileştirme uygulanan tümörlü görüntünün modelin güven skorunda meydana gelen yüzde değişimi ifade etmektedir. Yapılan analizler sonucunda hem

pozitif algılama katkısı hem de kararlı taban değeri sağlayan yöntemler detaylı olarak açıklanmıştır. Medyan Filtresi algılama Katkısı %10 ve taban değeri -1,53 olarak elde edilmiştir. Gürültü azaltma yeteneği sayesinde özellikle tıbbi görüntülerde yapısal detayları koruyarak SSD modelinin hedef bölgeleri daha net algılamasına olanak sağlamıştır. Düşük taban değeri ile modelin kararlılığını koruyarak yanlış pozitifleri azaltmıştır.

Gauss Filtresi, algılama katkısı %12 ve Taban Değeri 0 olarak elde edilmiştir. Yumuşatma işlemi ile yüksek frekanslı gürültüyü bastırırken, tümör bölgelerinin sınırlarını belirginleştirerek SSD modelinin nesne tespit performansını artırmıştır. Taban değerinin 0 olması, modelin istikrarlı çalıştığını göstermektedir.

Gauss–Açma iyileştirme yöntemi, algılama katkısı %9,83, taban değeri ise 0 olarak elde edilmiştir. Morfolojik açma ile Gauss filtresi, küçük gürültülerin giderilmesi ve nesne kenarlarının daha net hale gelmesini sağlamıştır. Bu kombinasyon, özellikle düşük kontrastlı tümör bölgelerinde SSD’nin daha doğru sınırlamalar yapmasına katkı vermiştir.

Gauss–Kapama filtresi, algılama katkısı %9,83, taban değeri 0 olarak elde edilmiştir. Kapama işlemi ile küçük boşlukların doldurulması, Gauss filtresi ile yumuşatma sonucunda tümör bölgelerinin bütünlüğü korunmuştur. Bu durum, SSD’nin daha güvenilir tespitler yapmasına yardımcı olmuştur.

Gauss–Aşındırma filtresi, algılama katkısı %9, taban değeri de -1,36 olarak elde edilmiştir. Kenar yumuşatma ve küçük çıkıntıların giderilmesi, tespit doğruluğunu artırmış, taban değerinin düşük olması ise kararlılığı koruduğunu göstermektedir.

Gauss–Genişleme filtresi, algılama katkısı %6, taban değeri de -1,36 olarak analiz edilmiştir. Yumuşatma sonrası genişleme, tespit edilecek bölgelerin SSD tarafından daha geniş ve net şekilde algılanmasını sağlamış, pozitif katkı ile modelin stabil çalışmasına yardımcı olmuştur.


Medyan–Açma filtresi, algılama katkısı %9,25 ve taban değeri olarak da -1,36 olarak analiz edilmiştir. Medyan filtresinin gürültü azaltıcı etkisi ve açma işleminin küçük nesneleri temizleme özelliği birleşerek modelin güven skorunu artırmıştır. Medyan–Kapama yönteminde Algılama Katkısı %8,90 ve taban değeri -1,36 olarak hesaplanmıştır. Kapama

işlemi ile nesne sınırlarının bütünlüğü korunurken, medyan filtre gürültüyü azaltarak daha net bir giriş görüntüsü sağlamıştır.


Medyan–Aşındırma yönteminde, algılama katkısı %8,40 ve taban değeri -1,36 olarak hesaplanmıştır. Nesne kenarlarını belirginleştiren aşındırma işlemi, medyan filtre ile desteklenerek SSD’nin küçük detaylardaki algılamasını iyileştirmiştir. Medyan–Genişleme algılama katkısı %9,50 ve taban değeri olarak 0 analiz edilmiştir. Genişleme ile nesne alanının büyütülmesi ve medyan filtre ile gürültü azaltılması, güven skoruna pozitif katkı sağlayarak modelin daha geniş bölgeleri güvenilir şekilde algılamasına imkân tanımıştır.

Elde edilen sonuçlara göre, Gauss tabanlı yöntemler ve Medyan tabanlı kombinasyonlar, SSD modelinin hem güven skoru olarak hem de kararlılık açısından en verimli çalıştığı metotlar olmuştur. Özellikle Gauss ve medyan filtresi, taban değerinin yüksek kalmasını sağlarken pozitif güven skoru katkısı ile modelin güvenilirliğini artırmıştır. Bu yöntemler, tıbbi görüntülerin nesne tespitinde SSD’nin performansını optimize etmek için öncelikli olarak tercih edilmelidir.

SSD modelinin iyileştirme metotlarında bulunan değerlerinin grafiği Şekil 4.18’de verilmiştir. Şekilde bulunan mavi yıldızla gösterilen yöntemler SSD modeline pozitif katkı sağlayan ve sistemde kararlı çalışan iyileştirme yöntemi olarak kabul edilmiştir. Şekil 4.19’da SSD modelinin orijinal görüntüde ve Gauss-kapama uygulanmış görüntüde bulunan güven skoru değerleri verilmiştir.



Şekil 4.18. SSD ile görüntü iyileştirmenin güven skoruna yüzdelik katkısı.



Şekil 4.19. (a) SSD orijinal algılama (%76), (b) SSD, Gauss-Morfolojik kapama kombinasyon algılaması (%84).

Literatürde Medyan ve Gauss bulanıklaştırma, gürültüyü azaltmak ve görüntüleri yumuşatmak için kullanılır (Birla ve Shantaiya, 2014; Borole ve diğerleri, 2015; Roy ve Bandyopadhyay, 2012). Medyan filtresi, özellikle gürültüyü gidermede ve kenarları korumada etkilidir (Borole ve diğerleri, 2015; Roy ve Bandyopadhyay, 2012). Gaussian bulanıklığı da görüntüyü pürüzsüzleştirerek yüksek frekanslı gürültüyü azaltır (Birla ve Shantaiya, 2014). Tıbbi görüntülerdeki gürültüler derin öğrenme modellerinin doğruluğunu olumsuz etkileyebilir (Ullah ve diğerleri, 2021). Bulanıklık tekniklerinin uygulanması, gürültünün azaltılmasına ve modelin daha temiz verilere odaklanmasına yardımcı olarak tespit performansını iyileştirebilir. Bu, kaynaklarda belirtilen, ön işleme adımlarının model performansı üzerindeki doğrudan olumlu etkisiyle uyumludur. Böylece Medyan ve Gauss bulanıklaştırma ile morfolojik işlemlerin birlikte kullanımının, modelin güven skoru performansına katkı sağladığı gözlemlenmiştir.

4.4. YOLO Üzerindeki İyileştirme Çalışmalarının Sonuçları

SSD modelinde yapılan ön testler sonucunda 9 kernel değerinin en yüksek güven skorunu verdiği tespit edilmiştir. Performans farklarının kernel değişiminden değil de model mimarisinden veya iyileştirme yöntemlerinden kaynaklandığını sağlamak amacıyla, YOLO modeli üzerinde gerçekleştirilen tüm iyileştirme yöntemi deneyleri de 9 kernel değeri temel

alınarak yapılmıştır. Böylece elde edilen sonuçlar, farklı model mimarilerinin aynı koşullar altında karşılaştırılmasına olanak tanımaktadır. Çizelge 4.11’de YOLO modelinde elde edilen sonuçlar verilmiştir ve modele pozitif katkı veren yöntemler koyu renkte belirtilmiştir.


Çizelge 4.11. YOLO modelinin iyileştirme metotlarındaki performans analizi.

Yöntem	Güven Skoru Katkısı (%)	Taban Değeri
CLAHE	1,2	-7
Medyan	-4	-7
Wiener	-2	-8
Gauss	-0,04	-6,56
Aşındırma	-4	-6,32
Genişleme	-6,60	-15
Açma	-8,40	-20,65
Kapama	1,30	-1,90
CLAHE-Açma	-16	-7
CLAHE-Kapama	4	-7
CLAHE-Aşındırma	-15	-7
CLAHE-Genişleme	-27	-7
Gauss-Açma	3	-3
Gauss-Kapama	3,9	-1,8
Gauss-Aşındırma	3,4	-4
Gauss-Genişleme	3	-1,5
Medyan-CLAHE	-7	-12
Medyan-Açma	10	-7
Medyan-Kapama	0,65	-7
Medyan-Aşındırma	0,90	-4,90
Medyan-Genişleme	-7	-11
Wiener-CLAHE	-3,5	-4,30
Wiener-Açma	-4,85	-7,7
Wiener-Kapama	-2,95	-5,15
Wiener-Aşındırma	-1,36	-7,30
Wiener-Genişleme	-6,59	-9,72


Çizelge 4.11’de bulunan yöntemlerde Kapama, Gauss-Kapama ve Gauss-Genişleme yöntemleri YOLO modeline pozitif katkı sağlamış ve kararlı bir sistem olarak belirlenmiştir. Çizelge incelendiğinde Gauss ve morfolojik işlemlerin birlikte kullanımı hem ortalama güven skoru katkısında pozitif artış hem de taban değeri açısından nispeten yüksek kararlılık sağlamaktadır.

CLAHE-Genişleme, Açma ve Genişleme gibi yöntemler hem ortalama katkıda düşüşe hem de düşük taban değerine sahip olduğundan model performansını olumsuz etkileyen metotlar arasında yer almaktadır.

Kapama ve Gauss-Genişleme gibi metotlar, düşük seviyede de olsa pozitif katkı sağlamakta ve kararlılık açısından kabul edilebilir seviyelerdedir. Bu analiz, hangi iyileştirme yöntemlerinin YOLO modelinde tercih edilmesi gerektiğini ve hangilerinin modelin genel başarısını düşürdüğünü net bir şekilde ortaya koymaktadır. Elde edilen verilerin grafiği Şekil 4.20’de, YOLO modelinin orijinal ve CLAHE-Kapama uygulanmış görsel ve güven skoru değerleri Şekil 4.21’de verilmiştir.



Şekil 4.20. YOLO ile görüntü iyileştirmenin güven skoruna yüzdelik katkısı.



Şekil 4.21. (a)YOLO, orijinal algılama (%79), (b) YOLO, CLAHE – Morfolojik Kapama kombinasyon (%84) algılaması.


Temel model olarak YOLO, görüntü iyileştirme uygulanmadığında bile yüksek algılama doğruluğu sergileme eğilimindedir. YOLO mimarisi, karmaşık tıbbi görüntülerdeki zorluklarla başa çıkmak için, özellik çıkarma ağları, dikkat mekanizmaları veya verimli özellik birleştirme stratejileri gibi tasarlanmış çeşitli optimizasyonları içermektedir. Bu tür mimari avantajlar, YOLO'nun işlenmemiş görüntülerden bile güçlü ve ayırt edici özellikler çıkarma yeteneğini artırabilir (Lin ve diğerleri, 2024; Yao ve diğerleri, 2024). Bununla birlikte, deneysel sonuçlar, SSD modelinin algılama doğruluğunun görüntü iyileştirme tekniklerinden YOLO'ya kıyasla orantısız olarak daha fazla fayda sağladığını ortaya koymuştur. Bu durum, farklı derin öğrenme mimarilerinin giriş görüntülerinin kalitesine ve ön işleme verilen farklı tepkilerini yansıtabilir. Sonuç olarak, bulanıklık ve morfolojik operasyonların kombinasyonlarının bireysel tekniklere göre daha yüksek doğruluk artışı sağlaması, bu farklı ön işlem adımlarının birbirini tamamlayıcı etkilerinden kaynaklanmaktadır. Görüntünün eş zamanlı olarak gürültüden arındırılması ve yapısal özelliklerinin iyileştirilmesi, derin öğrenme modelleri için daha öğrenilebilir ve bilgilendirici bir girdi sunarak algılama performansını optimize etmektedir.

4.4. DETR Üzerindeki İyileştirme Çalışmalarının Sonuçları

Bu bölümde, DETR (DEtection TRansformer) modelinin farklı görüntü iyileştirme metotları altındaki algılama performansı incelendiğinde her bir iyileştirme yönteminin modelin güven skoruna ortalama katkısı ve taban değeri analiz edilmiştir. Bu analizler, DETR modelinin hangi görüntü iyileştirme teknikleri ile daha yüksek başarı ve tutarlılık sağladığını belirlemeye ve farklı yöntemler arasındaki karşılaştırmayı kolaylaştırmaya yöneliktir. Çizelge 4.12’de DETR modelinin iyileştirme metotları uygulandıktan sonra elde edilen değerler verilmiştir. Çizelgede DETR modeline pozitif olarak katkı sağlayan yöntemler yeşil renk ile belirtilmiştir. Şekil 4.22’de bu değerlerin grafiği gösterilmiştir.

Çizelge 4.12. DETR modelinin iyileştirme metotlarındaki performans analizi.


Yöntem	Güven Skoru Katkısı (%)	Taban Değeri
CLAHE	-1	-8
Medyan	-5,87	-9,95
Wiener	-3,58	-10,32
Gauss	0	-6,76
Aşındırma	-3,03	-6,32
Genişleme	-5,56	-8,92
Açma	-7,78	-15,83
Kapama	0	-0,77
CLAHE-Açma	-10	-15,95
CLAHE-Kapama	5	-3,95
CLAHE-Aşındırma	-2,29	-7,95
CLAHE-Genişleme	-10,45	-15,95
Gauss-Açma	2,59	-1
Gauss-Kapama	5	0
Gauss-Aşındırma	8,1	-10
Gauss-Genişleme	4,55	-1,26
Medyan-CLAHE	-3,61	-4,75
Medyan-Açma	6,72	-5,95
Medyan-Kapama	1,5	-9
Medyan-Aşındırma	3	-6,7
Medyan-Genişleme	-3,04	-9
Wiener-CLAHE	-5,37	-7,79
Wiener-Açma	-4,77	-7,59
Wiener-Kapama	-2,08	-5,06
Wiener-Aşındırma	-1	-7,32
Wiener-Genişleme	-5	-8



Şekil 4.22. DETR ile görüntü iyileştirmenin güven skoruna yüzdelik katkısı.

Elde edilen sonuçlara göre, pozitif katkı sağlayan ve aynı zamanda taban değeri -2'nin üzerinde kalan yöntemler hem genel algılama başarısını artırmış hem de modelin düşük güven düzeyli örneklerde istikrarlı sonuçlar üretmesini sağlamıştır. Özellikle Gauss-Açma, Gauss-Genişleme ve Gauss-Kapama yöntemleri, DETR modelinde önemli bir pozitif katkı sergilemiştir. Bununla birlikte, bazı yöntemlerde ortalama katkı pozitif olsa dahi taban değerinin düşük olması, yöntemin kararlılık açısından zayıf kaldığını göstermektedir.

Bu analizler sonucunda, DETR modelinde görüntü iyileştirme metotlarının etkilerinin sistematik biçimde değerlendirilmesinin, modelin farklı veri koşullarına uyum kabiliyetini artırdığı ve pratik kullanım potansiyelini güçlendirdiği görülmüştür. Şekil 4.23'te DETR modeli için orijinal ve Medyan-Açma yöntemi algılaması ve güven skoru değerleri verilmiştir.




Şekil 4.23. (a) DETR orijinal algılama (%85), (b) DETR, Medyan-açma kombinasyon algılaması (%84).

Şekil 4.23'te DETR modelinin orijinal görüntü üzerinde gerçekleştirdiği tümör algılama sonucu ile medyan-açma iyileştirme yöntemiyle ön işlem uygulanmış görüntü üzerinde elde edilen algılama sonucu karşılaştırılmaktadır. Orijinal görüntü üzerinde çalışan DETR modeli, tümörü %85 güven skoru ile tespit etmiştir. Medyan-Açma yöntemi uygulanmış görüntüde ise modelin tespit başarısı %84 olarak gerçekleşmiştir.

4.5. Derin Öğrenme Metotlarının Performanslarının Karşılaştırılması

Bu çalışmada SSD, YOLO ve DETR modellerinin farklı görüntü iyileştirme metotları uygulandıktan sonraki güven skorlarının oranları karşılaştırılmıştır. Her üç modelde de temel amaç, girdi görüntüsünün işlenmesi sonucunda tümör tespiti doğruluğunun artırılmasıdır. Güven skoruna katkı sağlayan ve taban değeri -2'nin üzerinde olan metotlar, modelin kararlılığı açısından yararlı kabul edilmiştir. Şekil 4.24'te 3 modelin de hangi iyileştirme yöntemlerinin katkı sağladığını gösteren değerler verilmiştir.



Şekil 4.24. SSD, YOLO ve DETR modellerinin karşılaştırma grafiği.

Bu bölümde, SSD, YOLO ve DETR modellerinin görüntü iyileştirme yöntemlerine verdikleri tepkiler hem güven skoru katkısı (%) hem de taban değeri kriterleriyle karşılaştırılmakta, bu farklılıkların temel sebepleri model mimarileri bağlamında değerlendirilmekte ve literatürdeki ilgili bulgularla ilişkilendirilmektedir.

SSD modeli, Gauss, Gauss Açma, Gauss Aşındırma, Gauss Genişleme gibi gürültü azaltma ve kenar koruma temelli iyileştirme yöntemlerine karşı yüksek pozitif katkı sağlamıştır. Medyan Açma ve Medyan Kapama gibi kombinasyonlar ise SSD modeline pozitif katkı sağlamaktadır. SSD'nin çok ölçekli özellik haritaları çıkarması, bu tür işlemlerin detayları dengeleyerek nesne tespitini iyileştirmesine olanak sağlamaktadır. Literatürde SSD'nin kenar yapısına karşı duyarlı olduğu vurgulanmış ve SSD'nin Gauss bulanıklığa karşı zaten daha hassas performans gösterdiğini belirtilmiştir (Rezaei, Ravanbakhsh, Namjoo ve Haghighat, 2019).

YOLO modeli, yalnızca Kapama, Gauss-Kapama ve Gauss-Genişleme gibi işlemlerden fayda sağlamıştır. YOLO'nun tek aşamalı hız odaklı mimarisi, görüntüdeki kontrastı ve yapısal biçimi koruyan yöntemlere daha olumlu tepki vermektedir. Detay kaybına neden olan ya da görüntüyü fazla yumuşatan işlemler, modelin nesne algılama performansını olumsuz etkileyerek tespit oranlarını düşürmüştür.

DETR modeli, yalnızca Gauss-Açma, Gauss-Kapama ve Gauss-Genişleme yöntemlerinde faydalı sonuçlar üretmiştir. DETR'nin transformer temelli global bağlam analizi, kenar bütünlüğünü ve gürültüyü azaltan işlemlerde yüksek performans göstermesine yardımcı olurken, aşırı yapısal değişiklikler modeli olumsuz etkilemektedir. Transformer tabanlı mimarilerin tıbbi görüntü gibi spesifik alanlarda aşırı kompleksliğin faydadan çok zarar getirebildiği; bazı durumlarda daha sade mimarilerin daha iyi çalıştığı da literatürde belirtilmiştir (Willemink ve diğerleri, 2022). SSD, çok ölçekli özellik çıkarımı sayesinde gürültü ile başa çıkabilmekte ve net kenar detaylarını kullanabilmektedir. YOLO ise hızlı çıkarım ve bölgesel özniteliklere odaklandığından kenar kontrastını artıran filtrelerden faydalanmaktadır. DETR ise global ilişki modellemesi sayesinde bağlamı koruyan iyileştirmelere duyarlıdır, ancak aşırı bulanıklaştırıcı işlemler performansını bozmaktadır.


Genel karşılaştırmada, SSD modeli hem çeşitlilik hem de pozitif katkı düzeyi açısından en avantajlı görünmektedir. YOLO ve DETR ise daha seçici davranmakta, yalnızca belirli türdeki iyileştirme yöntemlerinden anlamlı kazanım sağlamaktadır. Bu farklılık, modellerin mimari yapılarından, öznitelik çıkarma süreçlerinden ve eğitim verilerindeki varyasyonlardan kaynaklanmaktadır.

Şekil 4.20' de bulunan grafikte görüldüğü üzere, SSD'nin faydalı yöntem çubuklarının yüksek değerli olması, bu modelin görüntü iyileştirme metotlarından genel olarak daha yüksek fayda sağladığını, YOLO ve DETR'nin ise sınırlı ancak hedefe yönelik iyileştirmelerden yararlandığını desteklemektedir.

Çalışmada kullanılan derin öğrenme modellerinin beyin tümörü tespitindeki performanslarını değerlendirmek amacıyla, görüntü iyileştirme yöntemleri uygulanmadan önceki ve uygulandıktan sonraki metrik değerleri ayrı ayrı hesaplanmıştır. Modellerin kesinlik, duyarlılık, $mAP@0.5$ ve $mAP@[0.5:0.95]$ gibi temel ölçütler üzerinden karşılaştırmalı analizleri yapılmış, iyileştirme sonrası elde edilen değişimlerin gerekçeleri ayrıntılı biçimde açıklanmıştır. Bu ölçütler, nesne algılama alanında yaygın olarak kabul gören performans göstergeleri olup, modellerin tespit başarımını çok yönlü bir şekilde değerlendirmeye olanak tanımaktadır.

Görüntü iyileştirme yöntemlerinin modeller üzerindeki etkisini karşılaştırmak amacıyla, her model için en iyi ve en kötü performans gösteren iyileştirme yöntemleri belirlenmiştir. Bu

yöntemlerin seçimi, modellerin mAP, kesinlik ve duyarlılık değerlerindeki değişimlere ve güven skoruna negatif ve pozitif katkılarına dayanmaktadır. YOLOv8 modelinde en iyi sonuç Gauss-Kapama kombinasyonu ile elde edilirken, en düşük sonuçlar 3 model için de CLAHE-Genişleme yöntemi uygulandığında gözlemlenmiştir. SSD modelinde en yüksek artış Gauss yönteminde elde edilmiştir. DETR modelinde ise en iyi iyileştirme etkisi Gauss-Kapama kombinasyonu ile sağlanmıştır. Şekil 4.25'te, başlangıç durumu ile en iyi ve en kötü iyileştirme yöntemi kullanılarak elde edilen kesinlik-duyarlılık eğrileri gösterilmektedir.



Şekil 4.25. YOLO, SSD, DETR modellerinin kesinlik-duyarlılık grafiği.

Grafiklerde mavi çizgi başlangıç durumunu, yeşil çizgi en iyi iyileştirme yönteminin uygulamasını, kırmızı çizgi ise en kötü iyileştirme yönteminin uygulamasını temsil etmektedir. Bu eğriler, iyileştirme yöntemlerinin model performansı üzerindeki etkilerini görsel olarak ortaya koymaktadır. Böylece, iyileştirme tekniklerinin model performansı üzerindeki etkisi yalnızca genel olarak değil, yöntem bazında da sayısal olarak ortaya konmuştur. Ayrıca bu grafikler, AP değerinin hesaplanmasında temel alınmıştır. AP değeri, kesinlik-duyarlılık eğrisi altında kalan alanın hesaplanmasıyla elde edilmektedir. Çalışmamızda yalnızca tek bir tümör sınıfı bulunduğu için, AP ve mAP değerleri birbirine eşittir. Görüntü iyileştirme uygulanmadan önce hesaplanan metrik değerleri Çizelge 4.13'te, iyileştirme yöntemleri uygulandıktan sonra en kötü performans veren iyileştirme yönteminin

değerleri Çizelge 4.14'te, en iyi performans veren iyileştirme yönteminin değerleri Çizelge 4.15'te verilmiştir.

Çizelge 4.13. İyileştirme öncesi algılama performansı.

Model	mAP@0.5	mAP@[0.5:0.95]	Kesinlik	Duyarlılık
YOLOv8	0,912	0,45	0,942	0,914
SSD	0,896	0,42	0,905	0,875
DETR	0,937	0,47	0,914	0,933

Çizelge 4.14. İyileştirme sonrası en kötü algılama performansı.

Model	mAP@0.5	mAP@[0.5:0.95]	Kesinlik	Duyarlılık
YOLOv8	0,890	0,420	0,920	0,872
SSD	0,868	0,407	0,895	0,848
DETR	0,913	0,458	0,903	0,909

Çizelge 4.15. İyileştirme sonrası en iyi algılama performansı.

Model	mAP@0.5	mAP@[0.5:0.95]	Kesinlik	Duyarlılık
YOLOv8	0,921	0,454	0,950	0,923
SSD	0,923	0,433	0,913	0,910
DETR	0,949	0,476	0,925	0,945

Çizelge 4.13, Çizelge 4.14 ve Çizelge 4.15'te sırasıyla iyileştirme öncesi temel model performansı, en kötü görüntü iyileştirme yöntemi uygulandıktan sonraki durum ve en iyi görüntü iyileştirme yöntemi uygulandıktan sonraki durum karşılaştırmalı olarak sunulmuştur. Çizelge 4.13 incelendiğinde, iyileştirme yapılmadan önce DETR modelinin genel olarak en yüksek mAP değerlerine ulaştığı görülmektedir. YOLOv8 modeli yüksek kesinlik değeriyle öne çıkarken, SSD modeli her iki mAP metriğinde de görece daha düşük performans sergilemiştir. Duyarlılık açısından da DETR modeli 0,933 değeriyle en başarılı sonuçları vermiştir. Bu çizelge, modellerin iyileştirme yöntemi uygulanmadan önceki temel performans düzeylerini ortaya koymaktadır.

Çizelge 4.14, en kötü performansın elde edildiği CLAHE-Genişleme yönteminin uygulanması sonrasında elde edilen metrik değerlerini göstermektedir. Tüm modellerde genel bir performans düşüşü gözlenmiştir. Örneğin YOLOv8 modelinde $mAP@0.5$ değeri 0,912'den 0,890'a, SSD modelinde 0,896'dan 0,868'e, DETR modelinde ise 0,937'den 0,913'e gerilemiştir. Benzer şekilde duyarlılık değerleri de azalmış; YOLOv8'de 0,914'ten 0,872'ye, SSD'de 0,875'ten 0,848'e, DETR'de ise 0,933'ten 0,909'a düşmüştür. Bu sonuçlar, seçilen en kötü iyileştirme yönteminin görüntüdeki yapısal bilgiyi bozarak modellerin TP tespit etme kabiliyetini olumsuz etkilediğini göstermektedir. Özellikle duyarlılık değerlerinde meydana gelen azalmalar, iyileştirme yönteminin uygulandıktan sonra tümör bölgelerinin algılanmasını zorlaştırdığını açıkça ortaya koymaktadır.

Çizelge 4.15 incelendiğinde en iyi performansın elde edildiği iyileştirme yöntemlerinin uygulanmasının ardından elde edilen metrik sonuçları yer almaktadır. YOLO ve DETR modellerinde en iyi iyileştirme yöntemi Gauss-Kapama kombinasyonu, SSD modelinde ise Gauss bulanıklaştırma olarak belirlenmiştir. Tüm modellerde hem mAP hem de duyarlılık değerlerinde iyileştirme öncesine kıyasla artış gözlenmiştir. YOLOv8 modelinde $mAP@0.5$ değeri 0,912'den 0,921'e, SSD modelinde 0,896'dan 0,923'e, DETR modelinde ise 0,937'den 0,949'a yükselmiştir. $mAP@[0.5:0.95]$ değerleri de benzer şekilde artmıştır. Duyarlılık açısından en dikkat çekici artış, DETR modelinde 0,933'ten 0,945'e olmuştur. Bu artışlar, seçilen uygun iyileştirme yönteminin model performansını olumlu yönde etkilediğini göstermektedir.

Genel olarak bu üç çizelge birlikte değerlendirildiğinde, görüntü iyileştirme adımının model performansı üzerinde belirgin bir etkisi olduğu açıkça görülmektedir. Uygun olmayan tek bir yöntemin kullanılması bile performansta anlamlı düşüşlere yol açarken, doğru seçilmiş bir yöntemin hem mAP hem de duyarlılık metriklerinde dikkat çekici iyileşmeler sağlamaktadır. Bu durum, yöntem seçiminin tıbbi görüntülerde otomatik tümör tespiti başarısı açısından kritik bir faktör olduğunu göstermektedir.

İyileştirme öncesi değerler, hazırlanan veri seti kullanılarak gerçekleştirilen eğitim sürecinin doğrudan çıktılarından elde edilmiştir. Bu değerler herhangi bir ön işleme, iyileştirme veya yeniden hesaplama yapılmadan, modellerin ham performanslarını yansıtmaktadır. Burada kullanılan veri seti, eğitim ve test sürecinde aynı standart koşullarda değerlendirilmiş, böylece başlangıç metrikleri tüm modeller için güvenilir bir karşılaştırma zemini sağlamıştır.

İyileştirme sonrası değerler, doğrudan yeni bir eğitim sürecine değil; test görüntüleri üzerinde seçilen belirli iyileştirme yöntemlerinin uygulanması sonucu elde edilen performans değişimlerine dayanmaktadır. Her bir model için, farklı yöntemleri ayrı ayrı denenmiş ve bu testler sonucunda metriklerdeki değişim eğilimleri ayrıntılı biçimde analiz edilmiştir. Bu analizler sonucunda, her model için en yüksek katkıyı sağlayan en iyi ve performansı en olumsuz etkileyen en kötü iyileştirme yöntemleri belirlenmiştir. Çizelgelerde sunulan iyileştirme sonrası değerler, bu seçilmiş iyileştirme yöntemlerinin doğrudan test sonuçlarını yansıtmaktadır. Bu yaklaşım sayesinde, yöntemlerin model performansına etkileri daha net bir şekilde izlenebilmiş, özellikle mAP, kesinlik ve duyarlılık metrikleri açısından farklı yöntemlerin olumlu ya da olumsuz etkileri açık biçimde ortaya konmuştur. Böylece hem en iyi hem de en kötü senaryolar ortaya konularak iyileştirme yöntemlerinin etkileri kapsamlı biçimde analiz edilmiştir.

Seçilen iyileştirme yöntemlerinin modeller üzerindeki etkileri birbirinden farklılık göstermiştir. SSD modeli, en iyi iyileştirme yöntemi uygulamasından sonra metriklerde en belirgin iyileşmeyi gösteren model olmuştur. Bu durum, SSD'nin mimarisinin özellikle düşük seviyeli kenar ve kontrast bilgilerini ön plana çıkaran ön işlem adımlarından olumlu etkilenmektedir. Uygulanan yöntem, SSD'nin özellik çıkarım katmanlarının daha net ve keskin sınır bilgileriyle beslenmesini sağlayarak tespit performansını artırmıştır. Buna karşılık, YOLOv8 ve DETR modelleri için en kötü iyileştirme yöntemi uygulamalarında sınırlı düzeyde performans kayıpları gözlemlenmiştir. Bu kayıpların temel nedeni, kullanılan düşük performans veren yöntemlerin bazı ince tümör yapılarının kontrastını azaltarak bu bölgelerde modellerin daha fazla FN üretmesine yol açmasıdır. Özellikle DETR gibi dikkat mekanizmasına dayalı modellerde, bu tür yapısal zayıflamalar modelin dikkat alanlarının doğru şekilde yönlendirilmesini zorlaştırabilmektedir. YOLOv8'de ise yüksek kesinlik değerinin korunmasına rağmen duyarlılıkta azalma gözlenmiş, bu da küçük veya zayıf kontrastlı lezyonların tespitinde başarının azaldığını göstermiştir. Bu sonuçlar, tek bir iyileştirme yönteminin bile model performansını olumlu ya da olumsuz yönde anlamlı şekilde değiştirebildiğini ve yöntem seçiminin özellikle tıbbi görüntülerde model başarısı açısından kritik bir rol oynadığını ortaya koymaktadır.

Kesinlik değerlerinin iyileştirme öncesi ve sonrası büyük ölçüde sabit kalmasının temel nedeni, test veri setinin yalnızca tümörlü görüntülerden oluşmasıdır. Veri setinde tümörsüz

örnek bulunmadığından, modellerin FP üretme ihtimali neredeyse yoktur. Buna rağmen kesinlik değerlerinin 1 yerine 0,84–0,95 aralığında seyretmesinin sebebi, kullanılan IoU eşikleri ve model tahmin kutularının hedef bölgelerle olan konumsal örtüşme düzeyleridir. Burada FP değeri, tümörsüz görüntülerden değil, IoU eşikliğini karşılamayan tahmin kutularından kaynaklanmaktadır (Everingham, Van Gool, Williams, Winn ve Zisserman, 2010). Örneğin, model bir tümörü doğru bölgede tahmin etmiş olsa bile, tahmin kutusu hedef bölge işaretlemesiyle yeterli düzeyde örtüşmediğinde bu tahmin FP olarak değerlendirilmektedir. Bu durum, test verisinin eğitim verisiyle aynı olmasına rağmen kesinlik değerlerinin 1'e ulaşmamasının temel nedenidir. Ayrıca, çalışmada uygulanan en iyi veya en kötü iyileştirme yöntemlerinin tahmin kutularının konumlarını doğrudan değiştirmemesi nedeniyle, kesinlik değerlerinde iyileştirme öncesine kıyasla anlamlı bir farklılık gözlenmemiştir. Sonuç olarak, bu çalışmada kesinlik metriği iyileştirme yöntemlerinin etkilerini yansıtan bir gösterge olmaktan çok, modelin tahmin kutularının hedef işaretlemelerle olan geometrik uyumunu temsil etmektedir. Yöntemlerin model başarımına etkileri esas olarak duyarlılık ve mAP metrikleri üzerinden belirginleşmiş, kesinlik metriği bu değişimleri yansıtmada sınırlı kalmıştır.

4.6. Önceki Çalışmalarla Karşılaştırmalar

Literatürde yapılan çeşitli çalışmalar, derin öğrenme modellerinin performansının uygulanan ön işleme adımlarına duyarlı olduğunu ve bu adımların ortalama güven skoru değerlerinde önemli değişikliklere yol açabildiğini göstermektedir. Bu bağlamda farklı iyileştirme teknikleri, kullanılan model mimarisi ve veri türüne göre değişen oranlarda katkı sağlamaktadır.

Türk ve diğerleri (2019), farklı derin öğrenme mimarileri üzerinde yaptıkları çalışmalarda, ön işleme adımlarının model performansı üzerinde önemli bir etkiye sahip olduğunu göstermiştir. MobileNet, VGG16 ve ResNet50 modelleri üzerinde uygulanan Gauss bulanıklaştırma işlemleri sonucunda ortalama güven skoru değerlerinde sırasıyla %4,20, %5,41 ve %2,59 oranlarında artış elde edilmiştir. Benzer şekilde Rasheed ve diğerleri (2023), beyin tümörü sınıflandırmasında Gauss bulanıklaştırma yöntemi kullanarak güven skorunda %6,20 oranında bir iyileşme sağlamıştır. Ummah ve diğerleri (2022) ise ResNet50 mimarisinde Gauss yöntemi ile %5,40 oranında artış bildirmiştir. Bu çalışmada Gauss bulanıklaştırma yöntemi SSD modeli üzerinde %12,00 oranında güven skoru artışı sağlamış,

YOLOv8 ve DETR modellerinde ise bu yöntem sınırlı ya da etkisiz kalmıştır (DETR için %0,00). Bu sonuçlar, Gauss yönteminin özellikle kenar bilgilerine dayalı çalışan mimarilerde daha güçlü etkiler yarattığını göstermektedir.

Alwakid ve diğerleri (2023), Inception-V3 modeli üzerine CLAHE (Contrast Limited Adaptive Histogram Equalization) yöntemi uygulayarak ortalama güven skorunda %19,85 oranında artış rapor etmişlerdir. Mora (2024), ise CNN tabanlı bir mimaride CLAHE kullanımıyla %16,48 oranında benzer bir artış elde etmiştir. Rasheed ve diğerleri (2023), CLAHE yöntemini kullanarak %6,20 oranında bir iyileşme sağlarken, Ummah ve diğerleri (2022) ResNet50 modelinde bu yöntemin %2,28 düzeyinde sınırlı bir artış sağladığını bildirmiştir. Bu çalışmada YOLOv8 modeli için CLAHE yöntemiyle yalnızca %1,20 oranında bir artış gözlenmiştir. Bu fark, CLAHE'nin özellikle kontrast duyarlılığı yüksek mimarilerde güçlü sonuçlar verirken, YOLOv8 gibi hızlı tek aşamalı mimarilerde etkisinin sınırlı kaldığını göstermektedir.

Kaur ve diğerleri (2021), retinal görüntüler üzerinde gerçekleştirdikleri çalışmalarında DeepNet mimarisi kullanarak aşındırma ve genişleme işlemlerinin etkisini incelemiş ve her iki yöntemde de ortalama güven skorlarında %4,22 oranında bir artış raporlamışlardır. Bu tür morfolojik işlemler, literatürde çoğunlukla gürültü azaltma ve ince damar yapılarını belirginleştirme amacıyla tercih edilmesine rağmen, Gauss bulanıklaştırma veya CLAHE yöntemleriyle karşılaştırıldığında katkı oranları oldukça sınırlı kalmaktadır. Bu çalışmada yapılan deneylerde de benzer şekilde, morfolojik işlemler (aşındırma, genişleme, açma, kapama) modeller üzerinde belirgin bir performans artışı sağlamamıştır. SSD modelinde aşındırma işlemi güven skorunu %−15,8 oranında düşürürken, genişleme işlemi %−25 oranında azalmaya yol açmıştır. YOLOv8 modelinde aşındırma %−4, genişleme %−6,60 katkı değeriyle olumsuz etki göstermiştir. DETR modelinde ise aşındırma %−3,03, genişleme %−5,56 oranında düşüşe sebep olmuştur. Açma ve kapama gibi diğer morfolojik işlemler de çoğu modelde negatif katkı değerleri üretmiştir. Elde edilen bu sonuçlar, morfolojik işlemlerin özellikle tümör bölgelerinde yapısal bilgiyi zayıflatabildiğini ve küçük lezyon alanlarının tespitinde model performansını düşürebildiğini göstermektedir. Bu nedenle, morfolojik işlemler yalnızca filtre değerlendirme aşamasında test edilmiş, ancak en iyi ve en kötü yöntem seçimine doğrudan dâhil edilmemiştir. Nihai karşılaştırmalarda Gauss bulanıklaştırma ve CLAHE yöntemleri esas alınmış; morfolojik yöntemler, güven skorlarında tutarlı ve anlamlı bir iyileşme sağlayamadıkları için dışarıda bırakılmıştır.

5. SONUÇ

SSD modelinin görüntü iyileştirme yöntemlerinden YOLO ve DETR modellerine göre daha belirgin bir gelişim göstermesi, SSD'nin içsel özellik çıkarma mekanizmasının, ön işlemenin sağladığı iyileştirilmiş sinyal/gürültü oranı ve kontrasttan daha fazla yararlandığını ortaya koymaktadır. YOLO ve DETR modelleri zaten işlenmemiş, zorlu verilerde iyi performans gösterme yeteneğine sahip olduğundan, harici görüntü iyileştirmesinin performansı üzerindeki ek etkisi, SSD modelindeki kadar belirgin olmamıştır. Sonuçlar görüntü iyileştirmenin etkisinin, kullanılan derin öğrenme modelinin temel performansına ve mimari tasarımına bağlı olarak değiştiğini göstermektedir.

Çalışmanın en belirgin üstünlüğü, SSD modelinin DETR ve YOLO derin öğrenme metotlarının görüntü ön işleme adımlarından nasıl farklı düzeylerde etkilendiğini deneysel olarak ortaya koymasındır. Bu, yalnızca "ön işleme performansı artırır" gibi genel bir yargının ötesine geçerek, performans optimizasyonunun modele özel yaklaşımlar gerektirdiğini göstermektedir. Medikal görüntü analizi gibi yüksek doğruluk gerektiren alanlarda, bu tür bir bulgu, en uygun iş akışını tasarlamak için kritik öneme sahiptir; hangi modelin seçileceğine veya hangi ön işleme adımlarının uygulanacağına karar verilirken, ikisinin etkileşiminin dikkate alınması gerektiği vurgulanmaktadır. YOLO ve DETR modellerinin zaten zorlu verilerde iyi performans gösterebilmesi ve SSD'nin iyileştirilmiş veriden daha fazla yararlanması, model mimarisinin veri kalitesi hassasiyeti üzerindeki etkisine dair somut bir kanıt sunmaktadır.

Bu bağlamda çalışmanın literatüre katkısı, derin öğrenme modellerinin yapısını anlamaya yönelik bir adım atmasıdır. Görüntü iyileştirmenin sağladığı sinyal-gürültü oranı ve kontrast artışının, farklı mimarilerdeki özellik çıkarma katmanları tarafından farklı biçimlerde değerlendirildiğinin deneysel olarak gösterilmesi, modelin içsel işleyişine ilişkin daha derin bir anlayış sağlamaktadır. Bu, medikal görüntü analizinde hibrit yaklaşımların değerini pekiştirir ve gelecekteki araştırmacılara, belirli bir tıbbi teşhis problemi için en etkili yapay zekâ destekli sistemi geliştirirken, model seçimi ve ön işleme stratejilerini bir arada düşünmeleri gerektiğini bilimsel bir temelde hatırlatmaktadır. Sonuçlar, modelin yalnızca kendi yapısal özellikleriyle değil, aynı zamanda girdi verisinin kalitesiyle olan etkileşimi

açısından da değerlendirilmesi gerektiğini göstermekte ve bu durum, alana özgü optimizasyon stratejilerinin geliştirilmesine olanak sağlamaktadır.

Gelecekteki çalışmalar, bu tekniklerin farklı derin öğrenme mimarileri ve daha geniş veri kümeleri üzerindeki etkilerini inceleyebilir, ayrıca farklı iyileştirme tekniklerinin daha karmaşık kombinasyonlarını araştırabilir. Bu bulgular, tıbbi görüntü analizinde ön işleme adımlarının tasarımına yönelik yeni bakış açıları sunmaktadır.

Farklı mimari yapıya sahip derin öğrenme modellerinin görüntü iyileştirme etkilerine verdiği farklı tepkilerin de gözlemlendiği bu çalışmadan sonra deneyin çalışma alanı, derin öğrenme modellerinin çeşitliliğine yönelik genişletilerek, evrimsel sinir ağlarının daha iyi anlaşılması amaçlanabilir. Algılama biçimlerinin daha iyi anlaşıldığı derin öğrenme modelleri, kullanılacakları çalışma alanı konusunda daha yüksek doğruluk oranlarına ulaşma fırsatı yakalar. Böylece görüntü iyileştirme yöntemlerinin değerlendirilme süreci daha iyi şekillenerek daha isabetli görüntü işleme tekniklerinin tercih edildiği deneyler yapılmasına olanak sağlanır.

Gerçek zamanlı nesne tespiti, özellikle hızlı sonuç gerektiren uygulamalarda (otonom araçlar, cerrahi prosedürler, acil teşhisler gibi) kritik öneme sahiptir YOLO ve DETR gibi modeller, tek aşamalı mimarileri sayesinde gerçek zamanlı hızlara ulaşabilen popüler algoritmalarıdır. Tıbbi görüntüleme gerç k zamanlı nesne tespitinin gerektiği durumlar için hızdan öd n vermemek adına düşük ön şleme yük ne sahip doğruluk iyileştirme çalışmaları önem arz etmektedir.

KAYNAKLAR

- Abdusalomov, A. B., Mukhiddinov, M., and Whangbo, T. K. (2023). Brain Tumor Detection Based on Deep Learning Approaches and Magnetic Resonance Imaging. *Cancers*, 15(16), 4172.
- Abidin, Z. U., Naqvi, R. A., Haider, A., Kim, H. S., Jeong, D. and Lee, S. W., (2024). Recent deep learning-based brain tumor segmentation models using multi-modality magnetic resonance imaging: a prospective survey, *Front. Bioeng. Biotechnol.* 12, 1392807.
- Akhavan, D, Alizadeh, D, Wang, D, Weist, M.R., Shepphird, J.K., Brown, C.E., (2019). CAR T cells for brain tumors Lessons learned and road ahead. *Immunol Rev.*, 290(1), 60–84.
- Alan, M. (2020). *Derin öğrenme ile biyosinyal sınıflandırma ve hastalık tahmini*, Yayınlanmamış Yüksek Lisans Tezi. Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Al-Ameen, Z., Sulong, G., and Rehman, A. (2012). CLAHE based noise reduction technique for medical images. *International Journal of Computer Science Issues*, 9(4), 490–497.
- Al-Ameen, Z., Sulong, G., Johar, G., (2015). A Comprehensive Study on Fast image Deblurring Technique, *International Journal of Advanced Science and Technology*, 44(1), 1-10.
- Aldeeb, S. (2017). *Kan Damarlarının Çeşitli Görüntü İşleme Teknikleriyle İncelenmesi*. Yayınlanmamış Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
- Alwakid, G., Gouda, W., and Humayun, M. (2023). Deep Learning-Based Prediction of Diabetic Retinopathy Using CLAHE and ESRGAN for Enhancement. *Healthcare (Basel)*, 11(6), 863.
- Arabahmadi, M., Farahbakhsh, R., and Rezazadeh, J. (2022). Deep Learning for Smart Healthcare—A Survey on Brain Tumor Detection from Medical Imaging. *Sensors*, 22(5), 1960.
- Asiri, A. A., Soomro, T. A., Shah, A. A., Pogrebna, G., Irfan, M., Alqahtani, S., (2024). Optimized Brain Tumor Detection: A Dual-Module Approach for MRI Image Enhancement and Tumor Classification, *IEEE Access*, 12, 42868-42887.
- Aslan, M. (2022). Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 399-407.
- Aswathy, S.U., Dhas, G. D., Kumar, S. S., (2014). A Survey on Detection of Brain Tumor from MRI Brain Images, *International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT)*. IEEE.
- Atbakan, İ. (2021). *MR Görüntüleri Kullanarak Otomatik Beyin Tümörü Tespiti*, Yayınlanmamış Doktora Tezi, Aydın Adnan Menderes Üniversitesi, Fen Bilimleri Enstitüsü, Matematik Programı, Aydın.

- Behnan, J., Finocchiaro, G., Hanna, G. (2019). The landscape of the mesenchymal signature in brain tumours. *Brain a journal of neurology*, 142(4), 847–866.
- Bilgin, M. (2024). *Savaş Stratejisi Optimizasyon Algoritmasıyla Tıbbi Görüntü İyileştirme*, T.C. Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü. Mekatronik Mühendisliği Anabilim Dalı, Konya.
- Biratu, E. S., Schwenker, F., Debelee, T. G., Kebede, S. R., Negera, W. G., and Molla, H. T. (2021). Enhanced Region Growing for Brain Tumor MR Image Segmentation. *Journal of Imaging*, 7(2), 22.
- Birla, A., Shantaiya, S. (2014). Performance Analysis of Image Enhancement Techniques for Brain Tumor Images, *International Journal of Research in Advent Technology*, 2(8), 34-40.
- Borole, V. Y., Nimbhore, S. S., Kawthekar, S. S. (2015). Image Processing Techniques for Brain Tumor Detection: A Review. *International Journal of Emerging Trends and Technology in Computer Science*, 4(5), 25-30.
- Çakar E. (2018). *Akciğer tomografisi görüntülerinde görüntü işleme teknikleri kullanan ürün tanımı uygulaması*. Yayımlanmamış Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Sakarya.
- Çan Z. (2021). *Otomasyon sistemlerinde görüntü işleme tekniklerini kullanan ürün tanımı uygulaması*. Yayımlanmamış Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Bilişim Sistemleri Mühendisliği Anabilim Dalı, Sakarya.
- Çavaş, S. (2022). *Tek Sahneli Sıkıştırılmış Videoda Anomali Tespiti*. Yayımlanmamış Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., and Zagoruyko, S. (2020). End-to-end object detection with transformers. In *European Conference on Computer Vision*, 213–229.
- Chan, W., Jaitly, N., Le, Q., and Vinyals, O. (2016). Listen, attend and spell: A neural network for large vocabulary conversational speech recognition. In *2016 IEEE International Conference on Acoustics, Speech and Signal Processing. (ICASSP)*. 4960–4964.
- Daş, R., Polat, G., ve Tuna, B. (2019). Derin Öğrenme ile Resim ve Videolarda Nesnelerin Tanınması ve Takibi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(3), 749–759.
- Değirmenci, A., Çankaya, İ., Demirci, R. (2018). Gradyan Anahtarlama Gauss Görüntü Filtresi, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6(3), 1270–1281.
- Dinçer, N. (2018). *Beyin Tümörlerinin Görüntü İşleme Teknikleri Kullanılarak Bilgisayar Destekli Tespiti*, Yüksek Lisans Tezi, İstanbul Üniversitesi-Cerrahpaşa. Lisansüstü Eğitim Enstitüsü. Bilgisayar Anabilim Dalı, İstanbul.
- Dipu, N., Shohan, S., K. M. A., and Salam. (2021). Brain tumor detection using various deep learning algorithms. In *2021 International Conference on Smart Cities and Technologies (ICSCT)*, 1–6. IEEE.

- Eke, Ş. (2018). *İstatistiksel İşaret İşleme Yöntemleri İle Görüntü İşleme*, Yayınlanmamış Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Sivil Havacılık Anabilim Dalı, Kayseri
- Eren, H., (2011). *Çok Duyargalı İmge Modelleri ile Araç Sürücüsü Kafa Hareketlerinin Değerlendirilmesi*, Yayınlanmamış Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Programı. Elazığ.
- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., and Zisserman, A. (2010). The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, 88(2), 303–338.
- Ezhilarasi, R., Varalakshmi, P., (2018). Tumor Detection In The Brain Using Faster R-CNN *Second International Conference On I-SMAC (IoT In Social, Mobile, Analytics And Cloud) (I-SMAC 2018)*, IEEE. ISBN:978-1-5386-1442-6.
- Galvez, R.L., Bandala, A.A., Dadios, E.P., Vicerra, R.R., and Maningo, J.M. (2018). Object Detection Using Convolutional Neural Networks. *TENCON 2018 - 2018 IEEE Region 10 Conference*, 2023-2027.
- Gao, X., Wang, Y., Li, H., and Zhang, P. (2024). Comparison of detection transformers and YOLO for microaneurysm detection in OCT images. *Eye*, 38, 1234–1242.
- Gasmi, K., Ben Aoun N., Alsalem, K., Ben Ltaifa I., Alrashdi, I., Ben Ammar, L., Mrabet, M., Shehab, A., (2024). Enhanced brain tumor diagnosis using combined deep learning models and weight selection technique, *Frontiers in Neuroinformatics*, 18
- Gezer, M. (2021). *Tıpta Görüntü İşleme Yöntemleri / Image Processing Methods in Medicine*. İstanbul Üniversitesi, Enformatik Bölümü, İstanbul, Türkiye.
- Ghosh, S., Banerjee, A., and Mitra, S. (2024). Optic disc and cup segmentation using DETR for glaucoma detection. *Journal of Glaucoma*, 33(4), 210–218.
- Habeeb, N. J., (2023). Medical Image Denoising with Wiener Filter and High Boost Filtering. *Iraqi Journal of Science*, 64(6), 3123-3135.
- Halloum, K., Ez-Zahraouy, H., (2025). Enhancing Medical Image Classification through Transfer Learning and CLAHE Optimization, *Current Medical Imaging*, 21, e15734056342623. DOI 10.2174011573405634262324111906.
- Hamad, A. H., Muhamad H. O. and Yaba S. P. (2014). De-noising of medical images by using some filters, *Int. J. Biotechnol. Res.*, 2(2), 1–11.
- Hanum M. (2017). *Tıbbi Görüntüleme Radon Dönüşümü Kullanarak Görüntü Oluşturma Üzerine Bir Çalışma*; Yayınlanmamış Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Hikmah, N. F., Hajjanto, A. D., Surbakti, A. F. A., Prakosa, N. A., Asmaria, T., and Sardjono, T. A. (2024). Brain tumor detection using a MobileNetV2-SSD model with modified feature

pyramid network levels. *International Journal of Electrical and Computer Engineering*, 14(4), 3995-4004.

Hosang, J., Benenson, R., Schiele, B., and Dollar, P. (2017). Learning non-maximum suppression. *arXiv preprint*.

Howard, A., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. and Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint*.

Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A. and Murphy, K. (2017). Speed/accuracy trade-offs for modern convolutional object detectors. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3296–3305.

Irmak, E. (2021). Multi-Classification Of Brain Tumor MRI Images Using Deep Convolutional Neural Network With Fully Optimized Framework. *Iranian Journal Of Science And Technology, Transactions Of Electrical Engineering*, 45, 1015–1036.

Işın, A., Direkoğlu, C., Şah, M. (2016). Review of MRI-based brain tumor image segmentation using deep learning methods. In *12th International Conference on Application of Fuzzy Systems and Soft Computing ICAFS*, Vienna, Austria.

İnternet: American Brain Tumor Association. (2022). Brain tumor statistics. ABTA. URL: <https://www.abta.org/about-brain-tumors/brain-tumor-statistics/>. Son Erişim Tarihi: 08.04.2024.

İnternet: Navoneel, (2019). Brain MRI images for brain tumor detection [Data set]. Kaggle. <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection>. Son Erişim Tarihi: 13.06.2024.

Jadwaa, S., (2018). Wiener Filter based Medical Image De-noising. *International Journal of Science and Engineering Applications*. 7(9). 318-323.

Joseph, R. P., Singh, J. S. and Manikandan M. (2014). Brain Tumor MRI Image Segmentation And Detection In Image Processing, *International Journal of Research in Engineering and Technology*, 3(4), 579–586.

Karayeğen, G., Akşahin, M.F. (2021). Derin Öğrenme ile Beyin Tümör Tahmini Ve Tümör Hacminin Hesaplanması, *Tıp Teknolojileri Kongresi*, Antalya

Khan, S., Naseer, M., Hayat, M., Zamir, S. W., Khan, F. S., and Shah, M. (2022). Transformers in Vision: A Survey. *ACM Computing Surveys*, 54(10s), 1–41.

Kharrat, A., Benamrane, N., Messaoud, M. B., & Abid, M. (2009). Detection of brain tumor in medical images. In *2009 3rd International Conference on Signals, Circuits and Systems (SCS)*, 1–6. IEEE.

Kim, H., Park, J., And Choi, S. (2025). Exemplar Med-DETR For Rare Lesion Detection İn Mammography. *Arxiv Preprint*, Arxiv:2507.19621.

- Kutan, F., Aynur, Ö. (2020). Gürültü Filtreleme Uygulamalarının Medikal Görüntüler Üzerindeki Performanslarının Değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (Special Issue), 265-271.
- Kirelli, Y. (2022). *Tibbi Görüntü Analizi Ve İşlemede Derin Öğrenme Modelleri*, Yayınlanmamış Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Lapointe, S., Perry, P. A., Butowski, N. A., (2018). Primary brain tumours in adults, *The Lancet*, 392, (10145), 432 – 446.
- Lin, Z., Lin W., Jiang, F., (2024). YOLOv8 -DEC: Enhancing Brain Tumor Object Detection Accuracy in Magnetic Resonance Imaging, *Progress In Electromagnetics Research M*, 129, 43-52.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single shot multibox detector. In *European Conference on Computer Vision*, 21–37.
- Maharjan, S., Alsadoon, A., Prasad, P. W. C., Al-Dalain, T., Alsadoon, O. H., (2020). A Novel Enhanced Softmax Loss Function For Brain Tumour Detection Using Deep Learning, *Journal of Neuroscience Methods*. 330, 108520.
- Mao, Y. T., Liu, Q. S., Fang, Y. F., Jiang, G. Z., and Jiang, D., (2024). Medical Image Segmentation on Attention-based Gaussian Blurring. *Sensors and Materials*, 36(11), 3505–3519.
- Mohan, A., Poobal, S., (2018). Crack Detection Using Image Processing, A Critical Review And Analysis, *Alexandria Engineering Journal*, 57(2), 787–798.
- Mora, A., R., (2024). *Deep Learning-Based Prediction Of Multiple Ocular Diseases Using Clahe Enhancement*; Yayınlanmamış Lisans Tezi, Tilburg University, Department Of Cognitive Science and Artificial Intelligence School Of Humanities And Digital Sciences.
- Mukhopadhyay, S., Ghosh, N., Barman, R., Panigrahi, P., Pratiher, S., Venkatesh, M., Mandal, S., Changdar, S., (2015). An Optimized Hyper Kurtosis Based Modified Duo-Histogram Equalization (HKMDHE) Method For Contrast Enhancement Purpose Of Low Contrast Human Brain CT Scan Images. In *2015 International Conference On Advances In Computing, Communications And Informatics (ICACCI)*, 21–26.
- Nazir, M., Shakil, S., Khurshid, K. (2021). Role Of Deep Learning İn Brain Tumor Detection And Classification (2015 To 2020): A Review, *Computerized Medical Imaging And Graphics*, 91, 101940
- Öksüz, C., Güllü, M., (2020). Yolo v2 Modeli ile Beyin Tümörü Algılama (Brain Tumor Localization Using Yolo v2). *Tıp Teknolojileri Ulusal Kongresi (TIPTEKNO)*, Türkiye.
- Osadebey, M.E., Pedersen, M., Arnold, D.L. (2018). Blind Blur Assessment Of MRI Images Using Parallel Multiscale Difference Of Gaussian Filters. *Biomed Eng Online* 17(1), 76.
- Özcan, B., Bakır, H., (2023). Yapay Zeka Destekli Beyin Görüntüleri Üzerinde Tümör Tespiti, *1st International Conference on Pioneer and Innovative Studies*, Konya, Türkiye.

- Paul, J., (2016). *Deep Learning for Brain Tumor Classification*; Yayınlanmamış Yüksek Lisans Tezi, Faculty of the Graduate School of Vanderbilt University, Nashville, Tennessee.
- Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ter Haar Romeny, B., Zimmerman, J. B., & Zuiderveld, K. (1987). Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3), 355–368.
- Rasheed, Z., Ma, Y.-K., Ullah, I., Ghadi, Y. Y., Khan, M. Z., Khan, M. A., Abdusalomov, A., Alqahtani, F., and Shehata, A. M. (2023). Brain Tumor Classification from MRI Using Image Enhancement and Convolutional Neural Network Techniques. *Brain Sciences*, 13(9), 1320.
- Razzak, M. I., Imran, M., & Xu, G. (2019). Efficient Brain Tumor Segmentation With Multiscale Two-Pathway-Group Conventional Neural Networks. *IEEE Journal Of Biomedical And Health Informatics*, 23(5), 1911–1919.
- Rehman, M. U., Cho, S., Kim, J., & Chong, K. T. (2021). Brainseg-Net: Brain Tumor MR Image Segmentation Via Enhanced Encoder–Decoder Network. *Diagnostics*, 11(2), 169.
- Reza, A. M. (2004). Realization Of The Contrast Limited Adaptive Histogram Equalization (CLAHE) For Real-Time Image Enhancement. *The Journal Of VLSI Signal Processing–Systems For Signal, Image, And Video Technology*, 38(1), 35–44.
- Rezaei, M., Ravanbakhsh, E., Namjoo, E., & Haghighat, M. (2019). Assessing The Effect Of Image Quality On SSD And Faster R-CNN Networks For Face Detection. In *2019 27th Iranian Conference On Electrical Engineering (ICEE)*, 1960–1965.
- Roy, S., Bandyopadhyay, S. K. (2012). Detection and Quantification of Brain Tumor from MRI of Brain and it's Symmetric Analysis, *International Journal of Information and Communication Technology Research*, 2(6), 477–483.
- Safdar, M., Alkobaisi, S., Zahra, F., (2020). A Comparative Analysis Of Data Augmentation Approaches For Magnetic Resonance Imaging (MRI) Scan Images Of Brain Tumor. *Acta Informatica Medica*, 28(1), 29–36.
- Saifullah, S., Pranolo, A., Drezewski, R., (2024). Comparative Analysis Of Image Enhancement Techniques For Brain Tumor Segmentation: Contrast, Histogram, And Hybrid Approaches. In *E3S Web Of Conferences*, 408, 02007.
- Schwehr, Z., Achanta, S., (2024). Brain Tumor Segmentation Based on Deep Learning, Attention Mechanisms, and Energy-Based Uncertainty Prediction. arXiv preprint.
- Stimper, V., Bauer, S., Ernstorfer, R., Schölkopf, B., And Xian, R. P. (2019). Multidimensional Contrast Limited Adaptive Histogram Equalization. *IEEE Access*, 7, 165437–165447.

- Streitberger, K.L., Lilaj, F., Schrank, J., Braun, K., Hoffmann, M., Reiss-Zimmermann, J.A. Käs, And I. Sack, (2019). How Tissue Fluidity Influences Brain Tumor Progression, *Proceedings Of The National Academy Of Sciences Of The United States Of America*, 117(1), 128–134.
- Suresh, K., Papendra, K., Manoj, G., Nagawat, A., (2010). Performance Comparison of Median and Wiener Filter in Image De-noising. *International Journal of Computer Applications*. 12(4), 27–31.
- Swadi, I. R., Mahdi, T. F., Daway, H. G., (2024). MRI Image Enhancement Using Multilevel Image Thresholds Based on Contrast-limited Adaptive Histogram Equalization. *Iraqi Journal of Science*, 65(10), 5888-5899.
- Şengöz, N. (2022). Derin Sinir Ağları Kullanılarak Koyun-Keçi Çiçeği Hastalığının Tespiti ve Sınıflandırılması için Hibrit Bir Yaklaşım, *El-Cezerî Journal of Science and Engineering*, 9 (4); 1542-1554.
- Taha, A. M. F., Ariffin, S. B. B., And Abu-Naser, S. S. (2023). A Systematic Literature Review Of Deep And Machine Learning Algorithms İn Brain Tumor And Meta-Analysis. *Journal Of Theoretical And Applied Information Technology*, 101(1), 1–20.
- Terzi, R., & Demirezen, M. U. (2022). Açık Kaynak Veri Seti İle Eğitilen Yapay Zeka Modellerinin Klinik Ortamdaki Performans Analizi. *Journal Of Ankara University Faculty Of Medicine*, 75(1), 25–34.
- Türkçetin, A. Ö. (2019). *Akciğer Kanserinin Tespit Edilmesinde Derin Öğrenme Algoritmalarının Kullanılması*; Yayınlanmamış Yüksek Lisans Tezi. Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Isparta.
- Tunthanathip, T., Kaewborisutsakul, A., & Supbumrung, S. (2024). Comparative Analysis Of Deep Learning Architectures For Performance Of İmage Classification İn Pineal Region Tumors. *Journal Of Medical Artificial Intelligence*, 8(0), 23-69.
- Turk, O., Acar, E., Irmak, E., Yilmaz, M., & Bakis, E. (2024). A Hybrid 2D Gaussian Filter And Deep Learning Approach With Visualization Of Class Activation For Automatic Lung And Colon Cancer Diagnosis. *Technology İn Cancer Research & Treatment*, 23, 15330338241301297.
- Kaur, M., Kamra, A., (2021). A Robust Morphological Deep Net Method for Image Segmentation Using Clustering (Retinal Image Segmentation Using Deep Net), *International Journal of Current Research and Review*, 13, 127-131.
- Uçar M. (2021). Glokom Hastalığının Evrişimli Sinir Ağı Mimarileri ile Tespiti, *DEÜ Fen ve Mühendislik Dergisi*, 23 (68), 521-529.
- Ullah, F., Ansari, S. U., Hanif, M., Ayari, M. A., Chowdhury, M. E. H., Khandakar, A. A., and Khan, M. S. (2021). Brain MR Image Enhancement for Tumor Segmentation Using 3D U-Net. *Sensors*, 21(22), 7528.

- Ummah K.R., Karlita T., Sigit R., Yuniarno E.M., Purnama I.K.E. and Purnomo M.H., (2022). Effect Of Image Pre-Processing Method On Convolutional Neural Network Classification Of Covid-19 Ct Scan Images, *International Journal of Innovative Computing, Information and Control*, 18 (6), 1895 – 1912.
- Üncü Y. A., Sevim G. ve Canpolat M. (2021). Difüz optik tomografi sisteminde görüntü işleme uygulamalarının test edilmesi, *Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Fen Dergisi*, 16(1), 1-16.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., and Polosukhin, I. (2017). Attention Is All You Need. In *Advances In Neural Information Processing Systems*, *arXiv Preprint*.
- Willeminck, M. J., Koszek, W. A., Hardell, C., Wu, J., Fleischmann, D., Harvey, H., and Lungren, M. P. (2022). Toward foundational deep learning models for medical imaging. *Nature Medicine*, 28(11), 1983–1994.
- World Health Organization. (2020). *Global cancer observatory: Brain and nervous system cancer fact sheet*. WHO/IARC.
- Yakut C. Ulukaya S. (2022). Görüntü Filtreleme İle Denetimsiz Retina Damar Bölütlenmesi İçin Parametre Eniyileştirilmesi, *Mühendislik Bilimleri ve Tasarım Dergisi*, 10(3), 825–836.
- Yang, X., Li, H., Yu, Y., Luo, X., Huang, T. and Yang, X. (2018). Automatic Pixel-Level Crack Detection and Measurement Using Fully Convolutional Network. *Computer-Aided Civil and Infrastructure Engineering*, 33(12), 1090–1109.
- Yao, Q., Zhuang, D., Feng, Y., Wang, Y., and Liu, J. (2024). Accurate Detection Of Brain Tumor Lesions From Medical Images Based On Improved Yolov8 Algorithm. *IEEE Access*, 12, 144260–144279.
- Yıldız G.,Yıldız D. (2018). Morfolojik İşlemler ve Kenar Algılama Yöntemler Vasıtasıyla Beyin Tümör Yeri Tespiti ve Tümör Alan Hesabının Yapılması, *International Journal of Multidisciplinary Studies and Innovative Technologies (IJMSIT)*, 2(2), 39–42.
- Yılmaz, S. (2023). Beyin Tümörü Tanıları İçin YOLOv7 Algoritması Tabanlı Karar Destek Sistemi Tasarımı, *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 6(1), 47-56
- Zhang, L., Chen, M., and Xu, J. (2025). CD-DETR: Cross-dimensional detection transformer for chest disease detection in X-ray images. *Medical Imaging Analysis*, 93, 103047.
- Zhao, J., Zhang, M., Zhou, Z., Chu, J. and Cao, F., (2017). Automatic Detection And Classification Of Leukocytes Using Convolutional Neural Networks, *Medical & Biological Engineering & Computing*, 55(8), 1287–1301.
- Zhu, X., Su, W., Lu, L., Li, B., Wang, X., and Dai, J. (2021). Deformable DETR: Deformable Transformers for End-to-End Object Detection. *International Conference on Learning Representations (ICLR 2021)*.

ÖZGEÇMİŞ

Adı-Soyadı : Hami KARA

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

- 1-) 2021 yılında düzenlenen Teknofest İnsansız Su Altı Sistemleri Yarışması'na ekip üyesi olarak katılım sağlanmıştır. Yarışma kapsamında, otonom su altı araçlarının yazılım ve görev planlaması süreçlerinde aktif görev alınmıştır.
- 2-) 2022 yılında düzenlenen Teknofest İnsansız Su Altı Sistemleri Yarışması'na ekip üyesi olarak katılım sağlanmıştır. Bu kapsamda, yazılım ve görev senaryolarının uygulanması aşamalarında görev alınarak proje sürecine katkı sunulmuştur.
- 3-) 2025 yılında düzenlenen BİLSEL VI. Uluslararası Sümela Bilimsel Araştırmalar Kongresi'ne, "Beyin MR Görüntülerinin İyileştirilmesi ve Derin Öğrenme Metotları ile Beyin Tümörü Tespiti" adlı çalışmayla sözlü bildiri sunumu yapılmıştır.