



Gökhan Gündoğdu

Fethi Sekin City Hospital, gokhangundogdu23@gmail.com,
Elazığ-Türkiye

Erhan Akın

Fırat University, eakin@firat.edu.tr, Elazığ-Türkiye

DOI	http://dx.doi.org/10.12739/NWSA.2025.20.2.1A0495	
ORCID ID	000-0001-8513-9332	0000-0001-6476-9255
Corresponding Author	Gökhan Gündoğdu	

BEYİN TÜMÖRÜ MR GÖRÜNTÜLERİNİN YOLOV8-SEG VE YOLOV11-SEG MODELLERİ İLE SEGMENTASYONU VE PERFORMANS ANALİZİ

ÖZ

Yapay zekâ teknolojilerinin hızla gelişmesiyle birlikte, bilgisayar bilimi sağlık alanında önemli uygulama alanları bulmaya başlamıştır. Özellikle derin öğrenme tabanlı yöntemler, tıbbi görüntüleme verilerinin analizinde etkili karar destek sistemlerinin geliştirilmesine olanak tanımaktadır. Bu çalışmada, beyin tümörlerinin otomatik segmentasyonu amacıyla YOLO mimarisine dayalı iki farklı model olan YOLOv8-seg ve YOLOv11-seg karşılaştırılmalı olarak değerlendirilmiştir. Geliştirilen sistemde, her iki model eğitim sürecinden geçirilmiş ve ardından segmentasyon başarımları çeşitli performans metrikleri üzerinden analiz edilmiştir. Değerlendirmede kullanılan metrikler arasında doğruluk (precision), geri çağırma (recall), mAP@0.5 ve mAP@0.5:0.95 yer almaktadır. Elde edilen sonuçlara göre, YOLOv11-seg modeli mAP@0.5 açısından en yüksek değeri sağlarken, YOLOv8-seg modeli mAP@0.5:0.95 metriğinde üstünlük göstermiştir. Yapılan karşılaştırma sonucunda, her iki modelin de beyin tümörü segmentasyonu görevinde yüksek doğrulukta sonuçlar ürettiği ve farklı metriklerde öne çıktığı belirlenmiştir. Bu çalışma, literatürde ilk defa YOLOv11-seg modelinin beyin tümörü segmentasyonunda performansını karşılaştırmalı olarak incelemektedir.

Anahtar Kelimeler: Derin Öğrenme, Beyin Tümörü Segmentasyonu, YOLOv8, YOLOv11, Görüntü Segmentasyonu

SEGMENTATION AND PERFORMANCE ANALYSIS OF BRAIN TUMOR MRI IMAGES USING YOLOV8-SEG AND YOLOV11-SEG MODELS

ABSTRACT

With the rapid development of artificial intelligence technologies, computer science has begun to find important applications in the field of healthcare. In particular, deep learning-based methods enable the development of effective decision support systems for the analysis of medical imaging data. In this study, two different models based on the YOLO architecture, YOLOv8-seg and YOLOv11-seg, were evaluated comparatively for the automatic segmentation of brain tumors. In the developed system, both models were trained and then their segmentation performance was analyzed using various performance metrics. The metrics used in the evaluation include precision, recall, mAP@0.5, and mAP@0.5:0.95. According to the results obtained, the YOLOv11-seg model provided the highest value in terms of mAP@0.5, while the YOLOv8-seg model showed superiority in the mAP@0.5:0.95 metric. The comparison showed that both models produced highly accurate results in brain tumor segmentation tasks and stood out in different metrics. This study is the first in the literature to comparatively examine the performance of the YOLOv11-seg model in brain tumor segmentation.

Keywords: Deep Learning, Brain Tumor Segmentation, YOLOv8, YOLOv11, Image Segmentation

How to Cite:

Gündoğdu, G. ve Akın, E., (2025). Beyin tümörü MR görüntülerinin YOLOv8-seg ve YOLOv11-seg modelleri ile segmentasyonu ve performans analizi, 20(2):33-49, DOI: 10.12739/NWSA.2025.20.2.1A0495.

1. GİRİŞ (INTRODUCTION)

Beyin tümörleri, diğer birçok hastalığa göre çok daha yüksek ölüm oranına sahip ciddi bir sağlık sorunudur [1]. Dünyada nüfus yaşı ilerledikçe beyin tümörlerinin görülme sıklığı artmakta ve günümüz araştırmaları her 100 bin kişiden yaklaşık 5'inde beyin tümörü gelişimi görülmektedir [2]. Beyin ya da omurilikte anormal hücre büyümesiyle oluşan tümörlerin erken tanı ve teşhisi, tedavi başarısını ve hastanın sağlıklı sürecini devamlılığını önemli ölçüde artırır. Bunun yanı sıra beyin tümörünün tanı ve lokalizasyon süreci son derece zorludur. Manyetik Rezonans (MR) görüntüleri, beyin tümörlerini saptamada önemli bir araç olsa da, bu görüntülerdeki tümörlerin elle tespiti ve segmentasyonu radyologlar için uzun sürecek, yorucu ve hata yapmaya açık bir süreçtir [2]. Tümör farklı boyutlarda ve beyin içinde farklı lokallerde olabildiği için, bir MR görüntüsünde tümörün sınırlarını manuel olarak çizmek tutarsızlıklar ve hatalı saptamalar gösterebilir ve küçük boyuttaki tümörler gözden kaçabilir [3]. Nitekim konvansiyonel yöntemlerle yapılan teşhislerde insan yorumuna dayalı öznel farklılıklar, tanı ve teşiste tutarsızlığa ve hata riskine yol açabilmektedir [4].

Tıbbi görüntülemelerde yapay zekâ ve derin öğrenme teknikleri, insan gözünden kaçabilecek ince desenleri seçebilme yetenekleri sayesinde son yıllarda önemli bir noktaya gelmiştir [4]. Derin öğrenme tabanlı modeller, büyük veri kütlelerinden eğitilerek beyin tümörü teşhis ve segmentasyonunda daha hızlı, tutarlı ve doğru sonuçlar elde etmeyi mümkün kılmakta ve hata riskini azaltmaktadır. Özellikle tek-adımlı nesne tespiti yaklaşımı ile gerçek zamanlı çalışabilen YOLO (You Only Look Once) algoritması, tıbbi görüntülerde tümör gibi anomalileri hızlı ve etkili bir şekilde saptama potansiyeli nedeniyle dikkat çekmektedir [5]. Bu çalışmada, beyin tümörü teşhisinde YOLO ailesinin son üyesi olarak varsayılan YOLOv11 modelinin (küçük boyutlu seg versiyonu olan YOLOv11s) segmentasyon performansı, güncel YOLOv8s segmentasyon modeli ile karşılaştırmalı olarak incelenmiştir. Böylece, beyin MR görüntülerinde otomatik tümör saptaması ve segmentasyonu için derin öğrenmenin sağladığı gelişmeler ortaya konulacaktır.

Beyin tümörlerinin görüntü tabanlı teşhisi üzerine literatürde hem klasik görüntü işleme yöntemleriyle hem de derin öğrenme tabanlı yaklaşımlarla çeşitli çalışmalar mevcuttur. Erken dönem çalışmalarda eşikleme, bölge büyütme ve kenar bulma gibi geleneksel yöntemler kullanılmış ancak bu yöntemler, parametrelere duyarlılıkları ve tümörlerin biçim çeşitliliği karşısında yetersiz kalmıştır [4]. Bulut ve ark. beyin MR görüntülerinde Markov Rastgele Alan (MRF), Kapur, Kittler ve Otsu eşikleme algoritmalarıyla tümör bölütleme yapmış; deneysel sonuçlarda en başarılı yöntemin MRF olduğu görülmüştür [6]. Bu dönem çalışmalarında genel olarak doğruluk oranları görece düşüktü ve model genelleme kapasitesi sınırlıydı. Derin öğrenme yöntemlerinin gelişmesiyle birlikte, beyin tümörü tespiti ve segmentasyonu alanında Convolutional Neural Network (CNN) tabanlı mimariler başarılı sonuçlar vermeye başlamıştır. Özellikle U-Net gibi evrimsel ağ mimarileri, BraTS gibi büyük veri kümelerinde tümör segmentasyonu için yaygın şekilde kullanılmıştır. Taşdemir ve Barışçi çalışmalarında dikkat mekanizmalı U-Net modellerinden oluşan bir topluluk (ensemble) öğrenimi yaklaşımı kullanarak beyin MR görüntülerinin otomatik segmentasyonunu gerçekleştirmişler ve dengesiz sınıf dağılımına rağmen BraTS2017 veriseti üzerinde ortalama %87.33 Dice skoru elde etmeyi başarmışlardır. Bu çalışmada nekrotik doku için %81.74, ödem için %91.57 ve kontrastlı tümör bölgesi için %76.03 Dice (zar) skoru rapor edilmiştir [1]. Benzer şekilde, Doğanay ve Yıldız klasik U-Net mimarisini geliştirdikleri Çok Ölçekli Çok Düzeyli Ağ (MM-Network) yapısıyla birleştirilerek MR görüntülerinde otomatik tümör segmentasyonu gerçekleştirilmiştir. Gerçekleştirilen deneysel analizler sonucunda, önerilen modelin tümör

tespitinde yüksek doğruluk sağladığı ortaya konmuştur [7]. Bu derin öğrenme tabanlı segmentasyon modelleri, elle çizilen segmentasyonlara kıyasla çok daha tutarlı ve hızlı sonuçlar üretmektedir. Beyin tümörü tespiti için nesne tespit modellerinin kullanımı da literatürde yer bulmuştur. Özellikle YOLO mimarisi, hız avantajı nedeniyle tıbbi alanda da uygulanmaya başlanmıştır [5]. Montalbo ve arkadaşları, YOLOv4-tiny modelini 30.364 kontrast artırılmış MRI taramasıyla eğitip transfer öğrenme ile ince ayar yaparak üç farklı beyin tümörü sınıfını tespit etmiş ve önerdikleri YOLOv4 tabanlı modelin önceki sürüm YOLO modellerine kıyasla daha iyi performans gösterdiğini belirtmişlerdir [2]. Yılmaz, YOLOv7 ve YOLOv7-tiny algoritmalarını 3203 MR görüntüsü ile eğiterek bir karar destek sistemi tasarlamış; görüntülerin makesense.ai platformunda elle anotlanmasıyla hazırlanan verisetinde yapılan deneylerde "tespitlerde %97'lere varan doğruluklar" elde edildiğini bildirmiştir [8]. Mercaldo ve ark. ise YOLOv8 modelini beyin tümörü tespitine uyarlayarak 300 MR görüntülük bir veriseti üzerinde %94.1 ortalama hassasiyet (mAP@0.5), %94.3 precision ve %92.3 recall değerleriyle başarılı sonuçlar elde etmişlerdir [5]. Bu çalışma, YOLO tabanlı yaklaşımın beyin kanseri görüntülerinde yüksek doğrulukla tümör lokalizasyonu yapabildiğini göstermiştir. Abdusalomov ve ark. , YOLOv7 modelini transfer öğrenme ile ince ayar yaparak glioma, meningioma ve pitüiter tümörleri içeren geniş bir veri kümesi üzerinde %99.5 gibi ilgi çekici bir doğrulukla tümör tespiti rapor etmişlerdir [3]. Bununla birlikte yazarlar, özellikle küçük tümörlerin tespitinde halen zorluklar olduğunu ve bu konuda daha fazla araştırmaya ihtiyaç duyulduğunu vurgulamışlardır. Bu durum, nesne tespit modellerinin tek başına segmentasyon detaylarında zorlanabildiğini, küçük ve belirsiz lezyonlar için iyileştirmeler gerektiğini göstermektedir. YOLO algoritmasının en güncel sürümlerine dair çalışmalar, bu kısıtların aşılabileceğine işaret etmektedir.

Özcan ve Bakır yaptıkları karşılaştırmalı çalışmada YOLOv5, YOLOv7 ve YOLOv8 modellerini aynı beyin MR veri seti üzerinde eğiterek değerlendirmiş ve en güncel model olan YOLOv8'in %87 mAP skoru ile en iyi sonucu verdiğini rapor etmişlerdir [2]. Bu çalışma, YOLO mimarisindeki ilerlemelerin tıbbi görüntülerde tespit performansını artırdığını göstermektedir. Khan ve ark. tarafından sunulan bir araştırmada, YOLOv8 ile örnek tabanlı (instance) tümör segmentasyonu ele alınmış; eski nesil YOLOv4 tabanlı segmentasyon yöntemlerinin yüksek tespit başarısına karşın segmentasyon detaylarında yetersiz kaldığı, buna karşılık YOLOv8 modelinin "tümörleri yüksek bir doğrulukla konumlandırmakla kalmayıp mevcut standartlara eşdeğer veya daha iyi kesinlikte maskeler üretebildiği" belirtilmiştir [4]. Son olarak, YOLO modellerinin transfer öğrenme ile ön-eğitilmiş olarak kullanımı da önemli kazanımlar sağlamaktadır. Ranjbarzadeh ve ark. yaptıkları çalışmada, COCO gibi büyük bir veri kümesinde önceden eğitilmiş YOLOv8 modellerinin beyin tümörü lokalizasyonunda daha yüksek IoU ve Dice skorları elde ettiğini göstermiştir. Örneğin, COCO üzerinde ön-eğitilmiş YOLOv8-XS modeli, eğitimsiz haline göre tümör tespitinde yaklaşık %15 daha yüksek başarı ile 0.278 IoU ve 0.435 Dice skoru elde etmiştir [9]. Benzer şekilde, ön-eğitilmiş YOLOv8-Large modeli 0.269 IoU değeriyle, Mask R-CNN (IoU: 0.212) ve Faster R-CNN (IoU: 0.228) gibi geleneksel iki-aşamalı tespit modellerini geride bırakmıştır [9]. Kang ve ark. beyin tümörü tespiti için YOLO tabanlı yeni bir nesne tespit modeli olan BGF-YOLO'yu geliştirmişlerdir. Bu model, YOLOv8 mimarisine çift düzeyli yönlendirme dikkat mekanizması, genelleştirilmiş özellik piramidi ağı (Generalized FPN, GFPN) ve ek bir dördüncü tespit katmanı entegre ederek MRI görüntülerinde tümörlerin daha duyarlı tespit edilmesini amaçlanmıştır [10]. Kassam ve ark. intraoperatif MRI koşullarında glioma tümörlerini tespit ve segment etmek amacıyla YOLOv8 ve Segment Anything Model (SAM)

yaklaşımlarını birleştiren bir derin öğrenme yöntemi önermişlerdir. Elde edilen deneysel sonuçlara göre YOLO+SAM modeli, gürültülü test verisinde etkin tümör bölgesini segmentlemede 0.79 Dice skoruna ulaşmıştır [11]. Magadza ve Viriri, derin öğrenme tabanlı beyin tümörü segmentasyonu yöntemlerini kapsamlı biçimde inceleyen bir literatür çalışması sunmuşlardır. Bu derlemede, MRI üzerinde otomatik tümör bölütleme için kullanılan güncel tam konvolüsyonel ağ mimarileri ayrıntılarıyla ele alınmıştır [12]. Aslan, beyin tümörlerini MRI görüntülerinden otomatik olarak tespit etmek için derin öğrenme ve geleneksel yöntemlerin hibrit bir yaklaşımını önermişlerdir. Bu çalışmada MobileNetV2 tabanlı bir konvolüsyonel sınır ağı, görüntülerden derin özellikler çıkarmak üzere kullanılmış; ağın önceden eğitilmiş modelinin tam bağlantı katmanından elde edilen özellikler, sonrasında bir k-en yakın komşu algoritması ile sınıflandırılmıştır [13]. Jia ve ark. beyin tümörü segmentasyonu alanına yönelik geliştirdikleri UPMAD-Net adlı derin öğrenme modelinde, belirsizlik tahmini ve çok modlu özellik birleştirme yöntemlerini entegre ederek önemli bir ilerleme sağlamışlardır. Çalışmalarında, BraTS2021 veri seti üzerinde gerçekleştirdikleri deneylerde Whole Tumor, Tumor Core ve Enhancing Tumor bölümlerine ait Dice skorlarında sırasıyla %93.67, %91.23 ve %89.18 gibi yüksek performanslar elde etmişlerdir. Model, özellikle Monte Carlo dropout tabanlı belirsizlik mekanizması sayesinde segmentasyon doğruluğuna ek olarak güvenilirlik açısından da katkı sunmuştur. Ayrıca multimodal MRI verilerinin adaptif olarak birleştirilmesi, modelin gerçek dünya klinik uygulamalarına daha uygun hale getirilmesini sağlamıştır [14]. Fadugba ve ark. sınırlı kaynaklara sahip ortamlarda yüksek doğrulukta beyin tümörü segmentasyonu gerçekleştirebilecek derin ensembel yapılar üzerine odaklanmıştır. Çalışmalarında UNet3D, V-Net ve MSA-VNet gibi farklı mimarileri bir araya getirerek oluşturdukları ensembel yaklaşımıyla, Whole Tumor, Tumor Core ve Enhancing Tumor bölgelerinde sırasıyla %85.21, %83.58 ve %81.67 oranlarında Dice skorları elde etmişlerdir. Araştırma, özellikle gelişmekte olan ülkelerde sınırlı donanımla çalışan sağlık sistemlerinde kullanılabilecek pratik, güvenilir ve taşınabilir çözümlerin geliştirilebileceğini göstermesi açısından literatürde dikkat çeken bir katkı sunmaktadır [15].

Tüm bu çalışmalar, YOLO tabanlı yaklaşımların beyin tümörü tespitinde hız ve doğruluk bakımından ciddi avantajlar sağladığını, ancak segmentasyon doğruluğunu artırmak için mimari geliştirmeler ve birleşik modellerin gerekebileceğini ortaya koymaktadır.

Bu çalışma, YOLOv8 ve YOLOv11 modellerinin segmentasyon performanslarının detaylı metrikler üzerinden karşılaştırılmasıyla, literatürde mevcut olan derin öğrenme tabanlı beyin tümörü segmentasyon çalışmalarına katkı sunmaktadır. YOLOv8 ve YOLOv11 mimarileri, mAP@0.5 ve mAP@0.5:0.95 gibi detaylı metrikler üzerinden karşılaştırılmıştır.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Beyin tümörleri, bireyin yaşam kalitesini ciddi şekilde etkileyen ve erken teşhisi hayati öneme sahip olan hastalıklar arasında yer almaktadır. Bu tümörlerin tespiti ve sınırlarının doğru bir şekilde belirlenmesi, uygulanacak tedavi planının başarısı açısından kritik rol oynamaktadır. Geleneksel yöntemler ile yapılan görüntü analizi işlemleri zaman alıcı olup uzman yorumuna dayandığı için subjektif hatalar içerebilir. Bu nedenle, yapay zekâ destekli otomatik segmentasyon sistemlerinin geliştirilmesi, tıbbi görüntüleme alanında önemli bir ihtiyaç haline gelmiştir. Bu çalışma, güncel derin öğrenme mimarilerinden YOLOv8s-seg ve YOLOv11s-seg modellerini kullanarak beyin tümörlerinin segmentasyonunu gerçekleştirmekte ve modellerin başarımını karşılaştırmalı olarak ortaya koymaktadır.

Araştırmanın önemi, yalnızca yüksek doğrulukta segmentasyon sağlayan yöntemlerin denenmesiyle sınırlı kalmayıp, aynı zamanda YOLO mimarisine ait farklı versiyonların aynı veri kümesi üzerinde değerlendirilerek performans farklarının sistematik şekilde analiz edilmesinde yatmaktadır. Bu çalışma ile elde edilen bulgular; hassasiyet, doğruluk, geri çağırma ve mAP gibi metrikler açısından hangi modelin daha uygun olduğunu göstermekte ve tıbbi görüntü işleme literatürüne anlamlı bir katkı sunmaktadır. Ayrıca bu çalışma, beyin tümörü segmentasyonuna yönelik karar destek sistemlerinin geliştirilmesine katkı sağlayabilecek pratik çıktılar üretmekte ve ileriye dönük klinik uygulamalara temel oluşturabilecek niteliktedir.

Önemli Noktalar (Highlights)


- Beyin tümörlerinin segmentasyonu için YOLOv8s-seg ve YOLOv11s-seg mimarileri karşılaştırmalı olarak incelenmiştir.
- Segmentasyon başarımı; hassasiyet, doğruluk, geri çağırma ve mAP metrikleri ile değerlendirilmiştir.
- Çalışma, yapay zekâ destekli karar destek sistemlerinin geliştirilmesine katkı sağlayarak klinik uygulamalara yönelik pratik çıktılar sunmaktadır.

3. MATERYAL VE METHOD (MATERIALS AND METHODS)


Bu çalışmada, beyin tümörü segmentasyonu amacıyla derin öğrenme tabanlı bir yaklaşım benimsenmiştir. Segmentasyon işlemi için Ultralytics tarafından geliştirilen YOLOv8s-seg ve YOLOv11s-seg modelleri tercih edilmiştir. Her iki model, etiketli beyin tümörü görüntüleri üzerinde eğitilmiş ve test edilmiştir. Modellerin eğitimi ve değerlendirilmesi, Python programlama dili kullanılarak Google Colab ortamında gerçekleştirilmiştir. Eğitim sürecinde Ultralytics'in sağladığı fonksiyonlar yardımıyla segmentasyon performansını ölçmek üzere doğruluk (precision), geri çağırma (recall), mAP@0.5 ve mAP@0.5:0.95 gibi metrikler dikkate alınmıştır.

3.1. Veri Seti (Dataset)

Bu çalışmada, beyin tümörlerinin segmentasyonu amacıyla Roboflow platformunda yayımlanmış olan açık erişimli bir veri kümesi kullanılmıştır [16].




Şekil 1. Beyin manyetik rezonans görüntüsü
(Figure 1. Brain magnetic resonance image)



Şekil 2. Etiketlenen beyin manyetik rezonans görüntüsü
(Figure 2. Labeled brain magnetic resonance image)


Veri kümesi, malign (kötü huylu) beyin tümörlerini içeren görüntülerden oluşmakta olup her görüntüye karşılık gelen segmentasyon etiketleri de sağlanmaktadır. Görüntüler, YOLOv8 ve YOLOv11 mimarilerinin gerekliliklerine uygun olacak şekilde 640×640 piksel

boyutlarına yeniden ölçeklendirilmiştir. Şekil 1'de örnek bir görüntünün orijinal hali sunulmuş, Şekil 2'de ise aynı görüntü üzerinde tümörlü alanın etiketlemesi hali gösterilmiştir. Toplam 834 adet görüntü kullanılarak veri kümesi oluşturulmuştur. Bu görüntülerin %70'i (583 adet) eğitim, %15'i (123 adet) doğrulama ve %15'i (128 adet) test verisi olarak ayrılmıştır. Veri setine ilişkin dağılım Şekil 3'te sunulmuştur.



Şekil 3. Veri seti dağılımı
(Figure 3. Data set distribution)

Bu çalışmada önerilen yöntem Şekil 4'te şematik olarak sunulmuştur. Toplam 834 görüntüden oluşan veri seti üç alt kümeye ayrılmıştır. Bu alt kümeler oran olarak %70 eğitim, %15 doğrulama ve %15 test olarak ayrılmıştır. Eğitim ve doğrulama verileri, YOLOv8-seg ve YOLOv11-seg mimarileri kullanılarak modelin öğrenme süreci için kullanılmıştır. Bu süreçte, modelin parametreleri optimize edilerek en iyi sonuçları veren yapı elde edilmeye çalışılmıştır. Eğitilen model daha sonra test verileri üzerinde değerlendirilmiş ve segmentasyon performansı ölçülmüştür. Elde edilen sonuçlar, model başarımını göstermek üzere değerlendirme metrikleri ile birlikte analiz edilmiştir. Çalışma ile ilgili önerilen yöntem Şekil 4'te sunulmuştur.



Şekil 4. Önerilen yöntemin şematik gösterimi
(Figure 4. Schematic representation of the proposed method)

3.2. YOLO (You Only Look Once) Modeli (YOLO (You Only Look Once) Model)


Bu çalışmada beyin tümörü segmentasyonunda iki farklı YOLO tabanlı segmentasyon modeli karşılaştırılmıştır. YOLOv8s-seg ve YOLOv11s-seg. YOLO (You Only Look Once) mimarileri, tek geçişli (one-stage) nesne tespiti ve segmentasyon modelleridir. Bunlar yüksek hız ve doğruluk sağlarlar [17]. YOLOv8s-seg, Ultralytics tarafından geliştirilmiş hafif bir varyanttır ve bounding box tahmini, sınıf tahmini ve piksel düzeyinde

maske tahmini üçlemesini aynı anda gerçekleştirir. YOLOv11s-seg ise daha ileri bir sürüm olup, özellikle çoklu IoU eşiği altında daha yüksek mAP ve mask performansı sunmak üzere tasarlanmıştır [18]. Her iki model de 640×640 piksel giriş gösterişli olup benzer eğitim protokolleri (AdamW optimizasyonu, dropout, weight decay gibi düzenlemeler) kullanılarak eğitilmiştir. YOLOv8s-seg hafif yapısı ile hızlı çıkarım sağlarken, YOLOv11s-seg slightly daha fazla parametreye sahip olmasına rağmen özellikle yüksek IoU eşiği altındaki mask hassasiyetinde üstün performans sergilemiştir.

3.2.1. YOLOv8 Modeli (YOLOv8 Model)

YOLOv8, Ultralytics tarafından geliştirilen ve 2023 yılında duyurulan en güncel YOLO sürümlerinden biridir. YOLOv5 ile YOLOv7 arasında yer alan birçok yapısal özelliği birleştiren bu model, modüler yapısı ve sadeleştirilmiş mimarisi ile öne çıkmaktadır. YOLOv8'in temel mimarisi üç ana bileşenden oluşur [19]. Bunlar, Backbone, Neck ve Head.

- **Backbone:** Görselden temel özellikleri çıkaran bu yapı, genellikle CSP (Cross Stage Partial) bloklarıyla desteklenmiş C2f modülüne dayanır. Bu modül, derinlik bilgisi ile hesaplama verimliliği arasında denge kurar.
- **Neck:** FPN (Feature Pyramid Network) ve PAN (Path Aggregation Network) yapılarını harmanlayan bir ara katman olup, çok ölçekli özellikleri birleştirerek hem küçük hem de büyük nesneler üzerinde performansı artırır.
- **Head:** YOLOv8'in segmentasyon ve tespit katmanlarında, sınıflandırma, konumlandırma ve segmentasyon görevleri için bağımsız çıkışlar bulunur. Bu sayede çok görevli öğrenme desteklenmektedir [18]. YOLOv8 modeli Şekil 5'te sunulmuştur.




Şekil 5. YOLOv8 model mimarisi [20]
(Figure 5. YOLOv8 model architecture)

3.2.2. YOLOv11 Modeli (YOLOv11 Model)

YOLOv11, YOLO mimarisinin deneysel olarak geliştirilmiş en yeni versiyonlarından biridir ve 2024 yılı itibarıyla özellikle segmentasyon görevlerine odaklı olarak tanıtılmıştır. Model, YOLOv8'den farklı olarak daha derin ve geniş bir yapıya sahiptir ve dikkat (attention) mekanizmalarının daha verimli kullanımı ile öne çıkar [19].

- **Backbone:** Daha gelişmiş bir özellik çıkarımı sağlamak amacıyla CSPNeXt ya da benzeri dikkat güçlendirmeli modüllerle güçlendirilmiştir. Özellikle EVCBLOCK gibi verimli evrişim bloklarının kullanıldığı bildirilmektedir.
- **Neck:** FPN yerine daha gelişmiş ağlar (örneğin BiFPN ya da GFPN) kullanılarak çok ölçekli bağlam ilişkileri kuvvetlendirilmiştir.
- **Head:** YOLOv11'de kullanılan tespit başlığı, daha iyi konumlandırma ve sınıf ayrımı sağlamak üzere Dynamic Head, Task-aligned Head gibi modern tasarım unsurlarını barındırır. Segmentasyon görevlerinde, segment maskesi üretimi için özel bir mask refine module (maske iyileştirme modülü) de eklenmiştir. Yolov11 mimarisi Şekil 6'da sunulmuştur.



Şekil 6. YOLOv11 model mimarisi [21]
 (Figure 6. YOLOv11 model architecture)

3.3. Kullanılan Değerlendirme Metrikleri (Evaluation Metrics Used)

Modeller, segmentasyon doğruluk ve kararlılığını objektif olarak değerlendirmek için aşağıdaki metriklerle analiz edilmiştir.

Karmaşıklık matrisi, modellerin performanslarının ölçülmesi için gerekli olan temel durum gerçek veri ve modellerin tahmin ettiği verilerin karşılaştırılmasıdır. Bunu için karmaşıklık matrisi oluşturulmaktadır. İkili sınıflandırma için 2x2 boyutunda matrisi oluşturulur. İkili sınıflandırma için oluşturulacak matrisi Şekil 7'de olduğu gibidir.

		Tahmin verisi	
		1	0
Gerçek Veri	1	TP	FN
	0	FP	TN

Şekil 7. Karmaşıklık matrisi [22]
(Figure 7. Confusion matrix)

- **Gerçek Pozitif (TP):** Modelin 1 sınıfına ait verileri doğru şekilde 1 olarak tahmin etmesi durumudur.
 - **Gerçek Negatif (TN):** Modelin 0 sınıfına ait verileri doğru şekilde 0 olarak tahmin etmesi durumudur.
 - **Yanlış Pozitif (FP):** Gerçekte 0 sınıfına ait olanların modelin 1 olarak tahmin ettikleri örneklerdir.
 - **Yanlış Negatif (FN):** Gerçekte 1 sınıfında olanların modelin 0 olarak tahmin ettikleri örneklerdir
- Bu dört temel değer üzerinden çeşitli performans metrikleri tanımlanmaktadır. İlgili metrikler doğruluk Denklem 1’de, Precision (Kesinlik) [22] Denklem 2’de, Recall (Duyarlılık) Denklem 3’de, Intersection over Union (IoU) [23] Denklem 4’de ve F1 Skoru [24] Denklem 5’de sunulmuştur.

- **Doğruluk:** Tüm veriler içerisinde doğru sınıflandırılanların oranını ifade eder.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- **Precision (Kesinlik):** Gerçek pozitif tahminlerin tüm pozitif tahminlere oranıdır. Bu metrik, modelin “tümör” olarak işaretlediği bölgelerin doğruluk oranını gösterir.

$$P = \frac{TP}{TP+FP} \quad (2)$$

- **Recall (Duyarlılık):** Gerçek tümör bölgeleri arasında modelin doğru tespit ettiği oranı ifade eder. Bu sayede modelin kaçırdığı hedef sayısı ölçülür.

$$R = \frac{TP}{TP+FN} \quad (3)$$

- **Intersection over Union (IoU):** Tahmin edilen maske ile gerçek maskenin örtüşme oranını düşeyde simgeler. $IoU > 0.5$ sınırı genellikle bölge doğruluğunun ölçümünde kritik eşiktir. $mAP@0.5$ ve $mAP@0.5:0.95$: $mAP@0.5$, 0.50 IoU eşiğinde hesaplanan ortalama AP’yi, $mAP@0.5:0.95$ ise 0.50-0.95 arası her 0.05’lik eşikte alınan AP’lerin ortalamasını verir. Bu metrikler, modelin farklı IoU eşikleri altındaki genel performansını ölçer [22].

$$IoU = \frac{TP}{TP+FP+FN} \quad (4)$$

- **F1 Skoru:** Precision ve Recall’un harmonik ortalaması olarak tanımlanır, dengesizlikleri telafi eder. Özellikle dengesiz sınıf dağılımlarında modelin güvenilirliğini ortaya koyar.

$$F1 = 2 \cdot \frac{P \cdot R}{P+R} \quad (5)$$

4. BULGULAR (FINDINGS)

Bu çalışmada beyin tümörü tespit edilmesi için derin öğrenme algoritması YOLO(YOLOv8s-seg, YOLOv11s-seg) modelleri kullanılarak MR görüntülerinde Segmentasyonları karşılaştırılmıştır. Modellerin Tesla T4 GPU (15 GB VRAM) kullanılarak. Giriş görüntü boyutu 640x640, batch size 16, optimizasyon algoritması AdamW, başlangıç öğrenme oranı (lr0)

0.001,aşırı öğrenmeyi önlemek amacıyla dropout oranı 0.2, weight decay 0.0001 ağırlıkların büyümesini engelleyen bir ceza terimi olarak kullanılmış ve modelin genellenebilirliğini artırmayı hedeflemiştir.


4.1. YOLOv8 ile Segmentasyon Sonuçları (Segmentation Results with YOLOv8)

Eğitim boyunca çeşitli epoch'larda elde edilen segmentasyon performans metrikleri dikkatle izlenmiştir. Özellikle 50. epoch sonrasında modelin doğruluk ve mAP değerlerinde anlamlı bir iyileşme gözlemlenmiş ve 90. epoch'tan sonra modelin performansı stabil hale gelmiştir. En iyi sonuçlar, 100. epoch sonunda best.pt ile kaydedilen model ağırlıklarıyla elde edilmiştir. YOLOv8s-seg Modelin eğitilmesinde edilen metrikler Tablo 1'de sunulmuştur. Doğrulama seti üzerindeki en iyi modelin değerlendirme sonuçları aşağıdaki gibidir.

Tablo 1. YOLOv8 maske ve kutu için elde edilen değerler
(Table 1. Values obtained for YOLOv8 mask and box)

Kapsam	Precision (P)	Recall (R)	mAP@0.5	mAP@0.5:0.95
Box	0.992	0.983	0.994	0.803
Mask	0.992	0.983	0.994	0.803


Bu sonuçlar, YOLOv8s-seg modelinin hem kutu tabanlı hem de maske tabanlı tümör segmentasyonunda oldukça yüksek doğruluk ve genelleme başarısı sergilediğini göstermektedir.




Şekil 8. YOLOv8 maske tespiti için elde edilen metrikler arası ilişkiler
(Figure 8. Relationships between metrics obtained for YOLOv8 mask detection)

Segmentasyon modelinin en iyi sonuç verdiği epoch sonunda doğruluk metrikleri temel alınarak yapılan hesaplamalarda, ortalama IoU skoru yaklaşık 0.976, F1 (Dice) skoru ise 0.988 olarak elde edilmiştir. Bu

değerler, modelin tümör bölgelerini yüksek hassasiyet ve kapsamlı başarıyla segmentlediğini göstermektedir. Sonuçlardan elde edilen YOLOv8 maske tespiti için metrikler arası ilişkiler Şekil 8’de, kayıp değerler Şekil 9’da ve karmaşıklık matrisi Şekil 10’da sunulmuştur.



Şekil 9. YOLOv8 kayıp değerleri
(Figure 9. YOLOv8 loss values)



Şekil 10. YOLOv8 karmaşıklık matrisi
(Figure 10. YOLOv8 complexity matrix)


4.2. YOLOv11 ile Segmentasyon Sonuçları (Segmentation Results with YOLOv11)

Bu çalışmada, beyin tümörü segmentasyonu amacıyla YOLOv11s-seg modeli 100 epoch boyunca eğitilmiş ve değerlendirme sürecinde modelin segmentasyon başarımı yüksek doğruluk oranlarıyla tespit edilmiştir. Aşağıdaki tabloda modelin kutu (box) ve maske (mask) bazlı değerlendirme metrikleri özetlenmiştir. YOLOv11s-seg Modelin eğitilmesinde elde edilen metrikler Tablo 2’de sunulmuştur.


Tablo 2. YOLOv11 maske ve kutu için elde edilen değerler
(Table 2. Values obtained for YOLOv11 mask and box)

Kapsam	Precision (P)	Recall (R)	mAP@0.5	mAP@0.5:0.95
Box	0.976	0.992	0.993	0.805
Mask	0.976	0.992	0.993	0.809


Maskeye dayalı metrikler kullanılarak yapılan hesaplamalar sonucunda, modelin F1 skoru %98.4, IoU (Intersection over Union) skoru ise %96.9 olarak elde edilmiştir. Bu sonuçlar, modelin hem doğru hem de kapsamlı segmentasyon maskeleri üretebildiğini göstermektedir. Ayrıca modelin mAP@0.5:0.95 değeri %80.9 ile segmentasyon görevinde farklı IoU eşiklerinde de yüksek performans sergilediğini ortaya koymuştur. Bu durum, YOLOv11s-seg modelinin beyin tümörü gibi medikal görüntülerde karmaşık nesne segmentasyonu için etkili bir yöntem olduğunu göstermektedir. Sonuçlardan elde edilen YOLOv11 maske tespiti için metrikler arası ilişkiler Şekil 11'de, kayıp değerler Şekil 12'de ve karmaşıklık matrisi Şekil 13'de sunulmuştur.



Şekil 11. YOLOv11 maske tespiti için elde edilen metrikler arası ilişkiler
(Figure 11. Relationships between metrics obtained for YOLOv11 mask detection)



Şekil 12. YOLOv11 kayıp değerleri
(Figure 12. YOLOv11 missing values)



Şekil 13. YOLOv11 karmaşıklık matrisi
(Figure 13. YOLOv11 complexity matrix)

4.3. Eğitilen Modellerin Karşılaştırılması (Comparison of Trained Models)

YOLOv8s-seg ve YOLOv11s-seg modellerin eğitim sürecinde elde edilen metrikler karşılaştırılmalı olarak Tablo 3’de sunulmuştur. Modelin süre ve boyutları Tablo 4’de sunulmuştur. YOLOv8s-seg ve YOLOv11s-seg modelleri kullanılarak aynı görüntü ile karşılaştırılması yapıldı. Yapılan karşılaştırılmanın görsel sonuçları Şekil 14’de sunulmuştur.


Tablo 3. Maske ve kutu tespiti için değerlerin karşılaştırılması
(Table 3. Comparison of values for mask and box detection)

Model	Kapsam	Precision (P)	Recall (R)	mAP@0.5	mAP@0.5:0.95
YOLOv8s	Box	0.992	0.983	0.994	0.803
	Mask	0.992	0.983	0.994	0.803
YOLOv11s	Box	0.976	0.992	0.993	0.805
	Mask	0.976	0.992	0.993	0.809

Tablo 4. Modellerin süre ve boyut karşılaştırılması
Table 4. Comparison of models in terms of duration and size

Model	Süre	Boyut
YOLOv8s	0.525	23.9MB
YOLOv11s	0.537	20.5MB

Eğitilen modeller toplam 128 tane test görüntüsü üzerinde karşılaştırılması yapıldı. Test görüntülerinin Modellerin metrikleri ve süre bakımında karşılaştırılması yapıldı. Tablo 5’te metrik değerlendirilmesi ve açıklamaları sunulmuştur.



Şekil 14. Modellerin test görüntüleri üzerinde karşılaştırılması
(Figure 14. Comparison of models on test images)

Tablo 5. Modellerin test görüntüsü ile karşılaştırılması
(Table 5. Comparison of models with test images)

Ölçüt	YOLOv8s-seg	YOLOv11s-seg	Açıklama
Box Precision (P)	0.992	0.959	YOLOv8s, kutu tabanlı tespitlerde daha yüksek kesinlik göstermektedir
Box Recall (R)	0.956	0.963	YOLOv11s, daha fazla doğru tespiti başarıyla kapsayabilmiştir
Box mAP@0.5	0.980	0.986	Her iki model de yüksek doğruluk göstermiştir; YOLOv11s hafif üstün
Box mAP@0.5:0.95	0.834	0.825	YOLOv8s daha genel ortalama kutu segmentasyonunda bir miktar öndedir
Mask Precision (P)	0.992	0.962	YOLOv8s, maske çıkarmada daha net tahminler yapmaktadır
Mask Recall (R)	0.956	0.970	YOLOv11s, tüm doğru maskeleri daha iyi yakalamıştır
Mask mAP@0.5	0.980	0.986	YOLOv11s-seg bu ölçütte daha iyi sonuç vermiştir
Mask mAP@0.5:0.95	0.813	0.812	Fark minimaldir, iki model de benzer performanstadır
Inference Süresi	1218.4ms	1249.9ms	YOLOv8s biraz daha hızlıdır (CPU ortamında)

5. SONUÇ VE ÖNERİLER (CONCLUSION AND RECOMMENDATIONS)

Bu bölümde, çalışmada kullanılan derin öğrenme tabanlı segmentasyon modellerinin (YOLOv8s-seg ve YOLOv11s-seg) elde ettiği çıktılar ayrıntılı olarak incelenmiş ve modellerin birbirlerine göre üstün ve zayıf yönleri değerlendirilmeye çalışılmıştır. Yapılan analizlerde, her bir modelin segmentasyon performansı başta olmak üzere, doğruluk, hassasiyet, geri çağırma ve mAP gibi metrikler üzerinden karşılaştırmalı bir değerlendirme yapılmış, bu bulgular ışığında modellerin beyin tümörü segmentasyonu görevindeki genel başarıları yorumlanmıştır. Gerçekleştirilen test aşamasında YOLOv8s-seg ve YOLOv11s-seg modellerinin beyin tümörü segmentasyonu üzerindeki performansları karşılaştırılmıştır. 128 adet test görüntüsü üzerinden yürütülen değerlendirmede, her iki modelin de oldukça yüksek doğruluk seviyelerine ulaştığı gözlemlenmiştir. YOLOv8s-seg, kutu tabanlı segmentasyonda (Box) %98.0 mAP@0.5 ve %83.4 mAP@0.5:0.95 elde etmiş, benzer şekilde maske tabanlı segmentasyonda (Mask) da %98.0 mAP@0.5 ve %81.3 mAP@0.5:0.95 başarı sağlamıştır. YOLOv11s-seg ise kutu segmentasyonunda %98.6 mAP@0.5 ve %82.5 mAP@0.5:0.95 elde ederek bu metrikte üstünlük göstermiştir. Maske segmentasyonunda ise %98.6 mAP@0.5 ve %81.2 mAP@0.5:0.95 başarıları ile benzer performans sergilemiştir.

İki modelin işlem süreleri karşılaştırıldığında, CPU ortamında YOLOv8s-seg modelinin ortalama 1.22 saniye/görüntü ile YOLOv11s-seg modeline göre biraz daha hızlı olduğu tespit edilmiştir. Ancak her iki model de doğruluk açısından oldukça başarılı sonuçlar vermektedir.

Sonuç olarak, YOLOv11s-seg modeli, kutu ve maske segmentasyonunda genel olarak daha yüksek mAP@0.5 değerleri ile öne çıkarken; YOLOv8s-seg modeli, daha hızlı tahmin süresi ve daha yüksek mAP@0.5:0.95 değeri ile dengeli bir performans sergilemiştir.

NOT (NOTICE)

Bu çalışma, Gökhan Gündoğdu tarafından Prof. Dr. Erhan Akın akademik danışmanlığında yürütülen "Derin Öğrenme Algoritmaları ile İnce İğne Aspirasyon Sitolojisi Örneklerinden Tiroid Papiller Karsinomun Bölütlenmesi" başlıklı Yüksek Lisans Tezinden türetilmiştir.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Yazarlar çıkar çatışması bildirmemişlerdir.

FİNANSAL AÇIKLAMA (FINANCIAL DISCLOSURE)

Yazarlar bu çalışma için herhangi bir mali destek almadığını beyan etmiştir.

ETİK STANDARTLAR BEYANI (DECLARATION OF ETHICAL STANDARDS)

Makalenin yazarları bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel izin gerektirmediğini beyan eder.

KAYNAKLAR (REFERENCES)

- [1] Taşdemir, B. ve Barışçı, N., (2024). Derin öğrenme ile beyin tümör segmentasyonu. *Bilişim Teknolojileri Dergisi*, 17(3):159-174. <https://doi.org/10.17671/gazibtd.1396872>.
- [2] Özcan, B. ve Bakır, H., (2023). Yapay zeka destekli beyin görüntüleri üzerinde tümör tespiti. *International Conference on Pioneer and Innovative Studies*, 1:297-306. <https://doi.org/10.59287/ICPIS.847>
- [3] 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. <https://doi.org/10.3390/CANCERS15164172>
- [4] Khan, M.J., Ahmed, M.R., Taha, M.A.A., and Sultana, R., (2025). Segmenting brain tumor detection instances in medical imaging with YOLOv8, ss:35-38. <https://doi.org/10.15439/2024R89>
- [5] Mercaldo, F., Brunese, L., Martinelli, F., Santone, A., and Cesarelli, M., (2023). Object detection for brain cancer detection and localization. *Applied Sciences*, 13(16):9158. <https://doi.org/10.3390/AP13169158>.
- [6] Bulut, F., Kılıç, İ. ve İnce, İ.F., (2018). Beyin tümörü tespitinde görüntü bölütleme yöntemlerine ait başarımların karşılaştırılması ve analizi. *DEÜ Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 20(58):173-186. <https://doi.org/10.21205/DEUFMD.2018205815>
- [7] Doğanay, T. ve Yıldız, O., (2022). Beyin tümör tespiti için derin öğrenme temelli bilgisayar destekli tanı sistemi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 10(4):1748-1762. <https://search.trdizin.gov.tr/en/yayin/detay/1256825>
- [8] Yılmaz, S., (2023). Beyin tümörü tanılarını için YOLOv7 algoritması tabanlı karar destek sistemi tasarımı. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 6(1):47-56. <https://doi.org/10.53410/koufbd.1236305>
- [9] Ranjbarzadeh, R., Crane, M., and Bendeche, M., (2025). The impact of backbone selection in YOLOv8 models on brain tumor localization. *Iran Journal of Computer Science*. <https://doi.org/10.1007/s42044-025-00258-4>.
- [10] Kang, M., Ting, C.M., Fung, F., Ting, R., and Phan, C.W., (2024). BGF-YOLO: Enhanced YOLOv8 with multiscale attentional feature fusion for brain tumor detection. <https://doi.org/10.1007/978-3-031-72111-3>
- [11] Kassam, S., Markham, A., Vo, K., Revanakara, Y., Lam, M., and Zhu, K., (2024). Intraoperative glioma segmentation with YOLO + SAM for improved accuracy in tumor resection.
- [12] Magadza, T. and Viriri, S., (2021). Deep learning for brain tumor segmentation: A survey of state-of-the-art. *Journal of Imaging*, 7(2):19. <https://doi.org/10.3390/jimaging7020019>.
- [13] Aslan, M., (2022). Derin öğrenme tabanlı otomatik beyin tümör tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1):399-407. <https://doi.org/10.35234/fumbd.1039825>.
- [14] Jia, Z., Yao, N., Sun, D., Han, C., Li, Y., Nan, J., Zhu, F.,

- Zhao, C., and Zhou, W., (2025). UPMAD-Net: A brain tumor segmentation network with uncertainty guidance and adaptive multimodal feature fusion. <https://arxiv.org/pdf/2505.03494> (Erişim: 16 Haziran 2025).
- [15] Fadugba, J., Lieberman, I., Ajayi, O., Osman, M., Akinola, S., Mustvangwa, T., Zhang, D., Anazondo, U., and Confidence, R., (2025). Deep ensemble approach for enhancing brain tumor segmentation in resource-limited settings. <https://arxiv.org/pdf/2502.02179> (Erişim: 16 Haziran 2025).
- [16] Roboflow, (2025). BRAIN-TUMOR - v1 2023-08-22. <https://universe.roboflow.com/iotseecs/brain-tumor-yzzav/dataset/1> (Erişim: 16 Haziran 2025).
- [17] Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., (2015). You only look once: Unified, real-time object detection. IEEE CVPR, 2016(Decem):779-788. <https://doi.org/10.1109/CVPR.2016.91>
- [18] Ultralytics, (2025). Örnek Segmentasyonu - Ultralytics YOLO Dokümanları. <https://docs.ultralytics.com/tr/tasks/segment/> (Erişim: 16 Haziran 2025).
- [19] Ultralytics, (2025). GitHub - ultralytics/ultralytics: Ultralytics YOLO11. <https://github.com/ultralytics/ultralytics> (Erişim: 16 Haziran 2025).
- [20] Yao, G., Zhu, S., Zhang, L., and Qi, M., (2024). HP-YOLOv8: High-precision small object detection algorithm for remote sensing images. Sensors, 24(15):4858. <https://doi.org/10.3390/S24154858>.
- [21] Huang, J., Wang, K., Hou, Y., and Wang, J., (2024). LW-YOLO11: A lightweight arbitrary-oriented ship detection method based on improved YOLO11. Sensors, 25(1):65. <https://doi.org/10.3390/S25010065>.
- [22] V7 Labs, (2025). Mean average precision (mAP) explained: Everything you need to know. <https://www.v7labs.com/blog/mean-average-precision> (Erişim: 16 Haziran 2025).
- [23] Encord, (2025). YOLO object detection explained: A beginner's guide. <https://encord.com/blog/yolo-object-detection-guide/> (Erişim: 16 Haziran 2025).
- [24] Ultralytics, (2025). Performans ölçümleri derin dalış - Ultralytics YOLO dokümanları. <https://docs.ultralytics.com/tr/guides/yolo-performance-metrics/> (Erişim: 16 Haziran 2025).