

YOLOv5 ile Beyin Tümörü Tespiti: Derin Öğrenmeye Dayalı Nesne Tanıma Yaklaşımı

Özet

Bu çalışma, beyin tümörlerinin tespiti ve sınıflandırılması için YOLOv5 nesne tanıma algoritmasının uygulanmasını kapsamaktadır. MRI görüntülerinden oluşan veri seti üzerinde ikili (positive/negative) ve dört sınıflı (healthy, unhealthy, benign, malignant) model varyasyonları ile deneyler yapılmıştır. Her iki modelin performansı, doğruluk, geri çağırım, F1 skoru ve mAP gibi metriklerle değerlendirilmiş ve görsel çıktılarla desteklenmiştir. Elde edilen sonuçlar, YOLOv5 algoritmasının tıbbi görüntü analizi alanında etkili bir araç olduğunu ortaya koymaktadır.

Abstract

This study focuses on the application of the YOLOv5 object detection algorithm for the detection and classification of brain tumors. Experiments were conducted using a dataset of MRI images with both binary (positive/negative) and four-class (healthy, unhealthy, benign, malignant) labeling schemes. The performance of both models was evaluated using metrics such as precision, recall, F1-score, and mAP, and supported with visual outputs. The results demonstrate the effectiveness of the YOLOv5 algorithm as a practical tool in the field of medical image analysis.

1. Giriş

Beyin tümörleri, merkezi sinir sistemi üzerindeki etkileri nedeniyle erken tespit edilmesi gereken ciddi rahatsızlıklar arasında yer almaktadır. Geleneksel tıbbi yöntemlerle (MRG, BT, biyopsi vb.) yapılan tespitler zaman alabilirken, yapay zeka ve özellikle derin öğrenme teknikleri sayesinde bu süreçler daha hızlı ve hassas hale getirilebilmektedir.

YOLO (You Only Look Once) algoritması, görüntüler üzerinde gerçek zamanlı nesne tespiti yapabilen, çok katmanlı bir derin öğrenme modelidir. Bu projede YOLOv5 algoritması, beyin MR görüntülerinden tümör tespiti yapmak için kullanılmış, ikili ve çoklu sınıflandırma modelleri geliştirilmiştir.

Amaç, sadece tümörün varlığını tespit etmek değil; aynı zamanda tümörün niteliğini (iyi/kötü huylu) de belirleyebilen, kullanışa hazır bir derin öğrenme sistemi tasarlamaktır.

2. Veri Seti ve Etiketleme Süreci

Bu projede kullanılan veri seti, açık kaynaklı MRI görüntülerinden oluşmaktadır. Görseller, beyin dokusunu çeşitli açılardan temsil eden axial kesitlerdir. Görüntüler JPEG formatında olup, her biri ile birlikte aynı isimde bir .txt dosyası yer almakta, bu dosya tümörün bulunduğu koordinatları ve sınıf bilgisini içermektedir.

İlk aşamada veri seti, ikili sınıflandırma amacıyla “positive” (tümörlü) ve “negative” (tümörsüz) olarak etiketlenmiştir. Daha sonra bu yapı genişletilmiş ve dört sınıfa ayrılmıştır:

- 0: healthy
- 1: unhealthy
- 2: benign
- 3: malignant

Etiket dosyalarında, her satırda bir nesne yer almakta ve şu formatta tanımlanmaktadır:

```
<class_id> <x_center> <y_center> <width> <height>
```

Veri seti, eğitim (%80), doğrulama (%10) ve test (%10) olmak üzere üçe ayrılmıştır. Ayrıca validation seti için eğitim klasöründen örnek görseller elle çekilerek manuel olarak oluşturulmuştur. Eğitim ve test veri setleri, YOLOv5’in beklediği dizin yapısına uygun hale getirilmiştir.

3. YOLOv5 Algoritması

YOLOv5, Ultralytics tarafından geliştirilen ve PyTorch tabanlı çalışan bir nesne tespiti modelidir. YOLO ailesinin önceki sürümlerine göre daha hızlı çalışmakta ve daha düşük hesaplama gücüyle yüksek doğruluk sağlamaktadır. Bu proje kapsamında, yolov5s.pt ve yolov5m.pt gibi önceden eğitilmiş ağırlıklar kullanılarak model, transfer öğrenme yöntemiyle yeniden eğitilmiştir.

YOLOv5 mimarisi aşağıdaki bileşenlerden oluşur:

- **Backbone:** Görselden öznitelik çıkarımı yapar.
- **Neck:** Öznitelikleri birleştirerek farklı ölçeklerde bilgi sağlar (FPN + PAN).
- **Head:** Nesne tespiti ve sınıflandırma işlemini yapar.

Model, aynı anda hem sınıfı hem de bounding box koordinatlarını tahmin edebildiği için nesne tespitinde oldukça etkilidir.

4. Model Eğitimi ve Ayarları


Modelin eğitimi Google Colab ortamında, GPU desteğiyle gerçekleştirilmiştir. Eğitim sürecinde kullanılan temel parametreler aşağıdaki gibidir:

- Görsel boyutu: 640x640 piksel
- Batch size: 16
- Epoch sayısı: 50
- Optimizasyon: SGD / Adam
- Ağırlık dosyası: yolov5s.pt
- Konfigürasyon dosyası: data.yaml

Eğitim iki aşamada yürütülmüştür:

1. **İkili Sınıflandırma (2 class)**
 - Sınıflar: positive, negative
 - Başarı oranı yüksek, özellikle mAP ve F1 skoru açısından tutarlı sonuçlar üretmiştir.
2. **Dört Sınıflı Sınıflandırma (4 class)**
 - Sınıflar: healthy, unhealthy, benign, malignant
 - Daha zorlu ancak daha ayrıntılı bir sınıflandırma sunmaktadır.
 - Veri çoğaltma (label replication) tekniğiyle bazı sınıflar desteklenmiştir.

Her eğitim seansında, YOLOv5 tarafından runs/train/ dizininde sonuç dosyaları ve grafiksel çıktılar (loss eğrisi, confusion matrix, PR curve vb.) otomatik olarak oluşturulmuştur.



Şekil 4.1: Eğitim Süreci Gözlem Grafikleri: Box loss, object loss ve class loss gibi eğitim süreci boyunca izlenen kayıplar zamanla azalmış; metriklerde gözlenen artışlar ise modelin başarıyla eğitildiğini ortaya koymuştur.

Tablo 4.1 – Modelin görüntü başına ortalama işlem süreleri. YOLOv5’in hızlı mimarisi sayesinde inference işlemi ~8.8 ms gibi kısa sürede tamamlanmıştır. Bu değer, tıbbi uygulamalarda gerçek zamanlı analiz yapılabilirliğini desteklemektedir.


Aşama	Ortalama Süre (ms)	Açıklama
Pre-process	0.5	Görüntü ön işleme süresi (boyutlandırma vb.)
Inference	8.8	Modelin tahmin yapma süresi
NMS (Non-Max Suppression)	4.3	Çakışan tahminlerin ayıklanma süresi


5. Performans Değerlendirme ve Sonuçlar

Modelin performansı, eğitim sürecinden sonra oluşan metrik görselleri ve test sonuçları üzerinden değerlendirilmiştir. İki ayrı model çıktısı analiz edilmiştir:

5.1 İkili Sınıf Modeli


- **Precision, Recall ve F1 Skoru** değerleri yüksek düzeyde elde edilmiştir.
- confusion_matrix.png görselinde modelin pozitif ve negatif örnekleri büyük ölçüde doğru sınıflandırdığı görülmektedir.
- PR_curve.png ve F1_curve.png grafiklerinde istikrarlı eğriler mevcuttur.
- Tahmin görsellerinde, tümörlü alanlar doğru şekilde kutu içerisine alınmış ve güven skorları yüksektir.






Şekil 5.1.1 İkili sınıflı YOLOv5 modeli tarafından yapılan test tahminlerinden örnek görüntüler. Görsellerde tespit edilen tümör alanları sınıf etiketi (positive/negative) ve tahmin güven skoru ile birlikte kutu içerisine alınmıştır. Model, çoğu negatif görüntüyü yüksek doğrulukla tanımlamış; pozitif tahminlerde ise farklı skor seviyelerinde başarı göstermiştir.


Negatif sınıf tahminlerinde 0.89'a varan yüksek güven skorları elde edilmiştir. Pozitif sınıf için 0.51–0.77 aralığında değişen başarılı tahminler gözlemlenmiştir.



Şekil 5.1.2 – Precision-Recall Eğrisi: Modelin test verisi üzerindeki yüksek doğruluk ve geri çağırma skorları, eğrinin sol üst köşeye yakın konumlanmasına neden olmuştur. Bu durum, modelin genel performansının oldukça istikrarlı olduğunu göstermektedir.



Şekil 5.1.3: Confusion Matrix: Tüm negatif örneklerin doğru şekilde sınıflandırıldığı görülmektedir. Pozitif örneklere dair sınıflandırma olmadığı için hücre boş kalmıştır. Bu durum modelin sınıf bazlı doğruluğunu gözler önüne sermektedir.



Şekil 5.1.4 – F1-Confidence Eğrisi: Güven skoru arttıkça modelin F1 başarımında yükselme gözlemlenmiştir. En yüksek F1 skoru, 0.84 güven skorunda elde edilmiştir.

Tablo 5.1.1: İkili sınıflı modelin sınıf bazlı performans metrikleri. Görüldüğü üzere, hem negatif sınıfta hem de genel doğrulukta oldukça yüksek başarı sağlanmıştır. mAP@0.5 değeri %99.5’e ulaşmış, model tüm negatif örnekleri doğru şekilde tanımlamıştır.

Sınıf	Görüntü Sayısı	Instance Sayısı	Precision (P)	Recall (R)	mAP@0.5	mAP@0.5:0.95
Tümü (all)	15	15	0.996	1.000	0.995	0.904
Negative	15	15	0.996	1.000	0.995	0.904

5.2 Dört Sınıflı Model


- Modelin daha ayrıntılı karar vermesi gerektiğinden ötürü genel başarı oranı ikili modele göre biraz daha düşüktür.
- Özellikle “benign” ve “unhealthy” sınıflarında karışıklıklar gözlemlenmiştir.
- confusion_matrix.png ve P_curve.png, R_curve.png analizlerine göre healthy ve malignant sınıflarında belirgin başarı mevcuttur.
- Görsel çıktılar üzerinde modelin doğru tahmin yaptığı örnekler olduğu kadar sınıf çakışmalarının da yer aldığı dikkat çekmektedir.

Sonuç olarak, ikili sınıflandırma modeli daha kararlı bir yapı sunarken, dört sınıflı model daha fazla bilgi üretmekte ancak sınıflar arası benzerlikten dolayı hata yapma eğilimindedir.


Tablo 5.2 Performans Metrikleri (4 Sınıflı Model)

Sınıf	Görüntü Sayısı	Instance Sayısı	Precision (P)	Recall (R)	mAP@0.5	mAP@0.5:0.95
Tümü (all)	15	15	0.988	1.000	0.995	0.893
Healthy	15	15	0.988	1.000	0.995	0.893


Precision ve recall değerleri oldukça yüksek olup, healthy sınıfı özelinde %100 doğruluk sağlanmıştır. mAP@0.5 değeri %99.5 ile güçlü bir başarı göstermektedir.




Şekil 5.2.1: Precision-Recall Eğrisi: Modelin test verisinde oldukça yüksek doğruluk ve çağırım değerleri sağladığı görülmektedir. Eğri, modelin sağlıklı verileri istikrarlı şekilde tanımladığını göstermektedir.




Şekil 4.3: Eğitim Süreci Grafikleri (4 sınıflı model): Eğitim ve doğrulama kayıplarındaki düşüş, modelin zamanla stabil hale geldiğini; precision ve recall metriklerindeki artış ise performansın öğrenme süreciyle birlikte yükseldiğini göstermektedir.




Şekil 5.2.2: Recall-Confidence Eğrisi: Güven skoru arttıkça geri çağırma başarısı azalmaktadır. Bu eğri, güven skorunun modelin hassasiyetine olan etkisini ortaya koymaktadır.




Şekil 5.2.3: Precision-Confidence Eğrisi: Daha düşük güven eşliğinde model tüm doğru sınıflandırmaları yakalamış; güven arttıkça precision yüksek kalmaya devam etmiştir.




Şekil 5.2.4: Confusion Matrix (4 sınıf): Sağlıklı (healthy) sınıfı için %100 doğruluk görülmektedir. Diğer sınıfların model tarafından yeterince temsil edilmediği ya da örnek içermediği anlaşılmaktadır.



Şekil 5.2.5: F1-Confidence Eğrisi: En yüksek F1 skoru 0.23 güven eşiğinde elde edilmiştir. Bu da modelin en dengeli sınıflandırmayı bu noktada yaptığını göstermektedir.





Şekil 5.2.6: Dört Sınıflı Modelin Tahmin Örnekleri: Aşağıdaki görseller, modelin test verisinde gerçekleştirdiği “healthy” sınıfı tahminlerini göstermektedir. Kutu içinde yer alan değer, tahmin edilen sınıf ve modelin bu tahmine olan güven skorudur.

Model, görseldeki ilgili bölgeleri tespit ederek “healthy” sınıfına ait olduğunu yüksek güvenle tahmin etmiştir. Bazı durumlarda sınıf çakışması veya düşük güven değeri de gözlemlenmektedir. Görsel doğrulamalar, modelin sağlıklı verilerde tutarlı tahminler yapabildiğini göstermektedir.

Tablo 5.3 İşlem Süreleri ve Model Çıktı Bilgisi

Bilgi	Değer
Pre-process	0.5 ms
Inference	7.7 ms
NMS (Non-Max Suppression)	2.6 ms
Label Sayısı	50
Label Dosyalarının Konumu	runs/detect/brain_tumor_predictions_4class/labels/
Tahmin Sonuçlarının Yolu	runs/detect/brain_tumor_predictions_4class/

Model, görsel başına ortalama 10.8 ms sürede tahmin yaparak gerçek zamanlı kullanıma yakın bir performans sergilemektedir.

6. Sonuç ve Öneriler

Bu proje kapsamında, YOLOv5 derin öğrenme mimarisi kullanılarak beyin tümörlerinin otomatik olarak tespit edilmesi ve sınıflandırılması hedeflenmiştir. İkili sınıflandırma modeli, özellikle hızlı ve doğru kararlar vermesi açısından yüksek performans sergilemiştir. Dört sınıflı model ise daha fazla bilgi sunmakla birlikte, sınıflar arası benzerlikler nedeniyle bazı sınıflarda başarı düşüşü göstermiştir.

Model, beyin tümörlerinin görsel özelliklerini öğrenme ve yorumlama konusunda etkili bir performans ortaya koymuştur. Bununla birlikte:

- Veri setinin genişletilmesi,
- Özellikle benign/unhealthy ayrımını güçlendirecek yeni örneklerin eklenmesi,
- Daha ileri modellerle (YOLOv8, Detectron2 vb.) karşılaştırmalı çalışmalar yapılması önerilmektedir.

Modelin tıbbi kararlarda yardımcı araç olarak kullanılması potansiyeli yüksektir. Ancak bu tür sistemlerin klinik karar süreçlerinde kullanılabilmesi için daha geniş ve dengeli veri setleri ile test edilmesi gereklidir.

Tablo 6.1. İkili ve Dört Sınıflı Modellerin Karşılaştırması

Model	Precision	Recall	mAP@0.5	mAP@0.5:0.95
İkili Sınıf	0.996	1.000	0.995	0.904
Dörtlü Sınıf	0.988	1.000	0.995	0.893

Her iki model de yüksek performans sergilemiştir. Ancak dört sınıflı model, detaylı analiz yapabilmesine karşın genel doğrulukta az da olsa bir düşüş göstermektedir. Bu durum sınıf sayısının artmasıyla birlikte modelin karar ayrımlarında daha fazla zorlandığını göstermektedir.

7. Kaynakça

1. Ultralytics. (2023). YOLOv5 GitHub Repository. <https://github.com/ultralytics/yolov5>
2. Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. arXiv:1804.02767.
3. Isensee, F. et al. (2021). nnU-Net: Self-adapting Framework for U-Net-based Medical Image Segmentation. Nature Methods.
4. Kaggle. Brain Tumor Detection Dataset. <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-brain-tumor-detection>
5. Selin Şenocak. (2024). YOLOv5 Beyin Tümörü Analiz Defteri, Colab Notebook.
6. Selen Gül (2023). Beyin Tümörlerinin Derin Öğrenme ile Sınıflandırılması, Bitirme Raporu.
7. Hamza Yılmaz (2023). MRI Görüntülerinde Tümör Tanı Sistemleri, Lisans Projesi Raporu.

Bu rapor, bilgisayarlı görü ve derin öğrenme tekniklerinin tıbbi alanda kullanımı üzerine uygulamalı bir örnek sunmakta ve YOLOv5 mimarisinin bu alandaki etkinliğini göstermektedir.