

YAPAY ZEKA DESTEKLİ BEYİN GÖRÜNTÜLERİ ÜZERİNDE TÜMÖR TESPİTİ

Büşra Özcan^{1*} ve Halit Bakır²

¹Savunma Teknolojileri A.B.D / Mühendislik ve Doğa Bilimleri Fakültesi, Sivas Bilim ve Teknoloji Üniversitesi, Türkiye

²Bilgisayar Mühendisliği / Mühendislik ve Doğa Bilimleri Fakültesi, Sivas Bilim ve Teknoloji Üniversitesi, Türkiye

*(220102003) Başlıca yazarın mail adresi

Özet – Günümüzde yapay zeka uygulamaları sağlık sektöründe büyük bir ivme kazanmıştır. Hem hız hem doğruluk açısından tercih edilmektedir. Bu çalışma kapsamında insan hayatı için kritik rol oynayan beyin tümörleri tespiti için en güncel obje tespit algoritmaları uygulanmış ve en iyi sonucu veren model tespit edilmiştir. Popüler ve güncel YOLO modellerinden olan YOLOv5, YOLOv7 ve YOLOv8 uygulanmıştır. Model eğitilmeden önce beyin tümörleri tespitinde daha iyi sonuç vermesi adına görüntüler üzerinde renk dönüşümleri, histogram eşitleme, renk kanalları ve bu kanallar üzerinde filtre işlemleri gerçekleştirilmiş ve en belirgin olan sonuç tüm görsellere uygulanmıştır. Bu işlemler sonucunda en iyi sonucu en güncel YOLO modeli olan YOLOv8 %87 mAP değeri ile vermiştir.

Anahtar Kelimeler – Makine Öğrenmesi, Beyin, Tümör, YOLOv5, YOLOv7, YOLOv8

I. GİRİŞ

Beyin tümörü beyindeki hücrelerin kontrolsüzce büyümesinden meydana gelmektedir [1]. Etkilendiği dokulara bağlı olarak 120'den fazla beyin tümörü bulunmaktadır [2]. Bu çeşitli tümörlerin hepsi kanser olarak sınıflandırılmamaktadır [2]. Ancak beyinde meydana gelen tümörler iyi huylu olsa bile yani kanserleşme dahi yeri ve büyüklüğü açısından ciddi problemlere yol açabilmektedir [2]. Dünya nüfusu yaşladıkça beyin tümörlerinin görülme oranı artmaktadır [3]. Birçok kanser türünde olduğu gibi, beyin tümörlerinin neden geliştiğine dair net bir açıklama bulunamamaktadır [3]. Beyin tümörleri ve yaş ilişkisi üzerine yapılan çalışmalara göre; dünya nüfusu yaşlandıkça beyin tümörlerinin görülme olasılığı artmaktadır [3]. Ancak beyin tümörü her yaş grubundan görülebilmektedir [3]. Dünya nüfusu yaşlanması nedeniyle, toplumda beyin tümörlerinin görülme oranının giderek sıklaşacağı tahmin ediliyor [3]. Araştırmalar her 100 bin kişiden 5'inde bir beyin tümörünün geliştiğini gösteriyor [3]. Bu oranın ilerleyen yıllarla artacağı öngörüsüyle, bilim insanlarının dikkatleri; beyin tümörlerinin tedavisine ve sonrasındaki yaşam kalitesine

odaklanıyor [3]. Bu noktada beyin tümörlerinin erken teşhisi hasta için çok önemli bir rol oynamaktadır.

Beyin tümörü tespiti beyinin karmaşık yapısından dolayı zor bir işlemdir [1]. Beyin tümörü teşhisi, tümörün çeşitli boyutlarda olması ve farklı konumlarda olmasından dolayı zorludur. Artan hastalık oranı ile birlikte teşhis için farklı yöntemler araştırılma yoluna gidilmiştir. Çünkü Radyologlar veya diğer klinik profesyoneller, manyetik rezonans (MR) görüntülerinden enfekte tümör alanını bölümlere ayırmak, saptamak ve çıkarmak için çok fazla zaman ve çaba harcamalıdır ve bunların doğruluğu yalnızca deneyimlerine bağlıdır [4]. Büyüme hızına göre, 2030 yılına kadar yapay zeka, sağlık sektörü üzerinde en önemli etkilerle birlikte, küresel ekonomiye yüzde on beşten fazla katkıda bulunacaktır [5]. Beyin tümörleri tanısında kullanılan görüntüleme yöntemleri sayesinde beyinin o anki durumu hakkında bilgi edinilebilmektedir. Bu görüntüler makine öğrenmesi aracılığı ile eğitilip yeni görüntüler üzerinde denenmektedir. En yaygın olarak kullanılan görüntüleme tekniği (Magnetic Resonance Image) MRI'dır [6]. Bu görüntüleme tekniği sayesinde tümörün bulunduğu bölge, bazen

tümörün cinsi ile bu tümörden beyin ve sinirlerin ne kadar etkilendiği konusunda ayrıntılı bilgi alınabilmektedir. Bu görüntüler üzerindeki beyin tümörleri derin öğrenme algoritmaları sayesinde tespit edilip işaretlendiği işlemler otomatikleştirildiği takdirde yapay zeka tarafından, sağlık sektörü üzerinden ciddi bir sorumluluk alınmış olur [7].

A. Literatür Taraması

Montalbo ve arkadaşları tarafından yapılmış olan çalışmada [8] üç farklı beyin tümörü tespit etmeye yönelik bir derin öğrenme modeli için transfer öğrenme modeli ve ince ayarlar önerilmektedir. Çalışmada YOLOv4 modeli, görev için önceden işlenmiş ve etiketlenmiş 30364 T1 ağırlık kontrastı artırılmış (CE)-MRI taramaları veri seti ile eğitilmiştir. 29 katmanlı YOLO v4 tiny modeli ile eğitilip çoğu platformda güvenilir çalışması için ince ayar yapılmıştır. COCO veri kümesinde önceden eğitilmiş ağırlıklarla daha hızlı çalışmak için özelleştirilmiştir. Sonuç olarak önerilen model YOLO modellerinin önceki sürümlerinden daha iyi bir performans göstermiştir ve %89.45 f1 skor değeri elde etmiştir.

Nadim Mahmud Dipu ve ekibinin yapmış olduğu çalışmalarında [9] nesne algılama algoritmalarından YOLO ve derin öğrenme fonksiyonu olan fastAI kullanılarak beyin tümörü tespiti için iki derin öğrenme tabanlı yaklaşım önerilmiştir. Çalışma 1992 adet beyin MRI görüntüsü içeren BRATS 2018 veri seti ile gerçekleştirilmiştir. YOLOv5 modeli %85.95 doğruluk oranı ve fastAI sınıflandırma modeli %95.78 doğruluk oranı elde etmiştir.

Dipu N ve ekibi tarafından yapılmış olan çalışmalarında [10] popüler olan derin öğrenme tabanlı nesne algılama algoritmalarından bazıları kullanılarak otomatik bir beyin tümörü algılama ve segmentasyon sistemi sunulmaktadır. YOLO v3 Pythorch, YOLO v4 Darknet, Scaled YOLOv4, YOLO v4 tiny, YOLO v5 Faster-RCNN, Detectron2 gibi yedi farklı sinir ağı tabanlı nesne algılama çerçevesi ve algoritması uygulanmıştır. Çalışmada kanser görüntüleme arşivinden(TCIA) dan alınan Brain-tumor-progression veriseti kullanılmıştır. Veri seti 641 MRI görüntüsü içermektedir. Yapılan araştırmalar sonucunda YOLO v5 modeli %95.07'lik doğruluk değeri ile en iyi performans gösteren model olmuştur. YOLO v3 Pythorch modeli ile %84.30 doğruluk değeri ile en kötü sonucu veren model olmuştur.

Kavitha ve arkadaşının yapmış olduğu çalışmada [11] beyin tümörlerini tespit etmek için Shuffled-YOLO ağı önerilmiştir. Model 2 farklı veri seti kullanılmıştır. BraTS 2020 ve BraTS 2019. Deneysel sonuçlar, önerilen Shuffled-YOLO ağının, son teknoloji modellere kıyasla çok minimum hesaplama karışıklığı ile BraTS 2020 için %98.07 ve BraTS 2019 için %97.04 gibi daha iyi bir doğruluk aralığına ulaştığı gözlemlenmiştir.

Kalyani ve ekibinin yaptığı çalışmada [12] beyin tümörü tespiti için YOLO v3 modeli kullanılmıştır. YOLO v3 modeli, önceden işlenmiş ve etiketlenmiş 3064 adet T1 ağırlıklı kontrastlı (CE) MRI görüntüsü kullanılarak eğitilmiştir. Transfer öğrenimi ve önceden eğitilmiş MSCOCO veri kümesinden alınan ağırlıklar kullanılarak beyin tümörü tespiti için güçlü bir özellik grubu oluşturulmuştur. Model %94.14 ortalama kesinlik, %91.34 kesinlik, %90.58 geri çağırma ve %92.33 f1-skor değeri elde etmiştir.

Kondratenko ve ekibi tarafından yapılmış olan [13] çalışmada ResNet, U-Net, SegNet ve YOLOv3 avantaj ve dezavantajları detaylı bir şekilde ele alınmıştır. Ek olarak, veri ön işleme yöntemlerinin analizi ve girdi verileri üzerinde bir çalışma gerçekleştirilmiştir. Karşılaştırma sonucunda son model olarak ek işleme yöntemlerine sahip U-Net mimarisine sahip bir model %94 doğruluk oranı ile seçilmiştir.

Öksüz ve arkadaşının yapmış olduğu çalışmada [14] REMBRANDT veri seti kullanılmıştır. Toplamda 3064 görüntü içermektedir. Nesne konumlarının algılanması için R-CNN, fast R-CNN ve faster R-CNN gibi yapıların kullanıldığı derin öğrenme temelli çalışmalarda çoğunlukla doğal görüntülerdeki nesnelerin algılanması üzerinde çalışılmıştır. Çalışmada tümör sınıflandırma için Alexnet modeli iskelet yapı olarak kullanılmıştır. Sınıflandırma için faster R-CNN yapısı kullanılarak bir model geliştirilmiştir. Çalışma sonucunda elde edilen doğruluk oranı %91.66 olarak elde edilmiştir.

Kumar ve ekibinin yapmış oldukları çalışmanın [5] amacı sınıflandırma ve nesne tanımlamadır. Darknet YOLO v4, sınıflandırmayı ve ilgili bölgeyi tespit etmede en iyi doğruluk puanlarını elde etmek için kullanılmıştır. Kullanılan veri kümesi 283 adet görüntüden oluşmaktadır. Model, tesla GPU ile eğitilmiş ve fetal beyin sınıflandırması ve lokalizasyonu alanında mevcut tekniklerin sonuçlarını elde etmiştir. Araştırma çalışmasında %97.92 doğruluk elde edilmiştir.

Hossain ve arkadaşlarının yapmış oldukları çalışmalarını [15] EM (elektromanyetik) görüntüler içeren bir veri seti üzerinde gerçekleştirilmiştir. Veri seti toplamda 1000 görüntüden oluşmaktadır. Algılama performansı farklı görüntü veri setleri ile incelenmiştir. Elde edilen algılama doğruluğu %95.62'dir. Çalışmada algılama modeli olarak YOLO V3 modeli yüksek doğruluk ve gelişmiş hesaplama hızına sahip olması nedeni ile seçilmiştir.

Alhussainan ve arkadaşlarının yapmış oldukları çalışmalarında [16] görüntülerin düşük seviyeli özellikleri ile sağlam/yumuşak sınıflar arasındaki ilişkiyi öğrenmek için MRI görüntülerini kullanarak menenjiyom beyin tümörlerinin otomatik sınıflandırılması için YOLO v4 modeli uygulayan bir öğrenme yaklaşımı rapor edilmiştir. Yerel bir üniversite hastanesinden elde edilen MRI veri seti kullanılarak işlemler gerçekleştirilmiştir. YOLO v4 modeline dayalı yaklaşımın F1-skor değeri %95.83 olarak elde edilmiştir.

Balaji ve ekibinin yapmış olduğu çalışmalarında [4] YOLO v3 algoritmasına dayalı bir MSF-YOLO modeli önerilmektedir. Modelin eğitim prosedürü optimize edilmiş ve modelin yakınsaması, COCO veri seti üzerinde eğitim yoluyla öğrenilen ağırlık parametreleri tanıtılarak hızlandırılmıştır. İki açık veri setindeki deneysel sonuçlar, MSF-YOLO'nun %98,67 oranı ile %97,51 doğruluk oranı elde eden YOLOv3 modelinden daha iyi bir performans gösterdiğini göstermiştir.

Samee ve ekibinin yapmış olduğu çalışmalarında [17] hibrit bir derin transfer öğrenme (GN-AlexNet) modeli sunulmuştur. Önerilen model, GoogleNet'in beş katmanını kaldırılarak ve özelliklerini otomatik olarak çıkaran ve sınıflandıran AlexNet modelinin on katmanını ekleyerek GoogleNet mimarisini AlexNet modeliyle birleştirmişlerdir. Aynı CE-MRI veri setindeki önerilen model, transfer öğrenme teknikleri (VGG-16, AlexNet, SqueezeNet, ResNet ve MobileNet-V2) ve ML/DL ile karşılaştırılmıştır.

Önerilen model, %99,51 doğruluk oranı ile mevcut yöntemlerden daha iyi bir performans göstermiştir.

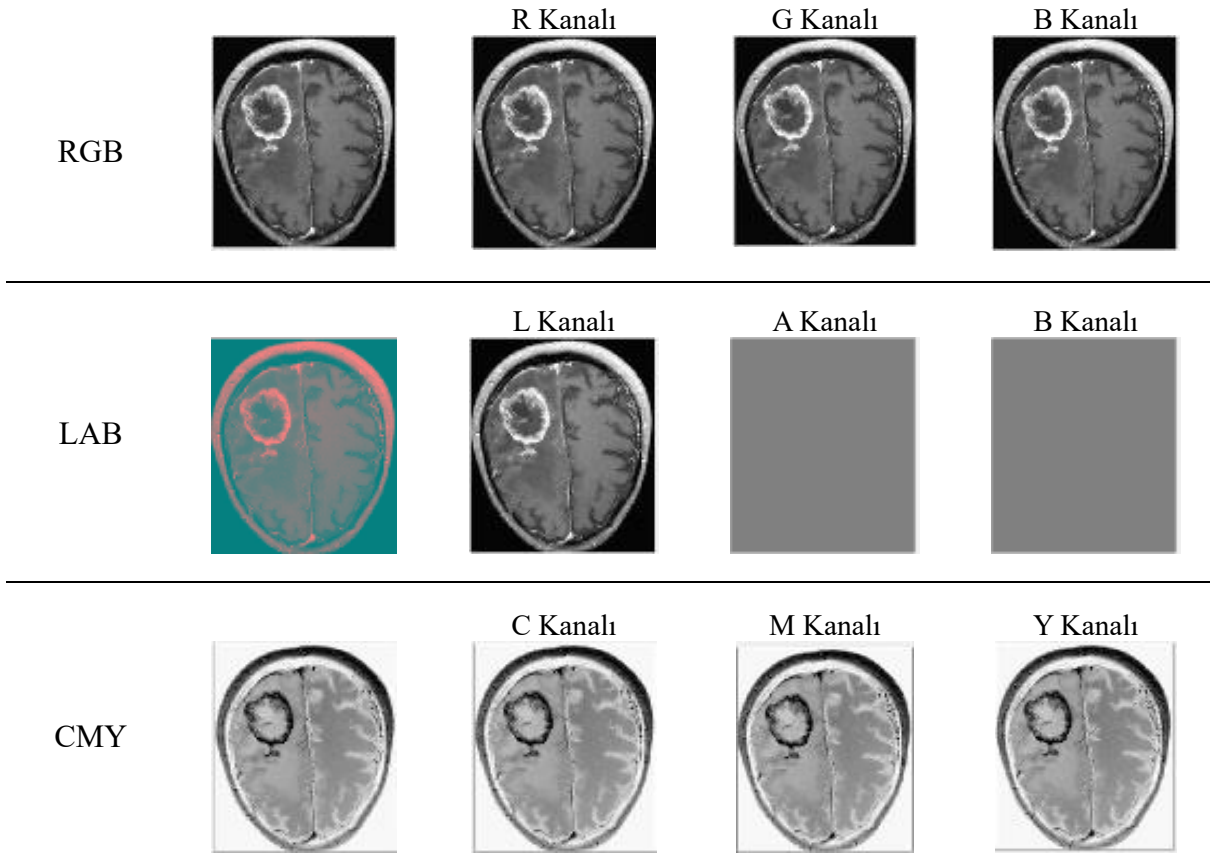
Yapılacak olan bu çalışmada 4600 Kaggle'dan alınan tümürlü ve sağlıklı beyin MRI görüntülerini içeren bir veri seti kullanılarak görsellerde tümör var veya yok olarak sınıflandırılıp işaretlenecektir. Bu işlemler en güncel YOLO modelleri kullanılarak gerçekleştirilecektir. Bu modeller YOLOv5, YOLOv7 ve YOLOv8'dir. Bu modeller çalıştırılmadan önce görüntülerdeki tümörlerin daha belirgin formunu yakalamak için görüntüler üzerinde işlemler gerçekleştirilecektir.

II. MATERYAL VE YÖNTEM

A. Görüntü Ön İşleme

Elimizdeki veriler ile modellerimizi eğitmeden önce renk dönüşümleri, filtreleme uygulamaları, kenar tespit algoritmaları, gürültü silme gibi işlemler uygulanmıştır. Yapılan bu işlemlerdeki amaç modele daha net görüntüler sunarak başarı oranını yükseltmek ve farklı dönüşümlerin modelin başarı oranını nasıl etkilediğini tespit etmektir. Yapılan deneyler veri seti üzerinde rastgele seçilmiş görüntüler üzerinde denenmiş ve karşılaştırılmıştır. Veri setimiz Kaggle üzerinden almış olduğumuz bir veri setidir. Veri seti 2.513 tümürlü beyin görüntüsü ve 2087 tane sağlıklı beyin görüntüsü olmak üzere toplam 4600 adet görüntüden oluşmaktadır.

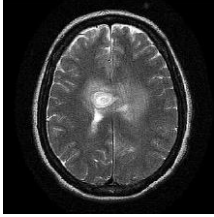

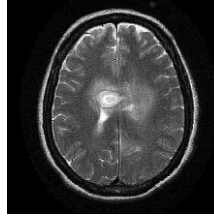
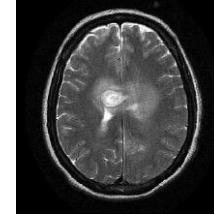
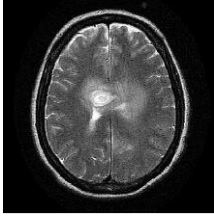

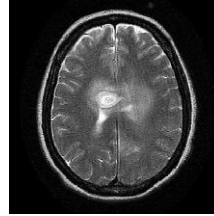
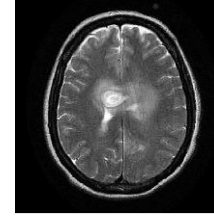


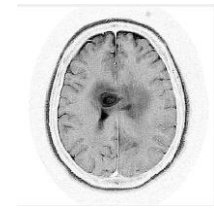
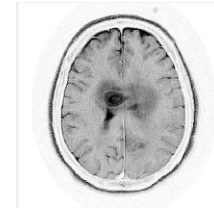
Görüntüler üzerindeki işlemler Matlab ortamında gerçekleştirilmiştir. Seçilen rastgele görüntü üzerinde Gray, HSV, HSI, LAB, CMY ve YUV olmak üzere 6 farklı renk uzayı dönüşümü uygulanmıştır. Her bir renk uzayı için renk kanalları ayrı olarak incelenmiştir. Dönüştürülen bu renk formatları ve renk formatlarına ait her kanal üzerinde histogram eşitleme metodu, Gauss filtresi ve median filtresi uygulanmıştır. Bu işlemlerde en net görüntüler CMY, RGB ve LAB dönüşümlerinde elde edilmiştir. Elde edilen sonuçlar Şekil 1' de verilmiştir.



Şekil 1. Tümörlü beyin görüntüleri üzerinde renk dönüşümleri ve kanalları

RGB renk formatı elektronik sistemlerde yaygın olarak kullanılan bir renk modelidir. Dijital görüntülerin ve ekranların temel rengi olarak kullanılmaktadır. Verilerimiz orjinal olarak rgb renk formatında bulunmaktadır. LAB renk modeli, renkleri insan görsel algısına daha uygun bir şekilde temsil etmek için kullanılan bir renk modelidir ve bu nedenle renk değişimi, renk analizi gibi birçok alanda tercih edilmektedir. CMY renk modeli cyan, magenta ve yellow renklerinden oluşmaktadır. Genellikle baskı ve renk ayrımı işlerinde tercih edilmektedir.

Tablo 1 incelendiğinde CMY formatına çevrilmiş görüntünün kanalları incelendiğinde üç kanalda da tümörlü bölge net bir şekilde gözlemlenmektedir. RGB formatında da bütün kanalları dahil olmak üzere tümörlü bölge nettir. LAB renk formatında ise A ve B kanallarında hiçbir bilgi gözlemlenmemektedir. 3 formata ait görüntülerin kanalları üzerinde CMY'nin C kanalı, RGB'nin R kanalı ve LAB'nin L kanalında histogram eşitleme, mod filtresi ve gaus filtresi uygulanmıştır. Deney sonucunda elde edilen görüntüler Şekil 2'de verilmiştir.

Renk Kanalı	Orijinal Resim	Histogram Eşitleme	Gaus Filtresi	Medyan Filtresi
R KANALI				
L KANALI				
C KANALI				

Şekil 2. RGB R Kanalı, LAB L ve CMY C Kanalı Üzerinde Filtre İşlemleri

Histogram eşitleme ile dokuları daha net görmek hedeflendi. Fakat elimizdeki verilerde histogram eşitleme olumlu sonuçlar vermedi. Öte yandan Gaus ve Medyan filtreleri uygulanarak değişimler incelendi. Resim üzerindeki gürültüyü azalttıkları Şekil 2' de net bir şekilde gözlemlenmektedir. Bütün sonuçlarda tümörlü alan net gözlemlenmektedir fakat en net gözlem CMY renk dönüşümü uygulanan resmin C kanalına uygulanmış medyan filtresi sonucu elde edilen görüntüde mevcuttur. Derin öğrenme modellerimize CMY renk formatına ait görüntünün C kanalına medyan filtresi uygulanmış resim verilecektir.


B. Makine Öğrenmesi

Veriler için yukarıda bahsedilen işlemler yapıldıktan sonra tümör tespiti ve işaretlendirme

işlemleri için YOLOv ve YOLOv7 modelleri eğitilecektir. Elde edilen model test için ayrılan görüntülerde doğrulanacaktır.

a) YOLOv5 Modeli

Bilgisayarlı görü modellerinden biridir [18]. YOLO modelleri görüntülerdeki veya videolardaki nesnelere ve bu nesnelere koordinatlarını aynı anda tespit edebilmektedir [19]. YOLOv5, GPU hızlandırma ile optimize edilmiştir ve yüksek hızlı nesne tespiti yapabilme yeteneğine sahiptir. YOLOv5 modeline ait mimari Şekil 3'te verilmiştir. YOLOv5 mimarisi Backbone, neck ve head olmak üzere 3 temel bileşenden oluşmaktadır. Bu üç bileşen bir araya gelerek nesne tespiti işlemini gerçekleştirir.

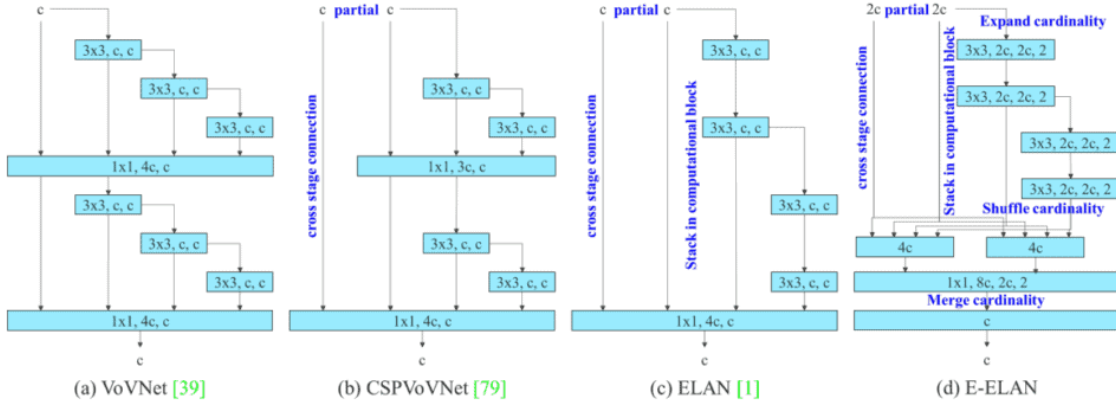


Şekil 3. YOLOv5 Model mimarisi [18]

Backbone bileşeni, temel görüntü özelliklerini çıkarmak için kullanılan bir evrişimli sinir ağı modelidir. Neck bileşeni backbone çıktıları işlemek ve daha yüksek seviyeli özellikler elde etmek için kullanılır. Bu bileşen, ölçeklendirme, birleştirme ve öznitelikleri düzenleme işlemleri gerçekleştirir. Head bileşeni ise nesne tespiti gerçekleştirildiği son aşamadır. Bu bileşen önceden belirlenmiş sınıf sayısına göre sınıflandırma ve sınırlayıcı kutu tahmini yapar.

b) YOLOv7 Modeli

Hız ve doğruluk açısından önceki YOLO modellerinden daha hızlıdır. Diğer sinir ağlarından daha ucuz donanım gerektirir ve önceden eğitilmiş herhangi bir ağırlık olmadan küçük veri kümelerinde daha hızlı eğitilebilir [20]. YOLOv7'ye ait mimari Şekil 4'de verilmiştir. YOLOv7 mimarisi, YOLOv4, YOLOv4 Scaled ve YOLO-R'dan türetilmiştir.



Şekil 4. YOLOv7 modeli mimarisi [21]

YOLOv7 mimarisi E-ELAN hesaplama bloğundan oluşmaktadır. E-ELAN mimarisi çerçevenin daha iyi öğrenmesini sağlar. Hız ve doğruluğu etkileyen faktörler bellek erişim maliyeti, G/Ç kanal oranı, Element bazlı işlem, aktivasyonlar ve gradyan yol analiz edilerek tasarlanmıştır [21].

c) YOLOv8 Modeli

YOLO modellerinden en güncel olan YOLOv8 mimarisi hakkında henüz net bir açıklama yok. Araştırmacıların incelemeleri ile birlikte bazı sonuçlar elde edilmiştir [22]. YOLOv5'ten farklı olarak Sabitleyici Olmayan Algılama (Anchor-Free Detection) ve Mozaik Büyütme (Mosaic Augmentation) güncellemeleri gerçekleştirilmiştir [22]. Diğer YOLO modellerinden daha hızlı bir performans sergilemektedir.

III. BULGULAR ve TARTIŞMA

Çalışma kapsamında elde edilen görüntülerin son halleri ile YOLOv5 ve YOLOv7 modelleri oluşturulmuş ve test edilmiştir. Görüntüler Roboflow aracılığı ile etiketlenmiştir. Sağlıklı beyin görüntüleri için hiçbir etiket kullanılmamıştır. Her iki model de 50 epoch değeri ile çalıştırılmıştır. Elde edilen sonuçlar mAP (Mean Average Precision – Ortalama Hassasiyet) değerine göre karşılaştırılmaktadır.

A. mAP

Bu parametre makine öğrenimi modellerini değerlendirmek için kullanılan bir performans metriğidir. Her bir sınıfın Tahmin ve Duyarlılık

eğrisi altındaki alanların (AUC) ortalaması olarak hesaplanır [23]. Formül şu şekildedir:

$$mAP = \frac{1}{N} * \sum_{i=1}^N AP_i \quad (1)$$

İlk olarak Tahmin-Duyarlılık eğrisi oluşturulur. Her sınıf için modelden elde edilen çıktılara göre bu doğru oluşturulur. Daha sonra her sınıf için oluşturulan bu eğriler altında kalan alan hesaplanır. Bu AP değeridir. Hesaplanan bu AP değerleri (1) numaralı formülde verildiği gibi toplanır ve mAP değeri elde edilir [23].

		Predicted	
		Positive	Negative
Ground-Truth	Positive	True Positive	False Negative
	Negative	False Positive	True Negative

Şekil 5. Karmaşıklık Matrisi

B. Kesinlik (P – Precision)

Kesinlik değeri, doğru olarak sınıflandırılan Pozitif değerlerin sayısının, pozitif olarak sınıflandırılan toplam değer sayısına oranı olarak hesaplanmaktadır [24]. Şekil 5'te verilen

karmaşıklık matrisine göre formül (2) numaralı formülde verilmiştir.

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (2)$$

Kesinlik parametresi modelin örnekleri pozitif olarak sınıflandırmada ne kadar güvenilir olduğu sonucunu bize vermektedir [24].

C. Duyarlılık (R - Recall)

Bu parametre, pozitif olarak doğru şekilde sınıflandırılan değişken sayısının toplam gerçek pozitiflere oranını ifade etmektedir. Duyarlılık yalnızca pozitif örneklerin nasıl sınıflandırıldığı ile ilgilienmektedir [24]. Şekil 5'te verilen karmaşıklık matrisine göre duyarlılık değişkeninin formülü (3) numaralı formülde verilmiştir.

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (3)$$


Duyarlılık modelin pozitif değerlerin tespit etme yeteneğini ölçmektedir. Duyarlılık ne kadar yüksek olursa, o kadar çok pozitif değişken tespit edilir [24]. Bu değişkenlere göre iki modele ait elde edilen çıktılar Tablo 3'te verilmiştir.

Tablo 3 Modeller ve elde edilen sonuçlar

Model	Precision	Recall	mAP
YOLOv5	0.897	0.776	0.852
YOLOv7	0,841	0.672	0.731
YOLOv8	0.887	0.783	0.874

mAP değerlerine ve R (duyarlılık) parametrelerine göre en iyi sonucu YOLOv8 modeli vermiştir. Precision ve Recall değerlerinin 1'e yakın olması modelin doğru tespitler yaptığını göstermektedir. Aynı zamanda YOLOv8 modeli mAP değeri %87 ile

diğer YOLO modellerinden yüksektir. Yani YOLOv8 modeli veri setimizde daha iyi bir başarı elde etmiştir. Modeller eğitildikten sonra elde edilen etkiletilenmiş verilere ait örnekler Şekil 6'da verilmiştir.



Şekil 6. YOLOv8 modeline ait etiketlenmiş veri örnekleri

IV. SONUÇ

Çalışma kapsamında Kaggle'dan almış olduğumuz 'Brian Tumor Dataset' başlıklı veri seti ile tümörlü bölgelerin tespiti işlemi gerçekleştirilmiştir. Obje tespitinden önce görüntüler üzerinde tümörlü bölgeyi daha çok ön plana çıkarmak için MATLAB aracılığı ile renk dönüşümleri, histogram eşitleme, renk kanalları kontrolü gibi işlemler gerçekleştirilmiş ve en uygun görülen sonuçlar modellerimize uygulanmıştır.

Model olarak YOLO modellerinden olan en güncel modeller seçilmiştir. YOLOv5, YOLOv7 ve YOLOv8 uygulaması gerçekleştirilmiş ve en iyi sonuç %87 mAP değeri ile YOLOv8 modelinden elde edilmiştir.

V. TEŞEKKÜR

Çalışma kapsamında kullandığımız veri setini kaggle platformu üzerinden paylaşarak bu çalışmayı yapmamızı sağlayan PREET VIRADIYA'ya teşekkür ederiz.

VI. SON NOT

Bu çalışma “Derin öğrenme teknikleri” dersi kapsamında yapılmıştır.

VII. KAYNAKLAR

- [1] B. Özcan and H. Bakır, “Derin Öğrenme Kullanılarak Beyin MR Görüntüleri Sınıflandırma,” *ICIAS*, 2023.
- [2] Prof. Dr. Serdar Baki Albayrak, “Beyin Tümörleri,” *Beyin Tümörü Nedir?* https://beyincerrahisiistanbul.com/beyin-tumorleri?gclid=CjwKCAjw586hBhBrEiwAQYEnHXud3xDt7sBtbyNE9MKWK7ySLIlwJqRofwrkz3ex8DvEQgieoePSwxoCcZ4QAvD_BwE (accessed Apr. 15, 2023).
- [3] Acıbadem, “Beyin Tümörleri,” Feb. 12, 2019. 3) <https://www.acibadem.com.tr/ilgi-alani/beyin-tumorleri/> (accessed Apr. 15, 2023).
- [4] R. Balaji, G. Prabaharan, A. R. Singh, S. Athisayamani, V. Sarveshwaran, and S. Daniya, “Multi-Scale Features Fusion with YOLOv3 for Detecting Small and Fine Tumors in MRI images,” in *6th International Conference on Electronics, Communication and Aerospace Technology, ICECA 2022 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 1545–1549. doi: 10.1109/ICECA55336.2022.10009122.
- [5] N. S. Kumar, A. K. Goel, and S. Jayanthi, “A Scrupulous Approach to Perform Classification and Detection of Fetal Brain using Darknet YOLO v4,” in *2021 International Conference on Advance Computing and Innovative Technologies in Engineering, ICACITE 2021*, Institute of Electrical and Electronics Engineers Inc., Mar. 2021, pp. 578–581. doi: 10.1109/ICACITE51222.2021.9404656.
- [6] H. Bakır, S. Oktay, and T. E. Tabaru, “DETECTION OF PNEUMONIA FROM X-RAY IMAGES USING DEEP LEARNING TECHNIQUES.”
- [7] H. Bakır and S. Yılmaz, “Using Transfer Learning Technique as a Feature Extraction Phase for Diagnosis of Cataract Disease in the Eye.”
- [8] F. J. P. Montalbo, “A computer-aided diagnosis of brain tumors using a fine-tuned yolo-based model with transfer learning,” *KSII Transactions on Internet and Information Systems*, vol. 14, no. 12, pp. 4816–4834, Dec. 2020, doi: 10.3837/tiis.2020.12.011.
- [9] N. M. Dipu, S. A. Shohan, and K. M. A. Salam, “Deep Learning Based Brain Tumor Detection and Classification,” in *2021 International Conference on Intelligent Technologies, CONIT 2021*, Institute of Electrical and Electronics Engineers Inc., Jun. 2021. doi: 10.1109/CONIT51480.2021.9498384.
- [10] N. M. Dipu, S. A. Shohan, and K. M. A. Salam, “Brain Tumor Detection Using Various Deep Learning Algorithms,” in *2021 International Conference on Science and Contemporary Technologies, ICSCCT 2021*, Institute of Electrical and Electronics Engineers Inc., 2021. doi: 10.1109/ICSCCT53883.2021.9642649.
- [11] A. R. Kavitha and K. Palaniappan, “Brain tumor segmentation using a deep Shuffled-YOLO network,” *Int J Imaging Syst Technol*, vol. 33, no. 2, pp. 511–522, Mar. 2023, doi: 10.1002/ima.22832.
- [12] B. J. D. Kalyani, K. Meena, E. Murali, L. Jayakumar, and D. Saravanan, “Analysis of MRI brain tumor images using deep learning techniques,” *Soft comput*, 2023, doi: 10.1007/s00500-023-07921-7.
- [13] Kondratenko Yuriy, Sidenko Ievgen, Kondratenko Galyna, Petrovych Valentyn, Taranov Mykyta, and Sova Ivan, “Artificial Neural Networks for Recognition of Brain Tumors on MRI Images,” *Communications in Computer and Information Science*, pp. 114–140, Mar. 2021, doi: 10.1007/978-3-030-77592-6_6.
- [14] C. Öksüz, K. Üniversitesi, and M. K. Güllü, “Yolo v2 Modeli ile Beyin Tümörü Algılama (Brain Tumor Localization Using Yolo v2) Smart Mirror Design and Prototype Production for Individuals with Diabetic Foot Ulcers View project Feature extraction and classification from magnetic resonance and computer tomography images View project.” [Online]. Available: <https://www.researchgate.net/publication/346535706>
- [15] A. Hossain *et al.*, “A YOLOv3 Deep Neural Network Model to Detect Brain Tumor in Portable Electromagnetic Imaging System,” *IEEE Access*, vol. 9, pp. 82647–82660, 2021, doi: 10.1109/ACCESS.2021.3086624.
- [16] N. F. Alhussainan, B. Ben Youssef, and M. M. Ben Ismail, “A Deep Learning Approach for Brain Tumor Firmness Detection Using YOLOv4,” in *2022 45th International Conference on Telecommunications and Signal Processing, TSP 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 342–348. doi: 10.1109/TSP55681.2022.9851237.
- [17] N. A. Samee *et al.*, “Classification Framework for Medical Diagnosis of Brain Tumor with an Effective Hybrid Transfer Learning Model,” *Diagnostics*, vol. 12, no. 10, Oct. 2022, doi: 10.3390/diagnostics12102541.
- [18] Jacob Solawetz, “What is YOLOv5? A Guide for Beginners,,” Jun. 2020, Accessed: May 30, 2023. [Online]. Available: <https://blog.roboflow.com/yolov5-improvements-and-evaluation/>
- [19] Ayşe nur Akdeniz, “YOLOv5 ile Nesne Tespiti,” Aug. 2021, Accessed: May 30, 2023. [Online]. Available: <https://medium.com/@akdenizz7/yolov5-ile-nesne-tespiti-8aa370febfc0>
- [20] Gaudenz Boesch, “YOLOv7: The Most Powerful Object Detection Algorithm (2023 Guide) Read more at: <https://viso.ai/deep-learning/yolov7-guide/>,” 2023, Accessed: May 30, 2023. [Online]. Available: <https://viso.ai/deep-learning/yolov7-guide/>
- [21] Kukil and Sovith Rath, “YOLOv7 Object Detection Paper Explanation & Inference,” 2022, Accessed: May 30, 2023. [Online]. Available: <https://learnopencv.com/yolov7-object-detection-paper-explanation-and-inference/>
- [22] Mukilan Krishnakumar, “A Gentle Introduction to YOLOv8,” May 2023.
- [23] David Cachard, “mAP : Evaluation metric for object detection models,” Sep. 2021, Accessed: May 31,

2023. [Online]. Available: <https://medium.com/axinc-ai/map-evaluation-metric-of-object-detection-model-dd20e2dc2472>

- [24] Ahmet Fawzy Gad, “Evaluating Deep Learning Models: The Confusion Matrix, Accuracy, Precision, and Recall,” 2020, Accessed: May 31, 2023. [Online]. Available: <https://blog.paperspace.com/deep-learning-metrics-precision-recall-accuracy/>