

FETHİ YAŞAR

DİCLE ÜNİVERSİTESİ SAĞ. BİL. ENST.

YÜKSEK LİSANS TEZİ

DIYARBAKIR-2025



TÜRKİYE CUMHURİYETİ
DİCLE ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENİMİ YÖNTEMLERİNİN BEYİN TÜMÖRÜ TESPİTİNDEKİ BAŞARISI

Fethi YAŞAR
YÜKSEK LİSANS TEZİ

BİYOİSTATİSTİK ANABİLİM DALI

DANIŞMAN
Dr. Öğr. Üyesi İsmail YILDIZ

DİYARBAKIR 2025



TÜRKİYE CUMHURİYETİ
DİCLE ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENİMİ YÖNTEMLERİNİN BEYİN TÜMÖRÜ TESPİTİNDEKİ BAŞARISI

Fethi YAŞAR
YÜKSEK LİSANS TEZİ

BİYOİSTATİSTİK ANABİLİM DALI

DANIŞMAN
Dr. Öğr. Üyesi İsmail YILDIZ

DİYARBAKIR 2025



TÜRKİYE CUMHURİYETİ
DİCLE ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

ONAY

Dicle Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik Anabilim Dalı Yüksek Lisans öğrencisi Fethi Yaşar'ın hazırladığı “Makine Öğrenimi Yöntemlerinin Beyin Tümörü Tespitindeki Başarısı” başlıklı tez Dicle Üniversitesi Lisansüstü Eğitim - Öğretim ve Lisansüstü Eğitim ilgili maddeleri uyarınca kapsam ve bilimsel kalite yönünden değerlendirilerek Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi İsmail YILDIZ

Jüri Üyeleri

İmza

Jüri Başkanı Prof. Dr. Zeki AKKUŞ

Üye Doç. Dr. Mehmet Onur KAYA

Üye Dr. Öğr. Üyesi İsmail YILDIZ

Tarih: .../.../2025

Bu tez Dicle Üniversitesi Sağlık Bilimleri Enstitüsü Yönetim Kurulu'nun/..../2025 tarih ve sayılı kararıyla onaylanmıştır.

...../...../2025

Prof. Dr. Mahmut BALKAN
Dicle Üniversitesi
Sağlık Bilimleri Enstitüsü Müdürü

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını ve tezimi Dicle Üniversitesi Sağlık Bilimleri Enstitüsü tez yazım kılavuzu standartlarına uygun bir şekilde hazırladığımı beyan ederim.

19/12/2025

Fethi YAŞAR

İmza

TEŞEKKÜR

Bu tez çalışmasının hazırlanması sürecinde, bilgi ve deneyimleriyle bana yol gösteren, her aşamada değerli katkılarını esirgemeyen danışmanım Dr. Öğr. Üyesi İsmail YILDIZ'a teşekkür ederim.

Yüksek lisansa başladığım günden bu yana sürekli desteğini aldığım değerli hocam Prof. Dr. Zeki AKKUŞ'a en içten teşekkürlerimi sunarım. Çalışmanın her aşamasında katkı sağlayan Doç. Dr. Hıdır SARI, Doç. Dr. Salih HATTAPOĞLU ve Dr. Mehmet Sait DUYU'ya teşekkür ederim. Ayrıca tez çalışmam sırasında değerli katkılarını sunan ve desteğini esirgemeyen Mehmet Ali YILDIRIM'a teşekkür ederim.

Hayatım boyunca beni emekle, zahmetle büyüten ve her zaman manevi desteğini esirgemeyen canım annem Hüsna, babam Mustafa YAŞAR'a, canım kardeşlerime ve arkadaşlarıma, tüm içtenliğimle sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

BEYAN.....	i
TEŞEKKÜR	ii
İÇİNDEKİLER	iii
TABLolar DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
KISALTMALAR ve SİMGELER DİZİNİ	vii
1. ÖZETLER	1
1.1. Türkçe Özet	1
1.2. Abstract	3
2. GİRİŞ ve AMAÇ	4
3. GENEL BİLGİLER.....	6
3.1. İnsan Beyni ve Tümör	6
3.1.1. Beyin tümörleri ve özellikleri	7
3.1.2. Pediatrik hastalarda beyin tümörleri	7
3.2. Beyin Görüntüleme Teknikleri.....	8
3.3. Yapay Zeka.....	9
3.4. Makine Öğrenimi	11
3.4.1. Denetimli öğrenme	12
3.4.2. Denetimsiz öğrenme	12
3.4.3. Yarı denetimli öğrenme	13
3.4.4. Takviyeli öğrenme	13
3.5. Derin Öğrenme	14
3.5.1. Evrişimli sinir ağı.....	14
3.5.2. Derin evrişimli sinir ağı ve mimarilerinin evrimi	15
3.5.2.1. AlexNet	15
3.5.2.2. VGGNet	16
3.5.2.3. Artık sinir ağları	17
3.5.2.4. Inception-v3	18
3.5.2.5. EfficientNet	18
3.5.2.6. Sadece bir kez bakarsın (You Only Look Once)	20
3.5.3. Model performanslarının değerlendirilmesi	22

3.5.4. Kayıp (Loss)	24
3.5.3.5. Epoch	25
4. GEREÇ ve YÖNTEM.....	26
4.1. Araştırma Tasarımı ve Evren.....	26
4.2. Değişkenler.....	26
4.3. Araştırma Hipotezleri	27
4.4. Dahil Etme ve Hariç Tutma Kriterleri.....	27
4.5. Makine Öğrenimi Modelleri ve İstatistiksel Analizler.....	27
4.6. Model Eğitimi ve Değerlendirme	31
4.7. Araştırmanın Kısıtlılıkları	31
4.8. Etik Onay ve Kurumsal İzin	32
5.BULGULAR	33
6.TARTIŞMA	44
7.SONUÇ ve ÖNERİLER.....	51
8. KAYNAKLAR	52
ÖZGEÇMİŞ	
EKLER.....	
EK-1	
EK-2	
EK-3	
EK-4	
ORJİNALLİK RAPORU	

TABLÖLAR DİZİNİ

Tablo 1. B0 ile B7 arasındaki temel modeller için giriş şekilleri (62).	19
Tablo 2. İkili karışıklık matris örneği.....	23
Tablo 3. Loss değerleri	24
Tablo 4. Tümör pozitif ve tümör negatif cinsiyet dağılımı.	33
Tablo 5. Eğitim ve test aşamalarındaki kayıp ve doğruluk değerleri.	34
Tablo 6. Geçerlilik değerlendirme tablosu	35
Tablo 7. Sınıflandırma tablosu	36



ŞEKİLLER DİZİNİ

Şekil 1. AI tarihsel gelişimi.	10
Şekil 2. ML algoritmaları.....	11
Şekil 3. CNN mimarisi.....	15
Şekil 4. AlexNet mimarisi.	16
Şekil 5. VGGNet ağının mimarisi.....	17
Şekil 6. Temel ResNet bloğu.	18
Şekil 7. Inception V3 modeli.	18
Şekil 8. EfficientNet'in şematik gösterimi.	19
Şekil 9. YOLO mimarilerinin evrimi.....	21
Şekil 10. YOLOv12 mimarisi diyagramı.....	22
Şekil 11. Araştırmanın metodolojisi	28
Şekil 12. CNN yönteminin şematik gösterimi	29
Şekil 13. Beyin MR görüntülerinde tümör negatif ve tümör pozitif örnekler	29
Şekil 14. YOLO yönteminin şematik gösterimi	30
Şekil 15. Veri setinin dağılımı.	30
Şekil 16. Roboflow ile işaretlenmiş tümör pozitif (sol) ve tümör negatif (sağ) MR görüntüsü.....	30
Şekil 17. Beyin tümörünün eğitim ve doğrulama kayıpları ile doğrulukları	34
Şekil 18. CNN modeline ait karışıklık matrisi.....	35
Şekil 19. Modelin 74. Epoch' taki genel doğrulama sonuçları.....	36
Şekil 20. F1 Güven eğrisi.	37
Şekil 21. Kesinlik-Duyarlılık eğrisi.	37
Şekil 22. Hassasiyet-Güven eğrisi.	38
Şekil 23. Duyarlılık- Güven eğrisi	38
Şekil 24. YOLO sınıflandırma başarısının normalize edilmiş karmaşıklık matrisi ile analizi.....	39
Şekil 25. Eğitim ve doğrulama kayıpları ile performans metrikleri	40
Şekil 26. Eğitilen YOLO modelinin beyin MR görüntüleri üzerindeki tahmin sonuçları.....	41
Şekil 27. YOLO ile beyin MR görüntülerinde tümör tespitine ait örnek tahmin çıktıları	42
Şekil 28. YOLO ile tümör pozitif beyin MR görüntülerine ait örnek tahmin çıktıları.	43

KISALTMALAR VE SİMGELER DİZİNİ

AI	: Yapay Zeka
BT	: Bilgisayarlı Tomografi
CNN	: Evrişimli Sinir Ağları
CDC	: Hastalık Kontrol ve Önleme Merkezleri
CBTRUS	: Amerika Birleşik Devletleri Merkezi Beyin Tümörü Kayıt Defteri
DL	: Derin Öğrenme
GPU	: Grafik İşlemci Ünitesi
HBYS	: Hastane Bilgi Yönetim Sistemi
MR	: Manyetik Rezonans
ML	: Makine Öğrenimi
NCI	: Ulusal Kanser Enstitüsü
OB	: Döner Sınırlayıcı Kutu
PET	: Pozitron Emisyon Tomografisi
PACS	: Görüntü Saklama ve İletişim Sistemleri
ReLU	: Rektifiye Edilmiş Lineer Ünite
ResNet	: Artık Sinir Ağları
RMSProp	: Kök Ortalama Karesel Yayılım
VGG	: Görsel Geometri Grubu
YOLO	: Sadece Bir Kez Bakarsın
WHO	: Dünya Sağlık Örgütü

Makine Öğrenimi Yöntemlerinin Beyin Tümörü Tespitindeki Başarısı

Öğrencinin Adı ve Soyadı: Fethi YAŞAR

Danışman: Dr. Öğr. Üyesi İsmail YILDIZ

Anabilim Dalı: Biyoistatistik

1. ÖZETLER

1.1. Türkçe Özet

Amaç: Radyoloji uzmanları tarafından tümör tanısı konulmuş pediatrik hastaların beyin MR görüntülerinin makine öğrenimi yöntemi kullanılarak eğitilen modeller ile test edilerek başarı düzeyinin araştırılmasıdır.

Gereç ve Yöntem: Bu çalışma, metodolojik bir araştırma olup; 2010–2024 yılları arasında üçüncü basamak sağlık hizmeti sunan Dicle Üniversitesi Tıp Fakültesi Hastanesi'ne başvuran 18 yaş altı pediatrik hastaların beyin MR görüntüleri retrospektif olarak değerlendirilmiştir. Radyoloji uzmanları tarafından beyin tümörü saptanan 230 hasta ile beyin tümörü saptanmayan 230 hasta çalışmaya dahil edilmiştir. Toplam 460 hastadan elde edilen 1380 MR görüntüsü analiz edilmiştir. Hastalar, tümör pozitif ve tümör negatif olmak üzere iki gruba ayrılmıştır. MR görüntülerinde tümör lokasyon tespiti ve ikili sınıflandırma yapmak amacıyla derin öğrenme tabanlı YOLOv12 ve EfficientNetB4 mimarileri değerlendirilmiştir. Görüntülerin analizinde Python programlama dili kullanılmış ve görüntülerin etiketlemesinde Roboflow platformu kullanılmıştır.

Bulgular: CNN modeli ile tümörlü ve tümörsüz MR imajı sınıflandırmasında EfficientNetB4 %97 doğruluk oranı bulunmuştur. YOLOv12 modeli ise mAP50 %89 doğruluk oranı bulunmuştur. Eğitim süreci boyunca her iki modelde de istikrarlı kayıp azalması ve doğrulama başarısı sağlanmıştır. Model hem eğitim hem test verilerinde tutarlı sonuçlar üretmiş olup, aşırı öğrenme gözlemlenmemiştir.

Sonuç: Çalışmada elde edilen bulgular, geliştirilen modellerin klinik karar destek sürecine katkı sağlayarak radyoloji uzmanlarına yardımcı bir araç olarak kullanıldığında iş yükü ve maliyet açısından fayda sağlayabilmektedir.

Anahtar Sözcükler: Beyin Tümörü, Makine Öğrenmesi, Derin Öğrenme, MR Görüntüleri



Success of Machine Learning Methods in Brain Tumour Detection

Student's Surname and Name: YAŞAR Fethi

Adviser of Thesis: Assist. Prof. Dr. İsmail YILDIZ

Department: Biostatistics

1.2. Abstract

Objective: The aim of this study is to evaluate the performance of machine learning models in detecting brain tumors by testing them on MRI images of pediatric patients who were diagnosed with tumors by radiology specialists.

Materials and Methods: This methodological study retrospectively evaluated brain MRI images of pediatric patients under the age of 18 who applied to the tertiary healthcare facility of Dicle University Faculty of Medicine Hospital between 2010 and 2024. A total of 460 patients were included, consisting of 230 patients diagnosed with brain tumors and 230 without. In total, 1,380 MRI images were analyzed. Patients were divided into two groups: tumor-positive and tumor-negative. Deep learning-based architectures, YOLOv12 and EfficientNetB4, were utilized for tumor localization and binary classification in MRI images. The Python programming language was used for image analysis, and the Roboflow platform was employed for image labeling.

Results: In the classification of tumor and non-tumor MRI images using the CNN model, EfficientNetB4 achieved an accuracy rate of 97%. The YOLOv12 model, on the other hand, reached an mAP50 accuracy of 89%. Throughout the training process, both models demonstrated stable loss reduction and consistent validation performance. The model produced reliable results on both the training and test datasets, and no overfitting was observed.

Conclusion: The findings of this study suggest that the developed models can serve as supportive tools in clinical decision-making processes, assisting radiologists while offering advantages in terms of workload reduction and cost efficiency.

Keywords: Brain Tumor, Machine Learning, Deep Learning, MRI Images

2. GİRİŞ ve AMAÇ

Beyin tümörleri, beyindeki hücrelerin olağan dışı ve kontrolsüz şekilde büyüüp çoğalmasıyla ortaya çıkar. Mortalitesi en yüksek olan kanser türlerinden biridir. Beyin dokularındaki bu anormallik sinir sistemine ciddi zarar vererek çoğu zaman hastanın yaşamını kaybetmesine neden olur. En yaygın beyin tümörleri genellikle beyaz madde lifleri çevresinde gelişir ve dokulara sızıcı bir özellik gösterir (1). Pediatrik yaş grubunda, lösemiden sonra en sık görülen tümörler arasında yer almakta ve çocukluk çağına bağlı kanser ölümlerinin önemli bir bölümünü oluşturmaktadır. Erken evrede doğru tanı ve sınıflandırma yapılması, tedavi sürecinin planlanmasında ve prognozun belirlenmesinde kritik rol oynamaktadır. Bu süreçte en sık kullanılan yöntem, yumuşak doku çözünürlüğü en yüksek radyolojik teknik olan manyetik rezonans (MR) görüntülemesidir. Ancak MR görüntülerinin değerlendirilmesi radyoloji uzmanlarının deneyimine bağlı olarak değişkenlik gösterebilmekte, yoruma dayalı farklılıklar ve zaman alıcı raporlama süreçleri nedeniyle sınırlılıklar barındırmaktadır (2).

Makine öğrenimi tabanlı yaklaşımların önemi; erken tanıya katkı sağlaması, radyoloji uzmanlarının hata oranını azaltması ve tedavi süreçlerini hızlanmasını sağlamaktır. Ayrıca bu yöntemler, sağlık hizmetlerinde dijital dönüşümün önemli bir parçası olarak değerlendirilmektedir (3, 4).

Makine öğrenimi yöntemlerinin beyin tümörü tespitinde kullanılması, bireyler açısından erken tanı ile yaşam süresinin ve yaşam kalitesinin artmasına doğrudan katkı sağlar. Tümörün erken evrede saptanması tedavi başarısını yükseltirken invaziv ve maliyetli girişimlerin azaltılmasına da olanak tanır. Doğru ve hızlı tanımlar sayesinde sağlık hizmetlerinin etkinliği artmakta, yanlış tanı oranlarının düşmesiyle kaynak israfı önlenmektedir. Yöneticilerin, sağlık sisteminde iş yükünü azaltarak insan gücü planlamasında kolaylık sağlamak ve sağlık politikalarının daha verimli yürütülmesine destek olmaktadır.

Yapay zeka destekli tanı sistemleri gereksiz tetkiklerin ve hatalı tedavi süreçlerinin önüne geçerek sağlık giderlerini azaltabilmektedir. Ayrıca hızlı tanı, erken müdahaleyi mümkün kılarak ileri evre tedavilerin getirdiği yüksek maliyetleri düşürmektedir. Hasta ve hekim için tanı süreci kısaltmakta, bu da daha fazla hastaya daha kısa sürede hizmet verilmesini sağlamaktadır (5).

Evriřimli sinir aęları (CNN) temelli modeller, grnt sınıflandırmada yksek doęruluk oranları ile ne ıkarken, nesne tespitine ynelik sadece bir kez bakarsın (YOLO) algoritmaları yalnızca sınıflandırma deęil aynı zamanda tmrlerin grnt zerinde konumlandırılmasını da mmkn kılmaktadır. Ayrıca EfficientNet gibi optimize edilmiř CNN mimarileri, parametre verimlilięi sayesinde daha az hesaplama maliyetiyle daha yksek bařarı saęlamaktadır (6). Literatrde yapılan alıřmalarda, CNN ve YOLO tabanlı modellerin farklı hasta gruplarında yksek bařarı elde ettięi ancak pediatrik hasta grubuna odaklanan alıřmaların sınırlı olduęu grlmektedir (7).

Trkiye zelinde ve zellikle Gneydoęu Anadolu Blgesinde bu arařtırmanın ayrı bir nemi bulunmaktadır. Nitelikli uzman sayısının sınırlı olması, saęlık hizmetlerine eriřimdeki blgesel farklılıklar ve grntleme merkezlerindeki yoęunluk gz nne alındıęında makine ęrenimi destekli tanı sistemleri kritik bir ihtiya olarak ne ıkmaktadır. Bu sistemler, hem iř ykn azaltarak daha hızlı ve doęru tanı konulmasını saęlayabilir hem de blgesel saęlık hizmetlerindeki eřiřsizlikleri azaltarak toplum saęlıęına katkıda bulunabilir (8, 9).

Bu alıřmanın amacı, nc basamak bir niversite hastanesine bařvuran pediatrik hastalara ait MR grntlerinde, makine ęrenimi yntemleri kullanılarak beyin tmrlerinin tespit edilmesini saęlamak ve elde edilen sonuları radyoloji uzmanlarının raporlarındaki tmr tanılarıyla karřılařtırmaktır. Ayrıca yapay zeka destekli makine ęrenmesi yntemlerinin doęruluęu ve gvenilirlięi deęerlendirilerek bu sistemlerin geleneksel grntleme raporlama teřhis srecine katkı saęlaması hedeflenmektedir.

3.GENEL BİLGİLER

3.1. İnsan Beyni ve Tümör

Beyin, yüz milyar nöron (sinir hücresi) içeren önemli bir organ olup kendine özgü özelliklere sahip olan çeşitli hücre tiplerinden oluşmaktadır (10). Beyin tümörü, kontrolsüz bir şekilde çoğalan hücrelerin anormal gelişimi olarak başlar ve merkezi sinir sisteminin çeşitli bileşenlerinden köken alarak kafatası içinde yüksek basınç oluşturduğu için beyine zarar verme potansiyeline sahiptir (11). Beyin tümörleri yaşamı tehdit eden bir hastalık olarak iyi huylu (benign) ve kötü huylu (malign) olabilir. Her yaşta ortaya çıkan beyin tümörleri primer tümörler (beyin dokusundan köken alan, genellikle benign) ve sekonder/metastatik tümörler (akciğer, meme gibi organlardan yayılan malign tümörler) olmak üzere iki türü vardır (12). Beyin tümörleri, dünya çapında önemli mortalite nedenidir ve teşhisinde kullanılan geleneksel görüntüleme yöntemleri ile segmentasyon ve sınıflandırma yapmak karmaşık ve zorlu bir iştir (13).

Dünya Sağlık Örgütü (WHO), 1956-1957 yılında başlattığı uluslararası insan tümörleri sınıflandırma sistemini açıkça tanımlanmış, histopatolojik ve klinik tanı kriteri oluşturmak amacı ile geliştirerek, epidemiyolojik araştırmalar ve klinik çalışmalar için evrensel bir temel oluşturmuştur (14). Mavi kitap olarak adlandırılan WHO tümör sınıflandırması, çeşitli bilgileri birleştiren kapsamlı bir kaynağa dönüşmüş ve her baskısı tümör sınıflandırmasının çok yönlü doğasına sistematik bir yaklaşım getirecek şekilde genişlemiştir (15).

Moleküler biyoloji alanındaki gelişmeler, merkezi sinir sistemi tümörlerinin sınıflandırılmasında WHO'nun 2021 yılında (2016 yılından 5 yıl sonra) yeni bir sınıflandırma yayınlamıştır. 2016 versiyonu, moleküler özellikleri tanı kriterlerine dâhil eden ilk sınıflandırma olduktan sonra 2021 versiyonu bu yaklaşımı genişleterek 40'tan fazla tümör tipi ve alt tipini moleküler profilleriyle tanımlayan kapsamlı bir kaynak haline gelmiştir (16).

Her yaşta görülen beyin tümörünün erken evrede tespit edilmesi ile birlikte yapılacak tedaviden başarılı sonuçlar alınabilir. Ancak beyin tümörünün teşhisi yorucu bir süreç olmakla beraber; MR, bilgisayarlı tomografi (BT), vb. gibi görüntüleme

teknikleri beyin tümörlerinin teşhisinde kullanılmaktadır (12). MR, beyin tümörlerinin teşhisinde ve segmentasyonunda genellikle kullanılan non-invaziv bir görüntüleme tekniğidir (10).

3.1.1. Beyin tümörleri ve özellikleri

Beyin tümörleri, merkezi sinir sistemindeki hücrelerin kontrolsüz çoğalması ile başlar ve meninkslerden kafatası tabanına kadar çok çeşitli bölgelerde gelişebilir. Her tümör tipinin kendine özgü biyolojisi, tedavisi ve prognozunun olması nedeni ile beynin benzersiz mikro çevresi ile birleştiğinde sınıflandırılması ve tedavisini karmaşık hale getiren ve güçleştiren temel nedendir (10).

Beyin ve diğer merkezi sinir sistemi tümörleri, çocukluk çağında en yaygın solid tümörler olarak bu yaş grubundaki kanser kaynaklı ölümlerin çoğunluğunu oluşturmaktadır (17). Merkezi sinir sistemi tümörlü birçok çocukta, intrakranial basınç artışı görülmektedir. Bu durum genellikle tümörün üçüncü veya dördüncü ventrikül seviyesinde beyin omurilik sıvısı akışını tıkaması ile (obstrüktif hidrosefali) veya beyinciği ve beyin sapını aşağıya doğru iterek foramen magnumdan fıtıklaşmasına neden olması ile ortaya çıkmaktadır (18).

3.1.2. Pediatrik hastalarda beyin tümörleri

Beyin tümörleri, çocuk ve ergenlerde kanser ilişkili morbidite ve mortalitenin en yaygın nedenlerinden biri olup bu yaş grubunda görülen tümörler, yetişkinlerden farklı histolojik, moleküler ve klinik özellikler gösterdiğinden pediatrik yaş grubuna özgü ayrı raporlama gereklidir (17).

Kötü huylu beyin neoplazmaları, gliyomlar, ependimomlar, embriyonal tümörler ve doğumdan yetişkinliğe kadar hastaları etkileyen çok sayıda nadir varlık ve alt türü kapsayan heterojen bir gruptur. Ameliyat, radyoterapi ve kemoterapi içeren yoğun tedavi protokollerine rağmen yüksek dereceli beyin tümörlü birçok hastanın prognozu genellikle zayıf kalmaya devam etmektedir (19).

Türkiye’de Sağlık Bakanlığı’nın 2020 yılı kanser istatistiklerinde “0-14 yaş bazı çocukluk çağı kanserlerin yıllara göre yaşa standardize hızları (dünya standart nüfusu, 1 000 000 kişide)” merkezi sinir sisteminin tümörleri (20,1) en çok görülen lösemi ve

lenfomadan sonra üçüncü sırada yer almaktadır. Ayrıca erkeklerde kadınlara oranla daha fazla beyin, meninksler ve merkezi sinir sistemi kanserleri görüldüğü belirtilmiştir (20).

Amerika Birleşik Devletleri Merkezi Beyin Tümörü Kayıt Defteri (CBTRUS), ABD nüfusundaki birincil beyin ve merkezi sinir sistemi tümörlerinin kapsamlı epidemiyolojik verilerini sağlayan ulusal bir kaynaktır. Hastalık Kontrol ve Önleme Merkezleri (CDC) ve Ulusal Kanser Enstitüsü (NCI) ile işbirliği içinde yürütülen bu kayıt sistemi, tümör insidansı, prevalansı ve sağkalım oranlarına ilişkin nüfus temelli istatistikler sunmaktadır. 2014-2018 yılları arasında ABD’de 0-19 yaş grubundaki çocuk ve ergenlerde beyin ve diğer merkezi sinir sistemi tümörlerinin yıllık ortalama yaşa özgü insidans oranı 100 000 kişide 6,23 olarak bildirilmiştir (kötü huylu tümörler 3,55 ve iyi huylu tümörler 2,67) (17).

Pediyatrik beyin tümörlerinden kurtulan çocuk sayısı arttıkça uzun dönemli sorunlar ile yaşayan hasta sayısı da artmaktadır. Hayatta kalan çocukların büyük bir kısmı kalıcı engellilikle baş etmekte ve yaşam boyu kapsamlı tıbbi izlem gerektiren endokrin bozukluklara sahip olmaktadır (21).

3.2. Beyin Görüntüleme Teknikleri

Tıbbi görüntüleme, vücudun iç yapılarını görünür kılarak modern tıpta tanı ve tedavi süreçlerine rehberlik ederek farklı klinik senaryolarda çeşitli patolojilerin tanımlanması ve izlenmesi için optimize edilmiş özelliklere sahiptir (22).

Beyin tümörü, nörolojik muayene ile başlar, görüntüleme testleri ile devam eder ve çoğu zaman biyopsiden oluşan kapsamlı bir sürecin sonunda teşhisi kesinleşmektedir. Teşhis sürecinde, MR ile elde edilen bulgular, Pozitron Emisyon Tomografisi (PET) ve BT gibi ek görüntüleme teknikleri ile desteklenebilmektedir (10). MR, beyin tümörlerinin değerlendirilmesinde kontrastlı BT göre birçok avantaj sunmaktadır. MR, daha iyi yumuşak doku kontrastı ve iyonlaştırıcı radyasyona maruziyetin olmamasından dolayı tercih edilen görüntüleme yöntemidir (23). Hastalığın erken teşhis edilmesi, hayatta kalma olasılığını artıran zamanında tedavi ile sonuçlanabilir. Ancak tümör bölgelerinin genellikle belirsiz morfolojik yapılara sahip olması nedeni ile kötü huylu tümörlerin tespiti zorlaşmaktadır (10).

Manyetik Rezonans Görüntüleme: Beyin tümörlerinin tanı ve tedavi planlamasında MR, tümörün kesin konumu ve yaygınlığını ortaya koyan etkin görüntüleme tekniğidir (24). Radyo dalgaları ve güçlü manyetik alanlar kullanan MR, vücut organlarının ayrıntılı görüntülerini sağlayan invaziv olmayan bir görüntüleme tekniğidir (10). MR, T1/T2 gevşeme süreleri gibi doku parametreleri aracılığı ile üstün doku karakterizasyonu sağlayarak; T2 ve FLAIR sekansları, tümörün yaygınlığını ve ödemi göstererek genel değerlendirmeye olanak tanımaktadır. Kontrastlı T1 (T1c) ise tümör sınırlarının komşu normal dokulardan belirginleşmesine yardımcı olmaktadır (24).

MR ünitesinde, çocuk hastalara sedasyon veya genel anestezi verilmesi için en kritik gereksinim olan MR uyumlu ekipman (anestezi cihazı, aspiratör, hasta takip monitörü, SpO2, ETCO2, defibrilatör, vb.) ile donatılmış bir ortamda çekim yapılmasının sağlanması hasta güvenliği açısından önemlidir. Yapılacak sedasyon işlemi ve anestezi uygulanması ile birlikte çocuk hastalar ve kooperasyon kurulamayan hastaların MR çekimi sırasında hareket etmesi önlenerek elde edilen çekimin görüntü kalitesi artırılmaktadır (25).


3.3. Yapay Zeka

Bilgisayarların zeki davranabilmesi ve insan gibi sorgulayıcı düşünebilmesi fikri ilk olarak 1950 yılında Alan Turing tarafından ortaya atılmıştır (26). Turing, “*Bilgisayarlar ve Zekâ*” kitabında, bir makinenin zeki sayılabilmesi için insanla ayırt edilemeyecek şekilde iletişim kurabilmesi gerektiğini öne sürer. Bu fikir, sonradan "Turing Testi" olarak adlandırılmıştır (27).

Altı yıl sonra John McCarthy, 1956'daki Dartmouth Konferansı ile yapay zekayı bağımsız bir araştırma alanı haline getirmiştir. Yapay zeka (Artificial intelligence) için özel olarak LISP (LISt Processing, Liste İşleme) programlama dilini geliştirdi. Makinelerin mantık ve sembollerle akıl yürütebileceğini savunmuştur. Stanford'da uzun yıllar boyunca Yapay Zeka (AI) araştırmalarını yönetmiştir (28). Son zamanlarda AI teknolojilerinde yaşanan hızlı gelişmeler, sadece teknik ilerleme değil, aynı zamanda toplumsal yaşamın dönüşümünde de önemli bir dönüm noktası olmuştur. Makine öğrenmesi ve derin öğrenme alanlarındaki adımlar sayesinde, artık AI sadece bilimsel laboratuvarlarda değil, gündelik hayatta da yer almaktadır. Sağlık sektörü,

finans, e-ticaret, hukuk sistemi gibi pek çok sektörde AI uygulamaları verimliliği arttırmakta ve karar süreçlerini iyileştirmektedir. İnsan olarak bu teknolojilerin içinde yaşarken, bağımlılığımızın arttığını, kararlarımızın ve deneyimlerimizin daha çok algoritmalar tarafından şekillendirildiğini fark etmek düşündürücü olduğu kadar heyecan vericidir de. AI hayatımızın her konumuna gelmesi, büyük olanaklar sunarken aynı zamanda etik ve toplumsal boyutlarının dikkate alınması gereken yeni sorumluluk alanları yaratmaktadır (29).

Zamanla araştırmacılar, AI' ya dayalı yöntemlerin tıbbın çeşitli alanlarında nasıl kullanılabileceğini incelemeye başlamıştır. Cerrahi alandaki ilk AI uygulamalarına dair çalışmalar, 1976 yılında Gunn'un akut karın ağrısının tanısında bilgisayar analizlerinin kullanılabilirliğini araştırmasıyla ortaya çıkmıştır (30). Özellikle son yıllarda, tıpta AI' ya yönelik ilgi ve yatırımlar hızla artmıştır. Günümüzde modern tıbbın karşılaştığı en büyük zorluklardan biri, büyük ve karmaşık veri yığınlarını etkili bir şekilde toplamak, yorumlamak ve klinik uygulamalara entegre etmektir. Tıbbi AI bu noktada devreye girerek tanı koyma, tedavi planlama ve hastalıkların seyrini öngörme gibi süreçlerde doktorlara destek olmayı amaçlayan programların geliştirilmesiyle önem kazanmıştır. Bu tür sistemler, sağlık profesyonellerinin rutin işlerini kolaylaştırmak ve bilgi temelli karar süreçlerine katkı sağlamak için tasarlanmıştır (26). AI tarihsel gelişimi şekil 1'de verilmiştir.




Şekil 1. AI tarihsel gelişimi (31).

3.4. Makine Öğrenimi

Makinelerin verilerden öğrenmesini ve öğrendiklerini gelecekteki durumlara uygulamasını sağlayan bir yöntemdir. Artan veri miktarıyla birlikte, bu alana olan ilgi de hızla büyümektedir. İnsanların anlamlandırmakta zorlandığı büyük ve karmaşık veri kümeleri, makine öğrenimi (Machine Learning) teknikleriyle daha etkili şekilde analiz edilebilmektedir (32). Farklı sektörlerde yaygın olarak kullanılan makine öğrenimi, açıkça programlanmadan makinelerin öğrenmesini hedefler. Bu amaçla çeşitli algoritmalar geliştirilmiş olup her algoritmanın başarısı çözülecek problemin yapısına, veri türüne ve hedeflenen modele göre değişmektedir. Bu nedenle, en iyi sonucu elde etmek için doğru algoritmanın seçilmesi büyük önem taşır (33).

Bazı durumlarda, hazır ve tanımlı bir algoritmanın uygulanabilir bir çözüm sunmadığı ortamlar ortaya çıkabilir. Bu gibi senaryolarda Makine Öğrenimi (ML) teknikleri ön plana çıkar. Bu yöntemler, veriden doğrudan öğrenerek karar verme yeteneğine sahiptir ve önceden belirli bir yapı ya da kurala bağlı kalmaksızın çalışabilir. Böyle bir esneklik, ML' nin sağladığı en önemli faydalardan biridir (34). ML, AI' ın bir alt dalı olup dört temel çalışma modeline sahiptir: denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve takviyeli öğrenme. Hangi ML algoritmasının kullanılacağına karar verilirken öncelikle problem türü değerlendirilmelidir. Uygun yöntem seçilmediği takdirde, beklenen işlem başarıyla gerçekleştirilemeyebilir (35). Şekil 2' de ML algoritmaları verilmiştir.



Şekil 2. ML algoritmaları.

3.4.1. Denetimli öğrenme

Algoritmanın doğruluğu bilinen etiketli eğitici veriler üzerinde çalıştığı bir ML yaklaşımıdır. Örneğin, bir makine bileşenine ait veriler “F” (arıza) veya “R” (çalışır durumda) gibi etiketlerle sınıflandırılabilir. Bu süreçte, algoritma verilen girdilere karşılık doğru çıktıları alır, ardından kendi ürettiği sonuçlarla gerçek etiketler arasındaki hatayı değerlendirerek model parametrelerini yeniden düzenler (34). Sınıflandırma, regresyon, öngörü ve gradyan artırma gibi tekniklerle çalışan bu yöntem, daha önce etiketlenmemiş verilere ilişkin etiketleri tahmin etmek için öğrenilen kalıpları kullanır. Denetimli öğrenme, özellikle geçmiş verilerden yola çıkarak gelecekteki gelişmeleri öngörmeye yönelik uygulamalarda yaygın olarak tercih edilir (36).

Bu tez çalışmamız denetimli öğrenme kapsamında olup, kullanılan EfficientNetB4 ve YOLOv12 modelleri, beyin MR görüntülerinden elde edilen etiketli veriler üzerinde eğitilmektedir. Etiketli veri, her görüntüye karşılık gelen tümör pozitif ve tümör negatif sınıflandırması veya tümörün konumunu belirten bounding box bilgilerini içermektedir. Böylece model, girişte verilen görüntü ile çıktıdaki doğru etiket arasındaki ilişkiyi öğrenmekte ve yeni MR görüntülerinde benzer tahminler yapabilmektedir.

3.4.2. Denetimsiz öğrenme

Eğitim verileri yalnızca giriş değişkenlerinden oluşur; yani çıktı ya da etiket bilgisi bulunmaz veya bilinmez. Bu yaklaşımın temel hedefi, veri setinde yer alan gizli örüntüleri ve yapıları ortaya çıkarmaktır. Örneğin, kümeleme yönteminde benzer özellikler taşıyan veriler aynı gruplarda toplanırken, farklı özellikler taşıyan veriler farklı kümelerle ayrılır. Böylece, aynı kümedeki veriler arasındaki benzerlik en yüksek, kümeler arası farklılık ise en belirgin düzeyde olur (37). Boyut indirgeme görevlerinde ise yüksek boyutlu veriler daha sade, düşük boyutlu yapılara dönüştürülürken, verinin taşıdığı anlam korunmaya çalışılır. Denetimsiz özellik öğrenme ya da temsil öğrenme olarak adlandırılan bir başka yaklaşımda ise verilerin temel özellikleri doğrudan girişlerden elde edilir. Bu çıkarılan özellikler, verinin özünü yansıtmakla kalmaz, aynı zamanda sonraki analizler için de anlamlı ve kullanışlı bir temel sunar (38).

3.4.3. Yarı denetimli öğrenme

ML yaklaşımlarından biridir ve denetimli ile denetimsiz öğrenme arasında bir köprü görevi görür. Bu yöntemde kullanılan veri kümesi kısmen etiketlidir Yarı denetimli öğrenmenin temel amacı hem denetimli hem de denetimsiz öğrenmenin eksikliklerini gidermektir. Denetimli öğrenme; test verilerinin doğru şekilde sınıflandırılabilmesi için büyük miktarda etiketli veriye ihtiyaç duyar, bu ise maliyetli ve zaman alıcıdır (39). Denetimsiz öğrenme herhangi bir etiketli veriye gereksinim duymaz; veri noktaları arasındaki benzerliklere göre kümeleme veya maksimum olasılık yöntemleriyle çalışır. Ancak bu yöntem, daha önce görülmemiş verileri doğru şekilde gruplayamaz. Bu sorunlara çözüm olarak araştırmacılar tarafından yarı denetimli öğrenme önerilmiştir. Bu yaklaşım, az sayıda etiketli veriden öğrenerek bilinmeyen ya da test verilerini etiketleyebilir. Yarı denetimli öğrenme, birkaç etiketli örnekle bir model oluşturur ve kalan verileri test verisi olarak değerlendirir (40).

3.4.4. Takviyeli öğrenme

AI'nın çevresiyle etkileşim kurarak ve elde ettiği sonuçlara göre ödül ya da ceza alarak kendi deneyimlerinden öğrenmesini sağlayan bir yöntemdir. Bu yaklaşım, diğer ML tekniklerinden ayrılır çünkü hazır veri setlerine dayanmak yerine, öğrenme süreci deneme-yanılma yoluyla gerçekleşir (41). Takviyeli öğrenme sistemlerinde yer alan “etmen”, çeşitli durumlar karşısında farklı eylemler uygular ve bu eylemlerin ardından çevreden aldığı geri bildirimlerle hangi davranışların daha fazla ödül getirdiğini keşfeder. Nihai hedef, toplam ödülü en üst düzeye çıkarmaktır (42).


Bu alanda sıkça kullanılan algoritmalarından biri olan Q-learning, etmene hangi eylemin ne kadar fayda sağladığını öğrenme imkânı sunar ve bu süreci gerçekleştirirken çevrenin yapısal bir modeline ihtiyaç duymaz. Q-learning, derin öğrenme yöntemleriyle bir araya getirildiğinde ise “Derin Takviyeli Öğrenme” adını alır. Bu birleşim, özellikle karmaşık ortamlar ve büyük veri içeren senaryolarda etkili ve esnek karar mekanizmalarının oluşturulmasını mümkün kılar. Ayrıca, Çift Q-learning gibi gelişmiş teknikler, geleneksel algoritmaların daha verimli hale getirilmesi için geliştirilmiştir (43).

3.5. Derin Öğrenme

ML'nin bir alt alanıdır ve temelinde çok katmanlı yapay sinir ağları yer alır. Bu nedenle, bu yöntemler genellikle "derin sinir ağları" olarak adlandırılır. Derin öğrenme (Deep Learning), verilerden anlamlı özellikler çıkarmak ve bu özellikleri dönüştürmek için çok katmanlı ve doğrusal olmayan işlem basamaklarını kullanır (44). Alt katmanlar daha basit ve temel özellikleri öğrenirken, üst katmanlar bu bilgileri kullanarak daha karmaşık yapıları ortaya çıkarır. Bu katmanlı yapı, güçlü ve hiyerarşik bir öğrenme süreci sağlar. Derin Öğrenme (DL) bu sayede, büyük veri kümelerini ve farklı kaynaklardan gelen verileri analiz ederek anlamlı sonuçlar üretme konusunda oldukça başarılıdır (45).

3.5.1. Evrişimli sinir ağı

Nöron benzeri hesaplama bağlantılarının çok katmanlı yapısından oluşan ve adım adım minimal işlemeyi temel alan bir mimaridir. Bu yapı, bilgisayarlı görme alanında önemli ilerlemelerin kaydedilmesini sağlamıştır. Evrişimli sinir ağı (Convolutional Neural Network) öğrenme süreci, hayvanların görsel korteksinin çalışma prensibini taklit eder ve başarılı bir şekilde eğitildiğinde görüntü sınıflandırma sürecinde kenar, şekil, bileşen ve nesne düzeyinde hiyerarşik bilgi çıkarımı yapabilir (46). Evrişimli Sinir Ağı (CNN)'nin temel mimarisi; evrişimsel katmanlar, havuzlama katmanları ve tam bağlantılı katmanlardan oluşmaktadır. Evrişimsel katmanların ana görevi; görüntülerdeki kenar, çizgi ve diğer ayırt edici yerel görsel öğeleri tespit etmektir. Evrişim işlemi sırasında, öğrenilmiş parametrelerden oluşan küçük çekirdekler (kernel), belirli bir pikselin komşu pikselleriyle matematiksel çarpımlar yaparak özellikleri çıkarır. Bu çekirdekler aracılığıyla öğrenilen özellikler, görsel kortekste gözlemlenen kenar ve renk algısına benzer şekilde görsel bilgilerin hiyerarşik olarak elde edilmesini sağlar (47). CNN mimarisi şekil 3'te verilmiştir.



Şekil 3. CNN mimarisi (48).


3.5.2. Derin evrişimli sinir ağı ve mimarilerinin evrimi

Derin CNN'lerin gelişimi, özellikle tıbbi görüntü analizinde görüntü tanımda önemli ilerlemeler sağlamıştır. Krizhevsky ve arkadaşları tarafından 2012 yılında geliştirilen AlexNet, bilgisayarla görme alanında derin CNN mimarilerinin öne çıkmasında dönüm noktası olmuştur (44). Bu model, büyük veri kümeleri ve GPU'lar kullanılarak derin ağların etkin bir şekilde eğitilebileceğini kanıtlamış ve ImageNet görsel tanıma yarışmasında çığır açan sonuçlar elde etmiştir. Bu gelişmenin ardından U-Net, ResNet ve EfficientNet gibi yenilikçi mimariler, kaybolan gradyanlar, hesaplama verimsizliği ve piksel düzeyinde segmentasyon gibi temel sorunlara çözüm getiren yeni yaklaşımlar sunmuştur. Bu mimariler, tıbbi görüntüleme alanında yaygın olarak benimsenmeleri ve etkin performansları nedeniyle tercih edilmiştir.

3.5.2.1. AlexNet

Rektifiye edilmiş lineer ünite (Rectified Linear Unit) aktivasyon fonksiyonları, dropout düzenleme yöntemi ve grafik işlemci ünitesi (graphics processing unit) tabanlı eğitim gibi yeniliklerle DL alanında büyük bir dönüşüm yaratmıştır. Bu yenilikler sayesinde daha derin ağlar büyük veri kümeleri üzerinde etkili bir şekilde eğitilebilmiştir. Mimari yapısı beş evrişimli katman ve üç tam bağlantılı katmandan oluşmakta olup tüm yapı boyunca maksimum havuzlama ve Rektifiye Edilmiş Lineer Ünite (ReLU) aktivasyonları içermektedir (49). Modelin elde ettiği başarı, DL'nin görüntü sınıflandırmadaki potansiyelini açıkça ortaya koymuş ve bu alanın tıbbi görüntü analizine uyarlanmasında önemli bir rol oynamıştır. Özellikle dropout gibi düzenleme teknikleri, hastalık sınıflandırması ve organ segmentasyonu gibi görevlerde


yaygın olarak kullanılan CNN mimarilerinde standart bir uygulama haline gelmiştir (50). AlexNet mimarisi şekil 4’te verilmiştir.



Şekil 4. AlexNet mimarisi (51).

3.5.2.2. VGGNet


Görsel Geometri Grubu (Visual Geometry Group) 16 katmandan oluşan ve 3x3 boyutlarında evrişim filtreleri içeren basit ama derin bir mimariye sahiptir. Katmanların hiyerarşik olarak yığılması, özellikle görüntü sınıflandırma görevlerinde ayrıntılı desenleri öğrenmek için bu modeli oldukça uygun kılar (52). Bununla birlikte, mimarinin derinliği hesaplama açısından yüksek maliyetli olmasının yanı sıra, düşmanca girişlere karşı da savunmasız hale getirebilir; çünkü küçük bozulmalar çok sayıda katmanda yayılma eğilimi gösterir. Ayrıca katmanlar arasında özgün bağlantıların ve daraltıcı yapıların bulunmaması, modelin performansını daha da kırılgan hale getirebilmektedir (53). VGGNet ağının mimarisi şekil 5’te verilmiştir.



Şekil 5. VGGNet ağıının mimarisi (54).

3.5.2.3. Artık sinir ağıları


Yaygın olarak kullanılan CNN türlerinden biri olan Artık Sinir Ağları (Residual Network), giriş verilerinden bilgi çıkarma yeteneğini artırarak bilgi kaybı sorununu etkili bir biçimde çözmektedir. Bu başarı, ağ katmanları boyunca geçişi mümkün kılan bypass bağlantıları ya da alternatif yollar içeren özdeş eşleme mekanizmasıyla sağlanmaktadır (55). Artık Sinir Ağları (ResNet) mimarisi, bu yaklaşım sayesinde 152 katmana kadar derinleşebilmektedir. Geleneksel yöntemlerin aksine, ResNet her katmanda doğrudan hedef fonksiyonları öğrenmek yerine, giriş verisine göre artık fonksiyonları öğrenmeyi amaçlayarak bu süreci yeniden yapılandırır. (56). ResNet mimarisi şekil 6’da verilmiştir.



Şekil 6. Temel ResNet bloğu (57).

3.5.2.4. Inception-v3

GoogLeNet'in geliştirilmiş bir versiyonudur ve hesaplama verimliliğini artırmak için faktörizasyon yöntemlerini kullanır. Kök ortalama karesel yayılım (Root mean square propagation) optimizasyonu, batch normalization ve label smoothing gibi tekniklerle aşırı öğrenme ve gradyan sorunları azaltılmıştır. 42 katmanlı olan model yaklaşık 24 milyon parametre içerir ve farklı boyutlardaki filtreleri kullanarak yüksek performans sağlar (58). Inception V3 modeli şekil 7'de verilmiştir.




Şekil 7. Inception V3 modeli (59).

3.5.2.5. EfficientNet

Bir dizi CNN mimarisi olarak değerlendirilebilir ve bu seri, B0'dan B7'ye kadar toplam sekiz farklı yapıdan oluşur. Bu modellerde seviye arttıkça doğruluk oranı önemli ölçüde yükselirken parametre sayısındaki artış nispeten sınırlı kalır.

EfficientNet’i diğer CNN mimarilerinden ayıran başlıca farklardan biri, geleneksel ReLU aktivasyon fonksiyonu yerine Swish adlı daha yeni bir aktivasyon fonksiyonunu tercih etmesidir (6). Ayrıca bu model, derinlik, genişlik ve çözünürlük boyutlarını eş zamanlı ve dengeli şekilde ölçekleyen bileşik bir yaklaşım kullanarak daha küçük boyutlu yapılarda dahi etkili performans sunar. Bu ölçekleme stratejisinde ilk adım, sabit kaynak sınırları altında farklı yapıların nasıl ölçekleneceğine dair ilişkileri tanımlamak amacıyla bir ızgara araması gerçekleştirmektir. Bu arama sonucunda elde edilen ölçekleme katsayıları, temel modelin istenilen büyüklükteki hedef yapıya dönüştürülmesinde kullanılır (60). EfficientNet mimarisi şekil 8’de verilmiştir.



Şekil 8. EfficientNet'in şematik gösterimi (61).

EfficientNet temel modelleri için giriş şekilleri tablo 1’de verilmiştir.

Tablo 1. B0 ile B7 arasındaki temel modeller için giriş şekilleri (62).


Model	Çözünürlük
EfficientNetB0	224
EfficientNetB1	240
EfficientNetB2	260
EfficientNetB3	300
EfficientNetB4	380
EfficientNetB5	456
EfficientNetB6	528
EfficientNetB7	600

Bu çalışmada, AlexNet, derin CNN mimarisini ilk kez büyük ölçekli bir yarışmada (2012 yılında düzenlenen ImageNet Large Scale Visual Recognition Challenge (ILSVRC-2012)) başarıyla uygulayarak bu alandaki çalışmalara öncülük etmiştir. VGGNet, daha derin ve sade mimarisi ile doğruluğu artırmış, ResNet ise residual bağlantılar sayesinde çok daha derin ağların eğitilebilmesini mümkün kılmıştır. Inception-v3 mimarisi ise farklı filtre boyutlarını aynı anda kullanarak çok yönlü özellik çıkarımı sağlamıştır. Tezimiz kapsamında kullanılan EfficientNet mimarisi, ResNet ve VGGNet'in sağladığı derinlik ve verimliliği birleştirmektedir.

3.5.2.6. Sadece bir kez bakarsın (You Only Look Once)

Redmon ve arkadaşları tarafından 2015 yılında tanıtılmış olup, bölge önerisi ve sınıflandırmayı tek bir sinir ağı yapısında birleştirerek gerçek zamanlı nesne tespitte çığır açmıştır. Sadece bir kez bakarsın (You Only Look Once)'nın birleşik mimarisi, görüntüyü bir ızgaraya bölerek her hücre için doğrudan sınıf olasılıklarını ve sınırlayıcı kutuları tahmin eder; bu sayede uçtan uca öğrenme mümkün hale gelirken hesaplama süresi de büyük ölçüde azaltılmıştır (63). Bir görüntüye yalnızca bir kez bakarak nesneleri tanımlamayı mümkün kılar. Sadece Bir Kez Bakarsın (YOLO), evrimsel bir sinir ağı kullanarak aynı anda birden fazla nesneyi ve konumunu tespit eder. Hızlı ve basit yapısı sayesinde gerçek zamanlı uygulamalarda etkilidir. Ayrıca görüntünün tamamını değerlendirdiği için bağlamsal bilgi yakalayabilir ve farklı alanlara iyi genelleme yapabilir. Ancak, küçük nesneleri tespit etme konusunda hâlâ bazı zorluklar yaşamaktadır ve doğruluk açısından bazı gelişmiş sistemlerin gerisinde kalmaktadır (64).

YOLO serisi, gerçek zamanlı nesne tespitte mimari yenilikler ve performans iyileştirmeleriyle çığır açmıştır. Serinin gelişimi, her biri önemli ilerlemeler sunan farklı sürümler aracılığıyla izlenebilmektedir. YOLO mimarisinin evrimi şekil 9'da verilmiştir.




Şekil 9. YOLO mimarilerinin evrimi (65).

Yolov12: Serinin en güncel sürümü olup dikkat odaklı tasarımıyla hem hız hem de doğruluk açısından önemli gelişmeler sunmaktadır. Nano'dan Extra Large'a kadar beş ölçeklenebilir modelle gelen bu versiyon, nesne tespiti, örnek segmentasyonu ve döner sınırlayıcı kutu gibi çeşitli görevlerde esnek kullanım imkânı sağlar (66).

YOLOv12, geniş alansal algıyı korurken hesaplama yükünü ciddi şekilde azaltan area attention (A2) modülünü tanıtarak, doğruluktan ödün vermeden hız kazancı elde eder. Bununla birlikte, blok düzeyinde artık bağlantılar ve optimize edilmiş özellik birleştirme yoluyla eğitim sürecinde kararlılığı ve yakınsama başarısını artıran artık verimli katman toplama ağları (Residual efficient layer aggregation networks) mimarisi kullanır (67). Ayrıca FlashAttention teknolojisi ile bellek erişim yükü azaltılarak, CNN'lerle olan hız farkı kapatılmış olur.

Çok katmanlı algılayıcı oranı 4'ten 1,2'ye düşürülerek çalışma verimliliği artırılmış, konumsal kodlamalar kaldırılarak daha sade ve hızlı bir yapı oluşturulmuştur. Son aşamada üçlü blok yığmak yerine tek bir Artık Verimli Katman Toplama Ağı (R-ELAN) bloğu kullanılarak karmaşıklık azaltılmış, doğrusal katmanlar yerine evrişimsel katmanlar ve batch normalization tercih edilerek hesaplama etkinliği en üst düzeye çıkarılmıştır. Bu sayede, YOLOv12, gecikme-doğruluk dengesinde alanın en ileri modellerinden biri olmayı başarmıştır (68).

YOLOv12'nin gelişmiş nesne algılama yetenekleri, özellikle küçük boyutlu veya karmaşık yapılı nesnelerin tespitinde sergilediği yüksek performans sayesinde sağlık hizmetlerinde tıbbi görüntüleme verilerinin analizinde büyük değer taşımaktadır (67). YOLOv12 diyagramı şekil 10'da verilmiştir.



Şekil 10. YOLOv12 mimarisi diyagramı (69).

Bu çalışmada kullanılan, YOLOv12 modeli, Inception-v3'ün çok ölçekli özellik çıkarımına benzer şekilde farklı boyutlardaki tümörleri tespit edebilme yeteneği ile öne çıkmaktadır.

Yolo değerlendirme metrikleri: Nesne tespitinde model performansı genellikle model ortalama ortalama hassasiyet (Mean Average Precision), modelin başarısını ölçen "altın standart" metriktir. AP ve birleşim üzerindeki kesişim (intersection over union) gibi metriklerle ölçülmektedir. Ortalama ortalama hassasiyet (mAP), sınıflar genelinde doğruluk ve duyarlılığı dikkate alırken; AP, kesinlik-duyarlılık eğrisi altında kalan alanı ifade eder. Birleşim Üzerindeki Kesişim (IoU) ise tahmin edilen kutu ile gerçek kutu arasındaki örtüşme oranını gösterir (70).

3.5.3. Model performanslarının değerlendirilmesi

Görüntü sınıflandırma, insan vücudundaki hayati organlarda oluşabilecek kanserli tümörleri belirleme ve tahmin etmede sağlık alanında kritik bir işlev üstlenir. Farklı algoritmaların hastalık öngörülerindeki başarımı; doğruluk, kesinlik ve F1 skoru gibi metrikler kullanılarak ölçülebilir. Hassasiyet ve özgüllük ise gerçek pozitif (TP),

gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) değerleriyle ilişkili olarak sınıflandırmanın doğruluğunu ifade eder.

Derin öğrenme uygulamalarında, görüntü sınıflandırmanın etkinliğini değerlendirmek için kullanılan başlıca araçlardan biri de karışıklık matrisidir. Hata matrisi olarak da adlandırılan bu yapı, sınıflandırma sonuçlarını tablo biçiminde sunarak tahminlerin doğruluğunu görselleştirir. Matriste yer alan satırlar gerçek sınıflara, sütunlar ise modelin tahmin ettiği sınıflara karşılık gelir. Diyagonal üzerindeki hücreler doğru tahminleri, diyagonal dışındaki hücreler ise hatalı sınıflandırmaları temsil eder (71). İkili karışıklık matrisi örneği tablo 2’de verilmiştir

Tablo 2. İkili karışıklık matris örneği

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Doğruluk (Accuracy): Modelin yaptığı tüm tahminlerin ne kadar isabetli olduğunu gösteren bir performans ölçütüdür. Bu metrik, denklem 1’de belirtilen formül ile hesaplanır.

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

Özgüllük (Specificity): Gerçek negatif örneklerin toplam negatif örneklere oranı olarak hesaplanır. Başka bir deyişle, modelin negatif sınıfa ait verileri doğru bir şekilde tahmin etme başarısını gösterir. Denklem 2’de belirtilen formül ile hesaplanır.

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (2)$$

Kesinlik (Precision): Kesin, doğru olduğu tahmin edilen pozitif vakaların oranıdır. Modelin kesinliğini göstermektedir. Kesinlik, özellikle hatalı olarak olumlu

sonuç verilen durumların önlenmesinin kritik olduğu alanlarda tercih edilmektedir. Metrik denklem 3'te belirtilen formül ile hesaplanır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3)$$

Duyarlılık (Recall): Modelin doğru şekilde pozitif olarak sınıflandırdığı örneklerin oranını gösteren bir ölçüttür. Başka bir deyişle, gerçek pozitif örnekler içerisinde modelin doğru olarak tanımlayabildiklerinin yüzdesini ifade eder. Denklem 4'te belirtilen formül ile hesaplanır.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4)$$

F1 Skoru: Bir modelin hassasiyet ve duyarlılık değerlerini dengeli şekilde yansıtan harmonik veya ağırlıklı ortalamadır. Yanlış negatif ve yanlış pozitiflerin, doğru pozitif ve doğru negatiflere kıyasla daha önemli olduğu durumlarda doğruluğu değerlendirmek için tercih edilen bir metriktir. Bu metrik, denklem 5'te belirtilen formül ile hesaplanır.

$$\text{F1 Skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

3.5.4. Kayıp (Loss)

Modelin tahmin ettiği sonuç ile gerçek değer arasındaki farkı ölçen bir değerdir. Eğitim sırasında model parametreleri bu değeri minimuma indirmek için güncellenir. Yani loss, modelin ne kadar "yanıldığını" gösterir. Loss değeri 0'a yaklaştıkça modelin tahminleri gerçek değerlere o kadar yaklaşmış olur (72). Loss değerleri tablo 3'te verilmiştir.

Tablo 3. Loss değerleri

Loss değeri (Yaklaşık)	Yorum
$\leq 0,1$ (Çok düşük)	Model veriyi çok iyi öğrenmiş.
0,3 – 0,6 (Orta seviye)	Model öğrenmeye devam ediyor, kabul edilebilir sonuç.
$\geq 1,0$ (Yüksek)	Model yeterince öğrenememiş olabilir.

3.5.3.5. Epoch

Makine öğreniminde epoch, modelin eğitim verilerinin tamamını bir kez baştan sona işlemesi anlamına gelir. Bu süreçte her bir örnek modele sunulur, hata oranı hesaplanır ve modelin parametreleri buna göre güncellenir. Tek bir epoch genellikle yeterli olmadığından eğitim süreci birden fazla epoch ile yürütülür. Böylece model her turda parametrelerini iyileştirerek daha doğru sonuçlar üretmeye başlar.

Epoch sayısı ve erken durdurma (Early stopping): Model genellikle yüksek epoch sayıları (örneğin 100) ile eğitilir. Ancak aşırı eğitimi önlemek için early stopping tekniği kullanılır. Bu yöntem, doğrulama kaybı iyileşmediğinde eğitimi durdurarak hem zaman hem de kaynak tasarrufu sağlar.

Öğrenme oranı azaltma (Learning rate decay): Öğrenme oranı, modelin her güncellemede ne kadar büyük adımlar atacağını belirler. Yüksek oran modelin doğru çözüme ulaşmasını engellerken düşük oran öğrenmeyi yavaşlatır. Learning rate decay, eğitim ilerledikçe öğrenme oranının kademeli olarak düşürülmesini sağlar. Bu sayede başlangıçta büyük adımlarla hızlı öğrenme gerçekleşirken sonlara doğru daha küçük adımlarla daha hassas ayarlamalar yapılır (73).

Sonuç olarak, epoch sayısı modelin performansını doğrudan etkileyen kritik bir parametredir. Bu nedenle veri seti, model karmaşıklığı ve kullanılan optimizasyon teknikleri göz önünde bulundurularak dikkatli şekilde belirlenmelidir.

4. GEREÇ ve YÖNTEM

4.1. Araştırma Tasarımı ve Evreni

Bu çalışma, metodolojik bir araştırma olup, araştırmanın evrenini 2010–2024 yılları arasında üçüncü basamak sağlık hizmeti sunan Dicle Üniversitesi Tıp Fakültesi Hastanesi'ne başvuran pediatrik hastaların (1–17 yaş) beyin manyetik rezonans (MR) görüntülerinden oluşturmaktadır. Görüntüler, Philips Achieva marka 1.5 ve 3 Tesla MR cihazları ile elde edilmiştir. Cihazlardan 3 Tesla sistem 2005 yılında güncellenmiş, 1.5 Tesla sistem ise 2022 yılında modernize edilmiştir. MR görüntüleri retrospektif olarak değerlendirilmiştir.

Örneklem büyüklüğü, G*Power 3.1.9.7 programı kullanılarak ve Cohen'in etki büyüklüğü kriterleri referans alınarak hesaplanmıştır (74). Etki büyüklüğü 0,35, alfa değeri 0,05 ve test gücü 0,95 olarak belirlenmiş; bu doğrultuda her biri 224 bireyden oluşan iki grup için toplam minimum örneklem büyüklüğü 448 olarak tespit edilmiştir.

Çalışmaya, radyoloji uzmanları tarafından beyin tümörü olarak raporlanmış ve patolojik tanı ile doğrulanmış 230 hasta ile beyin tümörü saptanmamış 230 hasta olmak üzere toplam 460 hastaya ait beyin MR görüntüleri dahil edilmiştir. Her hastadan üç farklı düzlemde [sagittal (soldan sağa), aksiyel (yukarıdan aşağıya) ve koronal (arkadan öne)] alınan görüntülerle toplam 1380 MR görüntüsü elde edilmiş ve analiz edilmiştir. Hastalar, "tümör pozitif" ve "tümör negatif" olmak üzere iki gruba ayrılmıştır. Görüntüler, retrospektif olarak Hastane Bilgi Yönetim Sistemi (HBYS) üzerinden temin edilerek değerlendirilmiştir. Bu çalışmada sunulan bazı şekiller Canva (www.canva.com) görsel tasarım platformu kullanılarak oluşturulmuştur.

4.2. Değişkenler

Bağımlı Değişkenler:

- Beyin MR görüntülerinde tümör sınıflandırma sonucu (tümör pozitif / tümör negatif).
- Derin öğrenme modellerine ait performans metrikleri: doğruluk, duyarlılık, kesinlik, F1 skoru ve ortalama ortalama doğruluk (mean Average Precision) değerleri.

Bağımsız Değişkenler:

- Kullanılan derin öğrenme modelleri (EfficientNetB4, YOLOv12).
- Görüntü özellikleri: çözünürlük (380 piksel ve 512 piksel), görüntü düzlemi (aksiyel, sagittal, koronal).
- Model eğitimiyle ilgili parametreler: epoch sayısı, batch size, öğrenme oranı (learning rate).
- Veri setinin bölünme oranları: eğitim, doğrulama ve test alt kümeleri.

4.3. Araştırma Hipotezleri

H₀ (Null Hipotezi): EfficientNetB4 ve YOLOv12 modelleri, beyin MR görüntülerinde tümör varlığını sınıflandırmada istatistiksel olarak anlamlı bir performans göstermemektedir.

H₁ (Alternatif Hipotez): EfficientNetB4 ve YOLOv12 modelleri, beyin MR görüntülerinde tümör varlığını sınıflandırmada istatistiksel olarak anlamlı bir performans göstermektedir.

4.4. Dahil Etme ve Hariç Tutma Kriterleri

Çalışmaya dâhil edilme koşulları aşağıdaki gibidir:

- 18 yaşın altındaki pediatrik bireyler,
- Beyin MR raporlarında radyoloji uzmanlarınca tümör ön tanısı konulmuş ve patolojik tanı ile doğrulanmış hastalar,
- Radyoloji uzmanlarınca MR görüntüleri normal olarak raporlanan hastalar,
- Görüntü kalitesi tanısal değerlendirme yapmaya elverişli olan MR görüntüleri.


Aşağıdaki özelliklere sahip olgular çalışmaya dâhil edilmemiştir:

- 18 yaş ve üstü bireyler,
- Beyin tümörü dışında başka bir patolojisi bulunan hastalar (örneğin: travmatik beyin hasarı, hematoma, kistik yapılar, Multipl Skleroz vb.),
- MR görüntülerinde ciddi düzeyde artefakt bulunan hastalar.

4.5. Makine Öğrenimi Modelleri ve İstatistiksel Analizler

Hastane Bilgi Yönetim Sistemi'ndeki radyoloji uzmanları tarafından raporlanmış ve PACS (Picture Archiving and Communication System-Görüntü Saklama ve


İletişim Sistemleri) üzerinden temin edilen görüntüler, makine öğrenme yöntemi ile değerlendirilmiştir. Makine öğrenme aşamaları; Raporlanmış ve PACS sistemi üzerinden alınan MR görüntüleri toplanmıştır. Görüntüler yeniden boyutlandırılmış, normalize edildikten sonra eğitim, doğrulama ve test setlerine ayrılmıştır. CNN tabanlı derin öğrenme modeli kurulmuştur. Eğitim seti ile modelin ağırlıkları optimize edilmiş, doğrulama seti ve aşırı öğrenme kontrol edilmiştir. Yaş, cinsiyet ve benzeri demografik değişkenlerin analizinde SPSS (IBM Corp. Released 2012. IBM SPSS Statistics for Windows, Version 21.0. Armonk, NY: IBM Corp.) programı kullanılmıştır. Verilerin normallik dağılımı Kolmogorov-Smirnov testi ile değerlendirilmiştir. Gruplar arasındaki karşılaştırmalarda parametrik veriler için bağımsız örneklem t testi, parametrik olmayan veriler için Mann-Whitney U testi uygulanmıştır. Kategorik değişkenler arasındaki ilişkiler Ki-Kare testi ile analiz edilmiştir. İstatistiksel anlamlılık düzeyi $p < 0.05$ olarak kabul edilmiştir.




Şekil 11. Araştırmanın metodolojisi

CNN: İkili sınıflandırma amacıyla CNN mimarisinden EfficientNetB4 modeli kullanılmıştır. Veri seti, makine öğrenme eğitimi %80 ve test %20 olarak ayrılmış, görüntü boyutları 380 piksel çözünürlüğüne dönüştürülmüş ve eğitim sürecinde epoch sayısı dikkate alınmıştır. Epoch sayısı modelin eğitim bilgilerinin tamamından öğrenileceğini belirleyen, modelin nihai performansını ve doğrudan etkileyen önemli

bir parametredir. Çalışmamızda epoch sayısı, makine eğitimi sürecinde model tarafından optimum 24 epochs ile yürütüldü.




Şekil 12. CNN yönteminin şematik gösterimi




Şekil 13. Beyin MR görüntülerinde tümör negatif ve tümör pozitif örnekler

YOLO: Tümör bölgelerinin yer tespiti için YOLO versiyon 12 modeli kullanılmıştır. Görüntülerin manuel etiketlenmesi Roboflow platformu aracılığıyla yapılmıştır. Veri seti, eğitim %80, doğrulama %10 ve test %10 olmak üzere üç alt kümeye ayrılmıştır. Görüntü boyutları 512 piksel çözünürlüğüne dönüştürülmüştür. Eğitim 74 epochs ile yürütülmüştür. Eğitim sürecinde model farklı simülasyonlarla test edilerek hiper parametreleri optimize edilmiştir.




Şekil 14. YOLO yönteminin şematik gösterimi



Şekil 15. Veri setinin dağılımı.

Şekil 12’de örnek MR görüntüleri ve veri setinin dağılım oranları sunulmaktadır. Bu dağılım, modelin genelleme kabiliyetini artırmak ve aşırı öğrenmeyi önlemek amacıyla tercih edilmiştir.



Şekil 16. Roboflow ile işaretlenmiş tümör pozitif (sol) ve tümör negatif (sağ) MR görüntüsü

4.6. Model Eğitimi ve Değerlendirme

Model eğitimi ve değerlendirme sürecinde Python programlama dili kullanılmıştır (Python Software Foundation. (2025). Python (Version 3.x) [Computer software]. Python Software Foundation. <https://www.python.org/>). Python programlama dili ile ön işleme adımları yapılarak netliğini artırılmış, çözünürlük ise modeli eğitmek için uygun formata getirilmiştir. CNN mimarisi ile hastalar tümör pozitif ve negatif şeklinde sınıflandırılmış; tümörlerin yer tespitinde ise YOLO derin öğrenme mimarisi kullanılmıştır. Araştırmamızda makine öğrenme yöntemi, EfficientNetB4 ve YOLOv12 mimarileri olarak modellenmiştir.

Görüntülerin manuel etiketlenmesi Roboflow platformu aracılığıyla yapılmıştır (Roboflow: Organize, annotate, and train computer vision models. Retrieved [10.07.2025], from <https://roboflow.com>). Veri işleme ve eğitim adımları ise Google Colab Notebook (Google. (n.d.). Colaboratory. Retrieved from <https://colab.research.google.com/>) ortamında gerçekleştirilmiştir.

Modellerin performanslarını ölçmek amacıyla doğruluk, hassasiyet, duyarlılık ve F1 skoru gibi metrikler kullanılmıştır. Bu ölçütler hem tümör tespiti hem de tümör pozitif-tümör negatif sınıflandırmasının doğruluğunu değerlendirmek için hesaplanmıştır. Bulgular, EfficientNetB4 ve YOLOv12 modellerinin karşılaştırmalı analizine tabi tutulmuş, beyin tümörü tespitinde en iyi performansı sağlayan CNN modeli belirlenmiştir. ML tabanlı AI yöntemleri beyin tümörü sonuçları ve radyoloji uzmanlarının raporlarındaki tanıların doğruluğu ile güvenilirliği karşılaştırılmıştır.

4.7. Araştırmanın Kısıtlılıkları

- Veriler yalnızca Dicle Üniversitesi Tıp Fakültesi Hastanesi'nden elde edilmiştir. Bu durumun farklı merkezlerden toplanacak verilerle genellenebilirliği sınırlayabilmektedir.
- Çalışmamızda 460 hasta ve 1380 MR görüntüsü kullanılmıştır. Daha büyük ve çok merkezli veri setleri modelin performansını ve genellenebilirliğini artırabilmektedir.
- MR görüntüleri retrospektif olarak değerlendirildiği için görüntü kalitesi üzerinde ek bir işlem veya herhangi bir müdahalede bulunulmamıştır.

- Görüntülerin manuel etiketlenmesi insan hatasına açık olup, modelin eğitiminde sınırlayıcı bir faktör olabilmektedir.
- Model eğitimi belirli bir donanım kapasitesiyle yapılmış olup, daha yüksek donanım gücü ile hiper parametre optimizasyonu daha geniş kapsamlı yapılabilirdi.

4.8. Etik Onay ve Kurumsal İzin

Araştırma öncesi Helsinki Deklarasyonu'na uygun Dicle Üniversitesi Tıp Fakültesi Girişimsel Olmayan Klinik Araştırmaları Etik Kurulundan (16.04.2025 tarih ve 154 sayılı karar) onay alınmış ve Dicle Üniversitesi Hastaneleri Başhekimliğinden kurum izni (18/06/2025 tarih ve 944870 sayılı karar) alınmıştır.


5.BULGULAR

Bu çalışmada beyin MR görüntülerinde tümör tespitine yönelik geliştirilen derin öğrenme modellerinin performans sonuçları sunulmaktadır. Çalışmada CNN tabanlı EfficientNetB4 ve nesne yer tespiti için YOLOv12 mimarisi kullanılmıştır. Modellerin doğruluk, kesinlik, duyarlılık, F1 skoru ve ortalama ortalama doğruluk (mAP) gibi performans metrikleri üzerinden değerlendirilmiştir. Elde edilen bulgular tablolar ve grafikler aracılığıyla ayrıntılı olarak sunulmuştur. Sonuçlar, kullanılan mimarilerin tümör pozitif ve tümör negatif MR görüntülerini ayırt etmedeki etkinliğini ortaya koyacak şekilde karşılaştırmalı olarak verilmiştir. Çalışmada kullanılan toplam 460 pediatrik hasta ve 1380 MR görüntüsü üzerinde ayrı ayrı kapsamlı bir biçimde değerlendirilmiştir. Hastaların yaş ortalaması $9,42 \pm 5,25$ yıldır. Tablo 4'te, yaş gruplarına göre tümör pozitif ve tümör negatif olguların cinsiyet dağılımları gösterilmiştir (75).

Tablo 4. Tümör pozitif ve tümör negatif cinsiyet dağılımı.

	Cinsiyet				
	Kadın		Erkek		Toplam
	Pozitif	Negatif	Pozitif	Negatif	
1-4 Yaş	27 (25,5)	27 (25,5)	26 (24,5)	26 (24,5)	106 (23,1)
5-9 Yaş	23 (21,3)	23 (21,3)	31 (28,7)	31 (28,7)	108 (23,5)
10-14 Yaş	39 (35,5)	39 (35,5)	34 (31,5)	34 (31,5)	146 (31,7)
15-17 Yaş	21 (19,1)	21 (19,1)	29 (27)	29 (27)	100 (21,7)
Toplam	110 (23,9)	110 (23,9)	120 (26,1)	120 (26,1)	460 (100)

Yaş gruplarına göre tümör pozitif ve tümör negatif cinsiyetlere göre dağılımında anlamlı bir farklılık gözlenmemiştir ($p>0,05$). Kadın ve erkek bireylerde tümör pozitif-tümör negatif oranlarının birbirine yakın seyretmesi, örneklem grubunda cinsiyetin tümör varlığı üzerinde belirleyici bir faktör olmadığını göstermektedir.



Şekil 17. Beyin tümörünün eğitim ve doğrulama kayıpları ile doğrulukları


Eğitim sürecine ait grafikler incelendiğinde, eğitim ve doğrulama kayıp değerlerinin epoch sayısı arttıkça düzenli olarak azaldığı görülmektedir. En düşük doğrulama kaybı 24. epoch'ta elde edilmiştir. Doğruluk grafiğinde ise hem eğitim hem de doğrulama doğruluğunun epoch sayısı ile arttığı gözlenmiştir. En yüksek doğrulama doğruluğu 19. epoch'ta elde edilmiştir. Eğitim ve doğrulama eğrilerinin birbirine yakın seyretmesi, modelin aşırı öğrenme (overfitting) yapmadığını göstermektedir.

Tablo 5. Eğitim ve test aşamalarındaki kayıp ve doğruluk değerleri.

Metrik	Eğitim kümesi (%)	Test kümesi (%)
Kayıp	0,458	0,521
Doğruluk	0,996	0,971

*Yüzde ve oran olarak açıklanmıştır.

Modelin eğitim sonuçlarına göre, eğitim setinde kayıp değeri 0,46 doğruluk oranı ise %99,64 olarak elde edilmiştir. Test setinde ise kayıp değeri 0,52 olup doğruluk oranı %97 olarak bulunmuştur.



Şekil 18. CNN modeline ait karışıklık matrisi.

Karışıklık matrisi incelendiğinde, Tümör pozitif sınıfa ait 131 örnek doğru tahmin edilmiş, 7 örnek ise tümör negatif olarak hatalı sınıflandırılmıştır. Tümör negatif sınıfa ait 137 örnek doğru tahmin edilirken 1 örnek ise doğru tahmin edilmemiştir.

Tablo 6. Geçerlilik değerlendirme tablosu

	Doğru Etiket		Toplam
	Tümör Negatif (n)	Tümör Pozitif (n)	
Tahmini Etiket			
Tümör Negatif	137	7	144
Tümör Pozitif	1	131	132
Toplam	138	138	276

Modelin Duyarlılık %95, özgünlük %99, kesinlik %99, doğruluk %97 ve F1 skoru %97 olarak hesaplanmıştır.


Tablo 7. Sınıflandırma tablosu

	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)	N
Tümör Negatif	0,95	0,99	0,97	138
Tümör Pozitif	0,99	0,95	0,97	138
Doğruluk			0,97	276
Makro Ortalama	0,97	0,97	0,97	276
Ağırlıklı Ortalama	0,97	0,97	0,97	276

Çalışmadan elde edilen sınıflandırma performans sonuçları incelendiğinde, tümör negatif sınıfı için kesinlik %95, duyarlılık %99 ve F1 skoru %97 olarak hesaplanmış ve bu sınıfa ait toplam örnek sayısı 138’dir. Tümör pozitif sınıfı için ise kesinlik %99, duyarlılık %95 ve F1 skoru %97 olup, bu gruptaki örnek sayısı da 138’dir.


Genel doğruluk oranı %97 olarak elde edilmiş ve toplam 276 örnek üzerinden hesaplama yapılmıştır. Ayrıca, makro ortalama değerleri kesinlik, duyarlılık ve F1 skoru için %97 olarak bulunmuştur. Ağırlıklı ortalama değerleri de aynı şekilde kesinlik %97, duyarlılık %97 ve F1 skoru %97’dir.

YOLO modeli için analiz sonuçları;




Şekil 19. Modelin 74. Epoch’ taki genel doğrulama sonuçları

Modelin mAP50 değeri %89 ile en yüksek performansı ortaya koyarken, mAP75 değeri %76 ve mAP50-95 değeri ise %76 olarak hesaplanmıştır.




Şekil 20. F1 Güven eğrisi.

Modelin F1 eğrisine göre tüm sınıflar için en yüksek F1 skoru %89 olup, bu değer %36,5 güven seviyesinde elde edilmiştir.




Şekil 21. Kesinlik-Duyarlılık eğrisi.

Modelin sınıflandırma performansını gösteren hassasiyet eğrisine göre, tüm sınıflar için ortalama mAP 0.5 değerinin %92 olduğu görülmektedir.



Şekil 22. Hassasiyet-Güven eğrisi.


Kesinlik eğrisine göre, modelin tahmin güveni arttıkça kesinlik değerinin de yükseldiğini göstermektedir. Tümör negatif sınıfı yüksek kesinlik değeriyle modelin bu sınıfta daha başarılı olduğunu, tümör pozitif sınıfının ise nispeten daha düşük performans gösterdiğini ortaya koymaktadır.



Şekil 23. Duyarlılık- Güven eğrisi


Tümör negatif sınıfı yüksek duyarlılık değerleriyle modelin bu sınıfta güçlü bir performans sergilediğini göstermektedir. Tümör pozitif sınıfında ise duyarlılık değerleri nispeten düşük seyretmiştir. Tüm sınıflar için ortalama duyarlılığın %97

olarak bulunması, geliştirilen modelin genel olarak yüksek duyarlılığa sahip olduğunu ve tümör tespitinde etkili bir performans sergilediğini ortaya koymaktadır.



Şekil 24. YOLO sınıflandırma başarısının normalize edilmiş karmaşıklık matrisi ile analizi


Normalize edilmiş karmaşıklık matrisi incelendiğinde, modelin tümör negatif sınıfını doğru tahmin etme oranı %99 olarak elde edilmiştir. Tümör pozitif sınıfında doğru tahmin oranı %85, arka plan (background) sınıfında ise %78 bulunmuştur. Yanlış sınıflandırmalar incelendiğinde; tümör pozitif örneklerin %15'i arka plan sınıfına, tümör negatif örneklerin ise %1'i arka plan sınıfına yanlış sınıflandırılmıştır.



Şekil 25. Eğitim ve doğrulama kayıpları ile performans metrikleri


Eğitim ve doğrulama kayıplarının epoch ilerledikçe düzenli bir şekilde azaldığı görülmektedir. Özellikle kutu kayıp ve clas kayıp değerleri başlangıçta yüksek seviyelerde iken, süreç sonunda belirgin şekilde düşüş göstermiştir.

Performans metrikleri incelendiğinde, kesinlik ve duyarlılık değerlerinde epoch sayısı arttıkça yükselme eğilimi olduğu, benzer şekilde mAP50 ve mAP50-95 değerlerinin de artış göstererek modelin doğruluk seviyesini geliştirdiği belirlenmiştir.




Şekil 26. Eğitilen YOLO modelinin beyin MR görüntüleri üzerindeki tahmin sonuçları

Model, tümör negatif (mavi kutu) ve tümör pozitif (açık mavi kutu) örneklerini başarılı bir şekilde ayırt edebilmiştir. Görsellerde, tümör pozitif vakalarda tümör bölgesi doğru şekilde tespit edilmiş ve konumlandırılmış, tümör negatif vakalarda ise herhangi bir yanlış pozitif işaretleme yapılmamıştır.



Şekil 27. YOLO ile beyin MR görüntülerinde tümör tespitine ait örnek tahmin çıktıları

Modelin hem tümör pozitif hem de tümör negatif sınıfları için belirli doğruluk seviyelerinde tahminler gerçekleştirdiği görülmüştür. Görsellerde, modelin tümör varlığını tespit ettiği örneklerde olasılık değerlerinin 0,5 ile 0,9 arasında değiştiği, tümörsüz örneklerde ise genellikle 1'e yakın güven skorları ile tümör negatif çıktısı verdiği gözlemlenmiştir.



Şekil 28. YOLO ile tümör pozitif beyin MR görüntülerine ait örnek tahmin çıktıları.

YOLO modeli tümör pozitif MR görüntülerinde lezyon bölgelerini başarıyla tespit etmiş ve kırmızı sınırlayıcı kutularla işaretlemiştir.

6. TARTIŞMA

Bu çalışma, pediatrik yaş grubundaki (1-17 yaş) hastalara ait beyin MR görüntülerinde tümör tespiti ve sınıflandırması için geliştirilen AI tabanlı karar destek sistemi sunmaktadır. Çalışmamızı literatürdeki benzer çalışmalardan ayıran ve araştırmanın özgün değerini oluşturan en temel güçlü yönü, verilerin elde edildiği kaynağın niteliği ve kapsamıdır. Açık erişimli genel veri setleri (Kaggle, Figshare, BraTS vb.) yerine, Dicle Üniversitesi Tıp Fakültesi Hastanesi gibi üçüncü basamak bir sağlık kuruluşundan, 2010-2024 yılları arasını kapsayan geniş bir projeksiyonda elde edilen yerel ve klinik verilerin kullanılması, çalışmanın sonuçlarının gerçek klinik senaryolara uygunluğunu artırmaktadır.

Çalışmamızın sadece radyolojik görüntülere değil, patolojik tanı ile doğrulanmış olgulara dayanması metodolojik güvenilirliği önemli ölçüde güçlendirmiştir. Metodolojik açıdan, sınıflandırma için EfficientNetB4 ve lokasyon tespiti için güncel YOLOv12 mimarilerinin entegre kullanımı, çalışmanın hem "tümör var mı?" hem de "tümör nerede?" sorularına aynı anda yüksek başarıyla yanıt verilmesini sağlamıştır. Elde edilen EfficientNetB4 için %97'lik genel doğruluk (accuracy) ve %99'luk özgüllük (specificity), YOLOv12 için ise mAP50 %89 doğruluk değerleri, önerilen modelin özellikle sağlıklı dokuyu ayırt etmedeki başarısını ve yanlış pozitif oranının düşüklüğünü kanıtlamaktadır. Literatürde genellikle yetişkin verileriyle eğitilen modellerin aksine, bu çalışmanın beyin gelişimi ve anatomisi yetişkinlerden farklılık gösteren pediatrik popülasyona odaklanması, bu alandaki önemli bir literatür boşluğunu doldurmaktadır.

Rasa ve ark. (2024) çalışmalarında, BR35H ve Figshare veritabanlarından alınan 3064 veri kullanılarak glioma, meningioma, pituitary ve tümör yok olmak üzere dört sınıfta kontrastlı beyin MR görüntüsü üzerinde sınıflandırma yapmıştır. Farklı transfer öğrenme tabanlı CNN modellerini karşılaştırarak EfficientNet mimarilerinin diğer modellere kıyasla daha yüksek doğruluk sağladığını rapor etmişlerdir. Özellikle EfficientNet-B3 ve B4 modelleri ile %96–98 aralığında doğruluk değerleri elde edilmiş, ResNet veya VGG tabanlı modellerin ise daha düşük doğruluk oranlarında kaldığı bildirilmiştir (76). Çalışmamızda kullanılan EfficientNetB4 tabanlı model, literatürde bildirilen bu bulgularla paralellik göstermektedir. Çalışmamızın

EfficientNet mimarisinin pediatrik beyin MR görüntülerinde de güçlü bir sınıflandırıcı olarak kullanılabileceğini desteklemekte ve literatürdeki bulgularla tutarlı olduğu görülmektedir.

Ahamed ve Sadia (2022) çalışmalarında, BR35H veritabanından alınan ikili sınıflandırma için 3000 MR ve çoklu sınıflandırma için için 3064 MR görüntüsü kullanılarak Xception, VGG16, InceptionV3, ResNet50, DenseNet201, MobileNetV2, EfficientNet mimarileri kullanmıştır. Çalışmada İkili sınıflandırmada en yüksek performansı veren EfficientNet modeli %99,75 doğruluk elde etmiştir. Çoklu sınıflandırmada ise EfficientNet modeli %98,61 doğruluk oranı bulunmuştur. Bu çalışma, transfer öğrenmenin ikili sınıflandırmada modelin doğruluğunu istikrarlı şekilde arttırdığını göstermektedir (77). Çalışmamızda ise EfficientNet ile ikili sınıflandırma yapılmış ve benzer doğruluk oranına ulaşılmıştır.

Chen ve ark. (2024) BR35H veritabanından alınan 801 MR görüntüsü kullanılarak, YOLO tabanlı model olan YOLO-NeuroBoost mimarisi ile beyin tümörlerinin hızlı ve doğru bir şekilde tespit edilmesi amaçlanmıştır. Araştırmada kullanılan yöntem, YOLOv8 mimarisine eklenen dikkat mekanizmaları ve özellik güçlendirme modülleri sayesinde özellikle küçük boyutlu tümörlerin tespitinde performans artışı sağlamıştır. Çalışmanın sonuçlarına göre, model %97 doğruluk değerleriyle başarılı bir performans göstermiştir (78). Bu bulgular, tümör tespitinde gerçek zamanlı ve yüksek doğruluklu yaklaşımların mümkün olduğunu ortaya koymaktadır. İki çalışmanın farklı metodolojik yaklaşımları beyin tümörlerinin hem lokalizasyon hem de sınıflandırma süreçlerinde birbirini tamamlayıcı niteliktedir. Literatürde rapor edilen sonuçlar çalışmamızın bulgularını destekler nitelikte olup, kullanılan yöntem farklılıklarına rağmen her iki yaklaşımın da beyin tümörlerinin bilgisayar destekli tespitinde yüksek potansiyele sahip olduğunu göstermektedir.

Nayak ve ark. (2022) çalışmasında, Dense EfficientNet mimarisi kullanılarak glioma, meningioma, pituitary ve tümör yok olmak üzere dört sınıfta Kaggle'dan alınan 3.260 MR görüntüsü üzerinde sınıflandırma yapılmış ve test setinde %98,78 doğruluk oranı elde edilmiştir. Bu modelde min-max normalizasyon, veri artırma ve yoğun-dropout katmanlarının birlikte kullanılması ile yüksek bir performans sağlandığı rapor edilmiştir (79). Çalışmamızda elde edilen sonuçlar ile

kıyaslandığında, Nayak ve arkadaşlarının bulgularının yüksek doğruluk oranları ile benzerlik gösterdiği görülmektedir. Ancak bizim çalışmamızda iki sınıflı sınıflandırma yapılmıştır. Bu durum, sınıf sayısının artmasının modelin öğrenme kapasitesi ve genelleme başarısı üzerinde önemli bir etkiye sahip olabileceğini göstermektedir. Her iki çalışmada uygun mimari seçimlerin ve veri ön işleme tekniklerinin beyin tümörü sınıflandırma performansını arttırmada belirleyici olduğunu ortaya koymaktadır.

Vimala ve ark. (2023) Figshare veritabanından alınan 3064 MR görüntüsü kullanılarak farklı transfer öğrenme tabanlı CNN mimarilerini hibrit yaklaşımlarla birleştirerek beyin tümörü sınıflandırması yapan Vimala ve ark. çalışmalarında EfficientNet, ResNet ve Xception gibi mimarilerden elde edilen özellikler birleştirilmiş, ardından sınıflandırma katmanına aktarılmış ve böylece modelin doğruluk oranında artış sağlanmıştır. Araştırma sonuçlarına göre hibrit derin öğrenme yöntemleri ile %97'nin üzerinde doğruluk değeri elde edilmiştir. Bununla birlikte yazarlar, özellikle tümör pozitif sınıfında heterojen yapılar ve küçük boyutlu lezyonların sınıflandırma performansını düşürdüğünü, bu nedenle hibrit yaklaşımın avantajlı olduğunu vurgulamışlardır (80). Çalışmamızda yalnızca EfficientNet mimarisi kullanılmış olmasına rağmen elde edilen %97 doğruluk değeri Vimala ve ark. hibrit model sonuçlarıyla oldukça benzerdir. Ayrıca; tümör pozitif sınıfındaki duyarlılığın negatif sınıfına göre düşük kalması, onların da belirttiği gibi küçük tümör odaklarının ve etiketleme belirsizliklerinin sınıflandırmadaki temel zorluklardan biri olduğunu göstermektedir.

Rao ve ark. (2024) BR35H, SARTAJ ve Figshare veritabanlarından alınan 7022 MR görüntüsü kullanılarak ResNet ve EfficientNet gibi mimariler transfer öğrenme ile yeniden eğitilmiş ve özellikle EfficientNet tabanlı modelin diğerlerine kıyasla daha yüksek performans sergilediği rapor edilmiştir. Elde edilen sonuçlarda doğruluk oranı %96'nın üzerine çıkmış, ayrıca modelin eğitim süresince hesaplama verimliliği ve parametre optimizasyonundaki avantajlarına da dikkat çekilmiştir (81). Bu bulgular, bizim çalışmamızda EfficientNet ile elde edilen %97 doğruluk sonucuyla uyumludur. Rao ve arkadaşlarının belirttiği üzere EfficientNet, parametre sayısının görece az olmasına rağmen yüksek performans göstermesiyle öne çıkmaktadır. Çalışmamızda da benzer şekilde EfficientNet'in özellikle pediatrik beyin MR görüntülerinde ikili sınıflandırmada güçlü bir performans sunduğu görülmüştür. Bu sonuçlar

EfficientNet'in yalnızca çok sınıflı değil, aynı zamanda ikili sınıflandırma bağlamında da etkin olduğunu göstermektedir.

Khan ve Auvee (2024) Çalışmalarında Br35H (ikili sınıflandırma) ve Brain Tumor MRI Dataset (çoklu sınıflandırma) adlı iki farklı açık kaynak veri kümesi kullanılmıştır. İkili sınıflandırma için 3000 MR görüntüsü ve çoklu sınıflandırma için 7023 MR görüntüsü kullanmıştır. Araştırmacılar, kaynak verimliliğini gözetken özel CNN mimarileri geliştirmiş ve bunların performansını transfer öğrenme tabanlı derin ağlarla karşılaştırmışlardır. Elde edilen sonuçlara göre, Br35H veri kümesi üzerinde yapılan ikili sınıflandırmada %98,67 doğruluk, Brain Tumor MRI veri kümesinde ise %99,62 doğruluk elde edilmiştir (82). Bu bulgular, EfficientNet modelimizle elde ettiğimiz %97 doğruluk oranı ile karşılaştırıldığında Khan ve Auvee'nin kullandığı özel CNN mimarisine benzer bir performans sağladığını göstermektedir.

Krishnapriya ve Karuna (2024) çalışmalarında, BR35H veritabanından alınan 1437 MR görüntüsü kullanmıştır. YOLOv7 tabanlı derin öğrenme mimarisi ile beyin tümörlerinin MR görüntülerinden otomatik olarak tespiti ve GrabCut algoritmasıyla tümör bölgesinin ayrıştırılması amaçlanmıştır. Çalışmada modelin tümör tespitinde yüksek doğruluk oranına %99 ulaştığı ve GrabCut entegrasyonu sayesinde tümör sınırlarının daha doğru belirlendiği rapor edilmiştir. YOLOv7'nin hızlı tespit kabiliyeti, GrabCut algoritmasıyla birleştiğinde hem tespit hem de bölütleme açısından güçlü bir çözüm sunmuştur (83). Bizim çalışmamızda YOLO ile elde edilen sonuçlar incelendiğinde, çalışmamızdaki değerlerin literatürde bildirilen yüksek performanstan düşük olduğu ancak model mimarisi, veri seti büyüklüğü ve tümör çeşitliliği gibi faktörlerin performans farklılıklarına yol açabileceğini göstermektedir.

Almufareh ve ark. (2023) tarafından yürütülen çalışmada, beyin tümörlerinin otomatik tespiti ve sınıflandırılması için YOLO tabanlı derin öğrenme mimarilerinin etkinliği araştırılmıştır. Çalışmada, 233 hastadan elde edilen toplam 3.064 MR görüntüsü kullanılmış ve geliştirilen modelin %94 doğruluk değerine ulaştığı rapor edilmiştir. (84). Bu çalışmanın bulguları, çalışmamızda kullanılan YOLOv12 modelinin lokalizasyon performansı ile uyumluluk göstermektedir.

Tao Yang ve ark. (2024) çalışmalarında Kaggle'dan alınan 3439 MR (glioma, meningioma) görüntüsü kullanarak YOLO tabanlı beyin tümörü segmentasyon

algoritması, tümör tespitinde yüksek doğruluk %93 değeri ulaştığı rapor etmiştir (85). Çalışmamızda kullanılan YOLO modeliyle elde edilen doğrulama sonuçları incelendiğinde genel performansın %89 düzeyinde olduğu görülmektedir. Bu bulgular, Tao Yang'ın çalışmasında raporlanan değerlerle büyük ölçüde paralellik göstermekte olup özellikle mAP50 oldukça yakın sonuçlar elde edilmiştir. Bununla birlikte sınıf bazlı analizde dikkate değer farklılıklar gözlenmiştir. Modelimiz tümör negatif sınıfında son derece yüksek doğruluk sergilerken tümör pozitif sınıfında daha düşük doğruluk elde edilmiştir. Bu durum; Tao Yang'ın çalışmasında da belirtildiği üzere tümör pozitif vakalardaki heterojenite, küçük odakların tespiti ve segmentasyon belirsizliklerinin model performansını olumsuz etkilediği bulgusuyla uyumludur.

Jian Huang ve ark. (2025) tarafından geliştirilen YOLO-TumorNet modeli, beyin tümörü tespitinde klasik YOLO türevlerine kıyasla iyileştirilmiş bir mimari sunarak literatürde yüksek doğruluk oranlarıyla öne çıkmıştır. İlgili çalışmada modelin performansı Roboflow 76 MR veri setinde mAP50 %98, Br35H 801 MR veri setinde ise %99 olarak rapor edilmiştir. Bu sonuçlar, özellikle küçük tümör odaklarının saptanmasında dikkate değer bir başarı göstermektedir (86). Çalışmamızın YOLO-TumorNet'in rapor ettiği performans sonuçlarına kıyasla daha düşük olmakla birlikte, genel olarak literatürle uyumlu düzeydedir. Performans farkının başlıca nedenleri arasında kullanılan veri setlerinin farklılığı, örnek sayısının sınırlı olması, tümör boyutlarının ve kontrast özelliklerinin çeşitliliği ile etiketleme sürecindeki varyasyonlar sayılabilir. Ayrıca; YOLO-TumorNet'in özel olarak optimize edilmiş katman yapısına ve geniş veri seti üzerinde yeniden eğitilmiş ağırlıklara sahip olması, modelin genel başarısını artırmıştır. Buna karşılık bu çalışmada kullanılan YOLOv12 modeli, sınırlı sayıda pediatrik MR görüntüsü üzerinde eğitildiği için genel genelleme kapasitesi nispeten daha düşük kalmıştır.

Çalışmamızın bulguları yalnızca literatür ile uyumlu değil, aynı zamanda klinik açıdan da anlamlıdır. Geliştirilen EfficientNetB4 modeli; beyin tümörlerinin varlığını yüksek doğrulukla belirleyebilmekte, YOLOv12 modeli ise tümör bölgesini hızlı bir şekilde lokalize edebilmektedir. Klinik açıdan bakıldığında, bu tür bir ikili yapı özellikle pediatrik hastalarda erken tanı sürecinde kritik bir rol oynayabilmektedir. Çünkü küçük tümör odaklarının gözden kaçma ihtimali, manuel incelemelerde önemli bir sorundur. YOLOv12'nin sağladığı hızlı ve doğru lokalizasyon, radyoloji

uzmanlarının inceleme süresini kısaltarak hata riskini azaltmaktadır. Ayrıca EfficientNet mimarisinin hesaplama verimliliği, büyük hacimli MR verilerinin daha kısa sürede analiz edilmesine olanak tanımaktadır. Bu durum, klinik iş akışlarında zaman kazancı sağlamasının yanı sıra yoğun klinik ortamlarda kullanılabilirliğini de arttırmaktadır.

Çalışmamızda YOLOv12 modelinin tahmin olasılığının literatürden nispeten düşük çıkmasının nedeni küçük tümörlerin saptanmasında düşük performans göstermesidir. Sınırlı uzamsal çözünürlük, veri setindeki dengesiz dağılım ve küçük hedeflerin modelin öğrenme sürecinde baskın özellikler tarafından nedenleri arasında görülebilir. Bu durumu iyileştirmek amacıyla yüksek çözünürlüklü giriş görüntülerinin kullanılması, çok ölçekli özellik haritalarının entegrasyonu ve veri dengeleme stratejilerinin uygulanması önerilmektedir.

Bu çalışmada kullanılan veri setinin pediatrik yaş grubuna ait olması, modelin genellenebilirliği açısından önemli bir sınırlılık oluşturmaktadır. Pediatrik beyin yapıları, yetişkinlere kıyasla morfolojik ve anatomik olarak belirgin farklılıklar göstermektedir. Beyin gelişimi sürecinin devam etmesi nedeniyle kortikal kalınlık, beyin hacmi, gri ve beyaz madde oranları ile ventrikül boyutları yaşa bağlı değişkenlik göstermektedir. Bu durum MR görüntülerinde kontrast farklılıklarına yol açmaktadır. Ayrıca pediatrik hastalarda görülen tümör tipleri ve lokalizasyonları yetişkinlerden farklılık göstermekte (medulloblastom ve ependimom gibi) arka çukur yerleşimli tümörler daha sık izlenmektedir. Bu morfolojik ve patolojik farklılıklar, modelin yetişkin hasta verileri üzerinde aynı doğrulukta sonuçlar vermesini güçleştirebilmektedir.

Çalışmamızda kullanılan MR görüntülerinin farklı cihaz ve protokollerden kaynaklanabilecek varyasyonlara duyarlılığı da dikkate alınmalıdır. MR cihaz protokol farklılıkları (örneğin; manyetik alan gücü, üretici firma, çekim parametreleri ve kontrast ayarları gibi teknik unsurlar); görüntülerin kontrast, çözünürlük ve gürültü özelliklerini doğrudan etkilemektedir. Bu durum, derin öğrenme modellerinin özellikle özellik çıkarımı aşamasında tutarsızlıklara yol açabilmekte ve modelin farklı veri kaynakları üzerindeki performansını sınırlayabilmektedir. Özellikle pediatrik MR görüntülerinde küçük anatomik yapıların belirginliği ve kontrast farklılıklarının fazla

olması, modelin tümör bölgesini doğru biçimde tespit etmesini güçleştirebilmektedir. Bu nedenle çalışmada elde edilen yüksek doğruluk oranları, aynı protokol altında elde edilen görüntüler için geçerli olmakla birlikte farklı merkezlerden veya farklı cihazlardan gelen verilerde benzer performansın sağlanamayabileceği göz önünde bulundurulmalıdır.

Gelecek çalışmalarda, farklı yaş gruplarını kapsayan ve çok merkezli veri setlerinden elde edilecek verilerle modelin genellenebilirliğinin artırılması hedeflenmelidir. Böylece farklı cihazlar, MR görüntüleme protokolleri ve hasta profilleri üzerinde modelin performansı değerlendirilerek klinik geçerliliği daha güçlü biçimde ortaya konulabilir. Ayrıca geliştirilen AI tabanlı modelin, hastanelerde kullanılan PACS altyapısına entegre edilmesi, gerçek zamanlı testlerin yapılmasına ve modelin klinik iş akışına dahil edilmesine olanak sağlayacaktır. Bu tür entegrasyon çalışmaları, radyoloji uzmanlarının günlük uygulamalarda modelin performansını doğrudan gözlemlmelerine, geri bildirimlerde bulunmalarına ve sistemin pratik faydasını değerlendirmelerine imkân tanıyacaktır. Bununla birlikte, daha geniş örneklem gruplarında yürütülecek prospektif klinik araştırmalarla modelin doğruluk, hız ve kullanıcı dostu arayüz bakımından geliştirilmesi, klinik uygulanabilirliğini arttıracaktır. Bu sayede; geliştirilen sistemin yalnızca laboratuvar koşullarında değil, gerçek klinik ortamlarda da etkin ve güvenilir bir şekilde kullanılabilmesi mümkün hale gelecektir.

7. SONUÇ ve ÖNERİLER

Pediyatrik beyin MR görüntülerinde beyin tümörlerinin bilgisayar destekli tespiti ve sınıflandırılmasına yönelik derin öğrenme tabanlı EfficientNetB4 ve YOLOv12 modellerinin etkinliğini ortaya koymaktadır. Elde edilen bulgular, her iki modelin de klinik karar destek sürecine katkı sağlayabilecek düzeyde yüksek performans sunduğunu göstermektedir. EfficientNetB4 modeli tümör pozitif ve negatif ayrımında %97 doğruluk ile güçlü sonuç saptandı. YOLOv12 modeli ise tümör lokalizasyonun tespitinde mAP50 değerinde %89 güvenilirlik ile saptandı.

Bulgular, klinik açıdan değerlendirildiğinde, AI destekli görüntü analizi sistemlerinin özellikle pediyatrik yaş grubunda küçük lezyonların erken tespiti açısından geliştirilen modellerin radyoloji uzmanlarına yardımcı bir araç olarak kullanılabileceğini göstermektedir. Manuel incelemelerde gözden kaçabilecek küçük lezyonların AI destekli sistemler sayesinde daha hızlı ve güvenilir biçimde tespit edilebilmesi, erken tanı sürecine katkıda bulunabilir. Ayrıca EfficientNet' in parametre verimliliği sayesinde yüksek doğruluk elde edilirken hesaplama maliyetinin düşük tutulması da büyük ölçekli klinik uygulamalar için avantaj sağlayabilir.

8. KAYNAKLAR

1. Razzak MI, Imran M, Xu G. Efficient Brain Tumor Segmentation With Multiscale Two-Pathway-Group Conventional Neural Networks. *IEEE J Biomed Health Inform.* 2019;23(5):1911-9.
2. Alam MA, Sohel A, Hasan KM, Ahmad I. Advancing Brain Tumor Detection Using Machine Learning And Artificial Intelligence: A Systematic Literature Review Of Predictive Models And Diagnostic Accuracy. *Strategic Data Management and Innovation.* 2024;1(01):37-55.
3. Shen D, Wu G, Suk HI. Deep Learning in Medical Image Analysis. *Annu Rev Biomed Eng.* 2017;19:221-48.
4. Akkus Z, Galimzianova A, Hoogi A, Rubin DL, Erickson BJ. Deep Learning for Brain MRI Segmentation: State of the Art and Future Directions. *J Digit Imaging.* 2017;30(4):449-59.
5. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nat Med.* 2019;25(1):24-9.
6. Tan M, Le Q, editors. Efficientnet: Rethinking model scaling for convolutional neural networks. *International conference on machine learning*; 2019: PMLR.
7. Choudhury CL, Mahanty C, Kumar R, Mishra BK, editors. Brain tumor detection and classification using convolutional neural network and deep neural network. 2020 international conference on computer science, engineering and applications (ICCSEA); 2020: IEEE.
8. Özkan S, & Özkan S. Yapay zekâ destekli tıbbi görüntü analizi ve Türkiye'deki uygulama potansiyeli. *Türkiye Klinikleri Biyomedikal Mühendisliği.* 2020(Özel Konular, 6(2)):158–66.
9. Keles H, & Keles A. . Application of deep learning in neuroradiology: Opportunities for developing countries. *Clinical Imaging,* 56. 2019:123–9.
10. Ranjbarzadeh R, Caputo A, Tirkolaei EB, Ghouschi SJ, Bendeche M. Brain tumor segmentation of MRI images: A comprehensive review on the application of artificial intelligence tools. *Computers in biology and medicine.* 2023;152:106405.
11. Amin J, Sharif M, Yasmin M, Fernandes SL. A distinctive approach in brain tumor detection and classification using MRI. *Pattern Recognition Letters.* 2020;139:118-27.
12. Tamilselvi R, Nagaraj A, Beham MP, Sandhiya MB, editors. Bransit: a database for brain tumor diagnosis and detection. 2020 Sixth International Conference on Bio Signals, Images, and Instrumentation (ICBSII); 2020: IEEE.
13. Arbane M, Benlamri R, Brik Y, Djerioui M, editors. Transfer learning for automatic brain tumor classification using MRI images. 2020 2nd international workshop on human-centric smart environments for health and well-being (IHSH); 2021: IEEE.

14. Louis DN, Ohgaki H, Wiestler OD, Cavenee WK, Burger PC, Jouvet A, et al. The 2007 WHO classification of tumours of the central nervous system. *Acta neuropathologica*. 2007;114(2):97-109.
15. Gue R, Lakhani DA. The 2021 World Health Organization Central Nervous System Tumor Classification: The Spectrum of Diffuse Gliomas. *Biomedicines*. 2024;12(6):1349.
16. Smith HL, Wadhvani N, Horbinski C. Major features of the 2021 WHO classification of CNS tumors. *Neurotherapeutics*. 2022;19(6):1691-704.
17. Ostrom QT, Price M, Neff C, Cioffi G, Waite KA, Kruchko C, et al. CBTRUS statistical report: primary brain and other central nervous system tumors diagnosed in the United States in 2015–2019. *Neuro-oncology*. 2022;24(Supplement_5):v1-v95.
18. Lenzen A, Sosa RMG, Habiby R, DiPatri Jr AJ, Smiley NP. Pediatric central nervous system tumor diagnosis, complications, and emergencies. *Clinical Pediatric Emergency Medicine*. 2018;19(2):153-61.
19. Riedel NC, de Faria FW, Alfert A, Bruder JM, Kerl K. Three-dimensional cell culture systems in pediatric and adult brain tumor precision medicine. *Cancers*. 2022;14(23):5972.
20. T.C. SB. T.C. Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü. Türkiye Kanser İstatistikleri 2020. Ankara.2020.
21. Hollingworth MA, Chattopadhyay A, Walker D, Paine S, Kirkman MA. What you should you know about paediatric brain tumours in 2022. *Paediatrics and Child Health*. 2022;32(9):339-50.
22. Muhammad D, Bendeche M. Unveiling the black box: A systematic review of Explainable Artificial Intelligence in medical image analysis. *Computational and structural biotechnology journal*. 2024;24:542-60.
23. Ellingson BM, Bendszus M, Boxerman J, Barboriak D, Erickson BJ, Smits M, et al. Consensus recommendations for a standardized Brain Tumor Imaging Protocol in clinical trials. *Neuro-oncology*. 2015;17(9):1188-98.
24. Wadhwa A, Bhardwaj A, Verma VS. A review on brain tumor segmentation of MRI images. *Magnetic resonance imaging*. 2019;61:247-59.
25. Balkan B, Türk M, Moralar DG, Yaşaroğlu S, Yektaş A, Hergünsel GO. Çocuk Hastalarda Manyetik Rezonans Görüntüleme Esnasındaki Sedasyon/Anestezi Deneyimlerimiz. *Journal of Pediatric Emergency and Intensive Care Medicine*. 2018.
26. Ramesh AN, Kambhampati C, Monson JR, Drew PJ. Artificial intelligence in medicine. *Ann R Coll Surg Engl*. 2004;86(5):334-8.
27. Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *Gastrointest Endosc*. 2020;92(4):807-12.
28. Crevier D. AI: the tumultuous history of the search for artificial intelligence: Basic Books, Inc.; 1993.

29. Henkoğlu H. İnsan Odaklı Yapay Zekâ: İnsan Bilgisayar Etkileşimi ve Yapay Zekânın Keşisi Üzerine Bir Değerlendirme. B. Küçükcan, & BF Yıldırım (Dü) içinde. Yapay Zekâ Disiplinlerarası Yaklaşımlar. 2023:13-45.
30. Sajid MI, Ahmed S, Waqar U, Tariq J, Chundrigarh M, Balouch SS, et al. SARS-CoV-2: Has artificial intelligence stood the test of time. Chin Med J (Engl). 2022;135(15):1792-802.
31. Aubrey K. What's the Difference Between Deep Learning Training and Inference? 2016 [Available from: <https://blogs.nvidia.com/blog/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/>].
32. Xu C, Jackson SA. Machine learning and complex biological data. Genome Biol. 2019;20(1):76.
33. Mahesh B. Machine Learning Algorithms - A Review. International Journal of Science and Research (IJSR). 2020;9(1):381-6.
34. Jiang T, Gradus JL, Rosellini AJ. Supervised Machine Learning: A Brief Primer. Behav Ther. 2020;51(5):675-87.
35. Uçar MK, Nour M, Sindi H, Polat K. The Effect of Training and Testing Process on Machine Learning in Biomedical Datasets. Mathematical Problems in Engineering. 2020;2020:1-17.
36. Ongsulee P, editor Artificial intelligence, machine learning and deep learning. 2017 15th international conference on ICT and knowledge engineering (ICT&KE); 2017: IEEE.
37. Hastie T. The elements of statistical learning: data mining, inference, and prediction. Springer; 2009.
38. Ma L, Sun B. Machine learning and AI in marketing – Connecting computing power to human insights. International Journal of Research in Marketing. 2020;37(3):481-504.
39. van Engelen JE, Hoos HH. A survey on semi-supervised learning. Machine Learning. 2019;109(2):373-440.
40. Reddy Y, Viswanath P, Reddy BE. Semi-supervised learning: A brief review. Int J Eng Technol. 2018;7(1.8):81.
41. Ghasemi M, Moosavi AH, Ebrahimi D. A comprehensive survey of reinforcement learning: From algorithms to practical challenges. arXiv preprint arXiv:241118892. 2024.
42. Doya K. Reinforcement learning: Computational theory and biological mechanisms. HFSP J. 2007;1(1):30-40.
43. Bertolini M, Mezzogori D, Neroni M, Zammori F. Machine Learning for industrial applications: A comprehensive literature review. Expert Systems with Applications. 2021;175.
44. Mienye ID, Swart TG. A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications. Information. 2024;15(12).

45. Pramila P. Shinde DSS. A Review of Machine Learning and Deep Learning Applications. 2018.
46. Celeghin A, Borriero A, Orsenigo D, Diano M, Mendez Guerrero CA, Perotti A, et al. Convolutional neural networks for vision neuroscience: significance, developments, and outstanding issues. *Front Comput Neurosci*. 2023;17:1153572.
47. Lee JG, Jun S, Cho YW, Lee H, Kim GB, Seo JB, et al. Deep Learning in Medical Imaging: General Overview. *Korean J Radiol*. 2017;18(4):570-84.
48. ErÇELİK Ç, Hanbay K. Beyin Tümörü Sınıflandırmada Histogram Eşitleme Yönteminin Bazı Derin Öğrenme Modellerine Etkileri. *Computer Science*. 2023.
49. Tang W, Sun J, Wang S, Zhang Y. Review of AlexNet for medical image classification. *arXiv preprint arXiv:231108655*. 2023.
50. Liu X, Gao K, Liu B, Pan C, Liang K, Yan L, et al. Advances in Deep Learning-Based Medical Image Analysis. *Health Data Sci*. 2021;2021:8786793.
51. Mienye ID, Swart TG, Obaido G, Jordan M, Ilono P. Deep Convolutional Neural Networks in Medical Image Analysis: A Review. *Information*. 2025;16(3).
52. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:14091556*. 2014.
53. Dhamija L, Bansal U. Evaluating the Vulnerabilities of Deep Learning Architectures: A Case Study of VGGNet, ResNet50 and InceptionV3. *Proceedings of the 6th International Conference on Deep Learning, Artificial Intelligence and Robotics (ICDLAIR 2024)*. *Advances in Intelligent Systems Research*2025. p. 261-71.
54. Pandiyan V, Murugan P, Tjahjowidodo T, Caesarendra W, Manyar OM, Then DJH. In-process virtual verification of weld seam removal in robotic abrasive belt grinding process using deep learning. *Robotics and Computer-Integrated Manufacturing*. 2019;57:477-87.
55. He K, Zhang X, Ren S, Sun J, editors. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 2016.
56. Raj R, Kos A. An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions. *Sensors (Basel)*. 2025;25(4).
57. Kilic S, Askerzade I, Kaya Y. Using ResNet Transfer Deep Learning Methods in Person Identification According to Physical Actions. *IEEE Access*. 2020;8:220364-73.
58. Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z, editors. Rethinking the inception architecture for computer vision. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 2016.
59. Al Husaini MAS, Habaebi MH, Gunawan TS, Islam MR, Elsheikh EAA, Suliman FM. Thermal-based early breast cancer detection using inception V3, inception V4 and modified inception MV4. *Neural Comput Appl*. 2022;34(1):333-48.

60. Atila Ü, Uçar M, Akyol K, Uçar E. Plant leaf disease classification using EfficientNet deep learning model. *Ecological Informatics*. 2021;61.
61. Ahmed T, Sabab NHN. Classification and understanding of cloud structures via satellite images with EfficientUNet. *SN Computer Science*. 2022;3(1):99.
62. Fu Y. Image classification via fine-tuning with EfficientNet 2020 [Available from: https://keras.io/examples/vision/image_classification_efficientnet_fine_tuning/?utm_source=chatgpt.com](25.08.2025).
63. Sapkota R, Flores-Calero M, Qureshi R, Badgujar C, Nepal U, Poulose A, et al. YOLO advances to its genesis: a decadal and comprehensive review of the You Only Look Once (YOLO) series. *Artificial Intelligence Review*. 2025;58(9).
64. Redmon J, Divvala S, Girshick R, Farhadi A. You Only Look Once: Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)2016. p. 779-88.
65. Khanam R, Hussain M. A Review of YOLOv12: Attention-Based Enhancements vs. Previous Versions. *arXiv preprint arXiv:250411995*. 2025.
66. Tian Y, Ye Q, Doermann D. Yolov12: Attention-centric real-time object detectors. *arXiv preprint arXiv:250212524*. 2025.
67. AlifMAR, Hussain M. Yolov12: A breakdown of the key architectural features. *arXiv preprint arXiv:250214740*. 2025.
68. Jegham N, Koh CY, Abdelatti M, Hendawi A. Yolo evolution: A comprehensive benchmark and architectural review of yolov12, yolov11, and their previous versions. *arXiv preprint arXiv:241100201*. 2024.
69. Sapkota R, Meng Z, Churuvija M, Du X, Ma Z, Karkee M. Comprehensive performance evaluation of yolov12, yolov11, yolov10, yolov9 and yolov8 on detecting and counting fruitlet in complex orchard environments. *arXiv preprint arXiv:240712040*. 2024.
70. Padilla R, Netto SL, Da Silva EA, editors. A survey on performance metrics for object-detection algorithms. 2020 international conference on systems, signals and image processing (IWSSIP); 2020: IEEE.
71. Srinivas C, K SN, Zakariah M, Alothaibi YA, Shaukat K, Partibane B, et al. Deep Transfer Learning Approaches in Performance Analysis of Brain Tumor Classification Using MRI Images. *J Healthc Eng*. 2022;2022:3264367.
72. Goodfellow I, Bengio Y, Courville A, Bengio Y. *Deep learning*: MIT press Cambridge; 2016.
73. GeeksforGeeks. Epoch in Machine Learning 2025 [Available from: <https://www.geeksforgeeks.org/machine-learning/epoch-in-machine-learning/>].
74. Cohen J. *A Power Primer*. 1988.

75. Ostrom QT, Price M, Ryan K, Edelson J, Neff C, Cioffi G, et al. CBTRUS Statistical Report: Pediatric Brain Tumor Foundation Childhood and Adolescent Primary Brain and Other Central Nervous System Tumors Diagnosed in the United States in 2014-2018. *Neuro Oncol.* 2022;24(Suppl 3):iii1-iii38.
76. Rasa SM, Islam MM, Talukder MA, Uddin MA, Khalid M, Kazi M, et al. Brain tumor classification using fine-tuned transfer learning models on magnetic resonance imaging (MRI) images. *Digit Health.* 2024;10:20552076241286140.
77. Ahamed MA, Sadia RT. Examining the behaviour of state-of-the-art convolutional neural networks for brain tumor detection with and without transfer learning. *arXiv preprint arXiv:220601735.* 2022.
78. Chen A, Lin D, Gao Q. Enhancing brain tumor detection in MRI images using YOLO-NeuroBoost model. *Front Neurol.* 2024;15:1445882.
79. Nayak DR, Padhy N, Mallick PK, Zymbler M, Kumar S. Brain Tumor Classification Using Dense Efficient-Net. *Axioms.* 2022;11(1).
80. Babu Vimala B, Srinivasan S, Mathivanan SK, Mahalakshmi, Jayagopal P, Dalu GT. Detection and classification of brain tumor using hybrid deep learning models. *Sci Rep.* 2023;13(1):23029.
81. Rao KN, Khalaf OI, Krishnasree V, Kumar AS, Alsekait DM, Priyanka SS, et al. An efficient brain tumor detection and classification using pre-trained convolutional neural network models. *Heliyon.* 2024;10(17):e36773.
82. Khan MA, Auvée RBZ, editors. Comparative Analysis of Resource-Efficient CNN Architectures for Brain Tumor Classification. 2024 27th International Conference on Computer and Information Technology (ICCIT); 2024: IEEE.
83. Krishnapriya S, Karuna Y. A deep learning model for the localization and extraction of brain tumors from MR images using YOLOv7 and grab cut algorithm. *Front Oncol.* 2024;14:1347363.
84. Almufareh MF, Imran M, Khan A, Humayun M, Asim M. Automated Brain Tumor Segmentation and Classification in MRI Using YOLO-Based Deep Learning. *IEEE Access.* 2024;12:16189-207.
85. Yang T, Lu X, Yang L, Yang M, Chen J, Zhao H. Application of MRI image segmentation algorithm for brain tumors based on improved YOLO. *Front Neurosci.* 2024;18:1510175.
86. Huang J, Ding W, Zhong T, Yu G. YOLO-TumorNet: An innovative model for enhancing brain tumor detection performance. *Alexandria Engineering Journal.* 2025;119:211-21.

ÖZGEÇMİŞ

Adı	Fethi	Soyadı	YAŞAR
Doğum Yeri		Doğum Tarihi	
Uyruğu		Tel	
E-posta			

Eğitim Düzeyi

	Mezun Olduğu Kurumun Adı	Mezuniyet Yılı
Doktora/Uzmanlık		
Tezli Yüksek Lisans		
Lisans		
Önlisans		
Önlisans		
Lise		

İş Deneyimi

	Görevi	Kurum	Süre (Yıl - Yıl)

Yabancı Dil Sınav Notu

KPDS/ÜDS/YDS	YÖKDİL	IELTS	TOEFL IBT	TOEFL PBT	TOEFL CBT	FCE	CAE	CPE

	Sayısal	Eşit Ağırlık	Sözel
ALES Puanı			
(Diğer) Puanı			

EKLER

EK-1

**DİCLE ÜNİVERSİTESİ TIP FAKÜLTESİ GİRİŞİMSSEL OLMAYAN KLİNİK
ARAŞTIRMALAR ETİK KURULU
DİCLE UNIVERSITY MEDICAL FACULTY ETHICS COMMITTEE FOR
NONINTERVENTIONAL STUDIES**

154

KARAR

Dr. Öğretim Üyesi İsmail YILDIZ, Yüksek Lisans Öğrencisi Fethi YAŞAR, Prof. Dr. Zeki AKKUŞ, Arş. Gör. Hatice ORTAÇ, Doç. Dr. Salih HATTAPOĞLU, Doç. Dr. İbrahim İBİLOĞLU isimli araştırmacılar tarafından planlanan "Makine Öğrenimi Yöntemlerinin Beyin Tümörü Tespitindeki Başarısı" başlıklı araştırmaya *Dicle Üniversitesi Tıp Fakültesi Etik Kurul'u* tarafından toplantıda hazır bulunan üyeler tarafından oy birliği ile onay verilmiştir.

Klinik araştırma tamamlanıp yayın aşamasına geldiğinde, yayına sunulan bildiri veya makalenin bir örneğinin Etik Kurul'a verilmesi zorunludur.

DECISION

The project titled as "Success of Machine Learning Methods in Brain Tumour Detection" planned by İsmail YILDIZ, Fethi YAŞAR, Zeki AKKUŞ, Hatice ORTAÇ, Salih HATTAPOĞLU, İbrahim İBİLOĞLU has been approved by Ethics Committee of Dicle University Faculty of Medicine.

Oturum No (Meeting
number):

Tarih (Date): 16.04.2025

Saat (Hour): 10:00-12:00

KURUL BAŞKANI (CHIEF)

Doç. Dr. Mehmet Fatih AKKOÇ

KURUL ÜYELERİ / MEMBERS

	ÜNVANI	ADI-SOYADI	KURUMU	BRANŞI	İMZA
1	Doç. Dr.	Mehmet Fatih AKKOÇ	Dicle Üniversitesi Tıp Fakültesi	Plastik Cerrahi	
2	Prof. Dr.	Ulaş ALABALIK	Dicle Üniversitesi Tıp Fakültesi	Tıbbi Patoloji	
3	Doç. Dr.	Fikret SALIK	Dicle Üniversitesi Tıp Fakültesi	Anesteziyoloji ve Reanimasyon	
4	Doç. Dr.	Mehmet TÜRE	Dicle Üniversitesi Tıp Fakültesi	Çocuk Sağlığı ve Hastalıkları	
5	Doç. Dr.	Seyfettin ERDEM	Dicle Üniversitesi Tıp Fakültesi	Göz Hastalıkları	
6	Doç. Dr.	Muhammed Akif DENİZ	Dicle Üniversitesi Tıp Fakültesi	Radyoloji	
7	Doç. Dr.	Aysun EKİNCİ	Dicle Üniversitesi Tıp Fakültesi	Tıbbi Biyokimya	
8	Dr. Öğretim Üyesi	Diclehan ORAL	Dicle Üniversitesi Tıp Fakültesi	Tıbbi Biyoloji ve Genetik	
9	Dr. Öğretim Üyesi	İsmail YILDIZ	Dicle Üniversitesi Tıp Fakültesi	Biyoistatistik	
10	Dr. Öğretim Üyesi	Abdullah ŞEN	Dicle Üniversitesi Tıp Fakültesi	Acil Tıp	
11	Dr. Öğretim Üyesi	Zeynep ERDOĞMUŞ ÖZGEN	Dicle Üniversitesi Eczacılık Fakültesi	Farmakoloji	
12	Avukat	Şahhanım KAPLAN	Dicle Üniversitesi Rektörlük	Hukuk Müşavirliği	

EK-2

Evrak Tarih ve Sayısı: 18/06/2025-944870



T.C.
DİCLE ÜNİVERSİTESİ REKTÖRLÜĞÜ
Diyarbakır Dicle Üniversitesi Hastanesi Başhekimliği



Sayı : E-18330771-302.14.06-944870
Konu : Yüksek Lisans Tez Çalışması - Fethi
YAŞAR

18/06/2025

BİYOİSTATİSTİK ANABİLİM DALINA

İlgi : 10/06/2025 tarihli ve E- 45867530-302.14.06-938417 sayılı yazısı.

İlgi tarih ve sayılı yazıya istinaden; Hastane Bilgi Yönetim Sisteminde kayıtlı olan veriler tablo halinde hazırlanarak yazı ekinde sunulmuştur.
Bilgilerini ve gereğini rica ederim.

Prof. Dr. Tahsin ÇELEPKOLU
Başhekim a.
Başhekim Yardımcısı

Ek: Hasta Listesi (16 sayfa)

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : *BSDH0EVFS3* Pin Kodu : 18172 Belge Takip Adresi : <https://turkiye.gov.tr/ebd?eK=5539&eD=BSDH0EVFS3&eS=944870>
Adres: Dicle Üniversitesi Rektörlüğü, 21280-Diyarbakır
Telefon: +90 412 248 80 01-16 (16 Hat) Faks: +90 412 248 8523
e-Posta: hastane@dicle.edu.tr Elektronik Ağ: <http://hastane.dicle.edu.tr>
Kep Adresi: dicleuniversitesi@hs01.kep.tr

Bilgi için: Ayla Altunç
Unvanı: Sağlık Teknikeri



Tel No: 4048

Bu belge, güvenli elektronik imza ile imzalanmıştır.

EK-3

Eğitimde kullanılan kodların bir bölümü.

```
data_dir = ''
filepaths = []
labels = []

folds = os.listdir(data_dir)
for fold in folds:
    foldpath = os.path.join(data_dir, fold)
    filelist = os.listdir(foldpath)
    for file in filelist:
        fpath = os.path.join(foldpath, file)

        filepaths.append(fpath)
        labels.append(fold)

Fseries = pd.Series(filepaths, name= 'filepaths')
Lseries = pd.Series(labels, name='labels')
df = pd.concat([Fseries, Lseries], axis= 1)
```

```
g_dict = train_gen.class_indices
classes = list(g_dict.keys())
images, labels = next(train_gen)

plt.figure(figsize= (20, 10))

for i in range(8):
    plt.subplot(2, 4, i + 1)
    image = images[i] / 255
    plt.imshow(image)
    index = np.argmax(labels[i])
    class_name = classes[index]
    plt.title(class_name, color= 'blue', fontsize= 12)
    plt.axis('off')
plt.show()
```

```
tr_acc = history.history['accuracy']
tr_loss = history.history['loss']
val_acc = history.history['val_accuracy']
val_loss = history.history['val_loss']
index_loss = np.argmin(val_loss)
val_lowest = val_loss[index_loss]
index_acc = np.argmax(val_acc)
acc_highest = val_acc[index_acc]
Epochs = [i+1 for i in range(len(tr_acc))]
loss_label = f'En iyi epoch= {str(index_loss + 1)}'
acc_label = f'En iyi epoch= {str(index_acc + 1)}'

plt.figure(figsize= (20, 8))
plt.style.use('fivethirtyeight')

plt.subplot(1, 2, 1)
plt.plot(Epochs, tr_loss, 'r', label= 'Eğitim kaybı')
plt.plot(Epochs, val_loss, 'g', label= 'Doğrulama kaybı')
plt.scatter(index_loss + 1, val_lowest, s= 150, c= 'blue', label= loss_label)

plt.xlabel('Epochs')
plt.ylabel('Loss')
plt.legend()

plt.subplot(1, 2, 2)
plt.plot(Epochs, tr_acc, 'r', label= 'Eğitim Doğruluğu')
plt.plot(Epochs, val_acc, 'g', label= 'Doğrulama Doğruluğu')
plt.scatter(index_acc + 1 , acc_highest, s= 150, c= 'blue', label= acc_label)

plt.xlabel('Epochs')
plt.ylabel('Accuracy')
plt.legend()

plt.tight_layout
plt.show()
```

EK-4



SOSYAL BİLİMLER
ENSTİTÜSÜ



SAGLIK BİLİMLERİ
ENSTİTÜSÜ



EGİTİM BİLİMLERİ
ENSTİTÜSÜ

DİCLE ÜNİVERSİTESİ
LİSANSÜSTÜ BİLİMSEL ARAŞTIRMALAR SEMPOZYUMU
4-5 Kasım 2025
Diyarbakır/Türkiye

Bildiri Kabul Mektubu

22/10/2025

Sayın Fethi YAŞAR,

"Yapay Zeka'nın Tıp'ta Teşhis ve Tedaviye Etkileri" başlıklı bildiri ile 4-5 Kasım 2025 tarihlerinde, Dicle Üniversitesi 15 Temmuz Kültür ve Kongre Merkezinde düzenlenecek olan **"Dicle Üniversitesi Lisansüstü Bilimsel Araştırmalar Sempozyumu"**na yapmış olduğunuz başvuru, değerlendirme komisyonu tarafından kabul edilmiştir. Sözlü sunum yapmak üzere teşekkürleriniz rica olunur.

Sempozyum Düzenleme Kurulu

ORİJİNALLIK RAPORU

Makine Öğrenimi Yöntemlerinin Beyin Tümörü Tespitindeki Başarısı-Fethi YAŞAR

ORİJİNALLIK RAPORU

%8

BENZERLİK ENDEKSİ

%7

İNTERNET KAYNAKLARI

%5

YAYINLAR

%5

ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1

Submitted to Dicle University

Öğrenci Ödevi

%2

2

Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK)

Öğrenci Ödevi

%1

3

acikerisim.dicle.edu.tr

İnternet Kaynağı

%1

4

acikbilim.yok.gov.tr

İnternet Kaynağı

%1

5

dergipark.org.tr

İnternet Kaynağı

<%1

6

openaccess.hacettepe.edu.tr

İnternet Kaynağı

<%1

7

Submitted to Selçuk Üniversitesi

Öğrenci Ödevi

<%1

8

Oysu, Aslihan Semiz. "Bas Boyun tumorlerinin Tedavi sonrasi Takibinde Dinamik kontrastli

<%1