



Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi

<https://dergipark.org.tr/pub/yyufbed>



Araştırma Makalesi

Görüntü İşleme ve Derin Öğrenme Teknikleri ile Beyin Tümör Tespiti

Sinem BALİTATLI* Fatmana ŞENTÜRK

Pamukkale Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 20160, Denizli, Türkiye

*Sorumlu yazar e-posta: sinembalitatti@gmail.com

Öz: Beyin tümörlerinin erken teşhisi, tedavi seçeneklerini ve hastanın hayatta kalma oranlarını iyileştirir. Beyin tümörü tespitinde yapay zekâ kullanımı tespiti kolaylaştırmaktadır. Manyetik rezonans görüntüleme görüntüleri kullanılarak beyin tümörünü tespit etmek için Derin öğrenme yaklaşımları, hastalığın erken evresinde saptanmasında oldukça etkilidir. Bu alanda en başarılı derin öğrenme tekniklerinden evrişimli sinir ağı oldukça gelişmiş bir yöntemdir. Bu çalışmada, evrişimli sinir ağı model performansını görüntü işleme (image processing) teknikleri kullanarak artırmayı ve teşhis aşamasını kolaylaştırmayı hedeflenmiştir. Gürültü giderme metotlarından gauss filtre görüntülerdeki gürültüyü gidermek ve kontrast iyileştirme metotlarından Clahe metodu görüntülerdeki kontrast sorunu iyileştirmek için kullanılmıştır. Önerilen modelde derin öğrenme modeli kullanılarak yapılan sınıflandırma %96.48 doğrulama başarı (validation accuracy) değerine sahipken, görüntü işleme metotları dahil edildiğinde bu değer %98.52 olarak hesaplanmıştır.

Anahtar Kelimeler: Beyin tümör tespiti, Derin öğrenme, Evrişimli sinir ağı, Görüntü işleme

The Utilisation of Image Processing And Deep Learning Techniques For The Detection of Brain Tumours

Abstract: The early diagnosis of brain tumours has been demonstrated to improve treatment options and patient survival rates. The utilisation of artificial intelligence in the detection of brain tumours has been demonstrated to enhance the efficacy of the process. The utilisation of deep learning methodologies for the detection of brain tumours through the analysis of Magnetic Resonance Imaging images has been demonstrated to be a highly efficacious approach for the identification of the disease in its early stages. Convolutional neural network is a highly sophisticated deep learning technique that has achieved considerable success in this field. The objective of this study is twofold: firstly, to enhance the performance of convolutional neural network models through the utilisation of image processing techniques; and secondly, to streamline the diagnostic phase. The Gauss filter, a denoising method, was employed to eliminate noise in images, while the Clahe method, a contrast enhancement technique, was utilised to address the contrast issue in images. In the proposed model, the classification made using the deep learning model had a validation accuracy of 96.48%, while when image processing methods were included, this value was calculated as 98.52%.

Keywords: Brain tumor detection, Convolutional neural network, Deep learning, Image processing

1. Giriş

Beyin tümörü, dünya genelinde insan yaşamını tehdit eden ölümcül hastalıklardan biridir. Beyin tümörü, beyindeki hücrelerin olağandışı şekilde artması sebebiyle insan beynini kritik derecede rahatsız etmektedir. Beynin düzenli çalışmasını bozar ve yaşam için ölümcül olabilir. Dünya Sağlık Örgütü 'ne (WHO) göre; dünya çapında ikinci önde gelen ölüm nedeni beyin tümörüdür (Patil & Kirange, 2023). Son yıllarda yapılan WHO anketine göre, 2019'dan bu yana 86.000 kişiye beyin tümörü teşhisi

Gönderilme Tarihi: 17.06.2025

Kabul Tarihi: 20.09.2025

Nasıl atıf yapılır: Balitatti, S., & Şentürk, F. (2025). Görüntü işleme ve derin öğrenme teknikleri ile beyin tümör tespiti. *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 30(3), 1009-1026. <https://doi.org/10.53433/yyufbed.1721560>

konmuştur ve dünya çapında 700.000 kişi bir beyin tümörü ile yaşamaktadır (Satyanarayana ve ark., 2023). Bu nedenle, hastalığın zamanında ve erken tespitine ihtiyaç vardır. Erken teşhis ölüm oranının düşmesinde ve hastaların yaşam kalitesinin iyileştirilmesinde önemli bir rol oynamaktadır. Ancak beyindeki tümörün boyutu, şekli, yeri ve türü, beyin tümörünün teşhisini zor hale getirmektedir. Etkili bir tedavinin planlaması, beyin tümörlerinin hızlı ve kesin teşhisine bağlıdır.

Beyin tümörleri, Bilgisayarlı Tomografi (BT), ultrason ve Manyetik Rezonans Görüntüleme (MRG) gibi çeşitli tıbbi görüntüleme teknikleri ile tespit edilebilmektedir. MRG, BT ve ultrason tekniklerine oranla daha yüksek çözünürlükte görüntüler sunmaktadır. MRG görüntülerinde tümörlü yapı ve doku arasındaki farklılıklar, görüntü üzerindeki kontrast değişimleri ile ifade edilebilmektedir. Ayrıca, beyindeki tümör boyutu da MRG görüntüleri ile ölçülebilmektedir. Günümüzde radyoloji uzmanları, hastanın beyindeki MRG görüntülerine bakarak bir beyin tümörünün konumunu ve alanını manuel olarak bulabilmektedir. Ancak bir tümörün derecelendirilmesi için gereken süre, radyoloğun becerisine ve deneyimine bağlıdır. Ayrıca tümör tipi, yeri, boyutu ve büyüme hızı gibi faktörlere bağlı olarak büyük ölçüde değiştiğinden beyin tümörünü erken tahmin etmek oldukça zordur. Çeşitli beyin MRG görüntülerinin insan gücü ile manuel olarak değerlendirmek ve analiz etmek hem zaman alıcı ve maliyetlidir. Aynı zamanda MRG görüntülerinin işlenmesi ve sınıflandırılması uzmanlık gerektirdiği için hataya da açıktır. Beyin tümörünün mümkün olduğunca erken evrede ve hatasız olarak teşhis edilmesi önemlidir. Ayrıca uygulanacak olan tedavi yöntemi (cerrahi müdahale, radyasyon ve/veya kemoterapi gibi) teşhis sonucuna bağlı olarak seçilmektedir (Archana & Komarasamy, 2023). Bir tümör başlangıç noktasında uygun şekilde tanımlanırsa, hastanın iyileşme şansının büyük ölçüde artırılabilir. Bu nedenle, beyin tümörü tipinin kesin teşhisini almak ve cerrahinin gelecekteki karmaşıklığını önlemek için beyin MRG görüntülerinin tümör tespiti için yapay zeka (YZ) destekli bir teşhis aracı oluşturmak hem hastaların doğru teşhis edilmesini sağlayacak hem de erken evrede gözden kaçabilecek olan tümörlerin bulunabilmesine zekâ sağlayacaktır. Radyoloji alanında YZ kullanımı, uzman kişilerin hata oranlarını azalttığı görülmüştür (Arabahmadi ve ark., 2022).

Yapay zeka (YZ), beyin tümörlerinin saptanmasında ve teşhisinde önemli bir rol oynar. Bu amaçla, MRG görüntülerini kullanarak insan beyninde beyin tümörünü bulmak için birçok yöntem ve algoritma önerilen birçok çalışma bulunmaktadır (Logeswari & Karnan, 2010; Akram ve ark., 2011; El-Dahshan ve ark., 2014; Bouhafra & El Bahi, 2024). Son yıllarda MRG görüntü sınıflandırma sistemi geliştiricileri, bu alanda önemli ilerlemeler sağlamak için önemli zaman ve çaba sarf etmişlerdir. Yüksek sınıflandırma performansı olan bir yöntem elde etmek için çok sayıda strateji getirilmiştir. MRG görüntüleri üzerinden hastalığın erken evresinde beyin tümörünün tespiti için derin öğrenme yaklaşımları, etkin bir şekilde kullanılmaktadır. Derin Sinir Ağları (DSA), sınıflandırma problemlerini çözmek (Lakshmi & Nagaraja Rao, 2022) için hiyerarşik bir modeldir, milyonlarca parametre kullanabilir ve büyük veri tabanlarından öğrenebilirler. Doğru bir tespit oranı ve artan işlem hızı nedeniyle, derin öğrenme teknikleri tıbbi görüntüleme sistemlerinde yaygın olarak kullanılmaktadır (Amin ve ark., 2018; Siar & Teshnehlal, 2019; Qin ve ark., 2019; Sahaai ve ark., 2021; Rajendirane ve ark., 2024).

Bu amaçla kullanılan en başarılı derin öğrenme tekniklerinden biri ESA (Evrişimli Sinir Ağı-Convolutional Neural Network)'dır (Arđan ve ark., 2024). ESA modeli kullanılarak MRG görüntüleri tümör var ve tümör yok olarak sınıflandırma yapılabilir. Ancak bu yöntemde girdi olarak seçilen görüntülerinin kalitesi büyük önem taşır. Düşük görüntü kalitesi, eğitim verisi eksikliği, düşük kaliteli görüntü özellikleri, zayıf tümör lokalizasyonu ve diğerleri gibi birçok faktör beyin tümörü sınıflandırma sürecini etkileyebilir. Veri setindeki kalite farklılıkları yöntemin başarısına doğrudan etki ettiği görülmüştür (Nayan ve ark., 2022). Örneğin, BRATS-2018 veri setinde yöntemin doğruluk oranı %97.25 daha gelişmiş olan BRATS-2019 veri seti için yöntemin doğruluk oranı %98.10'dır. Benzer şekilde aynı yöntem BRATS-2020 veri seti ile çalıştırıldığında bu oran %98.49'dur (Geetha ve ark., 2023). İlgili çalışma görüntü kalitesinin yöntemin başarısına doğrudan etki ettiğini göstermektedir.

Bu alanda yapılan çalışmalarda derin öğrenme tabanlı geliştirilen çeşitli modeller kullanılmaktadır. Aslan ve ark. (2025) YOLOv8s-clas kullanmış ve model, beyin tümörlerini sınıflandırmada %98.7 doğruluk oranı elde etmiştir. Anantharajan ve ark. (2024) ilk olarak, MR görüntülerine Adaptif Kontrast Arttırma Algoritması ve medyan filtre kullanılarak ön işleme tabi tutmuştur. Ön işlenmiş görüntüler önerilen Topluluk Tabanlı Derin Sinir Destek Vektör Makinesi sınıflandırıcı ile sınıflandırılmış ve doğruluk %97.93 elde etmiştir. Agarwal ve ark. (2024) çalışmalarında iki aşamalı sınıflandırıcı kullanmıştır. İlk aşamada, görüntü kontrastını iyileştirmek ve

beyin tümörlerinin doğru teşhisini kolaylaştırmak için Otomatik Kontrast Arttırıcı yöntemi kullanılmış sonraki aşamada ise, derin öğrenme yöntemi (Inception V3 modeli) ile %98.89 doğruluk elde edilmiştir. [Aslan \(2024\)](#) çalışmasında ESA ve bir LSTM (Uzun Kısa Süreli Bellek) derin öğrenme katmanının birleştirilerek beyin tümörlerinin tespitinde %98.1 doğruluk elde edilmiştir. [Islam ve ark. \(2024\)](#) ESA-LSTM ve 2B ESA modellerini birleştirilerek hibrit bir ağ oluşturmuş ve %98.82 doğruluk elde etmiştir. [Aiya ve ark. \(2025\)](#) çalışmasında, VGG16 ve optimize edilmiş hiper parametreleri entegre eden hibrit bir derin öğrenme modeli önerilmektedir. Model beyin tümörlerinin türlerini (glioma, meningioma, hipofiz tümörü) ve tümör yok olarak sınıflandırır ve %99 test doğruluğu elde edilmiştir. [Kavitha ve ark. \(2024\)](#) geliştirdikleri derin öğrenme tabanlı MBConv-Finetuned-B0 modeli ile %94 doğruluk elde etmiştir. [Natha ve ark. \(2024\)](#) geliştirdikleri Yığınlı Toplu Transfer Öğrenme modeli ile %98.70 doğruluk elde etmiştir. [Guluwadi \(2024\)](#) ResNet50 adlı bir derin öğrenme modeli ile Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması yöntemini birleştirilerek %98.52 doğruluk elde etmiştir. [Zubair Rahman ve ark. \(2024\)](#) çalışmada MR görüntülerinden beyin tümörü tespiti için EfficientNetB2 derin öğrenme mimarisinden yararlanan yeni bir yapay zeka tabanlı yöntem sunmaktadır. Önerilen model, BD-BrainTumor, Brain-tumor-detection ve Brain-MRI-images-for-brain-tumor-detection veri setlerinde sırasıyla %99.83, %99.75 ve %99.2 doğruluk başarıları elde etmiştir. [Asiri ve ark. \(2024\)](#) beyin tümörü tespitinin hızını ve doğruluğunu artırmayı amaçlayan yenilikçi, iki modüllü bir bilgisayarlı yöntemi sunmaktadır. Birinci modül olan Görüntü İyileştirme Tekniği, adaptif Wiener filtreleme, sinir ağları ve bağımsız bileşen analizi olmak üzere üçlü bir makine öğrenimi ve görüntüleme stratejisini kullanarak görüntüleri normalize eder ve gürültü ile düşük kontrastlı bölgeler gibi sorunlarla mücadele eder. İkinci modül ise Destek Vektör Makineleri (SVM) kullanarak birinci modülün çıktısını doğrular ve tümör segmentasyonu ile sınıflandırmasını gerçekleştirmektedir. Geliştirdikleri yöntem %98.9 doğruluk elde etmiştir. [Priya & Vasudevan \(2025\)](#) çalışmada AlexNet ve Kapılı Tekrarlayan Birim sinir ağlarını birleştiren hibrit bir model ile yenilikçi bir yaklaşım sunmuştur. MRI görüntüleri, en iyi girdi verilerini sağlamak için öncelikle keskinleştirilip yerel olmayan ortalama filtresi kullanılarak gürültüden arındırılmıştır. Geliştirilen yöntem %97 doğruluk elde etmiştir.

Bu çalışma kapsamında, öncelikli olarak görüntü kalitesi düşük olan MRG görüntülerinin ön işlemden geçirilerek görüntü kalitesinin iyileştirilmesi ve sonrasında ise, ESA yöntemi kullanılarak tümörlü olup olmadığının tespitinin yapılması hedeflenmiştir. Ancak geliştirilen sistemin görüntü kalitesi düşük olsa da çalışması ve doğru sonuç vermesi amaçlanmıştır. Bu kapsamda tümör tespiti için taranacak olan görüntüler, model parametresi olarak gönderilmeden önce ön işlemlerden geçirilmiştir. Ön işlemden geçirilen görüntülerin, ESA yöntemiyle sınıflandırılması gerçekleştirilmiştir.


Bu makalenin devamında akış şu şekildedir: 2. Bölümde kullanılan materyal ve yöntemlere yer verilmiştir. 3. Bölümde deneysel uygulama sonuçları açıklanmıştır. Son bölümde ise, çalışmanın değerlendirilmesi ve gelecekte yapılacak çalışmalara yer verilmiştir.

2. Materyal ve Yöntem

Çalışmamızda beyin tümörü tespit aşamasında ESA derin öğrenme modeli eğitilmiş ve oluşturulan ESA modelinin performansını ve doğruluk oranını artırmak için görüntü işleme teknikleri kullanılmıştır. ESA, verileri eğitmek ve tümör tespit etmek için görüntü parçalarını kullanarak tıbbi görüntü işlemede en iyi sonuçlar verdiği görülmüştür ([Asad ve ark., 2023](#)).

2.1. Veri seti

Veri seti olarak ikili sınıflandırmaya uygun Br35H:Brain Tumor Detection veri seti Kaggle ([Anonim, 2025](#)) isimli açık veri kaynağı olan internet sitesinden elde edilmiştir. Veri seti görüntülerin özelliklerine göre, yes, no ve pred olmak üzere 3 farklı kategori içermektedir ve toplamda 3060 Beyin MRG görüntüsü bulunmaktadır. Yes kategorisi, beyin tümörüne sahip olan 1500 MRG görüntüsü içermektedir. No kategorisi, beyin tümörüne sahip olmayan 1500 MRG görüntüsü içermektedir. Pred ise; etiketlenmemiş MRG görüntülerini içermektedir (hem “yes” hem “no” olabilir). “yes” ve “no” olan görüntüler modelimizi eğitmek ve doğrulamak içindir; “pred” klasörü modeli beslenmez, eğitim bittiğinde modelinizin çıktısını (“tumor / no tumor”) üretmek için kullanılır. Veri seti, %80 eğitim ve %20 test olacak şekilde kullanılmıştır. Eğitim ve test için kullanılan veri setine ait tümör olan ve olmayan MR görüntülerine ait örnekler Şekil 1’de verilmiştir.



Şekil 1. İki farklı kategoride verilen örnek beyin MRG görüntüleri (Anonim, 2025).

2.2. Teknik altyapı detayları


Yüksek çözünürlüklü MRG veri setinin verimli bir şekilde işlenmesi ve derin öğrenme modellerinin daha hızlı bir şekilde eğitilmesi amacıyla tüm deneysel çalışmalar, Google Colab Pro + üzerinde T4 GPU, 50 GB RAM, 235 GB Disk ile donatılmış bir sistemde gerçekleştirilmiştir. ESA Modeli epoch sayısı 60 oluncaya kadar eğitilmiştir. Adam optimizasyon algoritması 0.001 öğrenme hızı ile kullanılmıştır. Adam optimizasyon algoritması ile modelin ağırlıkları ve toplam kaybı minimize edecek şekilde optimize edilmiştir. Ayrıca, platform veri işleme ve model geliştirme verimliliğini artırmak için Numpy, Pandas, Matplotlib, Sklearn, Keras ve TensorFlow gibi çeşitli kütüphaneleri kullanılmıştır.

2.3. Geliştirilen mimari

Geliştirilen sistemde, beyin tümörlerinin hızlı ve yüksek doğrulukla tespit edilmesi amaçlanmıştır. Bu kapsamda geliştirilen mimari içim uygulanan basamaklar şu şekildedir:

- **Veri setlerinin elde edilmesi:** Kaggle, Figshare, vb. gibi veri seti sitelerinden beyin MRG görüntülerine ait veri setleri elde edilmiştir.
- **Ön işleme:** Farklı kaynaklardan toplanan veriler farklı filtreleme teknikleri, optimizasyon ve tespit yöntemleri (Rasheed ve ark., 2023) ile veri setindeki MRG görüntüleri işlenerek optimize edilmiştir.
- **ESA modeli eğitimi ve testi:** Ön işleme tamamlanan veriler ESA (Modiya & Vahora, 2022; Ramtekkar ve ark., 2023) modeli kullanılarak beyin tümörü tespit edilmiştir.

Beyin tümörünün görüntü işleme kullanılarak tespit edilmesine yönelik geliştiren mimarinin Yöntem Akış Şeması Şekil 2'de gösterilmiştir. Buna göre, açık veri setlerinden elde edilen düşük kaliteli beyin MRG görüntüleri, görüntü işleme basamağına aktarılmaktadır. Görüntü işleme kısmında ise, görüntülerin kalitesi artırılmak amacıyla Gauss filtre, Otsu filtre, medyan filtre ve Clahe metodu ayrı ayrı uygulanmıştır. Ön işleme basamağından sonra elde edilen filtreli veriler, tümör tespitini yapan ikili sınıflandırma basamağına girdi olarak verilmiştir. İkili sınıflandırma basamağında evrişimli yapay sinir ağları kullanılmıştır.



Şekil 2. Beyin tümör tespiti yöntem akış şeması.

2.3.1. Ön işleme

Derin öğrenme modelinde eğitim ve test aşamalarında kullanılacak olan görüntünün kalitesini artırma amacıyla, sistematik bir ön işleme yaklaşımı uygulanmıştır. İlk olarak, gürültüyü azaltmak ve görsel netliği artırmak amacıyla orijinal veri setine gauss filtre uygulanmıştır. Bu temel adım, modelin görüntüleri daha iyi anlamasına olanak sağlayacak sonraki iyileştirmelere zemin hazırlamıştır. Görüntü kontrastını arttırmak ve ayrıntıları vurgulamak amacıyla Kontrast Sınırlamalı Uyarlamalı Histogram Eşitleme (Clahe) tekniğini uygulanmıştır. Clahe sayesinde, her görüntüde önemli özellikleri ön plana çıkarmayı ve anahtar detayların korunmasını sağlamayı hedeflenmiştir.

Geliştirilen mimaride kullanılan görüntü işleme teknikleri şu şekildedir:


- **Gauss filtre (Gaussian filter):** Gauss filtresi, görüntüdeki yüksek frekanslı bileşenleri (örneğin, keskin kenarlar ve ince detaylar) yumuşatarak gürültüyü azaltan bir düşük geçiren (low-pass) filtre türüdür. Özellikle Gauss tipi gürültü (Gaussian noise) içeren görüntüler için etkilidir. Bu filtre, piksellerin ağırlıklı ortalamasını alarak bir bulanıklık (blurring) işlemi uygular. Komşu pikseller, Gauss fonksiyonu kullanılarak belirlenen ağırlıklarla toplanır ve gürültü nedeniyle oluşan keskin değişiklikler, bu ortalama alma işlemiyle azaltılır.
- **Medyan filtre (Medyan filter):** Medyan filtresi, özellikle tuz ve karabiber (salt and pepper noise) tipi gürültünün giderilmesi için kullanılan bir tekniktir. Ortalamadan farklı olarak, piksellerin medyan değerini alır ve merkezi pikseli buna göre değiştirir. Seçilen komşuluk penceresindeki (örneğin, 3x3 veya 5x5) tüm pikseller sıralanır, ortadaki medyan (median) değer seçilir ve merkez piksel bu değerle değiştirilir. Bu işlem, gürültüye sahip olan uç (extreme) değerleri filtreleyerek görüntünün daha temiz hale gelmesini sağlar.
- **Otsu eşikleme:** Otsu yöntemi, görüntüyü eşikleme yoluyla ikili (binary) bir hale dönüştüren bir görüntü segmentasyon tekniğidir. Bu doğrusal olmayan süreç, pikselleri ön plan veya arka plan olarak sınıflandırarak iki tepe noktalı (bimodal) bir histogram oluşturur. Bu yöntem, ideal eşikleme aralığını belirlemek için istatistiksel prensiplere dayanır. Ön plan ve arka plan sınıflarındaki ağırlıklı

varyans toplamını en aza indirerek en iyi eşik değerini belirler. Böylece, görüntü iki sınıfa ayrılır ve toplam varyans en düşük seviyeye getirilmiş olur.

- **Clahe (Contrast limited adaptive histogram equalization):** Clahe, kontrast sınırlı adaptif histogram eşitleme yöntemidir. Görüntüdeki kontrastı artırırken, aşırı parlaklık veya karanlık bölgelerin ortaya çıkmasını engellemeye çalışır. Bu yöntem, bölgesel olarak her bir görüntü parçası için histogram eşitlemesi yaparak, görüntüdeki kontrastı iyileştirir. Özellikle düşük kontrastlı ve aydınlatma problemi olan görüntülerde etkili olur.
- **ESA (Evrişimli Sinir Ağı):** ESA, derin öğrenme modellerinden biridir ve özellikle görüntü işleme ve bilgisayarla görme uygulamalarında yaygın olarak kullanılır. Konvolüsyonel katmanlar (Conv2D), pooling katmanları (MaxPooling2D) ve tam bağlantılı katmanlar (Dense) gibi bir dizi katmandan oluşur. ESA'lar, özellik çıkarımı, sınıflandırma ve tahmin işlemleri için çok etkilidir ve özellikle görsel verilerde yüksek başarı sağlar. Görüntüdeki desenleri, kenarları ve diğer özellikleri otomatik olarak öğrenebilir. Her biri farklı bir işlem veya uygulama alanına hitap eder, ancak genellikle görüntü işleme, veri analizi ve makine öğrenmesi alanlarında önemli yer tutarlar.

2.3.2. Gürültü giderme

Sınıflandırma doğruluğu arttırmak için, MRG görüntü kalitesini en üst düzeye çıkarırken gürültüyü en aza indirmek gerekmektedir, çünkü beyin MRG görüntüleri diğer tıbbi görüntülere göre gürültüye daha duyarlıdır. Çalışmamızda, beyin MRG2'lerinde mevcut olan gürültüyü azaltmak için gauss filtre uygulanmıştır. Görüntü işleme metodlarının daha iyi sonuçlar verebilmesi için görüntü gri tonlamaya (grayscale) dönüştürülmüştür. Daha sonra Gauss filtrenin çekirdek boyutu (kernel size) 3x3 ve 7x7 değerleri kullanılarak uygulanmıştır. 3x3 çekirdek boyutuna sahip gauss filtre daha iyi sonuç vermiştir. Bunun sonucunda kontrast iyileştirme aşamasında gauss filtrenin 3x3 çekirdek boyutunda kullanılması sonucu elde edilen gürültüsü giderilmiş görüntüler kullanılmıştır. Şekil 3'te orijinal olarak verilen görüntü, veri setindeki ham başlangıç görüntüsüdür ve bu görüntü üzerine gauss filtre uygulandığında elde edilen sonuç Gasussian Blur olarak verilmiştir.




Şekil 3. Gauss Filtre uygulama.

2.3.3. Kontrast ayarlama

Görüntü kalitesini artırmak için yöntemini gürültüsü giderilmiş görüntüler üzerine Kontrast Sınırlamalı Uyarlamalı Histogram Eşitleme (Clahe) metodu uygulanmıştır. Global histogram eşitlemeden farklı olarak, Clahe, görüntüyü ayrı bölgelere ayırarak her bir bölge için ayrı ayrı eşitleme işlemi gerçekleştiren yerel bir strateji benimser. Görüntülerin yerel kontrast artırılır, ancak gürültü ve

aşırı parlaklık (over-amplification) önlenir. Clahe metodu kontrast sınırlaması (clipLimit) 3.0, 5.0 ve 7.0 değerli kullanılarak uygulanmıştır. En iyi sonuç 3.0 kontrast sınırlama değeri ile elde edilmiştir. Sonraki derin öğrenme modelinin gereksinimlerine uygunluğu sağlamak amacıyla, geliştirilen gri tonlamalı görüntü RGB renk uzayına dönüştürülmüştür. Şekil 4'te orijinal olarak verilen kısım, veri setindeki ham görüntüdür. Şekil 4'te Clahe olarak verilen görüntü ise; ham görüntü üzerine Clahe metodunun uygulanması sonucunda elde edilmiştir.




Şekil 4. Clahe Metot uygulama.

2.3.4. Derin öğrenme modeli


Sınıflandırma aşamasında derin öğrenme modeli olarak ESA model kullanılarak tümör var ve tümör yok şeklinde ikili sınıflandırma gerçekleştirilmiştir. ESA modeli, ağırlıkları olan 12 katmandan oluşmaktadır: üç evrişim (convolution) katmanı, bir tam bağlı (fully connected) katman ve bir çıktı (sınıflandırma) katmanı. Buna ek olarak, aktivasyon (ReLU), iki dropout, bir flatten ve max-pooling katmanı bulunmaktadır.

Önerilen model, iki farklı sınıfa (0 ve 1) karşılık gelen iki boyutlu bir vektör üreten bir çıktı katmanı içermektedir ve bu katmanın çıktılarına sigmoid fonksiyonu uygulanarak model ikili (binary) sınıflandırma yapmaktadır. Çıktıyı 0 ile 1 arasında bir olasılık değeri olarak üretir. 0'a yakınsa: Sınıf negatif (0) olarak etiketlenir. 1'e yakınsa: Sınıf pozitif (1) olarak etiketlenir. Mevcut önceden eğitilmiş (pretrained) ağırlarla karşılaştırıldığında, böyle özelleştirilmiş bir ağ oluşturma'nın temel amacı, algılama doğruluğunu korurken öğrenme hızını ve parametre sayısını azaltmaktır.

Geliştirilen ESA mimarisi, tümör olan ve tümör olmayan görüntüler ile test edilmiştir. Örneğin Şekil 5'te, filtreden geçirilmiş MRG görüntüsü (MRI input image) mimariye girdi olarak verildiğinde, tümör var olarak tespit edilmiştir. Şekil 6'da ise, tümör olmayan bir MRG görüntüsü ESA mimarisine girdi olarak verildiğinde tümör yok olarak tespit edilmiştir.



Şekil 5. Tümör var tahmin sonucu.



Şekil 6. Tümör yok tahmin sonucu.

Çizelge 1’de verildiği üzere, ilk evrişim (convolution) katmanı, $224 \times 224 \times 3$ boyutunda bir görüntüyü alır, 5×5 boyutunda 32 çekirdek (kernel) ile evriştirir ve stride=2 kullanılarak $112 \times 112 \times 32$ boyutunda bir çıktı üretmektedir. Evrişim katmanının çıktısı üzerinde ReLU aktivasyonu uygulanır ve ardından 2×2 boyutunda bir max-pooling katmanı kullanılarak özellik haritalarının boyutu küçültülür.

Önceki katmanın çıktısı bir sonraki evrişim katmanına gönderilir ve burada 3×3 boyutunda 64 çekirdek ile evriştirilir. Stride=2 kullanılarak özellik haritaları daha da küçültülerek $56 \times 56 \times 64$ boyutunda bir hacim elde edilir. Max-pooling işlemi tekrarlanarak çıktı $28 \times 28 \times 64$ boyutuna düşürülür.

Üçüncü evrişim katmanı, 128 çekirdek ile 3×3 boyutunda bir evrişim uygulamakta ve yine stride=2 kullanılarak çıktı boyutu $14 \times 14 \times 128$ olacak şekilde küçültmektedir. Max-pooling katmanı ile boyut $7 \times 7 \times 128$ seviyesine getirilir.

Önceki katmandan alınan verileri, 6272 boyutunda bir vektöre dönüştürülür. Ardından 0.4 dropout katmanı uygulanarak aşırı öğrenme (overfitting) önlenir. 128 nöron içeren tam bağlı (fully connected) katman eklenir ve ReLU aktivasyonu ile doğrusal olmayan dönüşüm sağlanır.

Son olarak, 1 nöronlu bir çıkış katmanı eklenir ve sigmoid aktivasyon fonksiyonu ile çıktının 0 ile 1 arasında bir olasılık değeri olarak hesaplanması sağlanır. Model, giriş görüntüsünü hiyerarşik özellik öğrenme ile işleyerek nihai sınıf tahminini gerçekleştirir.

Önerilen model, Adam optimizasyon algoritması kullanılarak eğitilmiştir. Kullanılan batch boyutu 32, epoch sayısı ise 60’dır. Kayıp fonksiyonu olarak ikili çapraz entropi (binary crossentropy) kullanılmış ve doğruluk metriği ile değerlendirilmiştir. Elde edilen eğitim doğruluğu 0.9958, kayıp değeri ise 0.0098’dir. Tüm modele ait katman özellikleri ve eğitim sırasında kullanılan parametreler Çizelge 1’de özet olarak gösterilmiştir.

3.Bulgular

Derin öğrenme ve görüntü işleme kullanarak gerçekleştirdiğimiz sınıflandırma modelimizin farklı görüntü işleme metotlarının kullanımı ve aynı görüntü işleme metotlarının farklı parametreler ile kullanımının karşılaştırmalı analizi sunulmuştur. Derin öğrenme modelinin doğruluma doğruluk oranı %96.48 başarı oranına sahipken, görüntü işleme metotlarının kullanımı ile derin öğrenme modelinin doğruluma doğruluk oranı %98.52 elde edilmiştir.

Önerdiğimiz modelin performans değerlendirmesi için, Br35H: Brain Tumor Detection veri seti Kaggle web sayfasından elde edilmiştir. Bu veri seti, iki sınıftan oluşmaktadır:

- No: Tümör içermeyen 1500 MRG görüntüleri,
- Yes: Tümör içeren 1500 MRG görüntüleri

Çizelge 1. ESA Modele ait parametre çizelgesi

Layer Type	Filters/Units	Kernel Size	Output Shape	Param#
Input Layer	-	-	(224,224,3)	0
Conv2D	32	(5,5)	(112,112,32)	2.432
MaxPooling2D	-	(2,2)	(56,56,32)	0
MaxPooling2D	-	(2,2)	(14,14,64)	0
MaxPooling2D	-	(2,2)	(3,3,128)	0
Flatten	-	-	(1152)	0
Dropout	-	-	(1152)	0
Dense	128	-	(128)	147.584
Dropout	-	-	(128)	0
Dense(Output)	1	-	(1)	129
TotalParameters	-	-	-	242.497
TrainableParameters	-	-	-	242.497

Geleneksel ESA modeli için, veri setini %80 eğitim ve %20 test oranında böldüğümüzde en iyi sonucu elde edilmiştir.

Önerdiğimiz metodolojiye dayanarak, ilk aşamada gürültü gidermek için MRG görüntülerine gauss filtre ve medyan filtreyi ayrı ayrı kullanarak farklı parametre değerleri ile denemeler yapılmıştır. Bu denemeler sonucunda gauss filtrenin medyan filtreden daha başarılı sonuç verdiği gözlemlenmiştir. İkinci aşama olan kontrast ayarlama aşamasına geçmeden önce en iyi sonuç vermesi nedeniyle MRG görüntülerindeki gürültü gauss filtrenin 3x3 çekirdek boyutu ile uygulanmıştır.

Veri seti herhangi bir ön işlemten geçirilmeden ESA modeli üzerinde test edilmiş ve %99.30 doğruluk oranı elde edilmiştir. Doğrulama başarısı ise %96.48 olarak hesaplanmıştır. Elde edilen sonuçlar Çizelge 2’de verilmiştir. Sonraki test aşamalarında, veri setindeki görüntülerde bulunan gürültü ve parlaklık sorunlarının ESA modelinin performansını olumsuz etkilediği görülmüş ve bu sorunların giderilmesi amacıyla çeşitli görüntü işleme yöntemleri farklı parametrelerle denenmiştir. Bu denemelere ilişkin sonuçlar Çizelge 2’de yer almaktadır.

ESA modeline görüntü işleme yöntemlerinin entegrasyonunda ilk olarak gürültü azaltmaya yönelik filtreler kullanılmıştır. Görüntülere 3x3 boyutunda matris ile Gauss filtresi uygulandığında doğrulama başarısı %97.59’a yükselmiştir. Bu artış dikkate alınarak, Gauss filtresi 7x7 boyutunda matris ile yeniden uygulanmış; ancak bu durumda 3x3 matris kullanımına kıyasla başarının düştüğü gözlemlenmiştir. Sonuç olarak, modelimiz ve veri seti için en uygun seçeneğin 3x3 boyutundaki Gauss filtresi olduğu belirlenmiştir.

Sonraki denemeler medyan filtre ile gerçekleştirilmiştir. Medyan filtre uygulamalarında 3x3, 5x5 ve 7x7 boyutlarında matrisler kullanılmış ve en yüksek doğrulama başarısı %97.22 ile 3x3 matrisli medyan filtresinde elde edilmiştir. Medyan ve Gauss filtrelerinin doğrulama başarı oranları karşılaştırıldığında, en yüksek başarının 3x3 matrisli Gauss filtresi ile sağlandığı tespit edilmiştir. Bu nedenle, modele gürültü giderme amacıyla 3x3 boyutundaki Gauss filtresi entegre edilmiştir. Model mimarisi kurulması sırasında, Br35H veri seti %80 eğitim ve %20 test verisi olarak kullanılmıştır. Veriler ESA model ile sınıflandırılmıştır. Model eğitimi sırasında, epoch 60 olarak ayarlanmıştır.

Çizelge 2. Gauss Filtre ve Medyan Filtre uygulanması sonucu ESA Model başarı oranı

Görüntü Metodu	İşleme	Doğruluk	Kayıp	Doğrulama Başarısı	Doğrulama Kaybı
Yok		%99.30	0.0266	%96.48	0.2105
Gauss Filtre(3,3)		%99.60	0.0115	%97.59	0.2105
Gauss Filtre(7,7)		%98.61	0.0387	%97.04	0.1587
Medyan Filtre(3.0)		%99.27	0.0209	%97.22	0.2702
Medyan Filtre(5.0)		%99.88	0.0048	%96.30	0.3014
Medyan Filtre(7.0)		%98.76	0.0322	%96.30	0.3014

İkinci aşamada, orijinal görüntülere kontrast ayarlama yöntemlerinden Clahe ve Otsu (Divya Shree, 2022) yöntemleri, farklı parametreler ile ayrı ayrı uygulanmıştır. Otsu yöntemi, 110, 120 ve 125 eşik değerleri kullanılarak test edilmiş; en iyi doğrulama başarısı %96.30 ile 120 eşik değeri kullanıldığında elde edilmiştir.

Clahe yöntemiyle gerçekleştirilen denemelerde ise 3.0, 5.0 ve 7.0 kontrast limiti (clipLimit) değerleri uygulanmıştır. Bu denemeler sonucunda en yüksek başarı, %97.04 doğrulama başarısı ve %99.64 doğruluk oranı ile 3.0 kontrast limiti kullanıldığında elde edilmiştir.

Elde edilen sonuçlar doğrultusunda, Otsu yönteminin kullanılan veri seti için uygun olmadığı belirlenmiş ve sonraki denemelerde Clahe yöntemi ile çalışmalara devam edilmiştir. Çizelge 3'te, Clahe ve Otsu yöntemlerinin farklı parametrelerle uygulanması sonucunda ESA modelinin elde ettiği başarı oranları gösterilmektedir.

Çizelge 3. Clahe ve Otsu metotlarının uygulanması sonucu ESA Model başarı oranı

Görüntü Metodu	İşleme	Doğruluk	Kayıp	Doğrulama Başarısı	Doğrulama Kaybı
Yok		%99.30	0.0266	%96.48	0.2105
Otsu(110)		%99.51	0.0122	%95.93	0.1776
Otsu(120)		%99.17	0.0300	%96.30	0.2122
Otsu(125)		%99.71	0.0144	%95.74	0.2359
Clahe(3.0)		%99.64	0.0155	%97.04	0.2136
Clahe(5.0)		%99.48	0.0186	%97.04	0.1958
Clahe(7.0)		%99.39	0.0190	%96.30	0.2120

Kontrast ayarlama yöntemleri arasında en iyi sonucun Clahe yöntemi ile elde edildiği Çizelge 3'de görülmektedir. Sonraki aşamada ise, 3x3 çekirdek boyutuna sahip Gauss filtresinden geçirilmiş görüntüler üzerinde Clahe yönteminin 3.0 kontrast limiti uygulanmış ve model doğruluğu açısından en yüksek performansın bu kombinasyonda elde edildiği tespit edilmiştir. Bu nedenle, sonraki denemeler Gauss filtresi ve Clahe yönteminin birlikte kullanılmasıyla gerçekleştirilmiştir.


Gürültü giderme işleminin ardından Clahe yönteminin başarı oranında değişimler olabileceği dikkate alınarak, gürültüsü azaltılmış görüntüler üzerinde Clahe yöntemi 3.0, 5.0 ve 7.0 kontrast limiti değerleri ile uygulanmıştır. Öngörüldüğü gibi, en iyi sonuç 3x3 matris boyutunda Gauss filtresi ve 3.0 kontrast limiti ile Clahe yönteminin birlikte uygulanmasıyla elde edilmiştir. Bu kombinasyonla eğitilen ESA modeli, %98.52 doğrulama başarısı sağlamıştır.

Çizelge 4'te, Clahe yönteminin Gauss filtresi ile birlikte farklı parametrelerle uygulanması sonucunda ESA modelinin elde ettiği başarı oranları sunulmaktadır.

Çizelge 4. Gauss Filtrenin ile Clahe Metodu uygulanması sonucu ESA Model başarı oranı


Görüntü İşleme Metodu	Doğruluk	Kayıp	Doğrulama Başarısı	Doğrulama Kaybı
Yok	%99.30	0.0266	%96.48	0.2105
Gauss Filtre(3,3) + Clahe(3.0)	%99.58	0.0098	%98.52	0.1690
Gauss Filtre(3,3) + Clahe(5.0)	%99.03	0.0387	%96.67	0.2184
Gauss Filtre (3,3) + Clahe(7.0)	%99.41	0.0158	%97.04	0.2150

Şekil 7'de gösterilen ESA modeline ait doğruluk grafiği, modelin Br35H veri setindeki güçlü öğrenme performansını göstermektedir. Eğitim doğruluk eğrisi %99.58'dir ve doğrulama başarı eğrisi %98.52 gibi yüksek bir değere ulaşarak etkili öğrenme işleminin gerçekleştiğini işaret etmektedir.




Şekil 7. Önerilen ESA Modelin doğruluk grafiği.

Şekil 8'de ESA modelinin kayıp grafiği verilmiştir ve Br35H veri setindeki güçlü öğrenme performansını göstermektedir. Eğitim kayıp eğrisi 0.0098 olarak hesaplanırken, doğrulama kayıp eğrisi yaklaşık 0.1690 seviyesinde sabitlenmiştir. Sonuç olarak, modelin zamanla hata oranlarını etkili bir şekilde minimize ettiğini göstermektedir.




Şekil 8. Önerilen ESA Modelin Kayıp (Loss) grafiği.

Şekil 9'da ise ESA modelinin karmaşıklık matrisi, sınıflandırma modelinin X-ray veri setindeki performansını göstermektedir. Bu, modelin 148 örneği doğru şekilde tümör yok (No Tumor) olarak ve 147 örneği doğru şekilde tümör (Tumor) olarak sınıflandırdığını, ancak 2 tümör değil örneğini yanlışlıkla tümör olarak ve 3 tümör örneğini yanlışlıkla tümör değil olarak sınıflandırdığını göstermektedir.



Şekil 9. Önerilen ESA Modelin hata matrisi (Confusion Matrix).

Şekil 10'da ise, ESA modeline ait Br35H veri setinde sınıf ayrımını gösteren ROC eğrisini sunmaktadır. Modelin AUC değeri 0.98 olarak hesaplanmıştır.



Şekil 10. Önerilen ESA Modelin ROC eğrisi

3.1. Model değerlendirme metrikleri

Bir ESA modelinin performansını değerlendirirken çeşitli ölçüm yöntemleri kullanılır. Modelin test verisi üzerindeki performansı dört temel ölçüt üzerinden değerlendirilir. Bu ölçütler Gerçek Pozitifler (TP), Yanlış Pozitifler (FP), Gerçek Negatifler (TN) ve Yanlış Negatifler (FN) olarak adlandırılır:

TP (Gerçek pozitif): ESA modeli, ait olduğu sınıfa doğru şekilde tahmin ettiğinde oluşur. Örneğin, model bir hastalık görüntüsünü doğru şekilde hastalıklı olarak sınıflandırdığında.

TN (Gerçek negatif): Model, negatif bir örneği doğru şekilde negatif olarak sınıflandırdığında oluşur. Örneğin, sağlıklı bir görüntüyü sağlıklı olarak tahmin ettiğinde.

FP (Yanlış pozitif): Model, negatif bir örneği yanlışlıkla pozitif olarak tahmin ettiğinde oluşur. Örneğin, sağlıklı bir görüntüyü hastalıklı olarak sınıflandırdığında.

FN (Yanlış negatif): Model, pozitif bir örneği yanlışlıkla negatif olarak tahmin ettiğinde oluşur. Örneğin, hastalıklı bir görüntüyü sağlıklı olarak sınıflandırdığında.

Bu ölçütler, ESA modelinin sınıflandırma doğruluğunu ve hatalarını değerlendirmek için kullanılır. Önerilen model Br35H veri seti kullanılarak eğitilmiştir. Model doğruluk(accuracy), kesinlik(precision), duyarlılık(recall), özgüllük(specificity) ana değerlendirme teknikleri kullanılarak değerlendirilmiştir. Bu model, aşağıdaki gibi matematiksel olarak denklemler (1), (2), (3), (4) ile tanımlanmıştır:

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

$$Sensitivity(recall) = \frac{TP}{TP+FN} \quad (2)$$

$$Specficity = \frac{TN}{TN+FP} \quad (3)$$

$$Precision(PPV) = \frac{TP}{TP+FP} \quad (4)$$

Model, %99.58 doğruluk(accuracy), %98.65 kesinlik (precision), %98duyarlılık (recall) elde ederek dengeli bir performans sergilemiştir. Ayrıca, %98.66 özgüllük (specificity) değeri, modelin negatif örnekleri başarılı bir şekilde tanımlama yeteneğini göstermektedir. Çizelge 5'te önerilen modele ait performans metrikleri gösterilmektedir.

Çizelge 5. Önerilen modelin performans metrikleri

Metrik	Değer
Doğruluk	%98.52
Kesinlik	%98.65
Duyarlılık	%98.0
Özgüllük	%98.66

4. Tartışma ve Sonuç

Bu çalışmada, düşük çözünürlüklü MRG görüntüleri üzerinde ön işlem uygulanarak, ESA kullanılarak görüntüler üzerinde tümör tespiti yapılmıştır. Bu amaçla, ikili sınıflandırmaya uygun 3060 MRI görüntüsü bulunan, Br35H:Brain Tumor Detection veri seti kullanılmıştır. Çalışma kapsamında, MRG veri setinin verimli bir şekilde işlenmesi ve derin öğrenme modellerinin daha hızlı bir şekilde eğitilmesi amacıyla tüm deneysel çalışmalar, Google Colab Pro + üzerinde T4 GPU, 50 GB RAM, 235 GB Disk ile donatılmış bir sistemde gerçekleştirilmiştir. ESA Modeli epoch sayısı 60 oluncaya kadar eğitilmiştir.

Daha önceki araştırmalarda, aynı veri seti üzerinde farklı beyin tümörlerini sınıflandırmak ve tümör varlığını tespit etmek için derin öğrenme (DÖ) algoritmaları kullanılmıştır. Önerilen yaklaşımın sonuçları, benzer bir yöntem uygulayan ve benzer veri seti kullanan önceki çalışmalarla karşılaştırılmıştır.

Çizelge 6’da, çalışmamızda temel alınan ESA modeli (Schiavon ve ark, 2023) ile görüntü işleme yöntemleri kullanılarak geliştirilen önerilen ESA modelinin karşılaştırması sunulmaktadır. Uygulanan görüntü işleme teknikleri sayesinde derin öğrenme modelinin başarı oranının artırıldığı görülmektedir. Sadece ESA modeli ile yapılan sınıflandırmada %96.48 doğrulama başarısı elde edilirken, önerilen model %98.52 doğrulama başarısına ulaşmıştır.

Çizelge 6. Önerilen tekniğin mevcut derin öğrenme modelleri ile karşılaştırılması

Metot	Doğruluk	Kayıp	Doğrulama Başarısı	Doğrulama Kaybı
Önerilen Model	%99.58	0.0098	%98.52	0.1690
ESA (Schiavon ve ark, 2023)	%99.35	0.0204	%96.48	0.1264

Görüntü işleme tekniklerinin kullanımı veri seti kalitesinin artmasını sağlayarak derin öğrenme modelinin doğruluğun artmasına ve üstün performans elde edilmesine katkıda bulunmuştur. Çizelge 7, en güncel yöntemleri önerilen yöntem ile karşılaştırmakta olup, önceki araştırmalardan daha iyi performans gösterdiği açıkça görülmektedir.

Çizelge 7. Önerilen tekniğin mevcut görüntü işleme yöntemleri dâhil edilen derin öğrenme modellerinin karşılaştırılması

Metot	Doğruluk	Kesinlik	Duyarlılık
Önerilen Model	%98.52	%98.65	%98
DenseNet169 (Islam ve ark., 2024) + Histogram Eşitleme	% 93.29	% 94	% 88
ESA+Gauss Filter (Islam ve ark., 2023)	%98.5	%98	%98
ESA+U-net (Jebin ve ark., 2025)	%97.31	%96.81	%97.83
Transfer Öğrenme Tabanlı Derin ESA (Bhardwaj ve ark., 2024)	%97	%97	%97

Bu çalışma, görüntü işleme metotları ile MRG görüntülerinin kalitesinin artırılması sonucunda ESA model ile MRG tabanlı beyin tümörü tespiti doğruluğunu ve güvenilirliğini önemli ölçüde artırdığını göstermektedir. Gürültü giderme metotlarından gauss filtre görüntülerdeki gürültüyü gidererek ve kontrast iyileştirme metotlarından clahe metodu görüntülerdeki kontrast sorunu iyileştirerek tümör tespit doğruluğunu iyileştirmektedir. Önerilen model sadece derin öğrenme modeli kullanılarak yapılan sınıflandırmada doğrulama başarı değeri %96.48 iken (Schiavon ve ark., 2023) görüntü işleme metotları ile ön işleme yaptıktan sonra geliştirdiğimiz derin öğrenme modeli doğrulama başarı değeri %98.52'dir. Bu sonuçlar, görüntü işleme metotlarının tıbbi görüntüleme alanındaki dönüştürücü potansiyelini vurgulayarak, beyin tümörü hastaları için daha hassas ve güvenilir tanı araçları sunarak erken teşhis ve tedavi sonuçlarını iyileştirme imkanı sağlamaktadır. Görüntü işleme metotlarının uygulanabilirliği, farklı tanısal görevlerde daha geniş bir uygulama alanına sahip olabileceğini göstermektedir.

MRG görüntülerinde tümör tespiti yanı sıra tümörlerin türünün tespiti üzerinde çalışmalarımız devam etmektedir. Bu kapsamda tümör türü tespiti sonrasında, geliştirilen yöntemin bir hastane uygulaması ile entegre edilmesi sağlanacaktır.

Teşekkür / Destekleyen Kuruluş

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 2209 – A projeleri kapsamında 1919B012321142 başvuru numarası ile desteklenmiştir. Projeye verdiği destekten ötürü TÜBİTAK'a teşekkürlerimizi sunarız.

Yazarların Katkı Oranı Beyanı

Sinem Balıatlı: Kuram/Teori Oluşturma, Algoritma Geliştirme, Görselleştirme, Araştırma, Makale Yazımı. **Fatmana Şentürk:** Kuram/Teori Oluşturma, Makale Yazımı, Gözden Geçirme ve Düzenleme.

Çıkar Çatışması Beyanı

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan eder.

Araştırma ve Yayın Etiği Beyanı

Bu makalenin yazarları çalışmalarında araştırma ve yayın etiğine uyduklarını beyan ederler.

Etik Kurul Beyanı

Bu makalenin yazarları çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

Kullanılan Verilere Erişim

Çalışma ile ilgili kullanılan veriler açık veri olup Kaggle üzerinden alınmıştır. (Br35H: Brain Tumor Detection 2020. Erişim Tarihi: 30.05.2025. <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection>)

Yapay Zekâ Kullanımı

Yazarlar, bu makalenin yazımında, görsellerin, grafiklerin, tabloların ya da bunlara karşılık gelen başlıkların oluşturulmasında herhangi bir tür üretken yapay zeka kullanmadıklarını beyan ederler.

Kaynakça

- Agarwal, M., Rani, G., Kumar, A., Kumar, P., Manikandan, R., & Gandomi, A. H. (2024). Deep learning for enhanced brain tumor detection and classification. *Results in Engineering*, 22, 102117. <https://doi.org/10.1016/j.rineng.2024.102117>
- Aiya, A. J., Wani, N., Ramani, M., Kumar, A., Pant, S., Kotecha, K., ... & Al-Danakh, A. (2025). Optimized deep learning for brain tumor detection: a hybrid approach with attention mechanisms and clinical explainability. *Scientific Reports*, 15(1), 31386. <https://doi.org/10.1038/s41598-025-04591-3>
- Akram, M. U., & Usman, A. (2011, July). Computer aided system for brain tumor detection and segmentation. In International conference on Computer networks and information technology (pp. 299-302). IEEE. <https://doi.org/10.1109/ICCNIT.2011.6020885>
- Amin, J., Sharif, M., Yasmin, M., & Fernandes, S. L. (2018). Big data analysis for brain tumor detection: Deep convolutional neural networks. *Future Generation Computer Systems*, 87, 290-297. <https://doi.org/10.1016/j.future.2018.04.065>
- Anantharajan, S., Gunasekaran, S., & Subramanian, T. (2024). MRI brain tumor detection using deep learning and machine learning approaches. *Measurement: Sensors*, 31, 101026. <https://doi.org/10.1016/j.measen.2024.101026>
- Anonim. (2025). Br35H: Brain Tumor Detection 2020. Erişim Tarihi: 30.05.2025. <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection>
- Arabahmadi, M., Farahbakhsh, R., & Rezazadeh, J. (2022). Deep learning for smart Healthcare—A survey on brain tumor detection from medical imaging. *Sensors*, 22(5), 1960. <https://doi.org/10.3390/s22051960>
- Archana, K. V., & Komarasamy, G. (2023). A novel deep learning-based brain tumor detection using the Bagging ensemble with K-nearest neighbor. *Journal of Intelligent Systems*, 32(1), 20220206. <https://doi.org/10.1515/jisys-2022-0206>
- Arđan, I. S., & Indraswari, R. (2024, January). Design of brain tumor detection system on MRG image using CNN. In 2024 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems (ICETIS) (pp. 1388-1393). IEEE. <https://doi.org/10.1109/ICETIS61505.2024.10459651>
- Asad, R., Rehman, S. U., Imran, A., Li, J., Almuhaimeed, A., & Alzahrani, A. (2023). Computer-aided early melanoma brain-tumor detection using deep-learning approach. *Biomedicines*, 11(1), 184. <https://doi.org/10.3390/biomedicines11010184>
- Asiri, A. A., Soomro, T. A., Shah, A. A., Pogrebna, G., Irfan, M., & Alqahtani, S. (2024). Optimized brain tumor detection: a dual-module approach for mri image enhancement and tumor classification. IEEE access, 12, 42868-42887. <https://doi.org/10.1109/ACCESS.2024.3379136>
- Aslan, E. (2024). LSTM-ESA hibrit modeli ile MR görüntülerinden beyin tümörünün sınıflandırılması. Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi, 11(22), 63-81. <https://doi.org/10.54365/adyumbd.1391157>

- Aslan, E., & Özupak, Y. (2025). Performance comparison of deep learning models in brain tumor classification. *Balkan Journal of Electrical and Computer Engineering*, 13(2), 203-209. <https://doi.org/10.17694/bajece.1617698>
- Bouhafra, S., & El Bahi, H. (2024). Deep learning approaches for brain tumor detection and classification using MRG images (2020 to 2024): A systematic review. *Journal of Imaging Informatics in Medicine*, 1-31. <https://doi.org/10.1007/s10278-024-01283-8>
- Bhardwaj, N. E. H. A., Sood, M., & Gill, S. (2024). Design of transfer learning-based deep CNN paradigm for brain tumor classification. *WSEAS Trans. Biol. Biomed*, 21, 162-169. <https://doi.org/10.37394/23208.2024.21.17>
- Divya Shree, C. K. (2022). Building efficient neural networks for brain tumor detection. *Journal of Positive School Psychology*, 6(11), 222-235.
- El-Dahshan, E. S. A., Mohsen, H. M., Revett, K., & Salem, A. B. M. (2014). Computer-aided diagnosis of human brain tumor through MRG: A survey and a new algorithm. *Expert systems with Applications*, 41(11), 5526-5545. <https://doi.org/10.1016/j.eswa.2014.01.021>
- Geetha, N., Rithika, V. A., Shobika, P., & Vyshnavi, S. (2023, April). Brain tumor detection using histogram equalization and deep learning. In *2023 IEEE International Conference on Contemporary Computing and Communications (InC4) (Vol. 1, pp. 1-6)*. IEEE. <http://dx.doi.org/10.1109/InC457730.2023.10263104>
- Guluwadi, S. (2024). Enhancing brain tumor detection in MRI images through explainable AI using Grad-CAM with Resnet 50. *BMC medical imaging*, 24(1), 1-19. <https://doi.org/10.1186/s12880-024-01292-7>
- Islam, M. A., Noshin, S. A., Islam, M. R., Razy, M. F., Antara, S., Reza, M. T., & Parvez, M. Z. (2023, March). A low parametric cnn based solution to efficiently detect brain tumor cells from ultrasound scans. In *2023 IEEE 13th Annual Computing and Communication Workshop and Conference (CCWC)(pp.1152-1158)*. IEEE. <https://doi.org/10.1109/CCWC57344.2023.10099302>
- Islam, M. N., Azam, M. S., Islam, M. S., Kanchan, M. H., Parvez, A. S., & Islam, M. M. (2024). An improved deep learning-based hybrid model with ensemble techniques for brain tumor detection from MRI image. *Informatics in Medicine Unlocked*, 47, 101483. <https://doi.org/10.1016/j.imu.2024.101483>
- Jebin, B. M., Shyla, S. I., Bel, K. N. S., & Sheela, C. J. J. (2025). Brain tumor detection and classification using u-net and CNN with brain texture pattern analysis. *Biomedical Signal Processing and Control*, 110, 108156. <https://doi.org/10.1016/j.bspc.2025.108156>
- Kavitha, P., Dhinakaran, D., Prabakaran, G., & Manigandan, M. D. (2024). Brain Tumor Detection for Efficient Adaptation and Superior Diagnostic Precision by Utilizing MBConv-Finetuned-B0 and Advanced Deep Learning. *International Journal of Intelligent Engineering & Systems*, 17(2). <https://doi.org/10.22266/ijies2024.0430.51>
- Lakshmi, M. J., & Nagaraja Rao, S. (2022). RETRACTED ARTICLE: Brain tumor magnetic resonance image classification: a deep learning approach. *Soft Computing*, 26(13), 6245-6253. <https://doi.org/10.1007/s00500-022-07163-z>
- Logeswari, T., & Karnan, M. (2010). An improved implementation of brain tumor detection using segmentation based on soft computing. *Journal of Cancer Research and Experimental Oncology*, 2(1), 006-014. <https://doi.org/10.5897/JCREO.9000002>
- Modiya, P., & Vahora, S. (2022). Brain tumor detection using transfer learning with dimensionality reduction method. *International Journal of Intelligent Systems and Applications in Engineering*, 10(2), 201-206. <https://ijisae.org/index.php/IJISAE/article/view/1310/704>
- Natha, S., Laila, U., Gashim, I. A., Mahboob, K., Saeed, M. N., & Noaman, K. M. (2024). Automated brain tumor identification in biomedical radiology images: A multi-model ensemble deep learning approach. *Applied Sciences*, 14(5), 2210. <https://doi.org/10.3390/app14052210>
- Nayan, A. A., Mozumder, A. N., Haque, M. R., Sifat, F. H., Mahmud, K. R., Azad, A. K. A., & Kibria, M. G. (2022). A deep learning approach for brain tumor detection using magnetic resonance imaging. *arXiv preprint arXiv:2210.13882*. <https://doi.org/10.48550/arXiv.2210.13882>
- Qin, P., Zhang, J., Zeng, J., Liu, H., & Cui, Y. (2019). A framework combining DNN and level-set method to segment brain tumor in multi-modalities MR image. *Soft Computing*, 23(19), 9237-9251. <https://doi.org/10.1007/s00500-019-03778-x>

- Patil, S., & Kirange, D. (2023). Ensemble of deep learning models for brain tumor detection. *Procedia Computer Science*, 218, 2468-2479. <https://doi.org/10.1016/j.procs.2023.01.222>
- Priya, A., & Vasudevan, V. (2024). Brain tumor classification and detection via hybrid alexnet-gru based on deep learning. *Biomedical Signal Processing and Control*, 89, 105716. <https://doi.org/10.1016/j.bspc.2023.105716>
- Rajendirane, R., Ananth Kumar, T., Sandhya, S. G., & Hu, Y. C. (2024). A novel brain tumor segmentation and classification model using deep neural network over MRG-flair images. *Multimedia Tools and Applications*, 1-32. <https://doi.org/10.1007/s11042-024-19487-z>
- Ramtekkar, P. K., Pandey, A., & Pawar, M. K. (2023). Innovative brain tumor detection using optimized deep learning techniques. *International Journal of System Assurance Engineering and Management*, 14(1), 459-473. <https://doi.org/10.1007/s13198-022-01819-7>
- Rasheed, Z., Ma, Y. K., Ullah, I., Ghadi, Y. Y., Khan, M. Z., Khan, M. A., ... & Shehata, A. M. (2023). Brain tumor classification from MRG using image enhancement and convolutional neural network techniques. *Brain Sciences*, 13(9), 1320. <https://doi.org/10.3390/brainsci13091320>
- Sahaai, M. B., Jothilakshmi, G. R., Prasath, R., & Singh, S. (2021). Brain tumor detection using DNN algorithm. *Turkish Journal of Computer and Mathematics Education*, 12(11), 3338-3345. <https://www.proquest.com/scholarly-journals/brain-tumor-detection-using-dnn-algorithm/docview/2623922122/se-2>
- Satyanarayana, G., Naidu, P. A., Desanamukula, V. S., & Rao, B. C. (2023). A mass correlation based deep learning approach using deep convolutional neural network to classify the brain tumor. *Biomedical Signal Processing and Control*, 81, 104395. <https://doi.org/10.1016/j.bspc.2022.104395>
- Schiavon, D. E. B., Becker, C. D. L., Botelho, V. R., & Pianoski, T. A. (2023, September). Interpreting convolutional neural networks for brain tumor classification: an explainable artificial intelligence approach. In *Brazilian conference on intelligent systems (pp. 77-91)*. Cham: Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-45389-2_6
- Siar, M., & Teshnehlal, M. (2019, October). Brain tumor detection using deep neural network and machine learning algorithm. In *2019 9th international conference on computer and knowledge engineering (ICCKE) (pp. 363-368)*. IEEE. <https://doi.org/10.1109/ICCKE48569.2019.8964846>
- Zubair Rahman, A. M. J., Gupta, M., Aarathi, S., Mahesh, T. R., Vinoth Kumar, V., Yogesh Kumaran, S., & Guluwadi, S. (2024). Advanced AI-driven approach for enhanced brain tumor detection from MRI images utilizing EfficientNetB2 with equalization and homomorphic filtering. *BMC Medical Informatics and Decision Making*, 24(1), 113. <https://doi.org/10.1186/s12911-024-02519-x>