

Evrişimli Sinir Ağları Kullanarak Beyin Tümörü Sınıflandırması

Firuze Damla ERYILMAZ¹, Meriç ÇETİN^{1*}

¹Pamukkale Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kınıklı Kampüsü, Denizli, TÜRKİYE, 0000-0002-7871-4850

* Corresponding Author: mcetin@pau.edu.tr

Received: 14 August 2024 ; Accepted: 16 October 2024

Reference/Atf: F. D. Eryılmaz Baran and M. Cetin, “Evrişimli Sinir Ağları Kullanarak Beyin Tümörü Sınıflandırması”, Researcher, vol. 04, no. 02, pp. 76–83, 2024.



Özet

Bu çalışmada, evrişimli sinir ağlarına dayalı olarak beyin MRI görüntülerinden beyin tümörünün erken teşhisini kolaylaştıran üç farklı derin öğrenme çerçevesi tasarlanmıştır. Beyin tümörü sınıflandırmasını yapabilmek için ResNet50, VGG16 ve InceptionV3 gibi literatürde çokça kullanılan mimariler tercih edilmiştir. Deneyler için hem orjinal MRI görüntüleri hem de çeşitli manipülasyon teknikleri ile oluşturulan sentetik veriler kullanılmıştır. İkili beyin tümörü sınıflandırma sürecine ek olarak, tasarlanan üç evrişimli sinir ağı modelinde iki farklı aktivasyon fonksiyonunun kullanımdaki etkisi de araştırılmıştır. Yapılan deneylere ait performans ölçütleri doğruluk, F-skor, kesinlik, hassasiyet ve hata oranı metrikleri ile sunulmuştur. Simülasyon sonuçlarında, evrişimli sinir ağının son katmanındaki aktivasyon fonksiyonunun seçimine göre sırasıyla InceptionV3 modeli için ortalama %96,75 doğruluk oranı ve ResNet50 modeli için ortalama %97,75 doğruluk oranı elde edilmiştir.

Anahtar Kelimeler: CNN, beyin tümörü, sınıflandırma, resnet50, vgg16, inceptionv3.

Abstract

In this paper, three different deep learning frameworks were designed based on convolutional neural networks that facilitate the early diagnosis of brain tumors from brain MRI images. In order to classify brain tumors, several architectures that are widely used in the literature such as ResNet50, VGG16 and InceptionV3 have been preferred. Both the original MRI images and synthetic images generated by various manipulation techniques were used for the experiments. In addition to the binary brain tumor classification process, the effect of two different activation functions on the use of the designed three-convolutional neural network model was also investigated. Performance measures of the experiments have been presented with accuracy, F-score, precision, precision and error rate metrics. In the simulation results, according to the selection of the activation function in the last layer of the convolutional neural network, an average %96.75 accuracy rate for the InceptionV3 model and an average of %97.75 accuracy rate for the ResNet50 model were obtained, respectively.

Keywords: CNN, brain tumor, classification, resnet50, vgg16, inceptionv3.

1. Giriş

Beyin hücrelerinin yenilenmesi sürecinde anormal hücrelerin büyümesi ve birikimi nedeniyle kümeleşmesi beyin tümörü olarak adlandırılmaktadır [1]. Beyin tümörü varlığında kafatası içindeki basınç nedeniyle tümörün bulunduğu yere göre hastalarda şiddetli baş ağrısı, bayılma atakları, denge ve yürüme problemleri, görme problemleri, konuşma bozuklukları, kişilik değişiklikleri gibi çeşitli belirtiler ortaya çıkmaktadır. Beyin tümörü tanısı, hastalık öyküsü, nörolojik muayene, yüksek verimli klinik görüntüleme cihazları ve patolojik incelemeler sonucu ile konulmaktadır. Teşhis için manyetik rezonans görüntüleme (MRI) ve beyin tomografisi öncelikle başvuru yöntemleridir [2].

Son yıllarda, makine öğrenmesi alanındaki gelişmeler sağlık alanında doktorların hastalıkları daha erken ve daha doğru bir şekilde teşhis etmesine olanak tanımıştır [3]. Evrişimli sinir ağları (CNN), özellikle tıbbi görüntülerin etiketlenmesinde, sınıflandırılmasında, segmentasyon işlemlerinde, nesne tespiti ve nesne takibinde sıklıkla tercih edilen bir makine öğrenme yöntemi olarak kullanılmaktadır. Bununla

birlikte, beyin tümörünün derecesini sınıflandırmak için destek vektör makineleri (SVM), bulanık kümeleme, lojistik regresyon, K-ortalamlar gibi denetimsiz öğrenme ve rasgele orman sınıflandırıcısı, yapay sinir ağları ve Naive Bayes gibi denetimli öğrenme teknikleri de kullanılmaktadır [1]. Bazı uygulamalarda aynı görev için hibrit evrişimli sinir ağları sınıflandırma görevini üstlenir [4].

Literatürde beyin tümörü sınıflandırması üzerine birden çok hesaplama katmanı ile verilerin temsilini sağlayan ve farklı derin öğrenme mimarilerinin kullanıldığı pek çok çalışma mevcuttur. Bu çalışmalar kısaca şu şekilde özetlenmiştir: Saxena ve ark., [5] beyin tümörü verilerini sınıflandırmak için transfer öğrenme yöntemini kullanarak ResNet50 modelinde %95 oranında bir doğruluk elde etmiştir. [6]'da, beyin tümörü verilerini sınıflandırmak için ayrık dalgacık dönüşümü kullanılarak tasarlanan model ile %93,94 oranında bir doğruluk elde edilmiştir. Çıtak ve ark., beyin tümörü üzerinde yaptıkları çalışmada [7] SVM, çok katmanlı algılayıcılar ve lojistik regresyon yöntemleri ile %93 oranında bir sınıflandırma başarımı elde etmişlerdir. Farklı bir çalışmada [8], GoogleNet temelli öğrenme transferi yapılarak beyin MRI görüntülerinin sınıflandırılması sağlanmış ve %97.1 doğruluk elde edilmiştir. [9]'da evrişimli kodlayıcı ağlara sahip çok katmanlı bir mimari beyin tümörü sınıflandırması için kullanılmıştır. Rehman ve ark., [10] önceden eğitilmiş üç farklı CNN modelini (VGG16, AlexNet ve GoogleNet) transfer öğrenme yaklaşımı ile birlikte kullanarak meningioma, glioma ve hipofiz şeklindeki 3 spesifik beyin tümörünü %98.67 doğruluk ile sınıflandırmıştır. [11]'de tümör derecelerini tahmin etmek üzere Naive Bayes ve k-en yakın komşu teknikleri kullanılarak %92.9 oranında doğruluk elde edilmiştir.

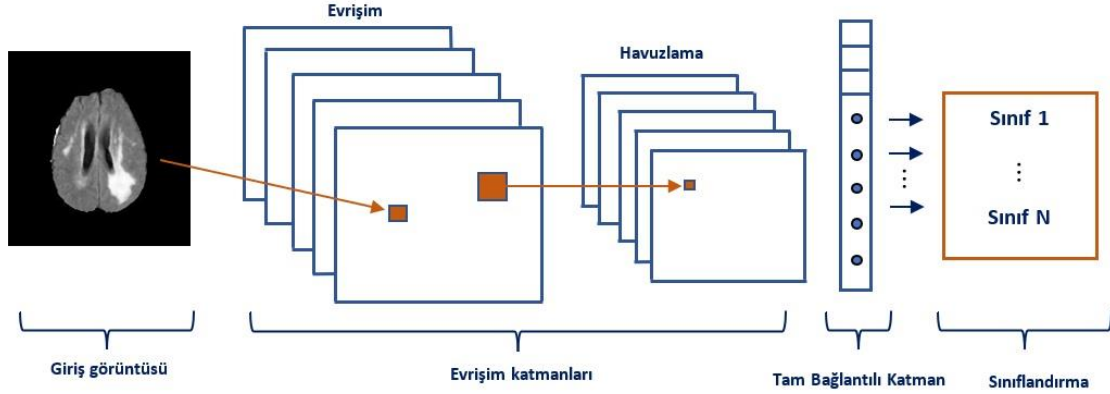
Bu çalışmada evrişimli derin sinir ağları kullanılarak beyin MRI görüntülerinden beyin tümörü sınıflandırması yapılması amaçlanmıştır. Bu amaçla, benzetim çalışmalarında ImageNet gibi çok sayıda veri kümesi üzerinde önceden eğitilmiş ResNet50 [12], VGG16 [13] ve InceptionV3 [14] olmak üzere üç CNN mimarisi beyin MRI görüntüleri veri seti üzerinde kullanılmıştır. Elde edilen sınıflandırma doğruluk değerlerine göre, evrişimli sinir ağları kullanılarak beyin tümörünün erken aşamada yakalanmasının mümkün olabileceği gösterilmiştir. Bu anlamda hem hastaya müdahalenin büyük ölçüde azalması, hem de sağlık ekiplerinin iş yükünü azaltan destekleyici süreçlerin kullanılması söz konusu olacaktır. Bu bildirinin devam eden bölümünde evrişimli sinir ağları, veri seti, ön işleme süreci ve tasarlanan modeller tanıtılmıştır. Bölüm 3'te performans ölçütleri vurgulanmış ve deneysel sonuçlar sunulmuştur. Son bölümde ise elde edilen sonuçlar değerlendirilmiştir.

2. Materyal ve Yöntem

Bu çalışmada, beyin tümörü sınıflandırma problemi için önceden eğitilmiş üç farklı evrişimli sinir ağı tercih edilmiştir. Bu bölümde öncelikle kullanılan modeller tanıtılmış, devamında veri seti ve performans ölçütleri hakkında bilgi verilmiştir.

2.1 Evrişimli Sinir Ağları

Özellikle görüntü tanıma problemlerinde kullanılan bir makine öğrenme tekniği olan evrişimli sinir ağları geleneksel yöntemlerin aksine, uzman bilgisine ihtiyaç duymaksızın veriye ait özellikleri otomatik çıkarabilme özelliğine sahiptir [15]. Derin sinir ağları eğitilebilen birçok katmandan oluşmaktadır. Çalışmada tasarlanan mimariye ait genel prensip şeması Şekil 1'de sunulmuştur.




Şekil 1: Evrişimsel Sinir Ağı Mimarisi

Böyle bir evrişimli derin sinir ağında girdi olarak verilen görüntülerin bilgisayarlar tarafından tanınması ve işlenebilecek bir formata dönüştürülmesi gerekir. Bu nedenle görüntüler önce matris formatına dönüştürülür. Tasarlanan ağ yapısı görüntülerdeki ve dolayısıyla matrislerdeki farklılıklara göre hangi görüntünün hangi etikete ait olduğunu belirler. Eğitim aşamasında bu farklılıkların etiket üzerindeki etkilerini öğrenir ve ardından bunları kullanarak yeni görüntüler için tahminler yapar. CNN, bu işlemleri etkin bir şekilde gerçekleştirmek için evrişim katmanı, havuzlama katmanı ve tam bağlantılı katman gibi farklı katmanlardan oluşur. Öznitelik çıkarma işlemi hem evrişim hem de havuzlama katmanlarında gerçekleşir. Sınıflandırma işlemi tam bağlantılı katmanda gerçekleşir. CNN mimarisinin temel katmanı olan evrişim katmanı giriş deseninin özelliklerini belirlemekten sorumludur. Bu katmanda, giriş görüntüsü 2x2, 3x3 ve 5x5 gibi filtrelerden geçirilir. Bu işlemin sonucunda görüntüdeki daha belirgin olan öznitelikler çıkarılarak yeni bir görüntü elde edilir. Bu görüntü özellik haritası olarak da bilinmektedir. Adım parametresi giriş matrisi üzerinden geçiş için ayarlanan adım sayısıdır. Bu katmandaki evrişimli işlem doğrusal bir işlemdir ve derinlik boyutu boyunca tüm filtrelerin aktivasyon haritalarının istiflenmesiyle çıktı hacmi elde edilir. Doğrusal işlem çoğunlukla, aynı girdi ile ağırlıkların çarpılmasını içerir. Evrişim katmanından sonra gelen havuzlama katmanı özellik haritalarının boyutlarını azaltmak için kullanılmaktadır. Bu durumda, evrişim katmanı tarafından oluşturulan özellik haritaları yerine özetlenen yeni veriler üzerinde işlemler gerçekleştirilir. Bu sayede, öğrenilecek parametre sayısı ve yapılan hesaplama yükü azaltılmış olur. CNN'in son ve en önemli katmanı olan tam bağlantılı katmanı, çok katmanlı bir algılayıcı gibi işlev görür. Tam bağlantılı katmanda yaygın olarak ReLU aktivasyon fonksiyonu kullanılırken, Softmax ve Sigmoid fonksiyonları son katmandaki çıktı görüntülerini tahmin etmek için tercih edilir. Tam bağlantılı katmandaki nöronlar, önceki katmandaki tüm aktivasyon fonksiyonları ile tam bağlantıya sahiptir.

Bu çalışmada, beyin tümörü ile ilgili görüntülerin ikili olarak sınıflandırılmasını sağlamak için evrişimli derin ağ mimarisindeki ResNet50, VGG16 ve InceptionV3 modelleri kullanılmıştır. Inception V3 [14] modeli, 2014 yılında GoogLeNet olarak tanıtılan Inception V1 temel modelinin üstün bir versiyonudur. Toplam 42 katmana ve önceki versiyonlarına göre daha düşük hata oranına sahiptir. VGG16 [13] modeli, 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan ImageNet veri seti için %92,7 test doğruluğu sağlamıştır. Bu mimaride büyük boyutlu filtreler birden fazla 3x3 çekirdek boyutunda filtreyle değiştirilmiştir. Daha küçük boyutlu filtrelerle ağırlıklı derinliğini artırma sayesinde daha başarılı iyileştirme sonuçları elde edilmiştir. Basit bir ağ modeli olan VGG16'nin öncesindeki modellerden en önemli farkı evrişim katmanlarının ikili ya da üçlü kullanılmasıdır. Ayrıca, tam bağlantılı katmanında görüntü matrisleri bir öznitelik vektörüne dönüştürülür. Hata oranı oldukça düşük olan ResNet50 [12], havuzlama katmanı ile birlikte 48 adet evrişim katmanına sahip ResNet modelinin farklı bir çeşididir. 3.8×10^9 kayan nokta işlemine sahiptir. ImageNet veri kümesi üzerinde eğitilmiş 50 katmanlı bir mimaridir.

2.2 Veri Seti

Çalışmada, Google LLC'nin bir yan kuruluşu olan Kaggle kullanılarak, 2019'da yayınlanan "Brain MRI Images for Brain Tumor Detection" (Beyin Tümör Belirleme için Beyin MRI Görüntüleri) veri seti ile "Brain Tumor" (Beyin Tümörü) veri seti kullanılmıştır. Görüntü boyutları birbirinden farklı olduğu için tüm görüntüler 224x224 piksel boyutuna getirilmiştir. Veri içeriğini çeşitlendirmek için orijinal görüntüler üzerinde bulanıklaştırma, döndürme, büyütme, yakınlaştırma gibi manipüle yöntemleri kullanılarak sentetik veriler oluşturulmuştur. Devamında, veri setleri birleştirilmiş ve toplamda 2000 adet görüntü üzerinde işlem yapılmıştır. Sentetik ve doğal görüntülerden oluşan 2000 adet görüntünün yarısı tümürlü yarısı tümürsüz olmak üzere kategorize edilmiştir. Eğitim, doğrulama ve test aşamalarında kullanılmak üzere veri seti sırasıyla 800, 800, 400 adet görüntü içerecek şekilde rastgele bölünmüştür. Şekil 2'de veri kümesindeki görüntülere ait örnekler sunulmuştur.



Şekil 2: Sınıflandırma için kullanılan görüntü örnekleri

2.3 Performans Ölçütleri

Sınıflandırma performanslarını değerlendirmek için literatürde çeşitli değerlendirme kriterleri kullanılmaktadır. Beyin tümörü sınıflandırması için tasarlanan üç farklı evrişimli sinir ağı modelinin ve bu modellerde kullanılan aktivasyon fonksiyonu değişiminin etkisini değerlendirmek üzere tercih edilen istatistiksel performans ölçütleri şu şekildedir: doğruluk, F-skor, kesinlik, hassasiyet ve hata oranıdır. Ölçüt denklemlerinde doğru tahmin edilen pozitif sonuçlar "DP", yanlış tahmin edilen pozitif sonuçlar "YP", doğru tahmin edilen negatif sonuçlar "DN", yanlış tahmin edilen negatif sonuçlar ise "YN" ile ifade edilmektedir. Doğruluk ölçütü sınıflandırıcının doğru tahmin ettiği örneklerin tüm örneklere oranı olup

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \times 100, \quad (1)$$

şekindedir. Bu metrik negatif bir durumun tahmin edildiği ve gerçek değerinin negatif olduğu durumları gösterir. Hassasiyet kriteri doğru tanımlanmış veri yüzdesini belirtir ve

$$\text{Hassasiyet} = \frac{DP}{DP + YN} \times 100, \quad (2)$$

şeklinde ifade edilir. Kesinlik metriği pozitif tahmin değerinin yüzdesidir ve şu şekilde tanımlanır:

$$Kesinlik = \frac{DP}{DP + YP} \times 100, \quad (3)$$

Bir testin doğruluğunu ölçmek için kullanılan F-Skor değeri kesinlik ve hassasiyet arasındaki harmonik ortalamadır. F-Skor puan aralığı [0, 1]'dir.

$$F - Skor = 2 \times \frac{(Kesinlik \times Hassasiyet)}{(Kesinlik + Hassasiyet)} \quad (4)$$

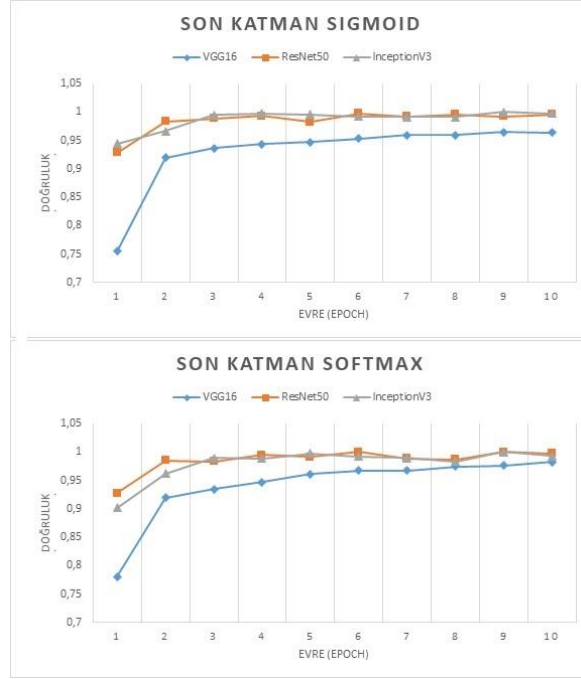
Hata oranı, gerçek değer ve elde edilen değer arasındaki farkın mutlak değeri şeklinde hesaplanmaktadır.

3. Nümerik Sonuçlar

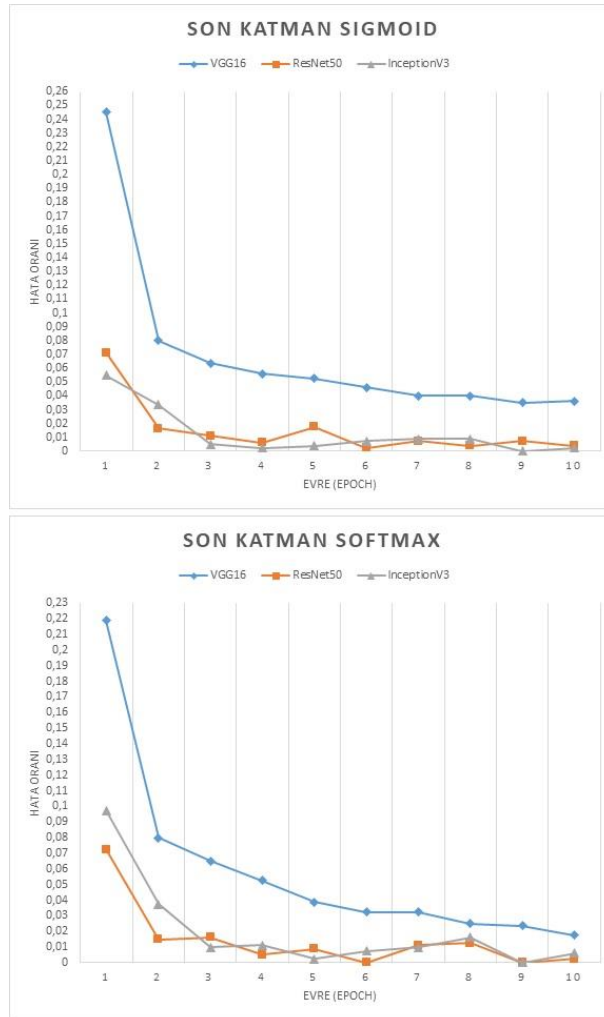
Çalışmada, evrişimsel sinir ağları ile tümör sınıflandırması yapmak amacıyla MRI görüntülerinden oluşan iki veri seti üzerinde öncelikle ağ eğitimi tamamlanmıştır. Devamında "tümörlü" ve "tümörsüz" olmak üzere sınıflandırma sonuçlarını elde etmek üzere tahminleme yapılmıştır. İkili tümör sınıflandırma sürecine ek olarak, tasarlanan üç farklı CNN mimarisi için "sigmoid" ve "softmax" aktivasyon fonksiyonlarının kullanımdaki etkisi de araştırılmıştır. En çok kullanılan aktivasyon fonksiyonlarından biri olan sigmoid fonksiyonu karar vermeye yönelik olasılıksal bir yaklaşımdır, sürekli ve değer aralığı [0,1] arasındadır. Ağ çıktısının hangi sınıfa ait olduğuna dair olasılıksal bir değer üretir. Türev değerinin fonksiyon sınır bölgelerinde sifra yakınsaması öğrenmenin yavaşlamasına veya durmasına sebebiyet verir. Bu sebeple çok katmanlı ağlarda sigmoid fonksiyonu yerine softmax fonksiyonunun kullanımı tavsiye edilir. Çoğu zaman çoklu sigmoid olarak da bilinen softmax fonksiyonu, çok sınıflı hedef değişkeni içeren sınıflandırma problemleri için daha uygundur. Softmax fonksiyonu ağ çıktısı olarak her sınıfa ait olasılık sonucunu üretir.

Deneyisel çalışmalarda tasarlanan derin öğrenme modellerini eğitmek için Python programlama dili kullanılmıştır. Tüm deneyler, merkezi işlem birimi (CPU), Tesla K80 grafik işlem birimi (GPU) veya tensor işlem birimi (TPU) donanımı ile çevrimiçi bulut hizmeti kullanılarak Ubuntu işletim sistemine sahip Google Colaboratory (Colab) Linux sunucusunda ücretsiz olarak gerçekleştirilmiştir. Veri setleri Kaggle veri seti web sitesinden temin edilmiştir. Veri manipülasyonu için VisualStudioCode editöründe Python programlama dili ve Pillow kütüphanesi kullanılmıştır.

Model seçiminde InceptionV3, VGG16 ve ResNet50 CNN mimarileri tercih edilmiştir. Modeller ile birlikte kullanılan kütüphaneler numpy, OpenCV, os, matplotlib, Sklearn, Tensorflow ve Keras kütüphaneleridir. Tümör sınıflandırması için tasarlanan üç mimarinin son katmanındaki aktivasyon fonksiyonu seçimine göre modellerin sergiledikleri performans değerleri Tablo 1'de listelenmiştir. ResNet50, VGG16 ve InceptionV3 ile 10 evre süresince yapılan deneylerde elde edilen doğruluk ve hata oranları Şekil 3 ve Şekil 4'te sunulmuştur. Sonuçlara göre, CNN modellerinde son katmanın aktivasyon fonksiyonu sigmoid ise en yüksek ortalama doğruluk oranı %96,75 ile InceptionV3 modelinde, softmax ise en yüksek ortalama doğruluk oranı %97,75 ile ResNet50 modelinde elde edilmiştir.



Şekil 3: Üç Farklı CNN Modeline Ait Doğruluk Performansları



Şekil 4: Üç Farklı CNN Modeline Ait Hata Oranları

Tablo 1: Model Performansları

Aktivasyon Fonksiyonu: Sigmoid					
Model	Doğruluk	F-Skor	Kesinlik	Hassasiyet	Hata Oranı
VGG16	0.9175	0.9192	0.9400	0.8995	0.0825
ResNet50	0.9500	0.9473	0.9000	1.0000	0.0500
InceptionV3	0.9675	0.9673	0.9650	0.9698	0.0325
Aktivasyon Fonksiyonu: Softmax					
Model	Doğruluk	F-Skor	Kesinlik	Hassasiyet	Hata Oranı
VGG16	0.925	0.9253	0.9207	0.9300	0.0750
ResNet50	0.9775	0.9771	0.9650	0.9897	0.0225
InceptionV3	0.9025	0.8937	0.9763	0.8250	0.0975

4. Sonuç

Bu çalışmada, beyin tümörünün erken aşamada tespitini sağlamak üzere derin öğrenme tabanlı ikili sınıflandırma işlemi gerçekleştirilmiştir. Bu kapsamda, önceden eğitilen ResNet50, InceptionV3, VGG16 modelleri üzerinde çeşitli performans karşılaştırmaları yapılmıştır. Veri seti büyüklüğü ve çeşitliliğinin sınıflandırma performansını artıracak düşünülerek manipülasyon teknikleri ile sentetik veriler oluşturulmuş ve bu veriler orjinal veri setleriyle birleştirilmiştir. Elde edilen bu sonuçlar, literatürdeki örnekleri ile karşılaştırıldığında tasarlanan CNN modellerinin tümör tespitinde oldukça başarılı bir performans sergilediğini göstermektedir.

Yazarların Katkısı

Bu makalenin yazılmasına tüm yazarlar eşit katkıda bulunmuştur.

Çıkar Çatışması

Yazarlar çıkar çatışması olmadığını belirtmektedir

Referanslar

- [1] J. Amin *et al.*, "Brain tumor detection: A Long Short-term Memory (LSTM)-based Learning Model." *Neural Computing and Applications*, vol. 32, no. 20, pp. 15965-15973, 2020.
- [2] A. Saleh, R. Sukaik, S. S. Abu-Naser, "Brain Tumor Classification Using Deep Learning." *International Conference on Assistive and Rehabilitation Technologies.*, pp. 131-136, 2020.
- [3] H. A. Khan *et al.*, "Brain Tumor Classification in MRI Image Using Convolutional Neural Network." *Math. Biosci. Eng.*, 17, pp. 6203, 2020.
- [4] T. Sadad *et al.*, "Brain Tumor Detection and Multi-Classification Using Advanced Deep Learning Techniques. *Microscopy Research and Technique.*" vol. 84, no. 6, pp. 1296-1308, 2021.
- [5] P. Saxena, A. Maheshwari, S. Maheshwari, "Predictive Modeling of Brain Tumor: A Deep Learning Approach." *Innovations in Computational Intelligence and Computer Vision.* pp. 275-285, 2021.
- [6] H. Mohsen *et al.*, "Classification Using Deep Learning Neural Networks for Brain Tumors." *Future Computing and Informatics Journal*, vol. 3, no. 1, pp. 68-71, 2018.
- [7] F. Citak *et al.*, "Machine Learning in Grading of Gliomas Based on Multi-parametric Magnetic Resonance Imaging at 3t. *Computers in Biology and Medicine*, 99, pp. 154-160, 2018.
- [8] S. Deepak and P. Ameer, "Brain Tumor Classification Using Deep CNN Features via Transfer Learning." *Computers in Biology and Medicine*, 111, pp. 103345, 2019.
- [9] K. Vaidhya, S. Thirunavukkarasu, V. Alex, and G. Krishnamurthi, "Multi-modal Brain Tumor Segmentation Using Stacked Denoising Autoencoders." *BrainLes.* Springer, pp. 181-194, 2015.
- [10] A. Rehman, S. Naz, M. I. Razzak, F. Akram and M. Imran, "A Deep Learning-based Framework for Automatic Brain Tumors Classification Using Transfer Learning." *Circuits, Systems, and Signal Processing*, vol. 39, no. 2, pp. 757-775,

2020.

- [11] V. Romeo *et al.*, “ Prediction of Tumor Grade and Nodal Status in Oropharyngeal and Oral Cavity Squamous-cell Carcinoma Using a Radiomic Approach. *Anticancer Research*, vol. 40, no.1, pp. 271-280, 2020.
- [12] K. He, X. Zhang, S. Ren and J. Sun, “Deep Residual Learning for Image Recognition.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 2016.
- [13] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-scale Image Recognition.” *ArXiv Preprint arXiv:1409.1556*, 2014.
- [14] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2818-2826, 2016.
- [15] H. Kutlu and E. Avcı, “A Novel Method for Classifying Liver and Brain Tumors Using Convolutional Neural Networks, Discrete Wavelet Transform and Long Short-term Memory Networks.” *Sensors*, vol. 19, no. 9, pp. 1992, 2019.