

Dört sınıflı veri seti kullanarak beyin tümörlerinin sınıflandırılması

Zihni KAYA^{1*}

Geliş tarihi / Received: 29.11.2023

Düzeltilerek geliş tarihi / Received in revised form: 04.12.2023

Kabul tarihi / Accepted: 06.12.2023

DOI: 10.17932/IAU.ABMYOD.2006.005/abmyod_v19i69003

Öz

Dünya Sağlık Örgütü raporlarına göre beyin tümörlerine bağlı olarak meydana gelen ölümlerin sayısı her geçen gün artmaktadır. Tüm hastalıklarda olduğu gibi beyin tümörlerinde de erken teşhis oldukça önemlidir. Hekimler tarafından MR görüntülerinden beyin tümörünün teşhis edilmesi hem zaman kaybına hem de hatalı yorumlara neden olabilir. Bu nedenle, zaman kaybını ve hata payını en aza indirmek için bilgisayar destekli otomatik tespit sistemleri önemli bir araştırma konusu haline gelmiştir. Bu çalışmada, önerilen model ile beyin tümörlerinin sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda, dört sınıflı veri seti kullanılarak transfer öğrenme tabanlı Inception-ResNet-V2 evrişimli sinir ağı modeli ile beyin tümörlerinin sınıflandırılması gerçekleştirilmiştir. Elde edilen sonuçlar, 5 kat çapraz doğrulama tekniği kullanılarak 1621 gliyom, 1645 menenjiyom, 1757 hipofiz bezi ve 2000 normal beyin görüntüsünün bulunduğu veri seti üzerinde test edilmiş ve %99,5 ortalama doğruluk başarımları elde edilmiştir.

Anahtar Kelimeler: *Beyin tümörü, evrişimli sinir ağları, transfer öğrenme, Inception-ResNet-V2*

¹İstanbul Aydın Üniversitesi, zihnikaya@gmail.com , Orcid: 0000-0001-6911-4995

Classification of brain tumors using a four-class data set

Abstract

According to World Health Organization reports, the number of deaths due to brain tumors is increasing day by day. As with all diseases, early diagnosis is very important in brain tumors. Diagnosis of brain tumors from MRI images by physicians can cause both loss of time and erroneous interpretations. Therefore, computer-aided automatic detection systems have become an important research topic to minimize time loss and error margin. In this study, the proposed model aims to classify brain tumors. For this purpose, a four-class data set was used to classify brain tumors using a transfer learning based Inception-ResNet-V2 convolutional neural network model. The obtained results were tested on a dataset of 1621 gliomas, 1645 meningiomas, 1757 pituitary glands and 2000 normal brain images using a 5-fold cross validation technique and an average accuracy of 99.5% was achieved.

Keywords: Brain tumor, convolutional neural networks, transfer learning, Inception-ResNet-V2

Giriş

Beyin tümörü, kafatası içindeki hücrelerin anormal bir şekilde çoğalması ve gelişmesiyle oluşmaktadır. Beyin, vücudun kontrol merkezi olduğundan tümörler kafatasına baskı yaparak insan sağlığını olumsuz yönde etkileyebilir (DeAngelis, 2001). Dünya Sağlık Örgütü (DSÖ) raporlarına göre beyin tümörlerine bağlı olarak meydana gelen ölümlerin sayısı her geçen gün artmaktadır. Tüm tümörlerde olduğu gibi beyin tümörlerinde de erken teşhis oldukça önemlidir. Beyin tümörlerinin erken teşhisi için genellikle Manyetik Rezonans Görüntüleme (MRG) tekniği kullanılmaktadır. MRG, manyetik alanlar ve radyo dalgalarını kullanarak vücudun iç yapısı ve organlar ile ilgili detaylı bilgi sağlar (Oyar, 2008).

Hekimler tarafından MR görüntülerinden beyin tümörünün teşhis edilmesi hem zaman kaybına hem de hatalı yorumlara neden olabilir. Bu nedenle, zaman kaybını ve hata payını en aza indirmek için bilgisayar destekli otomatik tespit sistemleri önemli bir araştırma konusu haline gelmiştir. Günümüzde, görüntü analizinde en başarılı derin öğrenme mimarisi olan Evrişimli Sinir Ağları (ESA) görüntü sınıflandırma alanında yaygın olarak

kullanılmaktadır (Eker ve Duru, 2021). ESA'nın geleneksel ağlara kıyasla en büyük avantajı, önemli özellikleri herhangi bir insan müdahalesi olmadan otomatik olarak algılamasıdır.

Literatürde, ESA modelleri beyin MR görüntülerinin sınıflandırılması amacıyla yaygın olarak kullanılmaktadır. Özkaraca ve arkadaşları dört sınıflı beyin MR görüntülerini kullanarak klasik ESA, VGG16Net, DenseNet ve kendi geliştirdikleri yoğun katmanlara sahip ESA modeli ile tümör görüntülerini sınıflandırmışlardır (Özkaraca ve ark., 2023). Geliştirdikleri modelin başarımını arttırmadığını gözlemlediklerinden transfer öğrenme yöntemini kullanmamışlardır. Model doğruluğunu tahmin etmek için 10 kat çapraz doğrulama tekniğini uygulamışlardır. Deneysel çalışmalarda kendi geliştirdikleri ESA modeli ile %97 doğruluk başarımı elde etmişlerdir.

Gomez Guzman ve arkadaşları dört sınıflı veri seti kullanarak önceden eğitilmiş InceptionResNetv2, Inceptionv3, Xception, Resnet-50, EfficientnetB0, Mobilenetv2 ve klasik ESA modelleri ile beyin MR görüntülerini sınıflandırmışlardır (Gomez Guzman ve ark., 2023). Veri setindeki görüntülere ön işlem aşamasında yeniden boyutlandırma, etiketleme ve veri çoğaltma teknikleri uygulamışlardır. Veri setini %80 eğitim ve %20 test verisi olarak bölmüşlerdir. Model performansını kestirmek için 5 kat çapraz doğrulama yöntemini benimsemişlerdir. Deneysel çalışmalarda, önceden eğitilmiş Inception V3 modeli ile %97,12 doğruluk başarımına ulaşmışlardır.


Ali ve arkadaşları dört sınıflı beyin MR görüntülerini hibrit bir yöntem kullanarak sınıflandırmışlardır (Ali ve ark., 2022). GoogleNet, Shuffle-Net ve NasNet-Mobile kullanarak çıkardıkları öznitelikleri k-En Yakın Komşu (KNN), Destek Vektör Makineleri (DVM) ve Doğrusal Diskriminant Analizi (LDA) adı verilen bir grup sınıflandırıcıyı kullanarak sınıflandırmışlardır. Deneysel çalışmalarda, en yüksek doğruluk başarımını %98,4 ile Shuffle-Net modelini DVM ile birleştiren yöntemden elde etmişlerdir.

Materyal ve Metot

Bu çalışmada öncelikle, beyin MR görüntüleri ön işleminden geçirilmiştir. Daha sonra, Inception-ResNet-V2 modelinin evrişim katmanları kullanılarak görüntülerden öznitelik çıkarımı yapılmıştır. Son olarak, veri seti, eğitim ve test kümelerine ayrılmış ve eğitim işlemi çok katmanlı sinir ağları kullanılarak gerçekleştirilmiştir.

Veri Seti

Bu çalışmada kullanılan veri seti Figshare, SARTAJ ve BR35H veri setlerinin birleşiminden oluşmaktadır (Nickparvar, 2023). Veri setinde, her biri, gliyom (1621), menenjiyom (1645), hipofiz bezi (1757) ve tümörsüz (2000) sınıflarına ait 7023 beyin MR görüntüsü bulunmaktadır. Beyin MR görüntüleri 512x512x3 boyutlarında ve JPG formatındadır. Şekil 1’de veri setindeki her bir sınıfa ait beyin MR görüntülerinden örnekler verilmiştir.




Şekil 1. Veri setindeki sınıflara ait beyin MR görüntüleri

Ön İşlem

İlk olarak, beyin MR görüntülerinin kontrastını arttırmak için görüntülere histogram eşitleme yöntemi uygulanmıştır. Sonrasında, görüntü yoğunluk değerlerinin ortalaması ve standart sapması hesaplanarak z-skor normalizasyon yöntemi ile normalize edilmiştir. Z-skor normalizasyon denklemi Eş.1’de verilmiştir.

$$z = \frac{x - \mu}{s} \quad (1)$$

Eş. 1’de x eğitim setindeki her bir örneği, μ ortalamasını s ise örneklerin standart sapmasını göstermektedir. Son olarak görüntüler 224x24x3 boyutlarında olacak şekilde yeniden boyutlandırılmıştır. Şekil 2’de ön işlem aşamasında yapılan işlemlerin blok diyagramı verilmiştir.



Şekil 2. Veri ön işlem aşamaları

Transfer Öğrenme

Transfer öğrenme önceden eğitilmiş bir modelden elde edilen bilginin başka bir veri setini öğrenmek için kullanıldığı bir yöntemdir (Deepak ve Ameer, 2019). Inception-ResNet-V2 modeli 164 katmana ve yaklaşık 54 milyon eğitilebilir parametreye sahiptir (Kanna ve ark., 2023). Bu tür derin öğrenme tabanlı modelleri eğitmek için büyük veri setlerine ihtiyaç duyulmaktadır. Eğitim veri boyutu küçükse aşırı öğrenme meydana gelebilir. Bu nedenle, Inception-ResNet-V2 modeli 1000 farklı kategoride 1,2 milyon görüntüden oluşan ImageNet veri seti kullanılarak eğitilmiştir. Bu çalışmada kullanılan veri setine sahip model, sıfırdan eğitilmek yerine, ImageNet veri setinde eğitilmiş modelin ağırlıkları ile başlatılmıştır. Ardından, bu çalışmanın amacı olan beyin tümörlerini sınıflandırma görevi için modelde ince ayar yapılmıştır.

Beyin tümörlerini sınıflandırma görevi için Inception-ResNet-V2 modelinde bazı değişiklikler yapılmıştır. Modelin başarımını arttırdığı gözlemlendiğinden, çıktı katmanından önce 5 sinir hücresinden oluşan bir ara katman eklenmiştir. 1000 farklı sınıfı sınıflandırmak için tasarlanan orijinal modelin tam bağlı çıktı katmanı kaldırılmış yerine 4 sinir hücresinden oluşan yeni bir tam bağlı çıktı katmanı eklenmiştir.

Inception-ResNet-V2 Modeli

Inception ve ResNet modellerinin birleşiminden meydana gelen Inception-ResNet-V2, filtre birleştirme yerine artık bağlantıları kullanan Inception tarzı evrişimli sinir ağı modelidir (Szegedy ve ark., 2017). Evrişimli sinir ağı modellerinde kaybolan/patlayan gradyan sorunu nedeniyle ağın derinliği arttıkça performansı azalmaktadır. Bu problemin çözümü için artık bağlantı modeli kullanılmaktadır. Bu sayede, ağın derinliği ve performansı artarken kaybolan/patlayan gradyan sorunu da ortadan kalkmaktadır (He ve ark., 2016).

Bulgular

DeneySEL çalışmalar, Windows 10 işletim sisteminin kurulu olduğu Intel i7 11. nesil merkezi işlemci, NVIDIA GeForce RTX 3060 grafik işlemci ve 16GB RAM belleğe sahip bilgisayarda yapılmıştır. Inception-ResNet-V2 modeli Python programlama dili ve TensorFlow üzerine inşa edilmiş Keras kütüphanesi kullanılarak uygulanmıştır.

Model, öğrenme oranı 0,0001, tur sayısı 100, en küçük yığın boyutu 32 ve optimizasyon algoritması olarak RMSProp seçilerek eğitilmiştir.

Modelin veri setine aşırı uyum sağlamasını önlemek için erken durdurma yöntemi kullanılmıştır. Model doğruluğunu tahmin etmek için 5 kat çapraz doğrulama yöntemi uygulanmıştır. Model doğruluğu, tahmin edilen örnek sayısının toplam örnek sayısına bölümü ile elde edilmektedir. Tablo 1, 5 kat çapraz doğrulama sürecinde model doğruluğunu göstermektedir.

Tablo 1. *Doğrulama setleri için doğruluk oranları*

Doğrulama seti	Doğruluk
Doğrulama seti-1	98,43%
Doğrulama seti-2	98,64%
Doğrulama seti-3	99,72%
Doğrulama seti-4	100%
Doğrulama seti-5	99,93%
Ortalama	99,54%

Tartışma ve Sonuç

Bu çalışmada, önceden eğitilmiş Inception-ResNet-V2 evrişimli sinir ağı modeli kullanılarak beyin tümörlerinin sınıflandırılması gerçekleştirilmiştir. Gliyom, menenjiyom, hipofiz bezi ve normal beyin MR görüntülerinden oluşan dört sınıflı veri seti kullanılarak beyin tümörleri sınıflandırılmıştır.

Tablo 2. *İlgili çalışmaların doğruluk oranları*

Çalışma	Yöntem	Veri Seti	Sınıf	Doğruluk
Özkaraca ve arkadaşları	VGG16Net/DenseNet-Softmax	Figshare, BR35H ve SARTAJ	4	94-97%
Gomez Guzman ve arkadaşları	Inception V3-Softmax	Figshare, BR35H ve SARTAJ	4	97,12%
Ali ve arkadaşları	ShuffleNet-DVM	Figshare, BR35H ve SARTAJ	4	98,40%
Önerilen model	Inception-ResNet-V2-Softmax	Figshare, BR35H ve SARTAJ	4	99,54%

Tablo 2’te literatürde yer alan dört sınıflı veri seti kullanılarak yapılan çalışmaların doğruluk oranları yer almaktadır. Bu çalışmadan elde edilen sonuçların daha yüksek bir doğruluk oranına sahip olduğu görülmektedir. Önerilen model sayesinde, uzmanlar, beyin tümörlerini daha doğru ve daha kısa sürede sınıflandırabileceklerdir. Gelecek çalışmalarda, önerilen modelin bir karar destek sistemine taşınarak tıp doktorlarına beyin MR görüntülerinin sınıflandırılması konusunda kolaylık sağlaması

amaçlanmaktadır. Bu amaç doğrultusunda web tabanlı açık kaynak kodlu bir yazılım geliştirilmesi düşünülmektedir.

Kaynaklar

Ali, R., Al-jumaili S., Duru, A. D., Uçan, O. N., Boyacı, A., Duru, D. G., (2022). Classification of brain tumors using MRI images based on convolutional neural network and supervised machine learning algorithms, *2022 International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 20-22 Ekim 2022. Ankara. ss. 822-827.

DeAngelis, L. M., (2001). Brain tumors, *New England Journal of Medicine*, 344, ss. 114-123.

Deepak, S., Ameer, P.M., (2019). Brain tumor classification using deep CNN features via transfer learning, *Computers in Biology and Medicine*, 111. ss. 1-7.

Eker, A.G., Duru, N., (2021). Medikal görüntü işlemede derin öğrenme uygulamaları, *Acta Infologica*, 5, ss. 459-474.

Gomez Guzman, M.A., Jimenez-Beristain, L., Garcia-Guerrero, E.E., Lopez-Bonilla, O.R., Tamayo-Perez, U.J., Esqueda-Elizondo, J.J., Palomino-Vizcaino, K., Inzunza-Gonzalez, E., (2023). Classifying brain tumors on magnetic resonance imaging by using convolutional neural networks, *Electronics*, 12. ss.1-22.

He, K., Zhang, X., Ren, S., Sun, J., (2016). Deep Residual Learning for Image Recognition, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas. ss.770-778.

Kanna, G.P., Kumar, S.J., Kumar, Y., Kumar, Y., Changela, A., Wozniak, M., Shafi J., Ljaz, M.F., (2023). Advanced deep learning techniques for early disease prediction in cauliflower plants, *Scientific Reports*, 13.

Nickparvar M., (2023). Brain tumor MRI dataset, <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>, (Erişim tarihi:16.11.2023).

Oyar, O., (2008). Magnetik rezonans görüntüleme (mrg)'nin klinik uygulamaları ve endikasyonları, *Harran Üniversitesi Tıp Fakültesi Dergisi*, 5. ss.31-40.

Özkaraca, O., Bağrıaçık, O.İ., Gürüler, H., Khan, F., Hussain, J., Khan, J., Laila, U., (2023). Multiple brain tumor classification with dense CNN architecture using brain MRI images. *Life*, 13.

Szegedy, C., Loffe S., Vanhoucke, V., Alemi, A.A., (2017), Inception-v4, inception-ResNet and the impact of residual connections on learning, *in Proc. 31st AAAI Conf. Artif. Intell.*, 23 Ağustos 2016, San Francisco.