

Derin Öğrenme Modelleri Kullanılarak Beyin Tümörlerinin Sınıflandırılması

Classification of Brain Tumors via Deep Learning Models

Kaya DAĞLI, Osman EROĞUL
Biyomedikal Mühendisliği Bölümü
TOBB Ekonomi ve Teknoloji Üniversitesi
Ankara, Türkiye
kdagli@etu.edu.tr, erogul@etu.edu.tr

Özetçe—Beyin tümörleri insan sağlığını önemli derecede etkileyebilmektedir. Bu tümörlerin yanlış teşhisi durumunda, müdahale için alınacak olan kararlar ve bireyin sağlık durumu efektif şekilde belirlenmemektedir. Manyetik rezonans görüntülerinin bir hekim tarafından incelenmesi, beyin tümörlerinin belirlenmesindeki geleneksel yöntemdir. Beyin tümörlerinin çeşitliliğinden ve hekimlerin incelemesi gereken birçok görüntü olduğundan ötürü, bu yöntem hem insan hatalarına yatkındır hem de fazla zaman tüketimine neden olmaktadır. Bu çalışmada, en yaygın görülen üç beyin tümörü çeşidi olan; Gliom, Meningiom ve Hipofiz tümörlerinin derin öğrenme modelleri kullanılarak sınıflandırılması üzerine çalışılmıştır. Çalışmada doğruluk oranının yüksek olmasına önem verilirken, farklı ağ yapılarındaki modellerin eğitimi için harcanan zaman da incelenmiştir. Bu sınıflandırma çalışması ile hekimlere yardımcı olabilecek bir sistem yaratmak amaçlanmıştır. Doğruluk oranı %90'a varan bir sistem oluşturulmuştur.

Anahtar Kelimeler—Beyin Tümörü, Derin Öğrenme, Doğruluk, Harcanan Zaman, Manyetik Rezonans Görüntüleri, Sınıflandırma

Abstract—Brain tumors threaten human health significantly. Misdiagnosis of these tumors decrease effectiveness of decisions for intervention and patient's state of health. The conventional method to differentiate brain tumors is by the inspection of magnetic resonance images by clinicians. Since there are various types of brain tumors and there are many images that clinicians should examine, this method is both prone to human errors and causes excessive time consumption. In this study, the most common brain tumor types; Glioma, Meningioma and Pituitary are classified using deep learning models. While the main objective of this study is to have a high rate of accuracy, the time spent is also examined. The aim of this study is to ease clinicians work load and have a time efficient classification system. The system which has been built has an accuracy up to 90%.

Keywords—Accuracy, Brain Tumor, Classification, Deep Learning, Magnetic Resonance Images, Time Consumption

I. Giriş

Dünya Sağlık Örgütü'nün tanımlamasına göre beyin tümörü, merkezi sinir sistemini etkileyen tümörlerdir [1]. Genellikle, düzensiz olarak çoğalan beyin hücreleri olarak tanımlanırlar. Bu tümörler beynin diğer bölgelerine de zarar vererek beynin normal işleyişine engel olmaktadır. Bir beyin tümörü birincil veya ikincil olarak sınıflandırılabilir. Birincil beyin tümörü, beyinde ortaya çıkan ve beyindeki hipofiz bezi, beyin zarı gibi bölgeleri de etkisi altına alan türdür. İkincil beyin tümörü ise, akciğer, böbrek, göğüs gibi vücudun başka yerlerinden beyne yayılan tümör tipidir [2,4]. Birincil beyin tümörü DNA'da meydana gelen mutasyonlar sonucu ortaya çıkmaktadır. Bu mutasyonların neden olduğu kontrolsüz hücre bölünmesi ile anormal hücrelerin sayısı artarken, normal hücreler ölmektedir. Bu durum beyin hasarı ve bazı zamanlar yaşamın sonlanması ile sonuçlanabilmektedir [1].

Beyin tümörlerinin ilerleme derecesini, Dünya Sağlık Örgütü 5 aşamada sınıflandırmaktadır. 0. aşamada tümör hücreleri mevcuttur fakat diğer hücrelere yayılmamaktadırlar. 1., 2. ve 3. aşamalarda hücreler hızla yayılmaktadır. 4. aşamada ise kanser vücudun her yerine yayılmaya başlamıştır [3]. Eğer kanser erken zamanda teşhis edilirse, birçok hayat kurtulacağından; beyin tümörlerinin doğru ve erken teşhisi, tedavi süreci ve iyileşme olasılığını önemli derecede etkilemektedir.

Beyin tümörleri iki ana gruba ayrılırlar. Bunlar; Gliom ve Gliom olmayan tümörlerdir [4]. Gliomlar en yaygın bulunan beyin tümörleridir. Tam kökenleri bilinmemekle birlikte, glial hücrelerden meydana geldikleri düşünülmektedir. Bir Glial hücre, beyindeki bir tür destekleyici hücredir. Gliom olmayan hücreler ise, beyindeki hücrelerden meydana gelirler. Bunlardan en yaygınları; meningiom ve hipofiz tümörleridir.

Meningiom tümörler, en yaygın görülen birincil beyin tümörleridir. Meninkslerden (beyin zarı) başlayan, genellikle kanser tehlikesi olmayan tümörlerdir. Fakat beyin veya omuriliğe baskı yaparak önemli sıkıntılar yaratabilirler. Bir diğer tümör olan hipofiz tümörleri ise, hipofiz bezinde ortaya çıkarlar.

Yukarıda belirtilen tümörler ve yaratabilecekleri tehlikeleri en erken ve doğru şekilde teşhis edebilecek birçok sistem üzerine çalışmalar yapılmıştır [3,5-8]. Bu çalışmanın yapılan çalışmalardan farkı, oluşturulan modellerin, doğruluk oranları ile eğitim sürelerinin birlikte incelenmesidir. Bu çalışmada, Jun Cheng'in oluşturduğu 3064 adet T-1 ağırlıklı beyin tümürlü MR görüntüsü, evrişimli sinir ağları (CNN) kullanılarak sınıflandırılmıştır [9]. Bu çalışmadaki amaç, oluşturulan modellerde doğruluk oranını yüksek tutarken, modellerin eğitimi için harcanan zamanı da kontrol ederek, ideal olan modeli bulmaktır.

II. VERİ SETİ VE MODELLER

Yapılan çalışmada kullanılan veri seti ve takip edilen adımlar şu şekildedir; veri setindeki görüntülerin eğitim, doğrulama ve test olacak şekilde 3 gruba ayrılması, görüntülerin yeniden boyutlandırılması, verilerin çeşitlendirilmesi, modellerin oluşturulup eğitim veri seti ile modellerin eğitilmesi, doğrulanması ve son olarak test edilmesi şeklindedir.

A. Veri Seti

Çalışmada evrişimli sinir ağlarını eğitmek için kullanılan veri seti uzmanlar tarafından işaretlenmiş ve etiketlenmiş olup, 3064 adet T-1 ağırlıklı manyetik rezonans beyin görüntüsü içermektedir [9]. Bu görüntülerden 1426 adeti gliom, 708 adeti meningiom ve 930 adeti hipofiz tümör sınıflarına aittir. Verilerin yaklaşık olarak %60'ı eğitim, %26'sı doğrulama ve %14'ü test olacak şekilde bölünmüştür. Orijinal veri seti MATLAB®'da oluşturulmuş olup, .mat formatındadır. Görüntüler kullanılmadan önce .jpeg formatına dönüştürülmüştür. Modelin eğitimi için harcanan zaman incelendiğinden, kullanılan bilgisayarın özellikleri önemli yer tutmaktadır.



(a) : Gliom (b) : Meningiom (c) : Hipofiz

Şekil 1. Veri Setindeki Tümör Görüntüleri [9]


Modeller eğitilirken kullanılan bilgisayarın özellikleri; i7-6700HQ, 2.60 GHz, 16 GB RAM, NVIDIA Geforce GTX 960M ekran kartı şeklindedir. Bu bilgi, çalışmada kullanılan modellerin çalışma süresi önem arz ettiği ve sonuçlar kısmında değerlendirildiği için burada belirtilmiştir.

B. Modeller

Evrişimli sinir ağı modelleri tasarlanmadan önce görüntüler üzerinde ön işleme uygulanmıştır. Öncelikle görüntüler tekrardan boyutlandırılmıştır. 512 x 512 olan boyutları 112 x 112 olarak yeniden ölçeklendirilmiş olup, bu sayede modellerin daha efektif ve hızlı eğitilmesi amaçlanmıştır.


Modeli eğitmek için kullanılacak veri sayısı çok fazla olmadığından ve aşırı uydurmanın önüne geçmek için veri seti çeşitlendirilmeye (data augmentation) başvurulmuştur. Veri seti çeşitlendirme, elde bulunan verilere birtakım dönüşümler uygulanarak gerçeğe yakın daha fazla veri oluşturur [10]. Yeni görüntüler oluşturulurken uygulanan dönüşümler; döndürme açısı, parlaklık aralığı, uzunluk ve genişlik kaydırma oranı, yatayda, dikeyde resmi döndürme, yaklaşma ve yeniden ölçeklendirme. Bu sayede eğitim sırasında modele daha fazla görüntü girdisi sağlanacak olup, daha güvenli sonuçlar elde edilmesi amaçlanmıştır.

Çalışmadaki modellerde kullanılan evrişimli sinir ağı modelinin genel yapısı Şekil 2'de gösterilmiştir. Katmanlar modeller arasında değişiklik göstermektedir.



Şekil 2. Evrişimli Sinir Ağı Modeli [11]

Modeller oluşturulurken ara katmanlarda kullanılacak olan aktivasyon fonksiyonu, negatif değerleri için sıfır çıktı verdiği için ReLU (Rectified Linear Unit) olarak seçilmiştir [10]. Son katman fonksiyonu, ağırlık çıktıları üzerinden kullanışlı sınıflar oluşturması açısından ve 3 adet sınıf olduğundan ötürü softmax kullanılmıştır.



Şekil 3. ReLu Fonksiyonu [10]

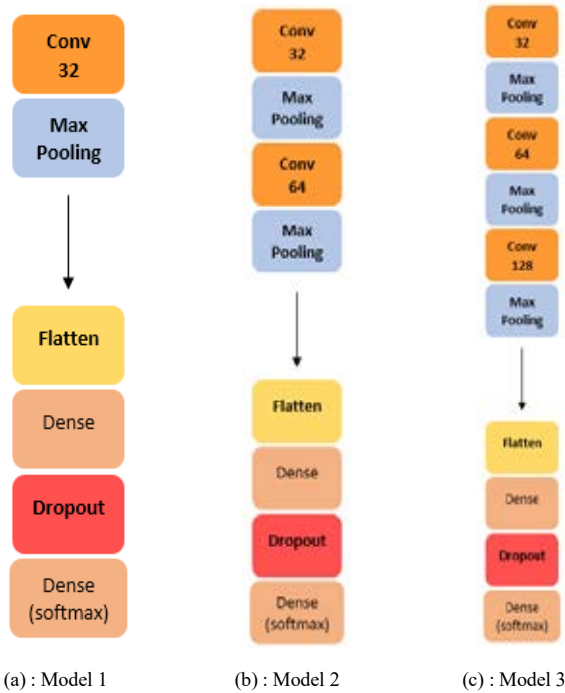
Veri setinde 2'den fazla sınıf olduğu için kayıp fonksiyonu olarak kategorik çapraz entropi kullanılmıştır. Optimizasyon mekanizması olarak da Adam tercih edilmiştir. Bunun sebebi, adaptif öğrenme hızına sahip olmasıdır.

Bu çalışma süresinde farklı ağ yapılarındaki modeller denenmiş olup aralarından 5 adet model seçilmiştir. Bu modellerin birbirleri arasındaki en belirgin fark katman sayılarıdır. Modeller aşağıdaki gibidir:

Model 1; bir adet 3 x 3 boyuta sahip 32 filtreli bir evrişim (convolution) katmanına sahip olmakla birlikte ReLU aktivasyon fonksiyonunu kullanmaktadır. Maksimum ortaklama (Max pooling) katmanı 2 x 2 boyutundadır. Sonrasında elimizdeki 3B çıktılar 1B vektörlere düzleştirmek için düzleştirme(flatten) katmanı eklenmiştir [10]. Tamamen bağlı katman olan yoğunlaştırma(dense) katmanından da geçirdikten sonra eksiltme(dropout) katmanı eklenmiştir. Bu katman sayesinde fazla sayıda bulunan nöronlar rastgele seçilerek eğitim aşamasında yok sayılmaktadır. Bu sayede aşırı öğrenme(overfitting) probleminin önüne geçilmesi amaçlanmaktadır. En sonda çıktı kısmında ise yoğunlaştırma katmanında 3 adet nöron bulunmaktadır. Bunlar; Gliom, Meningiom ve Hipofiz sınıflarını belirtmektedir. Burada ise softmax fonksiyonu yer almaktadır.

Model 2; model 1'den farklı olarak ilk evrişim katmanından sonra bir adet 3 x 3 boyuta sahip 64 filtreli evrişim katmanına sahip olup, 2 x 2 maksimum ortaklama katmanı ile beraber kullanılmıştır. Sonrasında gelen katmanlarda farklılık yoktur.

Model 3; model 2'nin en son bulunan evrişim katmanından sonra 3 x 3'lük 128 filtreye sahip bir evrişim katmanı ve 2 x 2

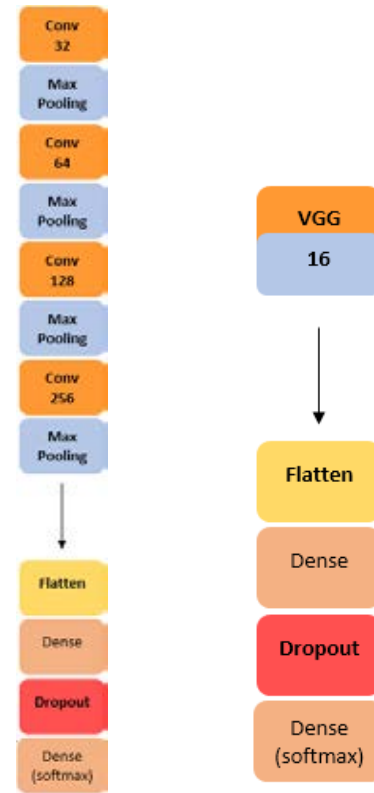


Şekil 4: Modellerin diagramları

boyuta sahip bir maksimum ortaklama katmanına sahip bir modeldir. Sonrasındaki katmanlar aynı şekildedir.

Model 4; model 3'teki yapıdan farklı olarak 128'lik evrişim katmanından sonra 3 x 3 boyuta sahip 256 filtreli bir evrişim katmanı eklenmesi ve 2 x 2'lik bir maksimum ortaklama katmanı ile oluşturulmuştur. Modelin sonraki kısımları diğer modeller ile aynıdır.

Model 5'te ise, diğer modellerden farklı olarak ön eğitimli evrişimli sinir ağı mimarisi olan VGG-16 kullanılmıştır [6]. VGG -16 katmanının üzerine diğer modellerde de bulunan düzleştirme, yoğunlaştırma ve eksiltme katmanları eklenmiştir.



Şekil 5: Modellerin diagramları

Modellerde evrişim için 3 x 3, maksimum ortaklama için 2 x 2 boyutunda filtrelerin kullanılmasının nedeni, deney aşamasında diğer boyutlara kıyasla daha iyi sonuçlar alınmasıdır.

Yukarıda belirtilen modeller, eğitim ve doğrulama veri setindeki görüntüler ile eğitilmiştir. Sonrasında test veri setindeki görüntüler ile doğruluk, kesinlik ve duyarlılık değerleri incelenmiştir. Bu modeller oluşturulurken, her bir yeni modelde katman sayısı artırılarak, doğruluk değeri incelenirken aynı zamanda modellerin eğitimi için gereken/harcanan zaman da gözlemlenmiştir.

III. SONUÇLAR

Derin öğrenme modeli eğitildikten sonra veri setinden önceden ayrılmış olan test seti kullanılarak, oluşturulan modelin başarı ölçümü için test edilmiştir. Bu testler sonucunda elde edilen değerler Tablo I ve Tablo II de gösterilmiştir. Buna göre; doğruluk, kesinlik ve duyarlılık oranı en yüksek olan Model 4'tür. Aynı zamanda çalışmanın bir diğer amacı olan zamandan kazanç durumu da incelenmiştir. Sonuç olarak, model 4 hem doğruluk oranı olarak hem de harcadığı zamanın diğer modellere göre daha ideal olmasından dolayı bu çalışmada oluşturulmuş olan en başarılı modeldir.

TABLO I. Modellerin Doğruluk, Kesinlik ve Duyarlılık Test Sonuçları

Modeller	Doğruluk	Kesinlik	Duyarlılık
Model 1	0.67	0.61	0.61
Model 2	0.69	0.66	0.62
Model 3	0.72	0.63	0.63
Model 4	0.90	0.89	0.90
Model 5	0.68	0.71	0.64


TABLO II. Modellerin Eğitimi için Harcanan Zaman

Modeller	Harcanan Zaman
Model 1	38 dakika
Model 2	30 dakika
Model 3	27 dakika
Model 4	26 dakika
Model 5	91 dakika

Oluşturulan modellerden en başarılı olan Model 4'ün hata matrisi (confusion matrix) Şekil 6'da gösterilmiştir.

IV. TARTIŞMA

Diğer modellerin hata matrislerine bakıldığı zaman anlaşıldığı üzere, oluşturulan modeller Gliom ile Meningiom arasında sınıflandırma yaparken zorlanmaktadır. Bunun nedeni veri setinde bulunan Gliom ve Meningiom veri sayılarının dengesizliği olabilir. Bu çalışmadan elde edilen sonuçları geliştirmek için daha fazla veriye ulaşılarak ve farklı hiper parametreler denenerek başarı oranı artırılabilir. Ayrıca bu çalışmada uygulanmamış olan fakat olumlu etki oluşturabileceği düşünülen farklı görüntü ön işleme yöntemleri de gelecek çalışmalarda denenebilir. En hızlı çalışan model olan model 4, zaman açısından modifikasyonlara uygun bir modeldir. Yapılacak değişiklikler ile hekimlere en etkili şekilde destek olabilecek bu sistem gelişime açıktır.



Şekil 6. Model 4'ün Hata Matrisi

KAYNAKLAR

- [1] WHO, *Statistics on Brain Cancer*. Accessed on: July 12, 2020. [Online]. Available: <http://www.who.int/cancer/en/>
- [2] *Brain tumor symptoms*. Accessed on: July 20, 2020. [Online]. Available: <https://www.mayoclinic.org/diseases-conditions/brain-tumor/symptoms-causes/syc-20350084>
- [3] Tandel, G. S., et al. "A review on a deep learning perspective in brain cancer classification", *Cancers* 11.111, 2019.
- [4] *Brain Tumor: Introduction*. Accessed on: August 3, 2020. [Online]. Available: <https://www.cancer.net/cancer-types/brain-tumor/introduction>
- [5] Das, S., O.F.M, Aranya, R. R., Labiba, N. N., "Brain tumor classification using convolutional neural network", *2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT)*. IEEE, 2019.
- [6] Rehman, A., et al. "A deep learning-based framework for automatic brain tumors classification using transfer learning." *Circuits, Systems, and Signal Processing* 39.2. 757-775, 2020.
- [7] Alqudah, A. M., Alguraan, H., Qasmieh, I. A., Alqudah, A., Al-Sharu, W., "Brain Tumor Classification Using Deep Learning Technique – A comparison between Cropped, Uncropped and Segmented Lesion Images with Different Sizes", Volume:8, No:6, 2019.
- [8] Sajjad, M., Khan, S., Muhammad, K., Wu, W., Ullah, A., Baik, S. W., "Multi-grade brain tumor classification using deep CNN with extensive data augmentation." *Journal of computational science* 30, 174-182, 2019.
- [9] Cheng, J., et al. "Enhanced performance of brain tumor classification via tumor region augmentation and partition." *PLoS one* 10.10, e0140381, 2015.
- [10] Chollet, F., *Python ile Derin Öğrenme*, Buzdağı Yayınevi, 2019, pp. 71, 147, 154.
- [11] Code to Light Accessed on 10 August, 2020. [Online]. Available: <https://codetolight.wordpress.com/2017/11/29/getting-started-with-pytorch-for-deep-learning-part-3-neural-network-basics/>