

PAPER DETAILS

TITLE: BEYİN MR GÖRÜNTÜLERİNDEN mRMR TABANLI BEYİN TÜMÖRLERİNİN
SINIFLANDIRMASI

AUTHORS: Burak TASCI

PAGES: 1-9

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/2564582>



BEYİN MR GÖRÜNTÜLERİNDEN mRMR TABANLI BEYİN TÜMÖRLERİNİN SINIFLANDIRMASI

Burak TAŞCI^{1*}

^{1*}Fırat Üniversitesi Teknik Bilimler MYO. Elektrik ve Enerji. Böl., Hibrid ve Elektrikli Taşıtlar Teknolojisi Programı, Elazığ,
btasci@firat.edu.tr, ORCID: 0000-0002-4490-0946

Geliş Tarihi(Received Date):29.02.2022

Kabul Tarihi(Accepted Date):19.09.2022

ÖZ

Beyin tümörleri nedeniyle ölen kişilerin sayısı gün geçtikçe artmaktadır. Beyin tümörünün tedavi planlamasında ve tedavi sonucunun değerlendirilmesinde erken teşhis çok önemlidir. Beyin tümörü olan bir hastanın, hastalığının erken teşhis edilmesi sayesinde doğru tedavi yöntemleri uygulanarak hayatta kalma ihtimali artabilir. Manyetik rezonans (MR) görüntüleme beyin tümörlerinin tanı ve teşhisinde önemli bir role sahiptir. Bununla birlikte, MR görüntüleri kullanarak beyin tümörlerini sınıflandırması beyin yapısının karmaşıklığı ve içindeki dokuların iç içe geçmesi nedeniyle zordur. Bu çalışma, DenseNet201 ön eğitilmiş modelinin avg_pool ve fc1000 katmanlarından elde edilen 2920 özneteliğin 500 adeti mRMR algoritması kullanılarak seçilmiştir. Öznetelik seçimi yapılmadan %95.00 doğruluk, mRMR öznetelik seçimi yapılarak %95.76 doğruluk elde edilmiştir.

Anahtar kelimeler: MR görüntüleri , sınıflandırma , beyin tümörü,DVM, K-EYK, mRMR

CLASSIFICATION OF mRMR-BASED BRAIN TUMORS from BRAIN MR IMAGES

ABSTRACT

The number of persons who pass away from brain tumors continues to rise on a daily basis. The planning of treatment and the assessment of the treatment's effectiveness are both significantly aided by an early detection of a brain tumor. A person with a brain tumor may have a better chance of living if the disease is found and treated early and in the right way. Imaging with magnetic resonance, sometimes known as MR imaging, plays an essential part in the detection and diagnosis of brain cancers. However, due to the intricate nature of the brain's structure and the interconnectedness of its tissues, classification of brain tumors using MR imaging can be a challenging endeavor. In this study, 500 of 2920 features obtained from avg_pool and fc1000 layers of DenseNet201 pre-trained model were selected using mRMR algorithm. 95.00% accuracy was obtained without feature selection, and 95.76% accuracy was obtained by mRMR feature selection.

Keywords: MR images, classification, brain tumor, SVM, kNN, mRMR

1. GİRİŞ

Beyin insan vücudunda karmaşık bir organdır. Beyindeki anormal hücrelerin büyümesi beyin tümörü olarak bilinir ve çeşitli tiplerde ortaya çıkabilir. Tümör, beynin herhangi bir yerinde herhangi bir boyutta ortaya çıkabilir. Beyindeki anormal hücrelerin büyümesi, kafatası içinde yüksek basınca neden olur ve vücudumuzda birçok tehlikeli sağlık sorunu yaratır. İyi huylu tümörler kanserli olmayan tümörlerdir. Ancak bazı tümörler kötü huylu (malign) olabilir ve teşhis edilmesi zordur ve hayatta kalma şansı en azdır. Malign beyin tümörü insanlarda ölümün başlıca nedenlerinden biridir ve her yaştan insanı etkileyen en yaygın onuncu tümör türüdür. Ancak erken teşhis edilirse en tedavi edilebilir tümör türlerinden biridir. Beyin tümörünün tedavi maliyeti çoğu hasta tarafından karşılanamamaktadır. Beyin tümörünün tedavisi tümörün boyutuna, tümörün tipine ve tümörün büyüme evresine göre yapılır. MR görüntüleri kullanılarak ilişkili rahatsızlıklar otomatik tanımlanabilmekte ve yapay zeka yöntemleri kullanılarak sınıflandırılabilir. Medikal görüntülerde ve sinyallerde derin öğrenme yöntemleri kullanılarak hastalık teşhisinde doktorlara destek olunması mümkündür[1, 2]. Literatürde MR görüntülerinin kullanıldığı beyin tümör sınıflandırması ile ilgili bazı çalışmalar aşağıda sunulmuştur.


Lakshmi ve arkadaşları [3], Inception-v3 evrişim sinir ağını kullanarak eğitim verilerinde %99.34 ve doğrulama verilerinde %89.00 doğruluk elde etmişlerdi. Veeramuthu ve arkadaşları [4], birleşik özellik ve görüntü tabanlı sınıflandırıcı kullanmışlardı. Çalışmada sırasıyla %98.86, %97.14 ve %98.97 duyarlılık, özgüllük ve doğruluk değerlerini elde etmişlerdi. Li ve arkadaşları [5], Brats 2018 veri setini kullanarak beyin tümör sınıflandırma çalışması yapmışlardı. Çalışmada bilgi füzyonu ve ESA modeli kullanarak %99.81 hassasiyet ve %92.7 kesinlik elde etmişlerdi. Singh [6], Fuzzy-C-Means ve DVM temelli hibrit bir yöntem geliştirmiştir. Önileşim aşamasında çift eşikleme ve morfolojik işlemlerle kafatası çıkarımı yapılmıştır. Özellik çıkarımı için gri seviyeli çalışma uzunluk matrisi kullanılmış ve özellikler DVM sınıflandırıcısını kullanarak sırasıyla duyarlılık, özgüllük ve doğruluk için %83.33, %100 ve %91.66 elde etmişlerdi. Parveen ve Agrawal [7]'te, Brats2013 veri setini kullanmışlardı. MR görüntülerinde beyin tümör tespiti için önileşimler uygulanmıştı. Sınıflayıcı aşamasında en küçük kareler destek vektör makinesi sınıflandırıcısını kullanarak sırasıyla özgüllük ve doğruluk için %81.33, ve %96.63 elde etmişlerdi. Thirumurugan ve arkadaşları [8]'da, Brats 2012-2013-2014 veri setlerindeki MR görüntülerinde Glioblastoma tümörü tespiti üzerine bir yöntem önerilmişti. Yaptıkları deneysel çalışmalarda sırasıyla duyarlılık, özgüllük ve doğruluk için %95.7, %97.8 ve %98.6 elde etmişlerdi. Chen ve Konukoglu [9]'de, HCP ve BrasTs2015 veri setlerindeki sağlıklı beyin MR görüntülerinin veri dağılımını öğrenmek için çekimsel kullanmışlardı. Denetimsiz öğrenme ile uygulanan yöntem sayesinde %92.0 AUC değerini elde etmişlerdi. Chen ve arkadaşları [10]'de, Brats 2015 ve atlas datasetlerini kullanarak değişimsel otokodlayıcıların ve çekimsel otokodlayıcıların tıbbi görüntüleme anomalisi tespit etmeye çalışmışlardı. Yaptıkları çalışmada %70 doğruluk elde etmişlerdi.

2. MATERYAL VE YÖNTEM

2.1. Veri Seti


Bu çalışmada kaggle sitesinde yer alan 4 sınıflı 3443 görüntüden oluşan veri seti kullanılmıştır [11]. Veri seti, 978 adet glioma tümörü, 990 adet kötü huylu tümör, 538 adet sağlıklı ve 937 adet hipofiz tümörü görüntülerinden oluşmaktadır. Veri setindeki her örnek farklı boyutlardaki görüntülerden oluşmaktadır. Veri setindeki görüntüleri DenseNet201'in girişinde kullanabilmek için tüm

görüntülerin genişliği ve yüksekliği 224x224 olarak değiştirilmiştir. Veri setindeki dört sınıfa ait görüntü örnekleri şekil 1’de verilmiştir.



Şekil 1. Veri setindeki sınıflardan örnekler.

Bu çalışmada ön eğitilmiş modellerden özellik çıkarılarak beyin tümör çalışması yapılmıştır. Ön eğitilmiş modelin ve sınıflandırıcısı seçmek için tablo 1’de verildiği gibi 19 ön eğitilmiş modelin DVM ve K-en Yakın Komşuluk (K-EYK) sonuçları incelenmiştir. Tablo 1’de görüldüğü gibi DenseNet201 ön eğitilmiş modelden elde edilen özneliklerin K-EYK sınıflandırıcısı ile sınıflandırılması ile en iyi sınıflandırma sonucu elde edilmiştir. Önerilen yöntemin temsili gösterimi Şekil 2’de verilmiştir. Önerilen yöntemin ilk aşamasında MR görüntülerinden öznelik çıkarmak için DenseNet201 modeli kullanılmıştır. DenseNet201’in “avg_pool” katmanından 1920 adet öznelik, “fc1000” katmanından 1000 adet öznelik alınarak birleştirilmiştir. Toplamda 2920 adet öznelik elde edilmiştir. Birleştirilen özneliklerden 500 tanesi mRMR öznelik seçim algoritması yardımıyla seçilmiştir. Elde edilen 500 öznelik K-EYK algoritmasında sınıflandırılmıştır.



Şekil 1. Önerilen yöntemin blok diyagramı.

3. DENEYSEL ÇALIŞMA

Bu bölümde, sunulan modeli uygulamak için kullanılan ortam sunulmuştur. Önerilen metotun karşılaştırmasının yapılması için 19 ön eğitilmiş modelden öznelik çıkarılmıştır. Çıkarılan öznelikler DVM ve K-EYK sınıflandırıcı ile tablo 1’deki gibi sınıflandırılmıştır.


Tablo 1. 19 Ön-eğitilmiş modelin sınıflandırma sonuçları.

Ön Eğitimli Model	DVM(%)	K-EYK(%)
GoogleNet [12]	89.6	88.0
DarkNet53 [13]	91.0	89.6
Inceptionv3 [14]	89.9	89.0
NasnetLarge [15]	89.7	87.9
NasnetMobile [15]	88.6	85.0
VGG19 [16]	88.5	88.8
VGG16 [16]	89.5	88.2
Resnet101 [17]	91.3	91.5
Inceptionresnetv2 [18]	91.0	88.3
AlexNet [19]	92.6	90.6
ShuffleNet [20]	92.1	90.9
Resnet50 [17]	92.2	90.5
Xception [21]	91.2	90.4
Resnet18 [17]	90.9	90.2
Darknet19 [13]	90.5	89.9

MobileVnet2 [22]	91.4	92.2
DenseNet201 [23]	92.8	93.7
SqueezeNet [24]	91.9	90.2
Efficient b0 [25]	93.1	93.6

En yüksek doğruluğu DenseNet201 10 kat çapraz doğrulama ile K-EYK seçilmiştir. MATLAB2021b sınıflandırma aracı kullanılarak sınıflandırıcılar test edilmiştir. K-EYK en iyi sonucu verdiği için seçilmiştir. Modellerimizi uygulamak için 1512 GB sabit disk, Windows 10.1 pro OS, 64 GB belleğe ve intel i9 9900 işlemciye sahip bir bilgisayar kullanılmıştır.

DenseNet201'in "avg_pool" katmanından 1920 adet öznitelik, "fc1000" katmanından 1000 adet öznitelik alınarak birleştirilmiştir. Toplamda 2920 adet öznitelik elde edilmiştir. mRMR öznitelik seçim algoritması yardımıyla 500 öznitelik seçilmiştir. Elde edilen 500 öznitelik K-EYK algoritmasında sınıflandırılmıştır. Öznitelik seçimi yapılmadan %95.00 doğruluk elde edilmiştir. mRMR ile 500 öznitelik seçilerek %95.76 doğruluk elde edilmiştir. Bu her iki durum için K-EYK sınıflandırıcısının karmaşıklık matrisi sonuçları Şekil 3'te verilmiştir. Şekil 3(a)'da öznitelik seçimi yapılmamıştır ve Şekil 3(b)'de öznitelik seçimi yapılmıştır.



Şekil 2. K-EYK sınıflandırıcısı karmaşıklık matrisleri.

Şekil 3'de verilen karmaşıklık matrisi sonuçları kullanılarak duyarlılık, özgüllük, kesinlik, ve F-skor metrik sonuçları Tablo 2'de verilmiştir. Öznitelik seçimi yapılmadan %95.00 doğruluk elde edilmiştir. mRMR ile 500 öznitelik seçilerek %95.76 doğruluk elde edilmiştir.

Tablo 2. K-EYK sınıflandırıcısının duyarlılık, özgüllük, kesinlik, F1-skor metrikleri.

	Doğruluk	Duyarlılık(%)	Özgüllük(%)	Kesinlik(%)	F1-Skor(%)
Öznitelik Seçimi Yok	%95.0	91,72	98,86	96,97	94,27
		94,24	96,25	91,02	92,61
		96,84	99,35	96,48	96,66
		98,19	98,68	96,54	97,35
mRMR Öznitelik Seçimi	%95.76	92,13	99,03	97,41	94,69
		96,16	96,58	91,89	93,98
		97,03	99,41	96,85	96,94
		98,40	99,16	97,77	98,09

Ayrıca, Tablo 3’de beyin tümör sınıflandırması ile ilgili yapılan çalışmalar verilmiştir.

Tablo 3. Bazı yöntemlerin performans karşılaştırmaları.

Referans	Dataset	Yöntem	Doğruluk(%)
Ghassemi vd.[26]	Figshare	ESA-ÇÜA	88.00
Çıtak vd.[27]	Klinik	DVM,ÇKA,LR	93.00
Shahzadi vd.[28]	Brats 2015	VGG,UKSB	84.00
Önerilen Yöntem	Kaggle	DenseNet201, mRMR	95.76

Ghassemi vd. [26] meningeoma (708 görüntü), glioma (1426 görüntü) ve hipofiz(930 görüntü) tümöründen oluşan veri setini kullanmıştı. çekişmeli üretken ağ (ÇÜA) kullanarak aşırı uyumun üstesinden gelmek için denetimsiz bir ön eğitim yöntemi kullanmıştı. 5-katlı çapraz doğrulama ile %93.01 doğruluk elde etmişti. Çıtak vd. [27] 43 hasta dahil edildiği gliomaların derecelendirilmeye çalışmışlardı.Çalışmada %86,70 özgüllük ile %93.00 doğruluk elde etmişti. Shahzadi vd. [28], yüksek dereceli (HG) ve düşük dereceli (LG)’yi sınıflandırmışlardı. VGG-16’dan gelen özellikler çıkardıktan sonra 3D beyin tümörü hacimlerini HG ve LG’yi sınıflandırmak için özellik temsillerini öğrenmek için Uzun Kısa Süreli Bellek (UKSB) ağını beslemişlerdi. Önerdikleri yöntem ile % 84.00 doğruluk elde etmişlerdi. Ayrıca, Tablo 3’teki ESA modellerinin kullanıldığı [26],[27] ve [28] referanslı çalışmalar ile karşılaştırıldığında daha hafif ağırlıklı olan DenseNet201 modeli ile daha yüksek bir sınıflandırma doğruluğu elde edilmesi önerilen yöntemin başarısını göstermektedir.

4. SONUÇLAR

Bu çalışmada MR görüntüleri kullanılarak beyin tümör sınıflandırılması yapılmıştır. Çalışmada 4 sınıflı 3443 görüntüden oluşan veri seti kullanılmıştır. 19 ön eğitilmiş modelden DenseNet201 modelinden çıkarılan öznitelikler en yüksek doğruluk sonucu vermiştir. Önerilen yöntemde DenseNet201’in “avg_pool” katmanından 1920 adet öznitelik, “fc1000” katmanından 1000 adet öznitelik alınarak birleştirilmiştir.Öznitelik seçimi yapılmadan %95.00 doğruluk, mRMR öznitelik seçimi yapılarak %95.76 doğruluk elde edilmiştir.mRMR öznitelik seçme algoritması ile %0.76 doğruluk metriğinde artış sağlanmıştır. Bilgisayar destekli tanı sistemi özellikle teşhis ve tanı da önemli rol oynamaktadır. Beyin analizi çeşitli yaklaşımlarla bulgular ve anatomik bölgelerin doğru

sınıflandırılmasına dayanır. Bu çalışmada insan hayatını olumsuz yönde etkileyen bir hastalığın teşhisine yönelik yöntem geliştirilmiştir.

Gelecekteki çalışmalarımızda, farklı beyin tümörlerini tespit etmek için daha fazla sınıflı ve daha fazla veriye sahip veri kümeleri üzerinde yeni bir model oluşturulması planlanmaktadır.

TEŞEKKÜR

Yazarın teşekkür edeceği herhangi bir kişi ve ya kuruluş bulunmamaktadır.

KAYNAKÇA

- [1] Abiwinanda, N., Hanif, M., Hesaputra, S. T., Handayani, A., and Mengko, T. R. (2019). Brain tumor classification using convolutional neural network. In World congress on medical physics and biomedical engineering 2018. Springer, Singapore. 183-189.
- [2] Seetha, J., and Raja, S. S. (2018). Brain tumor classification using convolutional neural networks. Biomedical and Pharmacology Journal, 11(3), 1457.
- [3] Lakshmi, M. J., and Nagaraja Rao, S. (2022). Brain tumor magnetic resonance image classification: a deep learning approach. Soft Computing, 1-9.
- [4] Veeramuthu, A., Meenakshi, S., Mathivanan, G., Kotecha, K., Saini, J. R., Vijayakumar, V., and Subramaniaswamy, V. (2022). MRI brain tumor image classification using a combined feature and image-based classifier. Frontiers in Psychology, 13.
- [5] Li, M., Kuang, L., Xu, S., and Sha, Z. (2019). Brain tumor detection based on multimodal information fusion and convolutional neural network. IEEE Access, 7, 180134-180146.
- [6] Singh, A. (2015, February). Detection of brain tumor in MRI images, using combination of fuzzy c-means and SVM. In 2015 2nd international conference on signal processing and integrated networks (SPIN) , IEEE. 98-102.
- [7] Praveen, G. B., and Agrawal, A. (2015, November). Hybrid approach for brain tumor detection and classification in magnetic resonance images. In 2015 Communication, Control and Intelligent Systems (CCIS), IEEE. 162-166.
- [8] Thirumurugan, P., Ramkumar, D., Batri, K., and Siva Sundhara Raja, D. (2016). Automated detection of glioblastoma tumor in brain magnetic imaging using ANFIS classifier. International Journal of Imaging Systems and Technology, 26(2), 151-156.
- [9] Chen, X., and Konukoglu, E. (2018). Unsupervised detection of lesions in brain MRI using constrained adversarial auto-encoders. arXiv preprint arXiv:1806.04972.

- [10] Chen, X., Pawlowski, N., Rajchl, M., Glocker, B., and Konukoglu, E. (2018). Deep generative models in the real-world: an open challenge from medical imaging. arXiv preprint arXiv:1806.05452.
- [11] (2022, 19.06.2022). *Brain Tumor MRI Image Classification* (<https://www.kaggle.com/datasets/iashiqu/brain-tumor-mri-image-classification>).
- [12] Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., and Fergus, R. (2013). Intriguing properties of neural networks. arXiv preprint arXiv:1312.6199.
- [13] Redmon, J., and Farhadi, A. (2017). YOLO9000: better, faster, stronger. In Proceedings of the IEEE conference on computer vision and pattern recognition, 7263-7271.
- [14] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, 2818-2826.
- [15] Zoph, B., Vasudevan, V., Shlens, J., and Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition , 8697-8710.
- [16] Simonyan, K., and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- [17] He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition, 770-778.
- [18] Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. A. (2017, February). Inception-v4, inception-resnet and the impact of residual connections on learning. In Thirty-first AAAI conference on artificial intelligence.
- [19] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 84-90.
- [20] Zhang, X., Zhou, X., Lin, M., and Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. In Proceedings of the IEEE conference on computer vision and pattern recognition, 6848-6856.
- [21] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition , 1251-1258.
- [22] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In Proceedings of the IEEE conference on computer vision and pattern recognition, 4510-4520.

- [23] Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition, 4700-4708.
- [24] Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., and Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. arXiv preprint arXiv:1602.07360.
- [25] Tan, M., and Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning, PMLR. 6105-6114.
- [26] Ghassemi, N., Shoeibi, A., and Rouhani, M. (2020). Deep neural network with generative adversarial networks pre-training for brain tumor classification based on MR images. Biomedical Signal Processing and Control, 57, 101678.
- [27] Citak-Er, F., Firat, Z., Kovanlikaya, I., Ture, U., and Ozturk-Isik, E. (2018). Machine-learning in grading of gliomas based on multi-parametric magnetic resonance imaging at 3T. Computers in biology and medicine, 99, 154-160.
- [28] Shahzadi, I., Tang, T. B., Meriadeau, F., and Quyyum, A. (2018, December). CNN-LSTM: cascaded framework for brain tumour classification. In 2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES), IEEE. 633-637.