



Classification of brain tumors using wavelet transform and Inception V3 convolutional neural network model

Zihni Kaya^{1*}, Zafer Aslan², Ali Güneş², Ali Okatan³

¹Department of Computer Engineering, Institute of Graduate Study, İstanbul Aydın University, 34295, İstanbul, Türkiye

²Department of Computer Engineering, Faculty of Engineering, İstanbul Aydın University, 34295, İstanbul, Türkiye

³Department of Software Engineering, Faculty of Engineering, İstanbul Aydın University, 34295, İstanbul, Türkiye

Highlights:

- Feature extraction with discrete wavelet transform
- Feature extraction and classification with convolutional neural networks
- Classification of brain tumors by transfer learning-based methods

Keywords:

- Brain Tumor
- Discrete Wavelet Transform
- Convolutional Neural Networks
- Transfer Learning
- Inception V3

Article Info:

Research Article
Received: 20.12.2022
Accepted: 17.09.2023

DOI:

10.17341/gazimmfd.1221952

Correspondence:

Author: Zihni Kaya
e-mail:
zihnikaya@aydin.edu.tr
phone: +90 532 470 5441

Graphical/Tabular Abstract

In this study, brain MRI images were classified with a pre-trained Inception v3 model that takes as input the features extracted using the discrete wavelet transform as shown in Figure A.

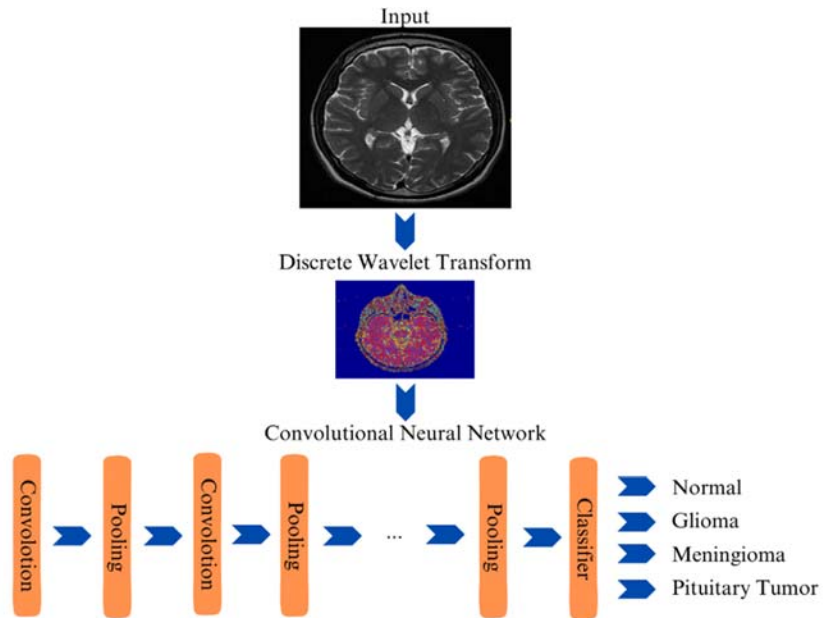


Figure A. Flowchart of the proposed methods

Purpose:

The performance of the classifier was measured with accuracy, precision, recall and F1-score on the validation set.

Theory and Methods:

Discrete wavelet transform is a powerful mathematical tool that provides a multi-resolution representation of any signal or image. It is used to extract features from images and reduce image size. Convolutional neural networks, created by modeling the human visual system, are a special type of neural network that uses a grid-like structure to analyze images. Transfer learning is widely used when the sample size of the dataset is small.

Results:

In this study, a transfer learning-based classification model is presented using wavelet features. Brain tumors were classified using a four-class dataset consisting of glioma, meningioma, pituitary gland and normal brain MRI images, and an accuracy of 99.65% was achieved.

Conclusion:

As a result, a study was conducted on the use of wavelet transform and convolutional neural networks in the classification of brain MRI images. When wavelet features are used as the input of the Inception V3 network, it is seen that the accuracy performance increases by 0.34%.



Dalgacık dönüşümü ve Inception V3 evrişimli sinir ağı modeli kullanarak beyin tümörlerinin

Zihni Kaya^{1*}, Zafer Aslan², Ali Güneş², Ali Okatan³

¹İstanbul Aydın Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Bölümü, 34295, İstanbul, Türkiye

²İstanbul Aydın Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34295, İstanbul, Türkiye

³İstanbul Aydın Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 34295, İstanbul, Türkiye

Ö N E Ç İ K A N L A R

- Dalgacık dönüşümü ile öznelik çıkarımı
- Evrişimli sinir ağları ile öznelik çıkarımı ve sınıflandırma
- Transfer öğrenme tabanlı yöntemlerle beyin tümörlerinin sınıflandırılması

Makale Bilgileri

Araştırma Makalesi

Geliş: 20.12.2022

Kabul: 17.09.2023

DOI:

10.17341/gazimmfd.1221952

Anahtar Kelimeler:

Beyin tümörü,
ayrık dalgacık dönüşümü,
evrişimli sinir ağları,
transfer öğrenme,
Inception v3

ÖZ

Son yıllarda, beyin tümörleri nedeniyle insan ölümleri yaygın olarak görülmektedir. Hastalığın tedavisi için tümörün erken ve doğru teşhisi oldukça önemlidir. Uzmanlar tarafından beyin MRG görüntülerinden tümörün sınıflandırılması zaman bakımından maliyetli ve hatalı olabilmektedir. Bu nedenle, beyin tümörlerinin otomatik olarak sınıflandırılmasına ihtiyaç duyulmaktadır. Bu çalışmada, geliştirilmiş olan uygulama ile beyin tümörlerinin sınıflandırılması amaçlanmıştır. Bu genel amaç kapsamında, dalgacık öznelikleri kullanılarak beyin tümörlerinin sınıflandırılması için derin öğrenmeye dayalı bir yöntem önerilmiştir. Dalgacık dönüşümü, görüntülerden öznelik çıkartmak ve görüntü boyutunu azaltmak için kullanılmıştır. Elde edilen dalgacık öznelikleri beyin MR görüntülerinden bilgilendirici öznelikleri keşfetmek için önceden eğitilmiş Inception v3 modelinin girdisi olarak kullanılmıştır. Sonrasında bu öznelikler beyin MRG görüntülerini etiketlemek için softmax sınıflandırıcısına iletilmektedir. Bu çalışmadan elde edilen sonuç; 1621 gliyom, 1645 menenjiyom, 1757 hipofiz bezi ve 2000 normal beyin görüntüsünün bulunduğu veri seti üzerinde test edilmiş ve %99,66 doğruluk başarımları elde edilmiştir.

Classification of brain tumors using wavelet transform and Inception v3 convolutional neural network model

H I G H L I G H T S

- Feature extraction with discrete wavelet transform
- Feature extraction and classification with convolutional neural networks
- Classification of brain tumors by transfer learning-based methods

Article Info

Research Article

Received: 20.12.2022

Accepted: 17.09.2023

DOI:

10.17341/gazimmfd.1221952

Keywords:

ABSTRACT

In recent years, human deaths due to brain tumors have become widely common. Early and accurate diagnosis of the tumor is very important for the treatment of the disease. Classification of tumors from brain MRI images by specialists can be costly and inaccurate in terms of time. Therefore, there is a need for automatic classification of brain tumors. In this study, it is aimed to classify brain tumors with the developed application. Within the scope of this general purpose, a deep learning-based method has been proposed for the classification of brain tumors using wavelet features. Wavelet transform is used to extract features from images and reduce image size. Pre-trained Inception v3 model was preferred to explore informative features from brain MR images. The resulting features are transmitted to the softmax classifier to label the brain MRI images. The result obtained from this study; It has been tested on a dataset of 1621 gliomas, 1645 meningiomas, 1757 pituitary glands, and 2000 normal brain images, with an accuracy of 99,66%.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *zihnikaya@aydin.edu.tr, zaferaslan@aydin.edu.tr, aligunes@aydin.edu.tr, aliokatan@aydin.edu.tr / Tel: +90 532 470 5441

1. Giriş (Introduction)

Son yıllarda, yaşamı tehdit eden beyin tümörü hastalıklarına karşı büyük ilgi görülmektedir. Uluslararası Kanser Araştırmaları Ajansı'na göre 2012 yılında 256.000 kişiye beyin ve merkezi sinir sistemi kanseri teşhisi konulmuş ve 189.000 kişi bu nedenle ölmüştür [1]. Beyin tümörü, beyinde bulunan hücrelerin farklılaşarak kontrolsüz bir biçimde çoğalmasıyla veya vücudun başka bir yerindeki kanser hücrelerinin beyne gelerek yayılmasıyla meydana gelen bir hastalıktır. Beyin tümörleri iyi huylu (kansersiz) ve kötü huylu (kansersiz olmayan) olmak üzere iki ana gruba ayrılır. İyi huylu beyin tümörleri, beynin diğer bölgelerine yayılmazlar ve cerrahi müdahale ile çıkartılabilirler. Ama beyindeki diğer dokuların normal çalışmasını engelleyebilirler. Kötü huylu beyin tümörleri ise akciğer ve meme gibi diğer organlardan beyne yayıldığında ortaya çıkar. Bu tümörlerin sınırları tam olarak belli olmadığından cerrahi müdahale ile çıkarılmaları zordur [2].

Beyin tümörlerinin tanısında, yaygın olarak manyetik rezonans görüntüleme (MRG) ve bilgisayarlı tomografi yöntemleri kullanılmaktadır. MRG, doku farklılıklarından yola çıkarak görüntüler elde edilebilmesini sağlayan bir tıbbi görüntüleme tekniğidir [3]. Beynin yumuşak dokusuyla ilgili yüksek çözünürlük görüntünün yanı sıra birden fazla şekil bilgisi de vermektedir. Bu nedenle, beyindeki anormalliklerin tespitinde genellikle MRG yöntemi kullanılmaktadır [4].

Beyin tümörünün erken teşhisi ile hastaların hayatta kalma oranı önemli ölçüde artırılabilir. Bu nedenle, MRG görüntülerinden tümör türünün hızlı ve doğru şekilde sınıflandırılması gerekmektedir. Ancak, uzmanlar tarafından manuel olarak yapılan tümör sınıflandırması zaman bakımından maliyetli ve hatalı olabilmektedir. Bu nedenle, beyin tümörlerinin yapay zekâ uygulamaları ile sınıflandırılması büyük önem taşımaktadır.

Literatürde, beyin tümörlerinin sınıflandırılması için evrişimli sinir ağı (ESA) modelleri yaygın olarak kullanılmaktadır. Özkaraca vd. [5] transfer öğrenme yöntemini kullanmadan yoğun katmanlara sahip ESA modelleri ile beyin MRG görüntülerini sınıflandırmışlardır. Deneysel çalışmalarda %94-97 arasında doğruluk başarımları elde etmişlerdir. Gomez Guzman vd. [6] önceden eğitilmiş ResNet50, InceptionV3, InceptionResNetV2, Xception, MobileNetV2 ve EfficientNetB0 modelleri ile beyin MRG görüntülerini sınıflandırmışlardır. Ön işlem aşamasında, görüntülere, veri çoğaltma, etiketleme ve yeniden boyutlandırma yöntemlerini uygulamışlardır. Model performansını değerlendirmek için 5 kat çapraz doğrulama tekniğini kullanmışlardır. Deneysel çalışmalarda en yüksek doğruluk başarımları %97,12 ile InceptionV3 modelinden elde etmişlerdir. Ali vd. [7] önceden eğitilmiş Shuffle-Net modelini DVM ile birleştiren hibrit bir yöntem kullanmışlardır. Deneysel çalışmalarda %98,40 doğruluk başarımları elde etmişlerdir.


Bu çalışmada, beyin MRG görüntülerine 1 seviyeli ADD ayrıştırması yapılmıştır. Elde edilen alt bileşenlerden yaklaşık bileşeni önceden eğitilmiş Inception V3 ağının girdisi olarak kullanılmıştır. Önerilen yöntem figshare, SARTAJ ve Br35H [8] veri setlerinin birleşiminden

oluşan dört sınıflı veri seti üzerinde test edilmiş ve literatürdeki çalışmalara göre daha yüksek bir doğruluk başarımları elde edilmiştir.

2. Materyal ve Metot (Material and Method)

2.1. Veri seti (Dataset)

Bu çalışmada kullanılan veri seti Kaggle web sitesinden alınmıştır. Veri setindeki görüntüler figshare, SARTAJ ve Br35H gibi üç veri tabanından alınan görüntülerin birleşiminden oluşmaktadır [8]. Veri setinde her biri dört sınıftan birine ait görüntülerinin yer aldığı toplam 7023 beyin MRG görüntüsü bulunmaktadır. Her bir görüntü JPG formatında ve 512x512x3 boyutlarındadır. Veri setinde 2000 tane normal beyin MRG görüntüsü bulunmaktadır. Tümörlü MRG görüntülerinin ise 1621 tanesi gliyom, 1645 tanesi menenjiyom ve 1757 tanesi hipofiz bezi türüne aittir [6]. Şekil 1'de normal ve tümörlü beyin MRG görüntüleri yer almaktadır.



Şekil 1. Normal ve tümörlü beyin MRG görüntüleri (Normal and tumor brain MRI images)

2.2. Ön İşlem (Pre-processing)


Beyin MR görüntülerinin kalitesini arttırmak için görüntülere histogram eşitleme yöntemi uygulanmıştır. Histogram eşitleme işleminden sonra görüntülere 1 seviyeli ADD ayrıştırması uygulanmış ve görüntü boyutları 256x256x3 boyutlarına düşürülmüştür. Sonrasında, görüntü yoğunluk değerleri Z-skor standardizasyon yöntemi ile ortalama değeri 0 ve standart sapması 1 olacak şekilde Eş. 1'de verildiği gibi standartlaştırılmıştır.

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

Eş. 1'de x eğitim setindeki her bir örneği, μ ortalamasını s ise örneklerin standart sapmasını göstermektedir. Son olarak görüntüler 224x224x3 boyutlarında olacak şekilde yeniden boyutlandırılmıştır. Şekil 2'de ön işlem aşamasında yapılan işlemlerin blok diyagramı verilmiştir.


2.3. Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)

Ayrık dalgacık dönüşümü (ADD), bir görüntüden anlamlı bilgiler çıkartmak, gürültü gibi istenmeyen verileri ortadan kaldırmak ve



Şekil 2. Veri ön işlem aşamaları (Data pre-processing stages)

boyut azaltmak için kullanılmaktadır. ADD, herhangi bir sinyal veya görüntünün çok çözünürlüklü gösterimini sağlayan güçlü bir matematiksel araçtır. Sinyali veya görüntüyü farklı frekans bileşenlerine ayırıştırır ve ardından her bileşeni kendi ölçeğine uygun bir çözünürlükle inceler [9].



Şekil 3. Dalgacık ayrıştırma ağacı (Wavelet parse tree)

Şekil 3’de bir sinyalin ADD kullanılarak alt bileşenlerine ayrıştırılması işleminin blok diyagramı gösterilmektedir. Bu diyagramda c katsayıları göstermektedir [10]. Alt bileşenlere ayırma işlemi sinyal üzerinde istenildiği kadar gerçekleştirilebilir. Sinyal, öncelikle yaklaşım ve detay bileşenlerine ayrıştırılır. Sonrasında, elde edilen yaklaşım bileşeni tekrar yaklaşım ve detay bileşenlerine ayrıştırılır. Bu işlem, ardışık olarak istenilen sonuç elde edilene kadar devam ettirilir. ADD uygulanmış bir beyin MR görüntüsünden elde edilen yaklaşım ve detay bileşenleri Şekil 4’te verilmiştir.

2.4. Transfer Öğrenme (Transfer learning)

Klasik makine öğrenmesi yöntemleri, bir problemi çözerken geçmiş bilgi ve deneyimlerden yararlanmamaktadır. Her problemi ayrı ayrı değerlendirip, sıfırdan çözümler bulmaya çalışmaktadır. İnsanlarda öğrenme ise geçmiş bilgi ve deneyimlerden yararlanarak gerçekleştirilir. Örneğin, bisiklet sürmeyi öğrenen bir kişi, elde ettiği bu bilgi ve deneyimi motosiklet sürmeyi öğrenirken kullanabilir. Transfer öğrenme (Transfer learning), bir makine öğrenmesi problemini çözerken elde edilen bilgiyi benzer başka problemlerin çözümünde kullanmaktır. Örneğin, otomobilleri tanımayı öğrenirken elde edilen bilgi otobüsleri tanıma probleminde kullanılabilir.

Klasik makine öğrenmesi yöntemlerinde görüntülerden manuel olarak çıkarılan özellikler ile sınıflandırma yapılmaktadır. Evrişimli sinir

ağlarında ise evrişim ve havuzlama katmanları tarafından otomatik olarak çıkarılan özellikler kullanılarak sınıflandırma yapılmaktadır. Bir ESA modelinde, gerekli özelliklerin çıkarılabilmesi için büyük veri setlerine ihtiyaç duyulmaktadır. Eğer, eğitim veri seti yeterince büyük değilse aşırı öğrenme (overfitting) meydana gelebilir [11]. Bu sorun, transfer öğrenme yöntemi kullanılarak çözülmektedir.

ESA modellerinin eğitimi için büyük veri setlerine ihtiyaç duyulmaktadır. Ancak, bu veri setlerini elde etmek pahalı, emek yoğun ve zaman alıcı olabilir. Ayrıca, modelin eğitimi için yüksek işlem kaynağı gerekmektedir. Eğitim veri setlerinin oluşturulmasının maliyetli olduğu durumlarda transfer öğrenme yaygın olarak kullanılmaktadır. Böylece, daha az maliyetle daha yüksek başarımlar elde edilmektedir.

2.5. Evrişimli Sinir Ağları (Convolutional Neural Network)


İnsan görme sisteminin modellenmesiyle oluşturulan ESA’lar görüntülerin analiz edilmesi için grid benzeri bir yapı kullanan özel bir sinir ağı türüdür. Başka bir deyişle katmanlarda matris çarpımı yerine evrişim işlemi yapılmaktadır. ESA’ların ilk katmanlarında kenar bilgisi gibi daha basit özellikler elde edilmektedir. Daha derin katmanlara geçildikçe görüntüyü temsil eden daha karmaşık özellikler çıkartılmaktadır [12].

Temel bir ESA; girdi, evrişim (convolution), havuzlama(pooling), tam bağlantı (fully connected) ve çıktı katmanı olmak üzere 5 katmandan meydana gelmektedir. Şekil 5’te bir evrişimli sinir ağı mimarisi görülmektedir. Girdi katmanında veri ham olarak ağı sunulmaktadır. Evrişim katmanında, girdi görüntüsünün üzerinde bir filtre dolaştırılarak özellik haritası (feature map) elde edilmektedir. Havuzlama katmanı ağı parametre sayısını ve boyutunu azaltmak için kullanılmaktadır. Tam bağlantı katmanı ise önceki katmanlardan gelen verileri ağırlıklandırarak birleştirir. Sonrasında, bir kayıp fonksiyonu kullanarak sinir hücrelerine eğitim süresince verilecek en uygun ağırlık değerlerini hesaplar [13].

2.5.1. Evrişim katmanı (Convolution layer)

Evrişim katmanı, ESA’nın temel bileşenidir ve en az bir katmandan oluşmaktadır. Bu katman, girdi verilerinden özellikler çıkarmak amacıyla kullanılmaktadır. Evrişim işlemi, iki fonksiyonun matematiksel bir işlemi olarak tanımlanmaktadır. ESA’da evrişim işlemi, girdi verisi üzerinde evrişim filtresi gezdirilerek yapılmaktadır [14]. Evrişim işleminde kullanılacak filtrenin x eksenine ve y eksenine göre simetriği alınmaktadır. Eş. 2’de evrişim işleminin formülü verilmiştir. Burada * işareti evrişim işlemi, I giriş görüntüsünü, K ise filtreyi ifade etmektedir.

$$S(i,j) = (K * I)(i,j) = \sum_m \sum_n I(m,n)K(i-m, j-n) \quad (2)$$



Şekil 4. ADD alt görüntüleri (DWT subimages)

2.5.2. Havuzlama katmanı (Pooling layer)

ESA'nın temel yapı taşlarından biri de havuzlama (Pooling) katmanıdır. Amacı, görüntü boyutunu küçültürken ağıdaki parametre sayısını ve hesap yükünü azaltmaktır [15]. Görüntü boyutunun küçülmesi veride kayıplara yol açmaktadır. Ancak, bu işlem, ağır ezberleme (overfitting) yapmasını önleyebilmektedir. Havuzlama katmanının kullanımı zorunlu değildir. Kullanıldığında ya evrişim katmanları arasına ya da evrişim katmanlarının en sonuna konmaktadır. Havuzlama işlemi, evrişim işlemi gibi, havuzlama penceresinin, adım sayısına ve havuzlama türüne bağlı olarak, girdi matrisi üzerinde geçtiği her konum için bir değer hesapladığı ve bu değeri çıktı matrisine yazdığı bir işlemdir. Havuzlama türlerinden en yaygın kullanılanları maksimum havuzlama (max pooling) ve ortalama havuzlamadır (average pooling). Maksimum havuzlamada, girdi görüntüsü üzerinde havuzlama penceresine denk gelen piksellerden en büyük olanı seçilir. Ortalama havuzlamada ise girdi görüntüsü üzerinde havuzlama penceresine denk gelen piksellerin ortalaması alınır [16].

2.5.3. Tam bağlantı katmanı (Fully connected layer)

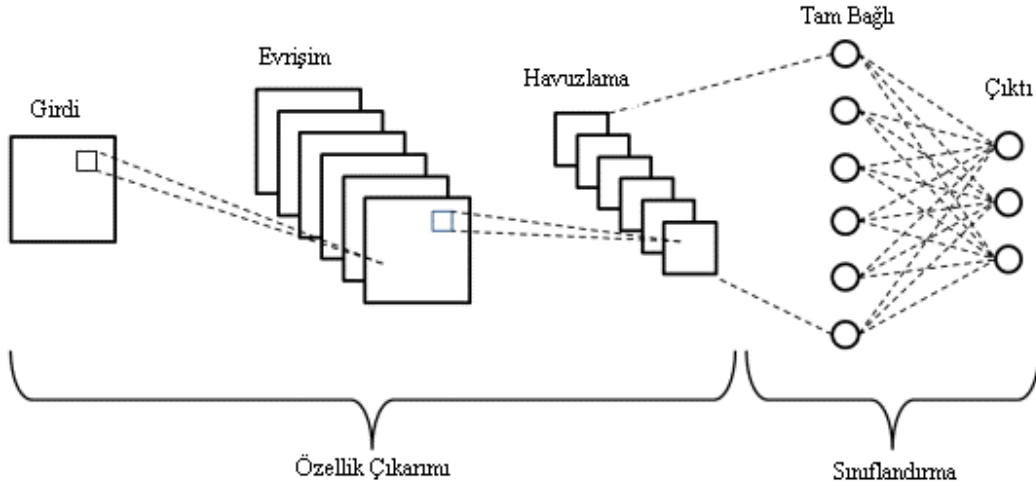
Tam bağlantı katmanı çok katmanlı algılayıcıyla aynı şekilde çalışmaktadır. Şekil 6'da görüldüğü gibi tam bağlantı katmanı kendinde önce gelen katmanların ürettiği değerleri girdi olarak

düzeltilme işlemi yapmakta sonrasında çıktı katmanındaki sınıf sayısı kadar sonuç üretmektedir [17].


2.6. Inception V3 (Inception V3)

Inception v3 modeli, inception mimarisine dayalı GoogLeNet modelinin üçüncü sürümüdür. GoogLeNet'te 22 olan katman sayısı Inception v3'te 42'ye çıkarılmıştır. Katman sayısındaki bu artışa rağmen hesaplama maliyeti yalnızca 2,5 kat daha yüksektir. Bunu sağlamak için daha fazla sayıda ve daha küçük boyutlarda evrişim işlemi yapılmaktadır [19]. Şekil 7'de Inception v3 modeli yer almaktadır.


Inception v3 modelinde GoogLeNet'teki inception modülü Inception-A, Inception-B ve Inception-C olarak üç farklı şekilde yeniden düzenlenmiştir. Orijinal inception modülündeki 5×5 evrişim filtresi yerine inception-A modülünde 2 tane 3×3 evrişim filtresi kullanılmıştır. Böylece, parametre sayısı $5 \times 5 = 25$ 'ten $2 \times (3 \times 3) = 18$ 'e düşürülmüştür. Inception-B modülünde $n \times n$ boyutlu evrişim filtreleri yerine $1 \times n$ ve $n \times 1$ kombinasyonlarında evrişim filtreleri kullanılmıştır. Inception-C modülünde ise 3×3 boyutlu evrişim filtreleri 1×3 ve 3×1 evrişim filtreleri ile değiştirilmiştir. Böylece, parametre sayısı $3 \times 3 = 9$ 'dan $(1 \times 3) + (3 \times 1) = 6$ 'ya düşürülmüştür. Sonuçta, Inception v3 modelinde ağı derinliği artarken parametre sayısı azalmaktadır.



Şekil 5. ESA mimarisi (CNN architecture)



Şekil 6. Tam bağlantı katmanı [18] (fully connected layer)



Şekil 7. Inception v3 modeli (Inception v3 model)

3. Deneysel Sonuçlar ve Tartışma (Experimental Results and Discussion)

Deneysel çalışmalar, Python programlama dilinin kurulu olduğu sekiz çekirdekli Intel i7 11. nesil işlemci, NVIDIA GeForce RTX 3060 grafik işlemci ve 16GB hafızaya sahip bilgisayarda gerçekleştirilmiştir. Dalgacık özniteliklerini çıkartmak için PyWavelet Kütüphanesi kullanılmıştır. Derin öğrenme tabanlı Inception v3 modeli TensorFlow alt yapısını kullanan Keras Kütüphanesi üzerinde uygulanmıştır.

Deneysel çalışmalarda, öğrenme oranı (learning rate) 0,0001, tur sayısı (epoch) 100 ve en küçük yığın boyutu (batch size) 32 olarak ayarlanmıştır. Optimizasyon algoritması olarak derin sinir ağlarında etkin bir yöntem olan RMSProp kullanılmıştır. Model doğruluğunu kestirmek için 5 kat çapraz doğrulama (cross validation) tekniği uygulanmıştır (%80 eğitim seti, %20 test seti). Bu yöntem ile veri seti 5 eşit parçaya bölünerek her parça hem eğitim hem de test için kullanılarak dağılım ve parçalanmadan kaynaklanan hatalar en aza indirilmiştir. Nihai sonuç, beş katlı test veri setinin ortalama sınıflandırma doğruluğundan elde edilmiştir.

Bu uygulamada kullanılan çok katmanlı algılayıcı yapısında 224x224 sinir hücresinden oluşan girdi katmanı, 4 sinir hücresine sahip gizli katman ve 4 sinir hücresinden oluşan çıktı katmanı yer almaktadır. Çıktı katmanından sonra dört sınıftan her birisi için olasılık değeri üreten softmax sınıflandırıcısı bulunmaktadır.

Modelin, eğitim setine aşırı uyum (over fitting) sağlamasını önlemek için erken durdurma (early stopping) tekniği kullanılmıştır. Bu tekniğin amacı model performansı gelişmeyi durdurduğunda eğitimin sonlandırılmasını sağlamaktır. Model performansı, doğrulama veri setinde, 3 tur boyunca gelişme göstermediğinde eğitim durdurulmuştur. Başlangıçta 100 olarak belirlenen tur sayısı, Tablo 1'de verilen tur sayıları tamamlandığında erken durdurma fonksiyonu tarafından eğitim süreci sonlandırılmıştır.

Tablo 1. Doğrulama setleri için erken durdurma tur sayıları
(Early stopping epochs for validation sets)

Doğrulama seti	Tur sayısı
Doğrulama seti-1	15
Doğrulama seti-2	11
Doğrulama seti-3	8
Doğrulama seti-4	4
Doğrulama seti-5	6

Sınıflandırma uygulamalarında doğruluk, modelde doğru tahmin edilen örnek sayısının toplam örnek sayısına oranı ile bulunmaktadır.

Tablo 2, ADD yapılmadan görüntüler doğrudan Inception V3 ağının girdisi olarak kullanıldığında 5 kat çapraz doğrulama sürecinin her testinde modelin doğruluğunu göstermektedir.

Tablo 2. Doğrulama setleri için doğruluk oranları
(Accuracy rates for validation sets)

Doğrulama seti	Doğruluk
Doğrulama seti-1	98,93%
Doğrulama seti-2	98,65%
Doğrulama seti-3	99,50%
Doğrulama seti-4	100%
Doğrulama seti-5	99,50%
<i>Ortalama</i>	99,31%

Inception V3 ağına girdi olarak verilen öznitelikleri elde etmek için görüntülere Daubechies dalgacık ailesinden db2 dalgacığı ile 1 seviyeli ADD ayrıştırması yapılmıştır. Elde edilen alt bileşenlerden yaklaşım bileşeni Inception V3 ağının girdisi olarak kullanılmıştır. Tablo 3, dalgacık öznitelikleri Inception V3 ağının girdisi olarak kullanıldığında 5 kat çapraz doğrulama sürecinin her testinde modelin doğruluğunu göstermektedir. Tablo 3 ve Tablo 4'deki ortalama doğruluk başarımları karşılaştırıldığında Inception V3 ağının girdisi olarak dalgacık öznitelikleri kullanıldığında doğruluk başarımının ortalama %0,34 arttığı görülmektedir. Ayrıca, önerilen modelin hesaplamaya maliyetinin ham verilerin ESA'ya girdi olarak verildiği orijinal yöntemle kıyasla daha düşük olduğu görülmüştür. Ham veriler ağına girdisi olarak kullanıldığında 5 kat çapraz doğrulama sürecinde eğitim süresi yaklaşık 27 saat sürmektedir, dalgacık öznitelikleri ağına girdisi olarak kullanıldığında ise eğitim süresi yaklaşık 21 saat sürmektedir. Sonuçta, dalgacık öznitelikleri ağına girdisi olarak kullanıldığında eğitim süresi %22 azalmaktadır.

Tablo 3. Dalgacık öznitelikleri kullanıldığında doğrulama setleri için doğruluk oranları
(Accuracy rates for validation sets when using wavelet features)

Doğrulama seti	Doğruluk
Doğrulama seti-1	99,00%
Doğrulama seti-2	99,72%
Doğrulama seti-3	99,57%
Doğrulama seti-4	100%
Doğrulama seti-5	100%
<i>Ortalama</i>	99,65%

Tablo 4'te literatürde yer alan ilgili çalışmaların doğruluk oranları yer almaktadır. Bu çalışmada sunulan yöntemle elde edilen sonuçlara göre doğruluk oranının daha yüksek olduğu görülmektedir.

Tablo 4. İlgili çalışmaların doğruluk oranları (Accuracy rates of related works)

Çalışma	Yöntem	Veri Seti	Sınıf	Doğruluk
Özkaraca vd. [5]	VGG16Net/DenseNet -Softmax	Figshare, BR35H ve SARTAJ	4	94-97%
Gomez Guzman vd. [6]	Inception V3-Softmax	Figshare, BR35H ve SARTAJ	4	97,12%
Ali vd. [7]	ShuffleNet-DVM	Figshare, BR35H ve SARTAJ	4	98,40%
Önerilen model	ADD-Inception V3-Softmax	Figshare, BR35H ve SARTAJ	4	99,58%

Tablo 5. Doğrulama seti-1 için karışıklık matrisi (The confusion matrix for validation set-1)

		Tahmin edilen sınıflar			
		Normal	Gliyom	Menenjiyom	Hipofiz bezi
Gerçek sınıflar	Normal	383	0	0	0
	Gliyom	0	317	7	0
	Menenjiyom	0	1	350	1
	Hipofiz bezi	1	0	4	341

Tablo 6. Doğrulama seti-2 için karışıklık matrisi (The confusion matrix for validation set-2)

		Tahmin edilen sınıflar			
		Normal	Gliyom	Menenjiyom	Hipofiz bezi
Gerçek sınıflar	Normal	398	0	0	0
	Gliyom	0	330	0	0
	Menenjiyom	0	2	340	1
	Hipofiz bezi	1	0	0	333

Tablo 7. Doğrulama seti-3 için karışıklık matrisi (The confusion matrix for validation set-3)

		Tahmin edilen sınıflar			
		Normal	Gliyom	Menenjiyom	Hipofiz bezi
Gerçek sınıflar	Normal	411	0	0	1
	Gliyom	0	302	1	0
	Menenjiyom	0	0	318	0
	Hipofiz bezi	2	0	1	368

Tablo 8. Doğrulama seti-4 için karışıklık matrisi (The confusion matrix for validation set-4)

		Tahmin edilen sınıflar			
		Normal	Gliyom	Menenjiyom	Hipofiz bezi
Gerçek sınıflar	Normal	411	0	0	0
	Gliyom	0	341	0	0
	Menenjiyom	0	0	298	0
	Hipofiz bezi	0	0	1	354

Karışıklık matrisi (confusion matrix), sınıflandırma modelinin, tahmin ettiği sınıflar ile gerçek sınıf bilgilerinin yer aldığı tablodur. Karışıklık matrisinden Eş. 3, Eş. 4 ve Eş. 5'de gösterilen aşağıdaki denklemlerle hesaplanan kesinlik, duyarlılık ve F1 puanı gibi farklı performans ölçütleri üretilebilir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (4)$$

$$\text{F1_puanı} = \frac{2 \cdot \text{duyarlılık} \cdot \text{kesinlik}}{\text{duyarlılık} + \text{kesinlik}} \quad (5)$$

Burada TP, FP, TN ve FN sırasıyla doğru pozitif, yanlış pozitif, doğru negatif ve yanlış negatif olarak sınıflandırılan görüntü sayısıdır. Doğrulama seti-1 için karışıklık matrisi Tablo 5'te verilmiştir. Görüldüğü üzere 7 tane gliyom, 2 tane menenjiyom ve 5 tane hipofiz bezi türü MRG görüntüsü yanlış olarak sınıflandırılmıştır. Normal MRG görüntüleri ise doğru olarak sınıflandırılmıştır.

Doğrulama seti-2 için karışıklık matrisi Tablo 6'da verilmiştir. Görüldüğü üzere 3 tane menenjiyom ve 1 tane hipofiz bezi türü MRG görüntüsü yanlış olarak sınıflandırılmıştır. Normal ve gliyom türü MRG görüntüleri ise doğru olarak sınıflandırılmıştır.

Doğrulama seti-3 için karışıklık matrisi Tablo 7'de verilmiştir. Görüldüğü üzere 1 tane normal, 1 tane gliyom ve 3 tane hipofiz bezi türü MRG görüntüsü yanlış olarak sınıflandırılmıştır. Menenjiyom türü MRG görüntüleri ise doğru olarak sınıflandırılmıştır.

Doğrulama seti-4 için karışıklık matrisi Tablo 8'de verilmiştir. Görüldüğü üzere bütün MRG görüntüleri doğru olarak sınıflandırılmıştır.

Doğrulama seti-5 için karışıklık matrisi Tablo 9'da verilmiştir. Görüldüğü üzere bütün MRG görüntüleri doğru olarak sınıflandırılmıştır.

Kesinlik, duyarlılık ve F1 puanı gibi farklı performans ölçüm metrikleri kullanılarak önerilen model değerlendirilmiştir. Önerilen model için kategoriye göre kesinlik, duyarlılık ve F1 puanı Tablo 10'da verilmiştir. Tablo 10'da verilen metrikler doğrulama setlerinin ortalama değerlerini göstermektedir. F1 puanı, kesinlik ve duyarlılığın ağırlıklı ortalaması olduğundan modelin performansını daha iyi gösterir. Buna göre, en yüksek F1 puanı yüzde 99,87 ile normal beyin MRG görüntülerinin sınıflandırmasından elde edilmiştir.

Bu çalışmada kullanılan veri seti ile yapılan deneylere ait kodlar Github linki (<https://github.com/zihnikaya/beyin-tumor-siniflandirma>) üzerinden paylaşılmıştır.

Tablo 9. Doğrulama seti-5 için karışıklık matrisi (The confusion matrix for validation set-5)

		Tahmin edilen sınıflar			
		Normal	Gliyom	Menenjiyom	Hipofiz bezi
Gerçek sınıflar	Normal	396	0	0	0
	Gliyom	0	323	0	0
	Menenjiyom	0	0	334	0
	Hipofiz bezi	0	0	0	351

Tablo 10. Kategoriyeye göre performans metriklerinin ortalama değerleri
(Average values of performance metrics by category)

Kategori	Kesinlik	Duyarlılık	F1 puanı
Normal	99,80%	99,95%	99,87%
Gliyom	99,81%	99,50%	99,65%
Menenjiyom	99,20%	99,71%	99,45%
Hipofiz bezi	99,82%	99,43%	99,63%

4. Sonuçlar (Conclusions)

Bu çalışmada, dalgacık öznelikleri kullanılarak transfer öğrenme tabanlı bir sınıflandırma modeli sunulmuştur. Gliyom, menenjiyom, hipofiz bezi ve normal beyin MRG görüntüsünden oluşan dört sınıflı veri seti kullanılarak beyin tümörleri sınıflandırılmıştır. Ayrık dalgacık dönüşümü kullanılarak çıkarılan öznelikler Inception v3 ağının girdisi olarak kullanılmıştır. Literatürdeki ilgili çalışmalarla kıyaslandığında bu çalışmada kullanılan modelin daha yüksek bir doğruluğa sahip olduğu görülmektedir. Dolayısıyla, önerilen yöntemin, uzmanlara, beyin tümörlerinin sınıflandırılmasında yardımcı olabileceği düşünülmektedir. Gelecek çalışmalarda, beyin tümörlerinin sınıflandırılması için uzmanlara yardımcı olacak açık kaynak kodlu bir yazılım geliştirilmesi düşünülmektedir.

Kaynaklar (References)

1. Ferlay J., Soerjomataram I., Dikshit R., Eser S., Mathers C., Rebelo M., Parkin D.M., Forman D., Bray F., Cancer incidence and mortality worldwide: Sources, methods and major patterns in GLOBOCAN 2012, *International Journal of Cancer*, 136 (5), 359 – 386, 2014.
2. Karayeğen G., Akşahin M.F., Brain tumor prediction with deep learning and tumor volume calculation, 2021 Medical Technologies Congress (TIPEKNO), Antalya-Türkiye, 4-6 Kasım, 2021.
3. Yüksel Z., Manyetik rezonans görüntüleme fizik temelleri ve sistem bileşenleri, *Black Sea Journal of Engineering and Science*, 2 (2), 57-65, 2019.
4. Aslan M., Derin öğrenme tabanlı otomatik beyin tümör tespiti, *Fırat Üniversitesi Müh. Bil. Dergisi*, 34 (1), 399-407, 2021.
5. Özkaraca, O., Bağrıaçık, O.İ., Gürüler, H., Khan, F., Hussain, J., Khan, J., Laila, U., Multiple brain tumor classification with dense CNN architecture using brain MRI images. *Life*, 13 (349), 2023.
6. Gómez-Guzmán, M.A., Jiménez-Beristain, L., García-Guerrero, E.E., López-Bonilla, O.R., Tamayo-Pérez, U.J., Esqueda-Elizondo, J.J., Palomino-Vizcaino, K., Inzunza-González, E., Classifying brain tumors on magnetic resonance imaging by using convolutional neural networks, *Electronics*, 12 (955), 1-22, 2023.
7. R. Ali, S. Al-jumaili, A. D. Duru, O. N. Uçan, A. Boyacı, D. G. Duru, 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), Ankara-Türkiye, 20-22 Ekim, 2022
8. Nickparvar M., Brain tumor MRI dataset, <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>, Erişim tarihi Kasım 11, 2022.
9. Aggarwal N., Agrawal R.K., First and second order statistics features for classification of magnetic resonance brain images, *Journal of Signal and Information Processing*, 3, 146-153, 2012.
10. Arı N., Özen Ş., Çolak Ö.H., Dalgacık Teorisi, Palme Yayıncılık, Ankara, 2008.
11. Mehrotra R., Ansari M.A., Agrawal R., Anand R.S., A Transfer Learning approach for AI-based classification of brain tumors, *Machine Learning with Applications*, 2, 1-12, 2020.
12. Eker A.G., Duru N., Medikal görüntü işlemede derin öğrenme uygulamaları, *Acta Infologica*, 5 (2), 459-474, 2021.
13. Kızrak M.A., Bolat B., Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma, *Bilişim Teknolojileri Dergisi*, 11 (3), 263-285, 2018.
14. Gürkahraman K., Karakiş R., Brain tumors classification with deep learning using data augmentation, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (2), 997-1011, 2021.
15. Arı A., Hanbay D., Tumor detection in MR images of regional convolutional neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3), 1395-1408, 2019.
16. Basha S.H.S., Dubey S.R., Pulabaigari V., Mukherjee S., Impact of fully connected layers on performance of convolutional neural networks for image classification, *Neurocomputing*, 378, 112-119, 2020.
17. Amidi A., Amidi S., Evrişimli sinir ağları el kitabı, <https://stanford.edu/~shervune/1/tr/teachung/cs-230/cheatsheet-convolutional-neural-networks/>, Erişim tarihi Kasım 14, 2022.
18. Lakshmi M.J., Nagaraja Rao S., Brain tumor magnetic resonance image classification: a deep learning approach. *Soft Computing*, 26, 6245–6253, 2022.
19. Advanced Guide to Inception v3, <https://cloud.google.com/tpu/docs/inception-v3-advanced>, Erişim tarihi Kasım 25, 2022.