

## Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti

Muzaffer ASLAN\*

\*1 Elektrik Elektronik Mühendisliği Bölümü, Mühendislik ve Mimarlık Fakültesi, Bingöl Üniversitesi, Bingöl, Türkiye  
\*1 muzaffer.aslan@bingol.edu.tr

(Geliş/Received: 22/12/2021;

Kabul/Accepted: 12/02/2022)

**Öz:** Beyin tümörleri, insan ölümlerinin en yaygın nedenlerinden biridir. Beyin tümörlerinin erken ve doğru teşhisi etkili bir tedavi için oldukça önemlidir. Manyetik rezonans görüntüleme (MRG), beyin tümörlerinin tespitinde en etkili verileri sağlayan temel araçlardan biridir. Geleneksel yöntemler ile yapılan hastalık tespiti yerine yapay zekâ temelli bilgisayar uygulamaları ile beyin tümörlerinin tespiti uzmanlara önemli katkılar sağlayabilir. Özellikle son dönemler popüler olan derin öğrenme yöntemlerinin, medikal görüntülerin işlenmesine dayalı hastalık tespiti sıklıkla kullanılmaktadır. Bu çalışmada, MRG görüntüleri ile beyin tümörlerinin tespiti için MobilNetV2 derin öğrenme modeli ile birlikte k en yakın komşu (k-EYK) algoritması kullanılmıştır. Çalışmada, öz nitelik olarak önceden eğitilmiş MobileNetV2 modelinin tam bağlantı katman değerleri kullanılmıştır. Elde edilen öz niteliklerin sınıflandırılması performansının artırılması için k-EYK sınıflandırma algoritması kullanılmıştır. Yapılan deneysel çalışmalarda, önerilen yöntem ile beyin tümörlerinin tespitinde k-EYK sınıflandırıcıda %96,44 doğruluk skoruna ulaşılmıştır. Aynı veri setinin kullanıldığı literatürdeki diğer bazı çalışmalar ile karşılaştırıldığında daha yüksek bir başarımla sağlanmıştır.

**Anahtar kelimeler:** Beyin Tümörü, Derin Öğrenme, MobileNetV2 Model, Sınıflandırma.

### Deep Learning-Based Automatic Detection

**Abstract:** Brain tumors are one of the most important causes of human death. Accurate and early diagnosis of brain tumors is crucial for treatment. Magnetic resonance imaging (MRI) is one of the basic tools that provide the most effective data in the detection of brain tumors. Detection of brain tumors with artificial intelligence-based computer applications instead of disease detection with traditional methods can provide significant contributions to experts. In particular, deep learning methods, which have been popular recently, and disease detection based on the processing of medical images are frequently used. This study used MobilNetV2 deep learning model and k Nearest Neighbor (k-NN) algorithm to detect brain tumors with MRI images. In the study, fully connect layer values of the pre-trained MobileNetV2 model were used as the feature. The k-EYK classification algorithm was used to increase the classification performance of the obtained features. In experimental studies, an accuracy score of 96.44% was achieved in detecting brain tumors with the proposed method. Higher performance was achieved when compared with some other studies in the literature using the same dataset.

**Keywords:** Brain Tumor, Deep Learning, MobileNetV2 Model, Classification

### 1. Giriş

Beyin tümörü hayatı tehdit eden ölümcül bir hastalıktır. Bu hastalık merkezi sinir sistemini ciddi şekilde bozabilecek beklenmedik şekilde yükselen beyin hücreleri kümesi olarak tanımlanır [1]. Beyin tümörleri, birincil ve ikincil olmak üzere ikiye ayrılırlar [2]. Birincil beyin tümörleri iyi huyludur ve beyinin diğer bölgelerine yayılmazlar. İkincil beyin tümörleri kötü huyludur, kanser hücreleri akciğer veya meme gibi diğer organlardan beyne yayıldığında ortaya çıkar [3]. Beyin tümörünün nedenleri tam olarak bilinmemektedir. Bununla birlikte bu hastalıkta genellikle baş ağrısı, kusma, göz anormallikleri veya çift görme zayıflığı, uyusukluk, yutma güçlüğü, kişilik veya davranış değişiklikleri, el titremesi gibi belirtiler ortaya çıkmaktadır. Beyin tümörünün tespitinde genellikle manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT) ve kafa biyopsisi yöntemleri kullanılmaktadır [4]. Fakat, MRG yöntemi beynin yumuşak dokusu hakkında yüksek çözünürlüklü bilginin yanı sıra aynı dokuya ait birden fazla şekilsel bilgi de sağlamaktadır [5]. Bu nedenle, beyin cerrahları beyindeki en küçük anormallikleri tespit için onlara yeterli bilgi sağladığında yaygın olarak kullanılmaktadırlar.

Dünya Sağlık Örgütü'nün son verilerine göre, beyin tümörü dünya çapında en yaygın kanser ölüm türlerinden biri olup her yaşta ortaya çıkabilmektedir [6]. Özellikle 40 yaşın altındaki insanlarda daha fazla ölümlere neden olmaktadır. Beyin tümörünün erken teşhisi, hastaların tedavi edilmesi için oldukça önemlidir. Ayrıca erken teşhis edilmiş hastaların hayatta kalmaları önemli oranda artırılabilir. Bu nedenle beyin tümörlerinin tespit ve tedavi planlamasının hayati önem taşıdığından görüntülerin değerlendirilmesi hızlı ve doğru yapılması oldukça önemlidir.

\* Sorumlu yazar: [muzaffer.aslan@bingol.edu.tr](mailto:muzaffer.aslan@bingol.edu.tr). Yazar ORCID Numarası: <sup>1</sup> 0000-0002-2418-947

[7]. Fakat radyolog ve doktorlar tarafından yapılacak manuel kontroller hem zaman alıcı olabilir hem de hatalı kararlar verilmesine neden olabilir. Bu nedenle birçok araştırmacı, radyolog ve doktorların beyin tümörü teşhisine yardımcı olabilecek bilgisayar destekli otomatik tespit sistemlerinin geliştirilmesine katkı sağlamaya çalışmıştır.

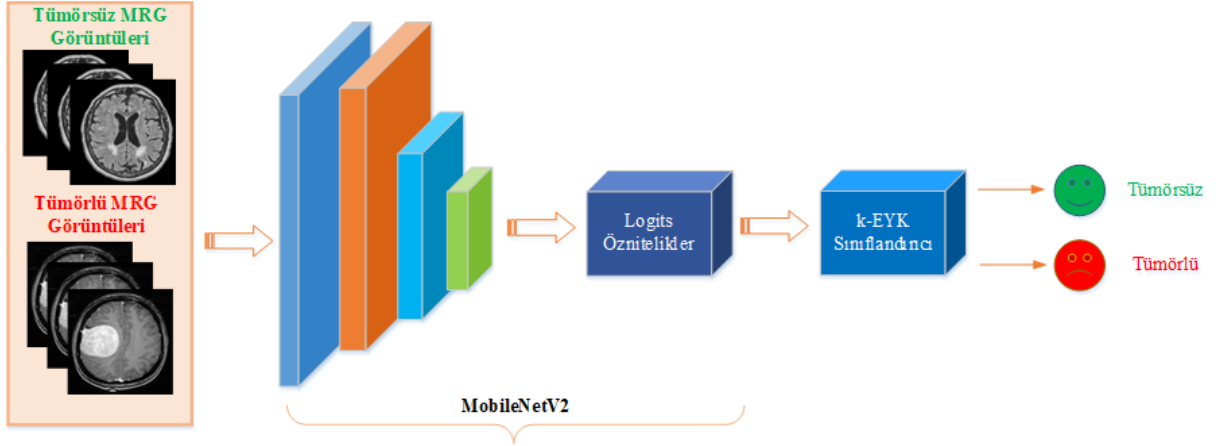
Literatürde beyin tümörü teşhisine yönelik makine öğrenmesi ve derin öğrenme modelleri yaygın olarak kullanılmıştır. Arı ve diğerleri [8] MRG görüntülerinin ön işlem aşamasında bölütleyerek bu bölgelerden elde edilen öz nitelikleri sınıflandırmışlardır. Deneysel çalışmalarda %83,39'luk sınıflandırma başarımı elde etmişlerdir. Bulut ve diğerleri [9] beyin tümör tespiti için MRG görüntülerinin segmentasyonunu dayalı bir model önerdiler. Deneysel çalışmalarda Markov rastgele alan yöntemi ile %87 doğrulukta beyin tümörlerini tespit etmişlerdir. Mohsen ve diğerleri [10] derin öğrenme yöntemleri ve Ayrık Dalgacık Dönüşümü (ADD) modelini kullanarak beyin tümörlerini sınıflandırmak amacıyla yeni bir yöntem önerdiler. Deneysel çalışmalarda bu model ile %93,94 doğruluk elde etmişlerdir. Afşar ve diğerleri [11] beyin tümörlerini sınıflandırmak için CapsNet olarak adlandırdıkları bir yöntem önerdiler. Önerilen yöntem ile daha veri ile daha yüksek bir doğruluk skorunu hedeflemişlerdir. Bu amaçla tek evrişim katmanından elde edilen 64 öz niteliği kullandılar. Yöntem ile beyin tümörünü sınıflandırılmasında %86,56 doğruluk oranı elde ettiler. Vani ve diğerleri [12] beyin tümörü sınıflandırmak için makine öğrenmesi tabanlı, Destek Vektör Makinası (DVM) yöntemini önerdiler. Çalışmalarında beyin tümörünü pozitif ve negatif olarak sırasıyla %82 ve %81,48 doğrulukta tahmin ettiklerini belirtmişlerdir. Çıtak ve diğerleri [13], beyin tümörü tespiti için DVM, çok katmanlı algılayıcılar (ÇKA) ve lojistik regresyon (LR) olmak üzere 3 farklı makine öğrenme yöntemi kullanımını önerdiler. Deneysel çalışmalarda beyin tümörü tespitinde %93 doğruluk oranına ulaştılar. Shahzadi ve diğerleri [14] beyin tümörlerinin tespit etmek amacıyla ESA tabanlı hibrit model yapısını kullandılar. Özellik çıkarımı ve sınıflandırma AlexNet ve VggNet ESA modelleri ile birlikte Uzun Kısa Süreli Bellek (UKSB) yapısını birlikte kullandılar. Yapılan çalışmada AlexNet-UKSB ile %71 doğruluk, VGGNet-UKSB ile %84 doğruluk performansları elde ettiler. Swati ve diğerleri [15] çok sınıflı beyin tümörleri sınıflandırması için transfer öğrenimini önerdiler. Bu amaçla AlexNet, VGG16 ve VGG19 ESA modellerini kullandılar. Deneysel çalışmalarda, AlexNet, VGG16 ve VGG19 modellerinde sırasıyla %89,95, %94,65, %94,82 doğruluk oranlarına ulaştılar. Taş ve Ergin [16], MR görüntülerinde beyin tümörünün tespit için derin öğrenme ve K-ortalama bölütlemeyi kapsayan bir yöntem önermişlerdir. Çalışma sonucunda beyin tümörünün tespitini %84,45 doğruluk oranı ve %95,04 hassasiyet ile gerçekleştirmişlerdir. Saxena ve diğerleri [17], transfer öğrenmeye dayalı Resnet-50 kullanarak beyin tümörü tespiti için tahmine dayalı bir model geliştirdi. Deneysel sonuçları %95 doğruluk oranına ulaştılar.

Bu çalışmada beyin tümörlerini tespiti için önceden eğitilmiş ESA modellerinden MobileNetV2 ve k-en yakın komşu (k-EYK) temelli bir model önerilmiştir. Bu modelde öz nitelik çıkarımı için MobileNetV2 kullanılmıştır. MobileNetV2 modeli mobil cihazlara veya düşük hesaplama gücüne sahip herhangi bir cihazda kullanılabilirliği için tercih edilmiştir. Derin öz nitelikler sınıflandırılma performansının artırılması için k-EYK sınıflandırıcıya uygulanmıştır. Çalışmanın literatüre katkıları şunlardır;

- Daha düşük kapasiteli donanımlarda kullanılabilir bir ESA modeli önerildi.
- MobileNetV2 genelleme performansının artırılması için veri çoğaltma yapıldı.
- k-EYK sınıflandırıcı ile sınıflandırma performansları artırıldı.

## 2. Materyal ve Metodoloji


Bu çalışmada, iki sınıflı (beyin tümörü olanlar ve olmayanlar) MGR görüntüleri beyin tümörünü sınıflandırmak için derin öğrenme tabanlı bir model önerilmektedir. Önerilen yöntem; veri çoğaltma (arttırma), derin öz nitelik çıkarımı ve bu öz niteliklerin sınıflandırılması olmak üzere üç aşamadan oluşmaktadır. İlk olarak, ön işlem aşamasında 253 olan MRG görüntüleri veri çoğaltma ile 1265 görüntüye çıkarıldı ve bu görüntüler MobileNetV2 girişine uygun olarak 224x224x3 şeklinde boyutlandırıldı. Ardından öz nitelik çıkarımı için tüm MRG görüntüleri önceden eğitilmiş MobileNetV2 modeline uygulandı ve modelin "Logits" tam bağlı katmanından 1000 derin öz nitelik alındı. Son aşamada, beyin tümör tespiti için bu derin öz nitelikler k-EYK sınıflandırıcıya uygulanmıştır. Öz nitelik çıkarımı ve sınıflandırıcı parametrelerinin belirlenmesi için kapsamlı deneysel çalışmalar yapılmıştır. Önerilen yöntemin blok diyagramı Şekil 1'de sunulmuştur.



Şekil 1. Önerilen modelin blok diyagramı


## 2.1. Veri seti ve veri çoğaltma

Deneysel çalışmalarda kullanılan veri seti kaggle sitesinden alınmıştır [18]. Veri seti 155'i tümörlü ve 98'i tümörsüz olmak üzere iki sınıflı toplam 253 MRG görüntüsünden oluşmaktadır. Veri seti uzmanlar tarafından gönüllü hastalardan elde edilmiştir. Görüntülerin her biri JPEG biçimini ve çeşitli çözünürlüklere sahiptirler. Şekil 2'de, tümörlü ve tümörsüz sınıflara ait bazı orijinal MRG görüntüleri yer almaktadır.



Şekil 2. Veri setinde sınıflara ait görüntüler

Derin evrişimli sinir ağlarının eğitimi için kullanılan veri kümelerinin büyüklüğü, ESA performanslarının belirlenmesinde önemli bir faktördür. Veri seti görüntü sayısının yeterli olmadığı durumlarda veri çoğaltma yapılır. Bu süreçte, veri setindeki beyin MRG tarama görüntülerinin sayısını artırmak için yatay, dikey, yatay-dikey eksenlerde çevirme ve 90°, 270° açılar ile döndürülmeyi içeren 5 farklı veri çoğaltma yöntemi kullanıldı. Böylece orijinal veri setindeki 253 MRG görüntüsü artırılarak, 775'i tümörlü ve 490'ı tümörsüz olmak üzere toplam 1265 MRG görüntüsü elde edildi. Böylelikle, önerilen ESA modelinin genelleme performansının artırılması ve ezberlemeyi önlemesi engellenerek çalışmanın güvenilirliği sağlanmıştır. Şekil 3'de beyin MRG görüntülere uygulanan veri çoğaltma yöntemlerine ait örnek görüntüler yer almaktadır.



Şekil 3. Veri çoğaltma yöntemlerine ait örnek görüntüler

## 2.2. Evrişimli sinir ağı

Evrişimli sinir ağları birkaç katmanın güçlü bir şekilde eğitildiği en önemli derin öğrenme yöntemlerinden biridir. Özellikle 2012 yılında Imagenet yarışmasını kazanan AlexNet modeli ile birlikte popülerliği artmış ve birçok alanda yaygın bir şekilde kullanılmaya başlanmıştır [11]. ESA modelleri oldukça verimlidir ve bundan dolayı çeşitli yapay görme ve tıbbi görüntü işleme uygulamalarında en yaygın kullanılan yöntemlerden biri olarak kabul edilmektedir [19]. Genel olarak bir ESA; evrişim katmanı, havuzlama katmanı ve derin özniteliklerin alındığı, ayrıca sınıflandırma gibi farklı görevleri yapabilen tam bağlantılı katman olmak üzere üç ana katmandan oluşmaktadır [20].

Evrişim Katmanı, tüm girdi görüntüsü boyunca soldan sağa doğru kayan ve bu görüntüye ait özelliklerini çıkarmak için (3×3, 5×5, 7×7 gibi) farklı boyutlardaki filtrelerin kullanıldığı katmandır [21]. Bu hareket filtrenin maksimum genişliğine ulaşana kadar devam eder ve böylece girdi görüntüsüne ait özellikler çıkarılır [22].

Havuzlama Katmanı, evrişim katmanından elde edilen özellik haritalarının boyutlarını küçültmek için kullanılır. Ayrıca genellikle her evrişim katmanından sonra bir havuz katmanı kullanılarak hesaplama karmaşıklığını azaltması ve fazla uyum probleminin çözümüne yardımcı olması için tercih edilir [23].

Tam Bağlantılı Katman, önceki evrişim ve havuzlama katmanlarından elde edilen öznitelikleri sınıflandırmak için düzleştirilir. Düzleştirme, bir matrisi vektöre dönüştürme işlemidir. Ayrıca ağı eğitimi aşamasında en iyi performansı elde etmek için uyarlanabilir moment tahmini (ADAM) ve momentumlu stokastik gradyan iniş (SGDM) gibi optimizasyon algoritmaları kullanılmaktadır [24].

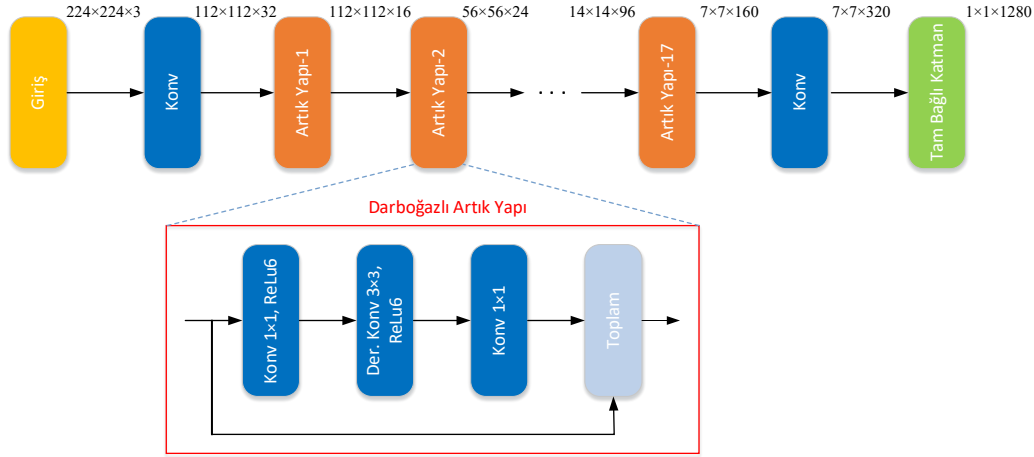
### 2.2.1. Transfer öğrenimi

Transfer öğrenimi, yeni farklı verileri öğrenmek için önceden eğitilmiş modeli kullanarak diğer sorunları çözmek için önceden öğrenilmiş özelliklerin kullanılmasıdır. Bu çalışmada, 1000 sınıfı tahmin etmek için 1,28 milyon görüntü (ImageNet) kullanılarak eğitilmiş MobileNetV2 ESA modeli kullanılmıştır.

### 2.2.2. MobilNetV2

2017 yılında Google tarafından önerilen MobileNetV1 modelinin en önemli özelliği mobil cihazlara veya düşük hesaplama gücüne sahip herhangi bir cihazda kullanılmak amacıyla geliştirilmiştir [25]. Bu model hafif bir yapıya sahip olup, ağır karmaşıklık maliyetini ve model boyutunu önemli ölçüde azaltan derinlemesine ayarlanabilen evrişimi temel almaktadır.

MobileNetV2, derinlemesine ayarlanabilen evrişimi koruyan MobileNetV1'in geliştirilmiş bir versiyonudur. Buna ek ters çevrilmiş artıklar ve doğrusal darboğazları kullanmaktadır [26]. Ters çevrilmiş artıklar, daha fazla özellik elde etmek için önce kanalı  $1 \times 1$  evrişim yoluyla genişletir. Ardından özellik çıkarımı için  $3 \times 3$  derinlemesine evrişimi kullanır ve son olarak kanal numarasını geri sıkıştırmak için  $1 \times 1$  noktadan noktaya evrişim kullanır. Lineer darboğazlar katmanı, öğrenmeyi hızlandırmak ve model kararlılığını arttırmak için ReLu6 aktivasyon fonksiyonunu kullanmaktadır [27]. Şekil 4'te MobileNetV2 modelinin yapısı görülmektedir.



Şekil 4. MobileNetV2 modelinin yapısı

### 2.3. k-EYK sınıflandırıcı

K-en yakın komşu, denetimli öğrenme temelli bir örüntü sınıflandırma algoritmasıdır. Basit ve yüksek performansı nedeniyle yaygın olarak kullanılan bir sınıflandırıcıdır. K-EYK, komşularının çoğunluk oyu ile görüntüleri sınıflandırır. Uzaklık matrisini oluşturmak için test görüntüsü öznelikleri ile her eğitim bir görüntüsü öznelikleri arasındaki uzaklık mesafesi kullanılır. Uzaklık matrisinin toplam değeri tahmin edilir ve daha sonra artan şekilde sıralanır. İlk olarak k eleman seçilir. Son olarak görüntüyü sınıflandırmak için çoğunluk sınıfının değeri belirlenir. Uzaklık hesaplamasında çoğunlukla Öklid  $\sqrt{\sum_{i=1}^k (x_i - y_i)^2}$  yöntemi kullanılmakla birlikte Minkowski  $(\sum_{i=1}^k (|x_i - y_i|^q))^{1/q}$  ve Manhattan  $\sum_{i=1}^k |x_i - y_i|$  yöntemleri de kullanılabilir.

### 2.4. Performans değerlendirme kriterleri

Genellikle sınıflandırma modellerinde, önerilen sınıflandırıcı başarısının ölçülmesi sınıflandırıcının etiketlediği sınıf değerleri ile gerçek sınıf değeri arasındaki ilişkilere göre belirlenir. Gerçek sınıf değeri pozitif olan bir veriyi pozitif olarak etiketlemeye DP (doğru pozitif), negatif olarak etiketlemeye yanlış negatif (YN), gerçek sınıf değeri negatif olan bir veriyi negatif olarak etiketlemeye doğru negatif (DN), pozitif olarak etiketlemeye de YP (yanlış pozitif) denmektedir. Buna göre karmaşıklık matrisindeki DP, DN, YP, YN değerleri kullanılarak performans değerlendirme kriterleri hesaplanmaktadır. Bilimsel çalışmalarda performans değerlendirme kriterleri olarak Doğruluk (Doğ), Duyarlılık (Duy), Özgüllük (Özg), Keskinlik (Kes) ve F1 skoru gibi ölçütler yaygın olarak kullanılmaktadır. Bununla birlikte ikili sınıflandırma modellerinde veri setinde bir dengesiz bir dağılım olması durumunda Matthews Korelasyon Katsayısı da (MCC) diğer değerlendirme kriterlerinin yanı sıra kullanılmaktadır [28]. Performans değerlendirme kriterlerine ait bağıntılar Denklem 1- 6'da verilmiştir [28,29].

$$\text{Doğ} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \times 100 \quad (1)$$

$$\text{Duy} = \frac{TP}{TP + FN} \times 100 \quad (2)$$

$$\text{Özg} = \frac{TN}{TN + FP} \times 100 \quad (3)$$

$$\text{Kes} = \frac{TP}{TP + FP} \times 100 \quad (4)$$

$$F1 \text{ Skor} = 2 \times \frac{\text{Duy} \times \text{Kes}}{\text{Duy} + \text{Kes}} \times 100 \quad (5)$$

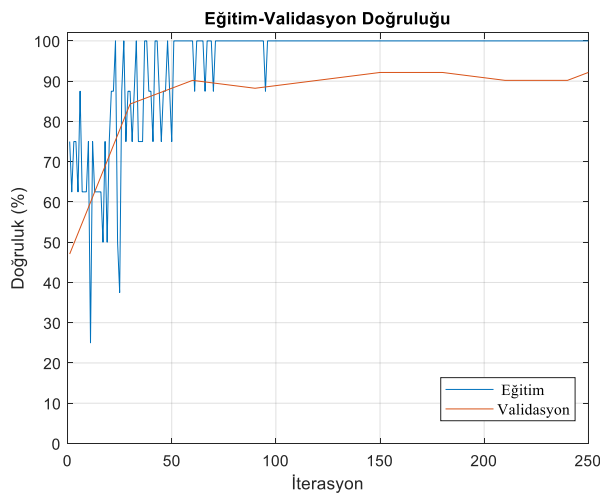
$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (6)$$

Tüm bu parametreler veri setinden çıkarılan öznelikler üzerindeki davranışını tahminine imkân sağlamaktadır.

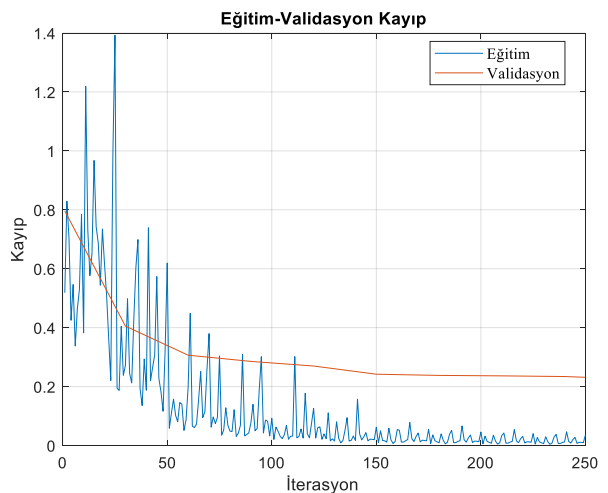
### 3. Deneysel Çalışmalar ve Sonuçlar

Deneysel çalışmalar, MATLAB (2020b) programının kurulu olduğu, dört çekirdekli, NVIDIA GTX 850M GPU ve 16GB hafızaya sahip bilgisayarda gerçekleştirildi. MobilNetV2 için MATLAB derin öğrenme araç kutusu kullanıldı. Deneysel çalışmalarda veri setinin %80'i (1012 MRG görüntü) eğitim ve %20'si (253 MRG görüntü) test için rastgele iki kısma ayrılmıştır. Eğitim veri seti önerilen MobilNetV2 modelin öğrenme sürecinde kullanıldı. Ayrıca test veri seti hem model parametrelerinin ayarlanmasında hem de performans değerlendirmesinde kullanıldı. MobilNetV2 parametreleri eğitim aşamasında optimize edilebilmesi birçok deney yapıldı. Bu deneysel çalışmalarda sonuçlarında MobilNetV2 için öğrenilebilir parametre optimizasyonu, stokastik gradyan iniş momentum (SGDM) algoritması, öğrenme oranı 0.0001 sabit, en yüksek tekrar sayısı 5 ve en küçük yığın boyutu 4 olarak seçilmiştir. K-EYK sınıflandırıcı için k değeri 5 olarak seçilmiştir. Ayrıca deneysel çalışmalarda 5 kat çapraz doğrulama yapılmıştır.

Transfer öğrenme aşamasında MobileNetV2 ESA modeline ait eğitim-validasyon doğruluk ve eğitim-validasyon kayıp grafikleri sırasıyla Şekil 5 ve 6'da görülmektedir. Şekil 5'de görüldüğü gibi eğitim süreci 250 yenilemede tamamlanmaktadır. Ağın eğitim aşamasında Şekil 6'da görülebileceği üzere kayıp oran 0,3'in altında kalarak önemli sayılabilecek bir veri kaybına uğramadan eğitim süreci tamamlanmıştır.



Şekil 5. MobileNetV2 eğitim-validasyon doğruluk grafiği



Şekil 6 MobileNetV2 eğitim-validasyon kayıp grafiği

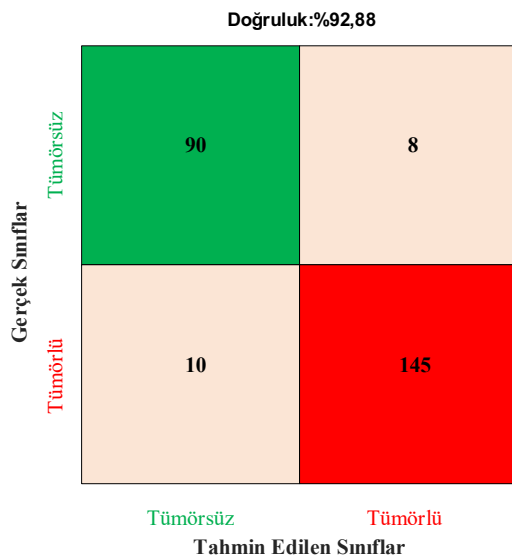
Önerilen MobileNetV2 ile yapılan deneysel çalışmalarda hem orijinal veri seti ve hem çoğaltılmış veri setine ait MobileNetV2 ve k-EYK performans karşılaştırma sonuçları Tablo 1’de verilmiştir.

**Tablo 1.** Orijinal ve çoğaltılmış veri setlerinde MobileNetV2 ve k-EYK performans karşılaştırma sonuçları

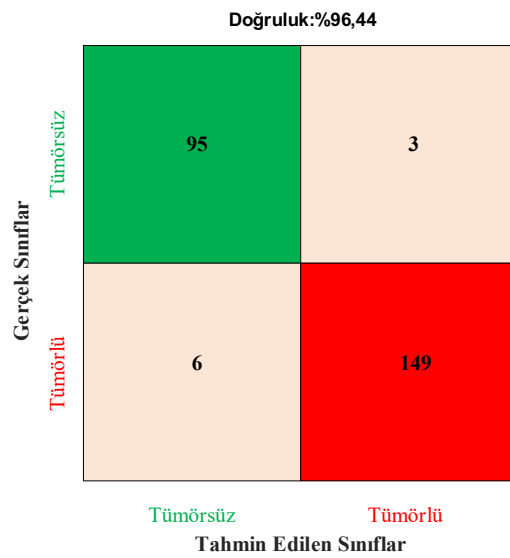
Veri Seti	Yöntem	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Skor	MCC
Orijinal	MobileNetV2	86,56	86,73	86,45	80,19	83,33	0,722
	k-EYK	89,72	88,78	90,32	85,29	87,00	0,785
Çoğaltılmış	MobileNetV2	92,89	91,84	93,55	90,00	90,90	0,850
	k-EYK	96,44	96,94	96,13	94,06	95,48	0,925

Tablo 1’deki sonuçlar dikkate alındığında orijinal (ham) veri setinde MobileNetV2 ve k-EYK sınıflandırma doğruluk oranlarında sırasıyla %86,56 ve %89,72 başarımlar sağlandı. MobileNetV2 ESA modeli ile derin öznelik çıkarım performansını arttırmak için bölüm 2.1 tanımlanan veri çoğaltma yöntemleri kullanılarak ham veri seti 5 kat artırılarak 253 olan MRG görüntülerinin sayısı 1265’e artırıldı. Bu veri seti kullanılarak MobileNetV2 Logits tam bağlı katmanından alınan derin öznelikler sınıflandırıldığında k-EYK sınıflandırıcıda doğruluk, duyarlılık, özgüllük, keskinlik, F1 skor ve MCC değerlendirme ölçütlerinde sırasıyla %96,44, %96,94, %96,13, %94,06, %95,48 ve 0,925 oranlarında başarımlar elde edildi. Böylece veri artırma işlemi ile k-EYK sınıflandırmada %6,72 doğruluk oranında ve %7,5 MCC değerinde artış elde edildi. Benzer şekilde diğer performans değerlendirme kriterlerinde de önemli derecede artışlar sağlanmıştır.

Önerilen yöntemin genel başarımlarını değerlendirmesi ile birlikte veri setindeki her bir sınıf etiketindeki başarımları görebilmek için karmaşıklık matrisleri kullanılmaktadır. Şekil 7 ve 8 sırasıyla çoğaltılmış veri setinde MobileNetV2 ve k-EYK karmaşıklık matrisleri verilmiştir. Her iki şekilde görüldüğü gibi deneysel çalışmalarda test için ayrılan %20’lik veri setinde 98 tümörsüz ve 155 tümörlü görüntü yer almaktadır. Şekil 7’deki MobileNetV2 karmaşıklık matrisinde 98 adet tümörsüz (sağlıklı) verinin 90’ı doğru olarak (TP) sınıflandırılırken, 8 veri hatalı bir şekilde (FN) tümörlü (hasta) olarak sınıflandırılmıştır. Şekil 7’de yine benzer şekilde 155 adet tümörlü verinin 145’i doğru olarak (TN) tümörlü (hasta) olarak sınıflandırılmış ve 10 veri hatalı bir şekilde (FP) tümörsüz (sağlıklı) şekilde sınıflandırılmıştır. Sınıflandırma performansını arttırmak için kullanılan k-EYK sınıflandırıcısına ait Şekil 8’deki karmaşıklık matrisi ile karşılaştırıldığında 98 adet tümörsüz verinin 95 adet veri doğru olarak (TP) tümörsüz (sağlıklı) ve 155 adet tümörlü verinin 149’u doğru olarak (TN) tümörlü (hasta) olarak tahmin edilmiştir. Her iki karmaşıklık matrisi karşılaştırıldığında k-EYK sınıflandırıcı, 5 tümörsüz (sağlıklı) ve 4 tümörlü (hasta) veriyi daha doğru olarak tahmin etmiştir.



Şekil 7. MobileNetV2 karmaşıklık matrisi



Şekil 8. k-EYK karmaşıklık matrisi

Önerilen yöntemin daha detaylı performans değerlendirmesi için, aynı ve benzer veri setlerinin kullanıldığı bazı yöntemlerin performans karşılaştırmaları Tablo 2’de verilmiştir. Tablo 2’de görüldüğü gibi, önerilen yöntemin mevcut diğer yöntemlerden daha iyi doğruluk performansına sahip olduğu görülebilmektedir

**Tablo 2.** Bazı yöntemlerin performans karşılaştırmaları

Yöntem	Model	Doğruluk (%)
Arı ve diğerleri [8]	Bölütleme+k-NN	86,39
Bulut ve diğerleri [9]	MRF	87,00
Mohsen ve diğerleri [10]	ADD+PCA	93,94
Afşar ve diğerleri [11]	CapsNet	86,56
Vani ve diğerleri [12]	DVM	81,48
Çıtak ve diğerleri [13]	DVM+ÇKA+LR	93,00
Shahzadi ve diğerleri [14]	VGG+UKSB	84,00
Swati ve diğerleri [15]	VGG19	94,82
Saxena ve diğerleri [17]	ResNet50	95,00
Önerilen Yöntem	MobileNetV2+k-EYK	96,44

Ayrıca, Tablo 2’deki ESA modellerinin kullanıldığı 14, 15 ve 17 çalışmalar ile karşılaştırıldığında daha hafif ağırlıklı olan MobileNetV2 modeli ile daha yüksek bir sınıflandırma doğruluğu elde edilmesi önerilen yöntemin başarısını göstermektedir.

#### 4. Sonuçlar

Bu çalışmada, MRG görüntülerini kullanarak otomatik beyin tümörü tespiti için etkili bir yöntem önerdik. Yöntem, MobileNetV2 ESA modelinden transfer öğrenmeye dayalı olarak derin öznitelik çıkarımı ve bu özniteliklerin k-EYK sınıflandırılmasını içeren bir yaklaşım sunulmuştur. Öznitelik çıkarımında performans arttırmak amacıyla beş farklı yöntem kullanılarak veri setindeki görüntü sayısı artırıldı. Deneysel sonuçlar, ayrı bir sınıflandırıcı kullanılmadan %92,88 sınıflandırma doğruluk skoruna ulaşılmıştır. K-EYK sınıflandırıcı ile sınıflandırma doğruluğu %3,56 oranında artırılarak %96,44 sınıflandırma doğruluğu sağlanmıştır. Ayrıca çalışmada, daha önceden eğitilmiş bir derin öğrenme modeli kullandığından öğrenilebilir parametrelerin optimizasyon süresi kısalmıştır. Böylelikle eğitim ve öznitelik çıkarım süreci yaklaşık 3 dakika gibi kısa sürede tamamlanmıştır. Ayrıca benzer yöntemler ile karşılaştırıldığında daha yüksek bir sınıflandırma oranı sağlanmıştır. Dolayısıyla önerilen bu yöntemin beyin tümörlerinin tespitinde uzmanlara karar vermede yardımcı olabileceği düşünülmektedir. Gelecekteki çalışmalarımızda, farklı beyin tümörlerini tespit etmek için büyük beyin tümörü veri kümeleri üzerinde yeni bir model oluşturmayı planlıyoruz.

#### Kaynaklar

- [1] Arbane M, Benlamri R, Brik Y, Djerioui M. Transfer learning for automatic brain tumor classification using MRI images. In: 2nd International Workshop on Human-Centric Smart Environments for Health and Well-Being; 9-10 February 2021; Boumerdes, Algeria: IEEE. pp. 210–214.
- [2] Tamilselvi R, Nagaraj A, Beham M. P, Sandhiya M. B. BRAMSIT: A Database for Brain Tumor Diagnosis and Detection. In: 2020 Sixth International Conference on Bio Signals Images and Instrumentation (ICBSII); 27-28 February 2020; Chennai, India: IEEE. pp. 1–5.



- [3] Hazra A, Dey A, Gupta S. K, Ansari M. A. Brain tumor detection based on segmentation using MATLAB. In: International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS); 1-2 August 2017; Chennai, India: IEEE. pp. 425-430.
- [4] Kapoor L, Thakur S. In: 7th International Conference on Cloud Computing, Data Science & Engineering - Confluence; 12-13 January 2017; Nodia, India: IEEE. pp. 582-585.
- [5] Maynard J, Okuchi S, Wastling S, Busaidi A A, Almossawi O, Mbatha W, Thust S. Prediction by mri morphologic features and apparent diffusion coefficient. *Radiology*. 2020; 296: 111–121.
- [6] Abd El Kader I, Xu G, Shuai Z, Saminu S, Javaid I, Salim Ahmad I. Differential Deep Convolutional Neural Network Model for Brain Tumor Classification. *Brain Sciences*. 2021; 11, 352.
- [7] Arı A, Alcin O. F, Hanbay D. (Brain MR Image Classification Based on Deep Features by Using Extreme Learning Machines. *Biomedical Journal of Scientific & Technical Research*. 2020;25;19137-19144.
- [8] Ari A, Alpaslan N, Hanbay D. Computer-aided tumor detection system using brain MR images. In: 2015 Medical Technologies National Conference (TIPTEKNO); 15-18 October 2015; Bodrum, Turkey : IEEE. pp. 1–4.
- [9] Bulut F, Kiliç I, Ince I. F. Beyin Tümörü Tespitinde Görüntü Bölütleme Yöntemlerine Ait Başarımların Karşılaştırılması ve Analizi. *Deu Muhendislik Fakültesi Fen ve Muhendislik*. 2018; 20:173–186.
- [10] Mohsen H, El-Dahshan E. S. A, El-Horbaty E. S. M, Salem A. B. M. Classification using deep learning neural networks for brain tumors, *Future Computing and Informatics Journal*. 2018; 3(1):68–71.
- [11] Afshar P, Mohammadi A, Plataniotis K. N. Brain Tumor Type Classification Via Capsule Networks. In: 25th IEEE International Conference on Image Processing (ICIP); 7-10 October 2018; Athens, Greece: IEEE. pp. 3129–3133.
- [12] Vani N, Sowmya A, Jayamma N. Brain Tumor Classification using Support Vector Machine. *International Research Journal of Engineering and Technology (IRJET)*. 2017;4(7):792–796.
- [13] Citak-Er F, Firat Z, Kovanlikaya I, Ture U, Ozturk-Isik E. Machine-learning in grading of gliomas based on multi-parametric magnetic resonance imaging at 3T. *Computers in Biology and Medicine*. 2018; 99:154–160.
- [14] Shahzadi I, Tang T. B, Meriadeau F, Quyyum A. CNN-LSTM: Cascaded framework for brain tumour classification. *IEEE EMBS Conference on Biomedical Engineering and Sciences, IECBES*; 3-6 December 2018; Sarawak, Malaysia: IEEE. pp. 633–637.
- [15] Swati Z N K, Zhao Q, Kabir M, Ali F, Ali Z, Ahmed S, Lu J. Brain tumor classification for MR images using transfer learning and fine-tuning. *Computerized Medical Imaging and Graphics* 2019; 75: 34–46.
- [16] Tas M O, Ergin S. Detection of the Brain Tumor Existence Using a Traditional Deep Learning Technique and Determination of Exact Tumor Locations Using K-Means Segmentation from MR Images. *İleri Mühendislik Çalışmaları ve Teknolojileri Dergisi* 2020;1: 91–97.
- [17] Saxena P, Maheshwari A, Tayal S, Maheshwari S. Predictive modeling of brain tumor: A Deep learning approach. *Advances in Intelligent Systems and Computing* 2019; 1189: 275–285.
- [18] N. Chakrabarty. Brain MRI Images for Brain Tumor Detection. <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection>. Erişim tarihi: Aralık 2021
- [19] Çınar A, Yıldırım M. (2020). Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture. *Medical Hypotheses* 2020; 139: 109684.
- [20] Budak Ü, Cömert Z, Rashid Z N, Şengür A, Çıbuk M. Computer-aided diagnosis system combining FCN and Bi-LSTM model for efficient breast cancer detection from histopathological images. *Applied Soft Computing Journal* 2019; 85:105765.
- [21] Aslan M. (2021). CNN based efficient approach for emotion recognition, *Journal of King Saud University - Computer and Information Sciences* 2021.
- [22] Demir F, Turkoglu M, Aslan M, Sengur A. A new pyramidal concatenated CNN approach for environmental sound classification, *Applied Acoustics* 2020; 170.
- [23] Turkoglu M, Alcin O F, Aslan M, Al-Zebari A, Sengur A. (2021). Deep rhythm and long short-term memory-based drowsiness detection. *Biomedical Signal Processing and Control* 2021; 65:102364.
- [24] Balaha H M, El-Gendy E M, Saafan M M. CovH2SD: A COVID-19 detection approach based on Harris Hawks Optimization and stacked deep learning. *Expert Systems with Applications* 2021:186.
- [25] Howard A G, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, Adam H. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *arXiv preprint* 2017;1704.04861.
- [26] Wang F, Zheng R, Li P, Song H, Du D, Sun J. Face recognition on Raspberry Pi based on MobileNetV2. *International Symposium on Artificial Intelligence and its Application on Media, ISAIAM*; 21-23 May 2021; Xi'an, China: IEEE. pp. 116–120.
- [27] Demir F. (Derin Öğrenme Tabanlı Yaklaşımla Kötü Huylu Deri Kanserinin Dermatolojik Görüntülerden Saptanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 2021;33: 617–624.
- [28] Bulut F. Örnek Tabanlı Sınıflandırıcı Topluluklarıyla Yeni Bir Klinik Karar Destek Sistemi. *Journal of the Faculty of Engineering and Architecture of Gazi University* 2017; 33: 65–76.
- [29] Siuly S, Alçın Ö F, Kabir E, Şengür A, Wang H, Zhang Y, Whittaker F. A New Framework for Automatic Detection of Patients with Mild Cognitive Impairment Using Resting-State EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2020; 28:1966–1976.