

## ARTIFICIAL INTELLIGENCE STUDIES

## Comparative Analysis of Deep Learning Methods for Brain Tumor Detection

Caner Karadağ<sup>a\*</sup>, Durmuş Özdemir<sup>b</sup>

## ABSTRACT

Nowadays, the number of people who lose their lives due to brain tumors is relatively high. Additionally, there has been an increase in brain tumor cases worldwide due to climate and dietary habits, as well as the influence of environmental factors. Tumors that form in the brain have two types, benign and malignant. Although the risk of death is not very high for benign tumors, early detection is crucial. These tumors can occur in any part of the brain and can be different sizes. Since brain transplantation is not possible with today's technology, if the tumor is not treated early, there is a risk of losing the patient. Expert physicians currently use medical imaging systems to detect brain tumors and allow for direct observation and analysis in a computer environment. Even if an expert performs specific tests, some tumors may go unnoticed. To prevent this, with the development of technology, AI-supported medical imaging systems produce supportive and accurate results to assist physicians in their decision-making processes. This study used a Convolutional Neural Network (CNN) classifier model to detect tumors that had formed in the brain. Within the scope of the research, as a result of the performance comparison using the ResNET50, VGG16, and VGG19 classifier models, the differences between them in terms of efficiency and accuracy in the classification process were examined in detail. Thanks to this analysis it is aimed to determine the model with the best performance and to suggest its use in related fields. As a result of the analysis detection, the improved CNN Classifier model has an accuracy of 94.70%, the ResNET50 model 71.95%, the VGG16 model 97.24%, and the VGG19 model 92.38% accuracy. After determining the practical parameter values at the end of the study, it is recommended that deep learning models can be used in decision support systems to analyze medical images.

<sup>a,\*</sup> Kütahya Dumlupınar University,  
Institute of Graduate Education,  
Dept. of Computer Engineering  
43020 - Kütahya, Türkiye  
ORCID: 0000-0003-1856-2880

<sup>b</sup> Kütahya Dumlupınar University,  
Faculty of Engineering,  
Dept. of Computer Engineering  
43020 - Kütahya, Türkiye  
ORCID: 0000-0002-9543-4076

\* Corresponding author.  
e-mail: info@canerkaradag.com

**Keywords:** Artificial Intelligence, Image Processing, Deep Learning, Brain Tumor

**Anahtar Kelimeler:** Yapay Zekâ, Görüntü İşleme, Derin Öğrenme, Beyin Tümörü

Submitted: 26.04.2023

Revised: 15.05.2023

Accepted: 27.05.2023

doi:10.30855/gmbd.2022.xx.xx

## Beyin Tümörü Tespiti İçin Derin Öğrenme Yöntemlerinin Karşılaştırmalı Analizi

## ÖZ

Günümüzde beyin tümörü nedeniyle hayatını kaybeden kişilerin sayısı oldukça fazladır. Ayrıca dünya genelinde iklim ve beslenme alışkanlıklarına bağlı olarak ya da çevresel faktörlerin etkisiyle beyin tümörü vakaları artış olduğu görülmektedir. Beyinde oluşan tümör iyi ve kötü olmak üzere iki türe sahiptir. İyi olan tümörlerin ölüm riski pek fazla olmasa da erken tanı tespit çok önemlidir. Bu tümörler beynin herhangi bir bölgesinde ve farklı büyüklüklere sahip olabilir. Günümüz teknolojiyle beyin nakli söz konusu olmadığından tümör erken müdahale edilmediği takdirde hastanın kaybedilmesi riskiyle karşı karşıya kalınır. Tıbbi görüntüleme sistemleri günümüzde beyin tümörlerinin tespiti için uzman hekimler tarafından kullanılmakta ve doğrudan bilgisayar ortamında gözlem yolu ile analizini mümkün kılmaktadır. Uzman tarafından belli tetkikler uygulansa bile bazı tümörler gözden kaçabilmektedir. Bunu önlemek için gelişen teknolojiyle birlikte yapay zekâ destekli tıbbi görüntüleme sistemleri hekimlere karar süreçlerinde yardımcı olmak için destekleyici ve doğru sonuçlar üretmektedir. Bu çalışma beyinde oluşmuş tümörlerin tespiti edilmesi için Convolutional Neural Network (CNN) sınıflandırıcı model kullanılmıştır. Araştırma kapsamında, ResNET50, VGG16 ve VGG19 sınıflandırıcı modelleri kullanılarak gerçekleştirilen performans karşılaştırması sonucunda, sınıflandırma işlemindeki etkinlik ve doğruluk bakımından aralarındaki farklar ayrıntılı bir şekilde incelenmiştir. Bu analiz sayesinde, en iyi performansı gösteren modelin belirlenmesi ve ilgili alanlarda kullanımının önerilmesi hedeflenmiştir. Analiz tespiti sonucunda geliştirilmiş CNN Sınıflandırıcı model %94,70, ResNET50 model %71,95, VGG16 model %97,24 ve VGG19 model %92,38'lik doğruluk elde edilmiştir. Çalışma sonunda etkili parametre değerlerinin belirlenmesi sonrasında derin öğrenme modellerinin medikal görüntülerin analizinde karar destek sistemlerinde kullanılabileceği tavsiye edilmektedir.

## 1. Giriş (Introduction)

Teknolojinin hızla gelişmesiyle birlikte ortaya çıkan yeni sorunlar, geleneksel yöntemlerle çözüm bulmak yerine her geçen gün yaşamımızın içinde uygulama alanları genişleyen yapay zeka ile daha pratik bir şekilde çözümlenmektedir [1]. Günümüzde Yapay zekâ, tıbbi alanda birçok farklı uygulama alanına sahiptir ve medikal görüntüleme cihazlarından elde edilen görüntülerin analizi için oldukça faydalıdır. Bu teknolojinin kullanımı, hastalıkların erken teşhisinde, tedavi planlamasında ve sağlık hizmetlerinin verimliliğinde önemli bir rol oynamaktadır. Tümörün görüntülenmesi için kullanılan tomografi, manyetik rezonans ve radyografi gibi cihazlardan elde edilen görüntülerin analizi de yapay zekâ teknolojisi ile hızlandırılmakta ve daha doğru sonuçlar elde edilmektedir [2].

Geleneksel olarak, medikal görüntülerin analizi ve yorumlanması, uzman hekimler tarafından yapılmaktadır. Ancak, bu süreç oldukça zaman alıcı ve bazen sonuçları da tartışmalı olabilmektedir. Yapay zekâ teknolojisi ise, bu süreci hızlandırarak ve daha objektif sonuçlar elde edilmesini sağlayarak önemli bir yardımcı haline gelmiştir [3].

Özellikle kanser teşhisinde, medikal görüntülerin analizi büyük önem taşımaktadır. Yapay zekâ teknolojisi sayesinde, tümörlerin erken teşhisi ve takibi daha kolay hale gelmektedir. Ayrıca, beyin, kalp ve akciğer gibi organların görüntülenmesi için kullanılan tomografi, manyetik rezonans ve radyografi gibi cihazlardan elde edilen görüntülerin analizi de yapay zekâ teknolojisi ile hızlandırılmaktadır.

Beyin, her biri kendine özgü özelliklere sahip birkaç hücre tipinden oluşmaktadır. Diğer organlardaki malignitelerin sonuçlarını beyinde ortaya çıkanlara genellemek imkansızdır [4]. Beynin benzersiz biyolojisi ve mikro ortamı, beyin kanserlerinin ana yönüdür [5]. Her bir tümör formunun kendi biyolojisi, tedavi süreci, prognoz görünümü ve farklı bir dizi risk faktörü vardır [6].

Beyin veya omurilik tümörünün neden olduğu kafadaki basınç, beyin kanserinin yaygın bir belirtisidir. Beyin tümörü olan kişilerin, bitkinlik, mide bulantısı veya rahatsızlık gibi spesifik semptomlara sahip olma olasılığı daha yüksektir. Beyin tümörleri ve beyin kanseri ile yaşamının diğer yan etkileri ateş, kızarıklık ve nabız artışı olmaktadır [7]. Uzmanlar, sorunu kesin bir şekilde tanımlamak için belirti ve semptomları ilişkilendirir. Fakat beyin tümörleri her zaman semptomlara neden olmamaktadır [8].

Bir beyin tümörünün teşhisi, görüntüleme testleri, nörolojik muayeneler ve biyopsi dahil olmak üzere üç farklı test ve prosedürü vardır. Fakat beyin kanserlerini teşhis etmek için en yaygın ve köklü yöntem Manyetik Rezonans Görüntüleme (MRI) kullanmaktır [9].

Sergio Pereira, Adriano Pinto, makalelerinde tümör segmentasyonu ve sınıflandırması için güvenilir ve otomatik tekniklerin gerekli olduğunu belirtmiştir [10]. Evrişim sinir ağı (CNN), daha derin bir mimarinin tasarlanmasına izin veren  $3 \times 3$  çekirdeğe sahip yazarlar tarafından önerildi ve ağda daha az sayıda ağırlık sağlayarak aşırı takılmaya karşı iyimser bir etki kazandı. Yoğunluk normalizasyonu CNN'de bir ön işleme aşaması olmasa da normalizasyondan sonra segmentasyon sonuçları çok etkili olmuştur [11].

ANT kolonisi optimizasyon işlemi ile BT tarama görüntülerini kullanarak beyindeki malign dokuyu tespit etme yöntemini geliştirmişlerdir. Kanserli tümörleri tespit etmek için en yaygın teknolojilerden biri MRI teknolojisinin kullanılmasıdır. Görüntülerini ayırt etmek normal görüntülerden daha zor. Kanserli beyin tümörlerini doğru bir şekilde teşhis etmek için optimizasyon teknikleri kullandılar. Sonuçlar optimizasyonun beyin kanseri tanısını önemli ölçüde iyileştirebileceğini gösterdi [12].

Dahab vd., olasılık nöral ağı prosedürlerini kullanan sağlıklı hücrelerden beyindeki kanserli dokuyu buldu. Beyin kanseri hücrelerinin tanısında olası sinir ağı teknolojisinin analizi BT tarama görüntüleri kullanılarak yapıldı. Sunulan teknolojinin değerlendirilmesinde eğitim performansı, hasarlı hücrelerin sınıflandırılmasındaki doğruluk ve bilgisayar hesaplamalarının süresi ölçülmüştür. Simülasyonun sonuçları, sunulan teknolojinin en hızlı hesaplama süresine ve kanserli beyin dokusunu sınıflandırma ve tespit etmede en yüksek doğruluğa sahip olduğunu göstermiştir. Ölçülen değerler, hasarlı hücreleri %100 doğrulukla sağlıklı hücrelerden izole edip ayırt edebildiğini göstermiştir. Bu yöntemdeki hesaplama işlem süresi, önemli bir miktar olan MRI tekniğine kıyasla yaklaşık %79 azaltılmıştır [13].

Khan vd., önceden eğitilmiş CNN kullanılarak tüm görüntü tabanlı kanserli ve kanserli olmayan MRI sınıflandırma yöntemini sunmuşlardır. Yöntem, VGG-16, ResNet-50 ve Inception-V3 olmak üzere üç önceden eğitilmiş model kullandı ve VGG-16 kullanarak en yüksek %96 doğruluğunu elde etti [14]. Anaraki vd., genetik bir algoritma (GA) kullanılarak geliştirilen bir CNN mimarisi ve üç sınıf menenjiyomları, gliomlar ve hipofiz tümörleri arasında tam beyin MRI bazlı bir veri kümesi kullanılarak sınıflandırılmış bir beyin tümörleri önermişlerdir. En yüksek %94,2 doğruluk, önerilen GA tabanlı CNN kullanılarak görülmüştür [15].

Khan vd., kötü huylu ve iyi huylu tümör MRG'si arasında DL tabanlı bir beyin tümörü sınıflandırma yöntemi önerdi. MRI veri seti Kaggle web sitesinden alınmıştır. Veri seti, 155 malign tümör görüntüsünü ve 98 iyi huylu tümör görüntüsünü içerir. Transfer öğrenme paradigmasında iyi bilinen önceden eğitilmiş üç CNN, VGG-16, ResNet-50 ve Inception-v3 modeli kullanılmıştır [16].

Beyin tümörü sınıflandırması konusunda yapılan araştırmalar, derin öğrenme tekniklerinin kullanımı ile son derece verimli sonuçlar vermektedir. Bu doğrultuda, farklı sınıflandırma modelleri kullanılarak yapılan çalışmalar da mevcuttur. Örneğin, AlexNet, VGG16, VGG19, ResNET50 ve InceptionV3 gibi önceden eğitilmiş ağlar kullanılarak yapılan çalışmalar, yüksek doğruluk oranları elde edilmesine olanak sağlamaktadır.

Khan vd., tarafından önerilen transfer öğrenmeye dayalı DL çerçevesi de beyin tümörü sınıflandırması için oldukça başarılı sonuçlar vermiştir. Bu çalışmada, VGG16 ve VGG19 ağları kullanılarak otomatik özellik çıkarımı yapılmıştır. Ayrıca, uygun öznitelik seçimi için korentropi ve kısmi en küçük kareler tabanlı yöntemler de kullanılmıştır. Deneyler için popüler Brain Tumor Segmentation (BraTs) veri seti kullanılmış ve elde edilen sonuçlar oldukça başarılı olmuştur [17].

Bu çalışma, beyin tümörlerinin erken tespiti ve doğru teşhisi için oldukça önemli bir adım niteliği taşımaktadır. Geliştirilen Python tabanlı derin öğrenme uygulaması sayesinde hastaların daha hızlı ve doğru bir şekilde teşhis edilmesi, tedavi sürecinin daha etkili ve başarılı olması hedeflenmektedir. Ayrıca, uygulama doktorların yükünü hafifletmek ve teşhisi doğrulamak için yardımcı bir araç olarak da kullanılabilir. Çalışmamız literatürden farklı olarak son güncel (state of art) derin öğrenme modellerinin karşılaştırmalı analizini beyin tümörlerinin erken tespiti ve doğru teşhisi problemi üzerinde sunmaktadır. [3].

## 2. Materyal ve Yöntem (Material and Method)

### 2.1. Kullanılan yöntemler (Methods used)

Evrişimli sinir ağı, bilgisayarlı görü uygulamalarında en çok kullanılan derin öğrenme modelidir [18]. Sınıflandırma performanslarını karşılaştırmak için VGG16, VGG19 ve ResNET50 modelleri kullanılmıştır.

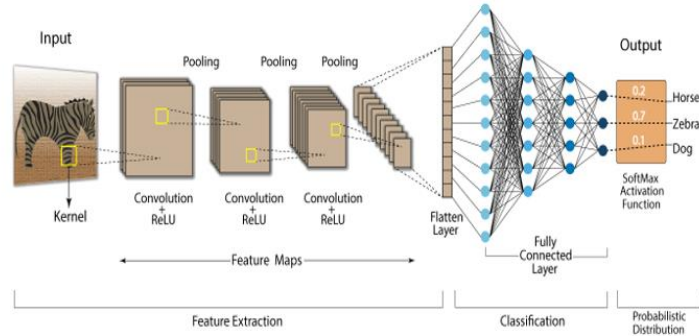
#### 2.1.1. Evrişimli sinir ağı modeli (Convolutional neural network model)

Evrişim katmanları, evrişim ve aktivasyon işlemlerini gerçekleştirir. Evrişim gibi doğrusal bir işlem, katmanlarının her birinin, çekirdek adı verilen bir dizi özellik ile tensör adı verilen dizi numaralarının girişi arasında öge bazında bir çarpma gerçekleştirdiği yerdir [19]. Çekirdek genellikle tanımlanmış bir boyuttadır,  $3 \times 3$  veya  $5 \times 5$ . Tek bir diziyi oluşturan yerel yamalardaki daha küçük dizilerde tekrarlanan işlemler, bir sonraki katmana girdi görevi gören bir özellik haritasına yol açmaktadır. Çeşitli konumlardaki bu tür kalıcı işlemler, katmandan [20] yerel bağlaçları algılamaktadır. N çekirdeğe sahip evrişimli bir katman, N özellik haritasının oluşumuyla sonuçlanan N yerel özelliği algılayabilir [21]. Bunu, fonksiyonun doğrusal olmama durumunu hesaplayan, daha önce gerçekleştirilen doğrusal evrişim işlemlerinden bir sıçrama olan ve yaygın olarak uygulanan doğrusal olmayan fonksiyonlar teğet işlevi (tanh) veya düzeltilmiş doğrusal birim (ReLU) olan sonraki bir aktivasyon işlevi takip eder.

Havuzlama katmanı (max-pooling), girdi katmanlarının boyutlarını küçültür ve ardından katman parametrelerini azaltır. Bu işlem, bu özellikleri içeren yamaları satırlar veya sütunlar arasında kaydırarak benzer özellikleri birleştirmektedir [22]. Daha yaygın olarak kullanılan bir havuzlama yöntemi olan max-pooling, çıkış tensörüne geçmek için bir çekirdekte en yüksek değeri seçerken,

ortalama havuzlama çekirdekteki ortalamayı hesaplar [23,34].

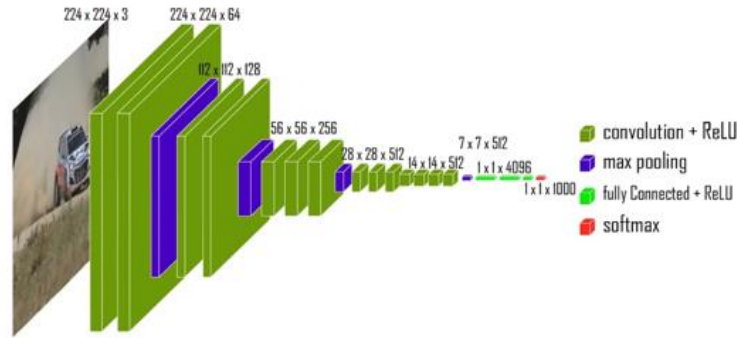
Tamamen bağlı katmanlar, önceki katmandaki her yerel girişi sonraki katmandaki her çıkışa bağlamaktadır. Rolü, evrişimli katmanlardan üretilen çıktılarının bölümlerini, bir etikete ait her özelliğin olasılıklarından oluşan tek boyutlu bir vektörle birleştirmektir. Bu katmanlardaki düğümler, girdileri istenen çıktılara eşleyebilen öğrenilebilir bir ağırlığa sahiptir [25]. Son katman, sınıflandırma problemlerine örnek olarak softmax ile diğer katmanlardan farklı bir aktivasyon fonksiyonundan oluşmaktadır.



Şekil 1. Evrişimli sinir ağı [27].  
(Convolutional neural network)

### 2.1.2. VGG16 Modeli (Vgg16 model)


VGG16 ağı, yalnızca ağ derinliğini artırmakla kalmaz, aynı zamanda performansı daha etkin bir şekilde geliştirmektedir. Basit modül, küçük bir evrişim çekirdeği, küçük havuzlama çekirdeği ve ReLU'dan oluşmaktadır. Şekil 2'de görüldüğü gibi, 5 evrişimli katman, 3 tamamen bağlı katman ve bir softmax çıkış katmanı vardır. Max pooling, katmanları ayırmak için, ReLU fonksiyonu ise tüm gizli katmanların aktivasyon birimleri için kullanılmaktadır [21]. Bu nedenle, VGG ağlarının en büyük avantajlarından biri, sinir ağlarının yapısını basitleştirmeleridir. Elde edilen  $7 \times 7 \times 512$  özellik haritası tamamen bağlanır ve ardından üç nesnenin tanıma sonuçlarının çıktısını almak için softmax aktivasyonu gerçekleştirilir.



Şekil 2. Vgg16 evrişimli sinir ağı [28].  
(Vgg16 convolutional neural network)

### 2.1.3. VGG19 Modeli (Vgg19 model)

VGG ağı, Simonyan ve Zisserman tarafından 2014'ün başlarında İngiltere'deki Oxford Üniversitesi'nde önerilen önceden eğitilmiş CNN modelinin ticari adıdır. VGG (Görsel Geometri Grubu), 100.000 görüntünün eğitim için ve 50.000 görüntünün doğrulama için kullanıldığı 1000 sınıftan oluşan 1,3 milyon görüntüden oluşan ImageNet ILSVRC veri kümesi üzerinde eğitildi. VGG mimarilerinin bir çeşidi olan VGG-19, son teknoloji ürünü diğer modellere kıyasla sürekli olarak daha iyi performans elde eden 19 derinlemesine bağlı katmana sahiptir. Model, daha iyi özellik çıkarımına ve SoftMax aktivasyon işlevini kullanarak önceki sınıflandırmayı alt örneklemek için Maxpooling'in kullanılmasına olanak tanıyan yüksek düzeyde bağlantılı evrişimli ve tam bağlantılı katmanlardan oluşur [29].

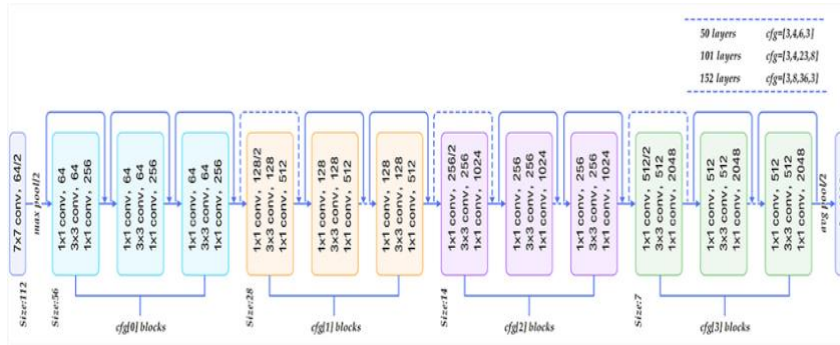


Şekil 3. Vgg19 evrişimli sinir ağı [30].  
(Vgg19 convolutional neural network)

#### 2.1.4. ResNet50 Modeli (ResNet50 model)

He ve diğerleri tarafından önerilen derin bir sinir ağıdır. Geleneksel derin sinir ağlarında meydana gelen gradyan kaybolması ve ağ bozulması sorunlarını etkili bir şekilde hafifleten, ağır onlarca hatta yüzlerce katmana sahip olmasına izin veren evrişimli katmanlar arasına atlama bağlantıları ekleyerek bilginin birden fazla örtük katman arasında yayılmasını sağlar. Günümüzde ResNet, yüz tanıma ve otonom sürüş gibi çeşitli mühendislik alanlarında yaygın olarak uygulanmaktadır. Parametre sayısı ve modelin performansı dikkate alınarak bu çalışmada modifikasyon için alt model ResNet-50 seçilmiştir [31].

Evrişim çekirdeği, görüntüden farklı çözünürlüklerde öznetelik çıkarmak için kullanılan  $1 \times 1$ ,  $3 \times 3$  ve  $5 \times 5$  olmak üzere üç boyut içerir ve evrişim katmanlarından sonra kullanılan aktivasyon fonksiyonlarının tümü ReLU'dur. Çıktı özelliği boyutu, adım boyutu 2 olan  $7 \times 7$  ortalama ve  $3 \times 3$  maksimum havuzlamadan sonra yarıya bölünür. Tamamen bağlı katmanın çıktı boyutu, burada 2 olarak ayarlanması gereken kategori sayısına karşılık gelir.




Şekil 4. ResNet50 modeli [32].  
(ResNet50 model)

## 2.2. Kullanılan görüntü veri seti (The image dataset used)

Beyin tümörü sınıflandırması için çalışmamızda kullandığımız Kidney Disease Classifier adlı veri seti de Kaggle'da açık erişim (public) olarak bulunmaktadır. Bu veri seti, çeşitli görüntü işleme teknikleri ve sınıflandırma modelleri için kullanılabilir büyük bir veri kümesi sunmaktadır. Bu veri seti, beyin tümörü sınıflandırması için kullanılan yöntemlerin geliştirilmesinde ve iyileştirilmesinde değerli bir araç olabilir [33].

## 2.3. Sağlıklı beyin görüntüleri (Healthy brain images)


Bilgisayarlı tomografi (BT) cihazından elde edilmiş sağlıklı beyin görüntüleri Şekil 5'te gösterilmiştir.



Şekil 5. Sağlıklı beyin görüntüleri [33].  
(Healthy brain images)

#### 2.4. Tümörlü olan beyin görüntüleri (Brain images with tumors)

Aşağıda gösterilen farklı 3 beyin tümörü örneği bulunmaktadır. Burada görüldüğü gibi her şekilde tümörün bulunduğu yer farklı boyuta ve konuma sahiptir.



Şekil 6. (a) da beyin sol arkasında, şekil (b) de beyin sol arkasının biraz önünde, şekil (c) de ise beyin sağ orta bölümünde alan işaretlenmiştir [33].

(The area is marked on the left back of the brain in (a), a little in front of the left back of the brain in figure (b), and the right middle part of the brain in figure (c))

#### 2.5. Performans metrikleri (Performance metrics)

Sınıflandırma tabanlı bir derin öğrenme modelinin performans değerlendirmesi metriklerinden biri olmaktadır. Modelin keskinliğini, geri çağırma, F1 puanını ve desteğini göstermektedir. Eğitimli modelin genel performansının daha iyi anlaşılmasını sağlamaktadır. Bir derin öğrenme modelinin sınıflandırma analiz raporunu daha iyi anlamak için raporda görüntülenen tüm metrikleri bilmemiz gerekmektedir. Burada net bir anlayışı ortaya koymak için, derin öğrenme modelin sınıflandırma analiz raporunu kolayca anlayabilmeniz için Tablo 1'de tüm metriklerin tanımı şu şekildedir:

Tablo 1. Parametre değerleri (Parameter values)

Patremetre	Metrikler
Precision (Keskinlik)	Keskinlik, gerçek pozitiflerin, doğru ve yanlış pozitiflerin toplamına oranı olarak tanımlanır.
Recall (Geri Çağırma)	Geri çağırma, modelin tahmin ettiği yanlış pozitiflerin sayısına bakmak yerine, tahmin karışımına atılan yanlış negatiflerin sayısına bakmaktadır.
F1 Score (F1 Puanı)	F1 puanı, keskinlik ve geri çağırma ağırlıklı ortalamasıdır. Keskinlikte ve geri çağırma bildiğimiz gibi, yanlış pozitif ve yanlış negatif vardır, bu yüzden ikisini de dikkate alır.
Accuracy (Doğruluk)	Doğruluk, bir algoritma tarafından yapılan tüm tahminler içindeki doğru tahminlerin oranıdır. Hassasiyetin hatırlamaya bölünmesiyle veya 1 eksi yanlış negatif oranının (FNR) yanlış pozitif orana (FPR) bölünmesiyle hesaplanabilir.
Specificity (Özgüllük)	Bir sınıflandırıcının özgüllüğü, ne kadarının doğru bir şekilde negatif olarak sınıflandırıldığı ile gerçekte ne kadarının negatif olduğu arasındaki orandır.

TP, FP, TN ve FN değerleri kullanılarak doğruluk, geri çağırma, özgüllük, kesinlik, F1-skor değerleri sırasıyla aşağıda verilen denklem (1) denklem (2) denklem (3) denklem (4) ve denklem (5)'teki formüllerle bulunur.

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

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (3)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4)$$

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

Karışıklık matrisi ve ilgili formüller Şekil 7'de gösterilmektedir.

		Precision $\frac{TP}{TP+FP}$	Negative Prediction $\frac{TN}{TN+FN}$	Accuracy $\frac{TP+TN}{TP+FN+TN+FP}$
True Label	Tumor	True Positive (TP)	False Negative (FN)	Sensitivity $\frac{TP}{TP+FN}$
	Normal	False Positive (FP)	True Negative (TN)	Specificity $\frac{TN}{TN+FP}$
		Tumor	Normal	
		Predicted Label		

Şekil 7. Performans metriği.  
(Performance metric)

### 3. Önerilen Model (Recommended Model)

#### 3.1. Parametrelerin belirlenmesi (Determining parameters)

Geliştirilmiş CNN, VGG16, VGG19 ve ResNet50 sınıflandırıcı modellerinin parametrelerine ilişkin Tablo 2'de sunulmuştur.

Tablo 2. Parametre değerleri (Parameter values)

Giriş Boyutu	Model	Parti Boyutu	Eğitim Tur Sayısı	Toplam Sınıf Sayısı	Ayrıntılı	Test Boyutu	Rastgele Durum	Karıştırma
224	CNN	20	5	5	1	0.3	0	false
224	VGG16	20	5	5	1	0.3	0	false
224	VGG19	20	5	5	1	0.3	0	false
224	ResNet50	20	5	5	1	0.3	0	false

#### 3.2. Cnn model'in katmanı (Cnn model's layer)

Programda kullanılan geliştirilmiştir CNN sınıflandırıcı modelin katman yapısı Tablo 3'te gösterilmiştir.

Tablo 3. Katman yapısı (Layer structure)

Katman (Layer)	Çıktı Şekli (Output Shape)	Parametre (Param)
Conv2D	(None, 224, 224, 32)	896
MaxPooling2D	(None, 112, 112, 32)	0
Dropout	(None, 112, 112, 32)	0
Conv2D	(None, 112, 112, 64)	18496
MaxPooling 2D	(None, 56, 56, 64)	0
Dropout	(None, 56, 56, 64)	0
Conv2D	(None, 56, 56, 128)	73856
MaxPooling 2D	(None, 28, 28, 128)	0
Dropout	(None, 28, 28, 128)	0
Flatten	(None, 100352)	0
Dense	(None, 128)	12845184
Dropout	(None, 128)	0

Dense

(None, 2)

258

### 3.3. Beyin tümörüne ait veri setleri (Brain tumor datasets)

Programda kullanılan beyin tümörüne ait veri setleri tablo 4'te gösterilmiştir. Tablo da eğitim, test, geçerleme ve toplam verileri bulunmaktadır.

Tablo 4. Parametre değerleri (Parameter values)

	Eğitim	Test	Geçerleme	Toplam
Veri Sayısı	3000	847	751	4598
Yüzde (%)	65,245759	18,4210526	16,3331883	100

### 3.4. Cnn model'in eğitilmesi (Training the cnn model)

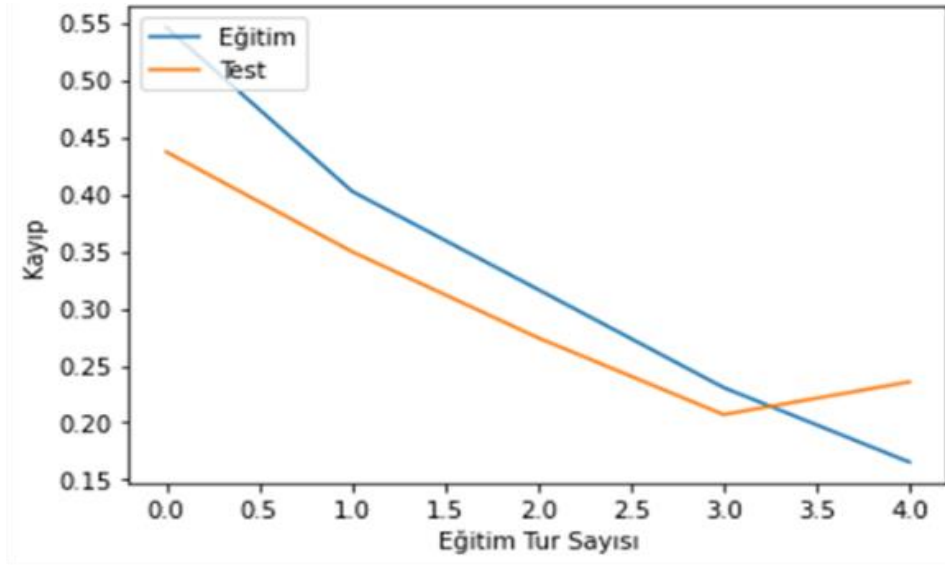
Programda beyin tümörü eğitimi için geliştirilmiş sınıflandırıcı CNN model ve aktivasyon fonksiyonu softmax kullanılmıştır. Eğitim seti başlangıçta ortalama %72'lik doğruluğa, son aşamaya geldiğinde ise %94'lük bir doğruluğa ulaşmıştır. Eğitim setinin başlangıçta %54'lük kayıp değeri sahipken son aşamaya gelindiğinde ise %16'lük kayıp değerine ulaşmıştır. Eğitim sonuçları Tablo 5'te gösterilmiştir.

Tablo 5. Eğitim analiz sonuçları (Training analysis results)

Eğitim Tur Sayısı	Kayıp Değeri	Doğruluk	Doğrulama Kaybı	Doğrulama Doğruluğu
1	0.5466	0.7271	0.4374	0.8100
2	0.4027	0.8225	0.3498	0.8383
3	0.3168	0.8692	0.2744	0.8717
4	0.2307	0.9104	0.2070	0.9100
5	0.1653	0.9408	0.2356	0.9117

### 3.5. Beyin tümörü tespiti ve kayıp grafiği (Brain tumor detection and loss graph)

Geliştirilmiş CNN sınıflandırıcı modeli ve softmax aktivasyon fonksiyonunun kayıp değeri, Şekil 8'deki grafikte ayrıntılı bir şekilde gösterilmiştir. Bu grafik, modelin eğitim sürecindeki performansını ve kaybın nasıl azaldığını göstermektedir. Sonuçlar, modelin sınıflandırma doğruluğunun zamanla arttığını ve eğitim sürecinin etkin olduğunu ortaya koymaktadır. Grafikteki düşüş eğrisi, modelin optimizasyon sürecinde kaybın nasıl azaldığını gösterirken, istikrarlı bir şekilde düşen eğri, modelin genel performansının arttığını göstermektedir. Bu bulgular, geliştirilen modelin başarılı bir şekilde sınıflandırma görevini yerine getirdiğini ve softmax aktivasyon fonksiyonunun bu başarıda önemli bir rol oynadığını göstermektedir.



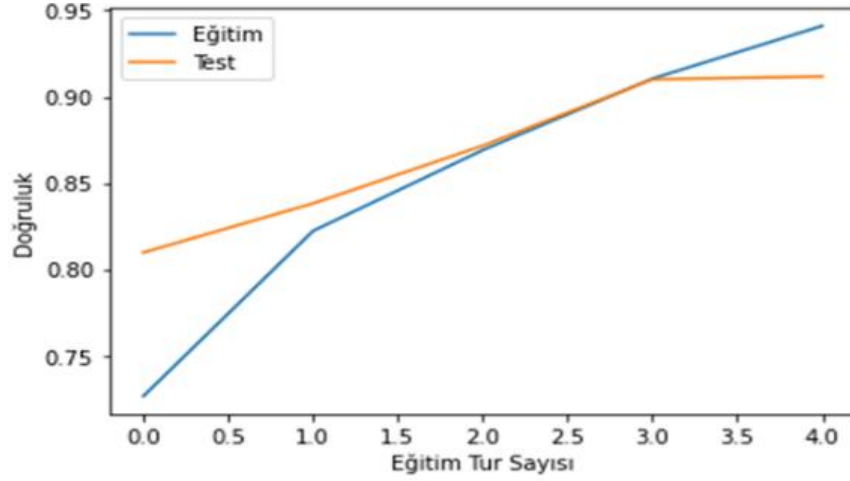
Şekil 8. Beyin tümörü ait kayıp grafiği.  
(Loss graph of brain tumor)

### 3.6. Beyin tümörü doğruluk grafiği (Brain tumor accuracy graph)

Geliştirilmiş Convolutional Neural Network (CNN) sınıflandırıcı modeli ve softmax fonksiyonunun kayıp



değeri, Şekil 8'deki grafikte ayrıntılı bir şekilde gösterilmiştir. Bu grafik, modelin eğitim sürecindeki performansını ve kaybın nasıl azaldığını göstermektedir. Yüksek başlangıç kaybından başlayarak, modelin iterasyonlar ilerledikçe kaybın hızla azaldığı ve sonunda kararlı bir seviyeye ulaştığı görülmektedir. Bu durum, modelin veri setine daha iyi uyum sağladığını ve sınıflandırma doğruluğunun arttığını göstermektedir. Şekil 9'daki grafik, modelin eğitim sürecindeki başarısını görsel olarak açık bir şekilde ortaya koymaktadır.



Şekil 9. Beyin tümörü ait doğruluk grafiği.  
(Accuracy graph of brain tumor)

Beyin tümörüne ait metrik analiz sonuçları Tablo 6'da sunulmuştur. Bu tablo, geliştirilen modelin sınıflandırma doğruluğunu, hassasiyeti, özgüllüğü ve diğer önemli metrikleri göstermektedir. Analiz sonuçları, geliştirilen CNN modelinin beyin tümörü sınıflandırma görevinde yüksek bir performans sergilediğini ve softmax fonksiyonunun etkili bir şekilde kullanıldığını göstermektedir. Bu bulgular, modelin tıbbi görüntüleme alanında değerli bir araç olarak kullanılabileceğini göstermektedir.

Tablo 6. Metrik analiz sonuçları (Metric analysis results)

Eğitim Tur Sayısı	Keskinlik	Geri Çağırma	F1 Puanı	Destek
Sağlıklı	0.99	0.85	0.92	343
Tümörlü	0.84	0.99	0.91	257
Doğruluk	-	-	0.91	600
Makro Ortalama	0.91	0.92	0.91	600
Ağırlıklı Ortalama	0.92	0.91	0.91	600

### 3.7. Beyin tümörü sınıflandırıcıların karşılaştırılması (Comparison of brain tumor classifiers)


Programda farklı sınıflandırıcı modelleri ve aktivasyon çıkış fonksiyonu olarak softmax kullanılmıştır. Sınıflandırıcı modellerin performans analiz sonuçları Tablo 7'de gösterilmiştir.

Tablo 7. Sınıflandırıcıların karşılaştırılması (Comparison of classifiers)

Sınıflandırıcı	Kayıp Değeri	Doğruluk Değeri	Doğrulama Kaybı	Doğrulama Doğruluğu
CNN	0.1653	0.9408	0.2356	0.9117
VGG 16	0.1223	0.9695	0.2341	0.9189
VGG 19	0.2391	0.9238	0.2316	0.9156
ResNet50	0.5550	0.7157	0.5937	0.7089

### 3.8. Tümör olup olmadığı tespiti (Detection of tumor)


Sistemin analiz ettiği 12 farklı bireyin beyinlerinde tümörlü bölge olup olmadığının tespiti Şekil 10'da gösterilmiştir. Softmax aktivasyon fonksiyonu kullanılarak eğitilen verilerin analizi sonucunda, bireylerin tümörlü (evet) veya tümörsüz (hayır) olup olmadıkları doğru bir şekilde ayrılmıştır.



Şekil 10. Beyin tümörüne ait analiz sonuçları.  
(Analysis results of brain tumor)

### 3.9. Tümörün konum tespiti (Tumor locating)


Tümörün konum tespiti için geliştirilmiş CNN sınıflandırıcı model ile softmax aktivasyon çıkış fonksiyonu kullanılmıştır. Beyindeki tümörlü bölgenin nerede olduğunu bulunması için bilgisayarlı tomografi cihazından elde edilen görüntüye 9 adım da maskeleme ve filtreleme işlemleri uygulanmıştır. Beyin tümörün konumu bulunmasına ait adımları Şekil 11’de gösterilmiştir.



Şekil 11. Beyin tümörüne ait konum tespiti.  
(Location detection of brain tumor)

### 3.9. Tümör 'ün bulunduğu konum ve boyutu (Location and size of the tumor)

Program sonunda beyindeki tümörün bulunduğu konum, yüksekliği ve genişliği Şekil 12’de yer verilmiştir. İşaretlenen beyin tümörü yüksekliği 0,9 cm, genişliği ise 1,1cm tespit edilmiştir.



Şekil 12. Beyin tümörüne ait boyutları.  
(Dimensions of brain tumor)

#### 4. Sonuç ve Tartışma (Conclusion and Discussion)

Yapay zekâ ve derin öğrenme, tıbbi görüntülerden sınıflandırma ve tespit modellerinin geliştirilmesinde önemli bir role sahiptir. Geleneksel yöntemlerin aksine, derin öğrenme modelleri, büyük veri setleri üzerinde eğitilerek, daha doğru sonuçlar elde edilmesine imkân tanır.

Beyin tümörü teşhisinde, MRI ve bilgisayarlı tomografi (BT) gibi görüntüleme teknolojileri kullanılır. Bu görüntülerin analizi için derin öğrenme teknikleri son yıllarda oldukça popüler hale gelmiştir. Beyin tümörü sınıflandırma çalışmalarında, Convolutional Neural Network (CNN) gibi derin öğrenme modelleri sıkça kullanılır. Ayrıca, veri setinin kalitesi ve boyutu da modelin performansını etkiler. Veri seti yeterli büyüklükte ve temsil edici özellikleri içerdiğinde, daha doğru sonuçlar elde edilir. Bu nedenle, derin öğrenme modellerinin eğitimi için yeterli sayıda örnek veri toplanması oldukça önemlidir.

Bunun yanı sıra, derin öğrenme modellerinin yanı sıra, transfer öğrenme teknikleri de sıklıkla kullanılır. Önceden eğitilmiş modeller, yeni veri setleri üzerinde eğitilerek, daha hızlı ve daha doğru sonuçlar elde edilmesini sağlar.

Beyin tümörü analiz edilmesi 4598 BT görüntüsü kullanılması sağlanmıştır. Uygulamada beyin tümörü için parti boyutu 20, eğitim tur sayısı 5 olarak belirlendikten sonra geliştirilmiş CNN sınıflandırıcı model ile softmax aktivasyon fonksiyonu kullanılarak 1. adım da doğruluk başarımı %72 olarak hesaplanmıştır. Daha sonra veri eğitim setinin tur sayısı 5. adıma geldiğinde %94'lük doğruluğa ulaşmıştır. Burada eğitim tur sayısını arttırdığımızda doğruluk değeri yüksek çıktığı görülmüştür.

Khan vd., beyin tümörü için önermiş olduğu modeli 15 eğitim tur sayısında %96 doğruluk ve %89 doğrulama doğruluğu bulmuştur. Buna çalışmasında 5 eğitim tur sayısında %94 doğruluk değeri ve %94 doğrulama doğruluğu bulunmuştur. VGG16 modelinde ise %90 doğruluk ve %87 doğrulama doğruluğu olarak bulunmasına karşın %97 doğruluk ve doğrulama doğruluğu %94 bulunmuştur [24].

En yüksek başarılı sınıflandırma VGG modeli ile elde edildiği görülmektedir. Modellerin performanslarını daha detaylı analiz etmek için çeşitli performans metrikleri kullanılmıştır. Yine bu metriklerde en yüksek değerler VGG modeli ile elde edilmiştir. CNN mimarilerinde katman sayısı sınıflandırma başarısı ile her zaman doğru orantılı değildir.

Yapay zekâ ve tıbbi medikal görüntülerden beyin tümörü tespit etmek için başarılı bir ikili sınıflandırıcı geliştirilmiştir. Eğitim tur sayısı ve parti boyutu artırılarak doğruluk değerinin artırılacağı fakat performans ve eğitim süresi gibi faktörlere bağlı olarak bu seçeneğin uygun olmayabileceği görülmüştür. Bu nedenle, düşük tur sayısında etkin başarı elde etmek için çalışılmıştır. Ayrıca, daha fazla kişinin verisi yüklendiğinde sistem başarı oranını arttıracaktır. Görüntü analizi sırasında harici uygulama geliştirmek yerine, cihaz içinde gömülü derin öğrenme uygulamalarının kullanılması hızlı aksiyon alma açısından faydalı olacaktır.

Medikal görüntülerden beyin tümörü tespiti için başarılı bir ikili sınıflandırıcı oluşturuldu. Geliştirilen CNN ve kullanılan aktivasyon transfer fonksiyonu olan softmax ile birlikte VGG16, VGG19 ve ResNet50 sınıflandırıcı modelleri arasındaki performans farkları da incelendi.

Daha sonra yapılacak çalışmalarda ENet, DenseNet veya Shuffile Net sınıflandırıcı modellerinin kullanılması ve eğitim tur sayısı parametresinin artırılması önerildi. Batch size değerinin artırılması ile doğruluk değerinin yükseltilebileceği ancak uygulamanın kurulduğu ortam ve performansı göz önünde bulundurularak eğitim zamanı ile ilgili sorunların da olabileceği belirtildi. Bu nedenle daha fazla hasta verisi kullanılması, görüntü analizinin cihaz içinde gömülü olarak yapılması gibi alternatif çözümlerle daha hızlı aksiyon alınabilir.

### Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Bu çalışmada yazarların herhangi bir çıkar çatışması bulunmadığı beyan edilmektedir.

### Etik Beyanı (Ethics Statement)

Etik Beyanı Bu çalışmada, “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması gerekli tüm kurallara uyulduğunu, bahsi geçen yönergenin “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbirinin gerçekleştirilmediğini taahhüt ederiz.

### Kaynaklar (References)

- [1] Beşkirli, M. (2019). Yüksek Boyutlu Test Fonksiyonlarında Ağaç Tohum Algoritmasının Performans Analizi. *European Journal of Science and Technology*, (Özel Sayı), 93-101.
- [2] Atlan, F. ve Pence, I. (2021). Yapay zekâ ve tıbbi görüntüleme teknolojilerine genel bakış. *Acta Infologica*, 5(1), 207-230. <https://doi.org/10.26650/acin.813736>.
- [3] Beşkirli, A., Beşkirli, M., Haklı, H. ve Uğuz, H (2018). Comparing Energy Demand Estimation Using Artificial Algae Algorithm: The Case of Turkey. *Journal of Clean Energy Technologies*, 6 (4), 349-352.
- [4] N.A. Charles, E.C. Holland, R. Gilbertson, R. Glass, H. Kettenmann, The brain tumor microenvironment, *Glia* 59 (8) (2011) 1169–1180, Aug. <https://doi.org/10.1002/GLIA.21136>.
- [5] B. Cacho-Díaz, D.R. García-Botello, T. Wegman-Ostrosky, G. Reyes-Soto, E. Ortiz-Sánchez, L.A. Herrera-Montalvo, Tumor microenvironment differences between primary tumor and brain metastases, *J. Transl. Med.* 18 (1) (Jan. 2020) 1–12, <https://doi.org/10.1186/S12967-019-02189-8>, 2020 18:1.
- [6] I. Koh, P. Kim, In vitro reconstruction of brain tumor microenvironment, *BioChip Journal* 13 (1) (Mar. 2019) 1–7, <https://doi.org/10.1007/S13206-018-3102-6>, 2019 13:1.
- [7] J. Kotia, A. Kotwal, R. Bharti, Risk susceptibility of brain tumor classification to adversarial attacks, *Adv. Intell. Syst. Comput.* 1061 (2020) 181–187, [https://doi.org/10.1007/978-3-030-31964-9\\_17/COVER/](https://doi.org/10.1007/978-3-030-31964-9_17/COVER/).
- [8] L. Desjardins, et al., Predicting Social Withdrawal, Anxiety and Depression Symptoms in Pediatric Brain Tumor Survivors, vol. 37, Jan. 2019, pp. 22–36, <https://doi.org/10.1080/07347332.2018.1535531>, 1.
- [9] A. Wadhwa, A. Bhardwaj, V. Singh Verma, A review on brain tumor segmentation of MRI images, *Magn. Reson. Imaging* 61 (Sep. 2019) 247–259, <https://doi.org/10.1016/J.MRI.2019.05.043>.
- [10] Pereira S, Pinto A, Alves V, Silva CA. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Trans Med Imag* 2016;35(5): 1240–51.
- [11] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Adv Neural Inf Process Syst* 2012:1097–105.
- [12] V. Soleimani, F.H. Vincheh, Improving ant colony optimization for brain MRI image segmentation and brain tumor diagnosis. in 2013 first Iranian conference on pattern recognition and image analysis (PRIA). IEEE, 2013.
- [13] D.A. Dahab, S.S. Ghoniemy, G.M. Selim, Automated brain tumor detection and identification using image processing and probabilistic neural network techniques, *Int. J. Image Processing Visual Commun.* 1 (2) (2012) 1–8.
- [14] H.A. Khan, W. Jue, M. Mushtaq, M.U. Mushtaq, Brain tumor classification in MRI image using convolutional neural network, *Math. Biosci. Eng.* 17 (2020) 6203–6216, <https://doi.org/10.3934/MBE.2020328>.

- [15] A. Kabir Anaraki, M. Ayati, F. Kazemi, Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms, *Biocybern. Biomed. Eng.* 39 (1) (2019) 63–74, <https://doi.org/10.1016/j.bbe.2018.10.004>.
- [16] H.A. Khan, W. Jue, M. Mushtaq, M.U. Mushtaq, Brain tumor classification in MRI image using convolutional neural network, *Math. Biosci. Eng.* 17 (5) (2020) 6203–6216, <https://doi.org/10.3934/mbe.2020328>.
- [17] M.A. Khan, I. Ashraf, M. Alhaisoni, R. Damaševičius, R. Scherer, A. Rehman, S.A. C. Bukhari, Multimodal brain tumor classification using deep learning and robust feature selection: a machine learning application for radiologists, *Diagnostics* 10 (8) (2020) 565, <https://doi.org/10.3390/diagnostics10080565>.
- [18] Akgül, İ., Kaya, V., Ünver, E., Karavaş, E., Baran, A., & Tuncer, S. (2022). Covid-19 detection on x-ray images using a deep learning architecture. *Journal of Engineering Research*, 1-16. <https://doi.org/10.36909/jer.13901>.
- [19] Yamashita R, Nishio M, Do RKG, Togashi K (2018) Convolutional neural networks: an overview and application in radiology. *Insights Imaging* 9:611–629. <https://doi.org/10.1007/s13244-018-0639-9>.
- [20] Min S, Lee B, Yoon S (2017) Deep learning in bioinformatics. *Brief Bioinform* 18:851–869. <https://doi.org/10.1093/bib/bbw068>.
- [21] Tajbakhsh N, Shin JY, Gurudu SR et al (2016) Convolutional neural networks for medical image analysis: full training or fine tuning? *IEEE Trans Med Imaging* 35:1299–1312. <https://doi.org/10.1109/TMI.2016.2535302>.
- [22] LeCun Y, Bengio Y, Hinton G (2015) Deep learning. *Nature* 521:436–444. <https://doi.org/10.1038/nature14539>.
- [23] Li Q, Cai W, Wang X, et al (2014) Medical image classification with convolutional neural network. 13th Int Conf Control Autom Robot Vision, ICARCV 2014 2014:844–848. <https://doi.org/10.1109/ICARCV.2014.7064414>.
- [24] Khan, H.A., vd. (2020). Brain tumor classification in mri image using convolutional neural network. *Math. Biosci. Eng.*, 17(5), 6203-6216. Retrieved from: <https://doi.org/10.3934/mbe.2020328>.
- [25] Basha SHS, Dubey SR, Pulabaigari V, Mukherjee S (2020) Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing* 378:112–119. <https://doi.org/10.1016/j.neucom.2019.10.008>.
- [26] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, in: 3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc., 2015.
- [27] 'Convolutional neural network', Developers Breach, 21-Aug-2020. [Online]. Available: <https://developersbreach.com/convolution-neural-network-deep-learning/>. [Accessed: 26-Apr-2023].
- [28] 'VGG-16', GeeksforGeeks, 26-Feb-2020. [Online]. Available: <https://www.geeksforgeeks.org/vgg-16-cnn-model/>. [Accessed: 26-Apr-2023].
- [29] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, in: 3rd Int. Conf. Learn. Represent. ICLR 2015- Conf. Track Proc, 2015, pp.1–14.
- [30] I. Sec, 'VGG-19 convolutional neural network', All about Machine Learning, 06-Mar-2021. [Online]. Available: <https://blog.techcraft.org/vgg-19-convolutional-neural-network/>. [Accessed: 26-Apr-2023].
- [31] K. He, X. Zhang, S. Ren, J. Sun Deep residual learning for image recognition *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2016), pp. 770-778.
- [32] A. Rastogi, 'ResNet50', Dev Genius, 14-Mar-2022. [Online]. Available: <https://blog.devgenius.io/resnet50-6b42934db431>. [Accessed: 26-Apr-2023].
- [33] 'Brain tumor detection CNN', 14-Jun-2019. [Online]. Available: <https://www.kaggle.com/code/loaiabdalslam/brain-tumor-detection-cnn/data>. [Accessed: 26-Apr-2023].
- [34] Lin M, Chen Q, Yan S (2014) Network In Network. *CoRR abs/1312.4:1–10.s*

This is an open access article under the CC-BY license

