

Araştırma Makalesi

MR Görüntülerinden Beyin Tümörünün A-ESA Tabanlı Bir Yaklaşımla Otomatik Sınıflandırılması

Elif AYDIN* , Fatih DEMİR , Abdülkadir ŞENGÜR 

Gönderim: 30.11.2023

Kabul: 22.06.2024

Fırat Üniversitesi, Teknoloji Fakültesi, Elektrik Elektronik Mühendisliği
Bölümü, Elazığ, Türkiye, elifyildiz94@outlook.com,
fatihdemir@firat.edu.tr, ksengur@firat.edu.tr

* Sorumlu yazar

Özet: Beyin tümörleri dünya çapında önemli bir patolojik durumu temsil etmektedir. Beyin içindeki dokunun anormal büyümesiyle karakterize edilen bu tümörler, sağlıklı beyin dokularını yerinden ederek ve kafa içi basıncını yükselterek ciddi bir tehdit oluşturmaktadır. Zamanında müdahale edilmediği takdirde bu durumun sonuçları ölümcül olabilir. Manyetik Rezonans Görüntüleme (MRG), özellikle yumuşak dokuları incelemek için çok uygun olan güvenilir bir tanı yöntemi olarak öne çıkmaktadır. Bu makale, Manyetik Rezonans (MR) görüntülerini kullanarak beyin kanserlerinin otomatik tespiti için yenilikçi bir derin öğrenme tabanlı yaklaşım sunmaktadır. Önerilen metodoloji, MR görüntülerinden derin özellikler çıkarmak için yeni bir Residual-ESA modelinin (A-ESA, yani Residual Convolutional Neural Network) sıfırdan eğitilmesini içermektedir. Önerilen yaklaşım, 2 sınıf (sağlıklı ve tümör) ve 4 sınıf (glioma tümörü, meningioma tümörü, hipofiz tümörü ve tümörsüz) veri setlerinden oluşan iki ayrı veri seti üzerinde değerlendirilmiştir. 2 sınıflı ve 4 sınıflı veri kümeleri için en iyi sınıflandırma doğruluğu sırasıyla %88.23 ve %77.14 olmuştur.

Anahtar Kelimeler: Beyin tümörü; MRG; derin öğrenme; sınıflandırma

Automatic Classification of Brain Tumor from MR Images Using an A-ESA Based Approach

Abstract: Brain tumors represent a significant pathological condition globally. Characterized by the aberrant growth of tissue within the brain, they pose a severe threat by displacing healthy brain tissues and elevating intracranial pressure. Without timely intervention, the implications of this condition can be fatal. Magnetic Resonance Imaging (MRI) stands as a dependable diagnostic modality, particularly well-suited for examining soft tissues. This paper introduces an innovative deep learning-based approach for the automatic detection of brain cancers utilizing Magnetic Resonance (MR) images. The proposed methodology involves the training of a novel Residual-ESA model (A-ESA, i.e., Residual Convolutional Neural Network) from the ground up to extract profound features from MR images. The proposed approach was evaluated on two separate data sets consisting of 2 classes (healthy and tumor) and 4 classes (glioma tumor, meningioma tumor, pituitary tumor and tumor-free) data sets. The best classification accuracy for the 2-class and 4-class datasets was 88.23% and 77.14%, respectively.

Keywords: Brain tumor; MRI; deep learning; classification

1. Giriş

Beyin vücudun en karmaşık kısımlarından biridir. Beyinde kontrolsüz olarak büyüyen ve çoğalan doku kitlesine beyin tümörü adı verilmektedir [1]. Amerikan Klinik Onkoloji Derneği'ne göre beyin tümörlerinin %85.0 ve %90.0'ı merkezi sinir sistemi tümörleridir [2]. Merkezi sinir sistemi tümörleri, özellikle beyin tümörleri, diğer tümör türlerine göre daha az görülmekle birlikte, beyin tümörlerinin ölüm oranı yüksektir. Bu nedenle beyin tümörlerinin erken tespiti, ölümlerin önlenmesinde ve tedavi başarısında kritik bir role sahiptir [3].

MR tekniğinin bilgisayarlı tomografi (BT) ve pozitron emisyon tomografisi (PET) gibi diğer görüntüleme tekniklerine göre birçok avantajı vardır. Beyin tümörlerinin tespiti için manyetik rezonans görüntüleme (MRI) teknolojileri, araştırmacılara gelişmiş kontrasta sahip yüksek kaliteli beyin görüntüleri sağlar. Ayrıca MR noninvazif bir tekniktir ve insan vücuduna zararsızdır. Üstelik manyetik rezonans (MR) yönteminin uygulanması hızlı olduğundan işlemler daha kısa sürede tamamlanmaktadır. Bu nedenle MR, klinik uygulamada beyin tümörü tespitinde en çok kullanılan teknik olmuştur.

Beyin tümörlerinin erken teşhisinde klinik veriler, deneyimli radyolog ve uzmanlar önemli faktörlerdir. Sağlık hizmetlerinde uzman ekip azlığı nedeniyle beyin tümörlerinin tespitine ilişkin karar verme prosedürleri zaman kaybına neden olabilmektedir. Yapay zekâ tabanlı bilgisayar destekli sistemler hem uzmanların iş yükünü azaltabilir hem de uzmanların karar verme sürecine yardımcı olabilir [4].

Önerilen yaklaşımın ana fikri, derin öğrenme yaklaşımını temel alan sağlam ve etkili bir mimari ile beyin tümörlerini MR görüntülerinden otomatik olarak sınıflandırmaktır. Önerilen yaklaşım da, otomatik sınıflandırma için sıfırdan tasarlanan ve eğitilen artık evrişimli sinir ağı (A-ESA) yapısı kullanılmaktadır. Önerilen artık yapıyla, önerilen yaklaşımın başarımı artırılmaya çalışılmıştır. Önerilen yaklaşım 2 sınıflı ve 4 sınıflı olmak üzere iki ayrı veri seti üzerinde değerlendirilmektedir.

1.1. İlgili Çalışmalar

Araştırma topluluğunda beyin tümörlerinin makine öğrenmesi teknikleriyle otomatik olarak tespit edilmesi konusunda birçok çalışma yapılmıştır. Bu çalışmalarda geleneksel ve derin öğrenme yöntemlerine dayalı iki ana yaklaşım benimsenmiştir. Geleneksel yöntemler, elle hazırlanmış özellik çıkarma ve tahmin süreçlerinden oluşmaktadır. Örneğin İslam ve ark. [5] beyin tümörlerini saptamak için çok düzeyli bir yaklaşım önerdiler. Ön işleme ve görüntü iyileştirme için medyan filtresi kullanıldı. Daha sonra özellik çıkarımı için süperpiksel ve temel bileşen analizi (TBA) tekniklerinden yararlanılmıştır. Beyin tümörlerinin segmentasyonu ve tespiti, bir şablon şemasına dayalı bir K-ortalama kümeleme algoritması ile gerçekleştirildi. Bu şablon şemasıyla algoritmanın yürütme süresi azaltıldı ve sınıflandırma performansı iyileştirildi. Ayrıca Usman ve Rajpoot [6], otomatik beyin tümörü tespiti için sağlam ve etkili bir yaklaşımı tercih etti. İlk olarak MR görüntüleri histogram eşleştirme ve sınırlayıcı kutu algoritmaları ile işlendi. İkinci olarak özellikler yoğunluk, yoğunluk farklılıkları, komşuluk bilgisi ve dalgacık teknikleriyle çıkarıldı. Son olarak, beyin tümörü örneklerini sınıflandırmak için rastgele bir orman sınıflandırıcısı kullanıldı. %88.0 doğruluk elde eden yöntem, tümörün tamamını, aktif tümörü ve gelişen tümör sınıflarını içeren 3 sınıflı bir veri seti üzerinde değerlendirildi. Ayrıca, Othman ve Basri [7] beyin tümörlerinin tespiti için TBA ve olasılıksal sinir ağına (OSA) dayalı bir

yaklaşım sundular. Özellik çıkarma ve sınıflandırma için sırasıyla TBA ve OSA algoritmaları kullanıldı. Spread değerlerine göre sınıflandırma performansı %73.0 ila %100.0 aralığında iyileştirildi.

Her bir veri yapısı için uygun özelliklerin çıkarılması gerektiğinden, geleneksel yöntemler bir veri seti için iyi performans gösterebilir ancak diğer bir veri seti için kötü performans gösterebilir. Derin öğrenme mimarileri, yapılarındaki evrişim filtreleri nedeniyle el yapımı özellik çıkarma ihtiyacını ortadan kaldırır. Bu nedenle, derin öğrenmeye dayalı çalışmalar birçok tıbbi görüntü sınıflandırma görevinde yüksek performans sağlamıştır [8-12].


Lu ve ark. [13] MR görüntülerinden beyin tümörlerini tespit etmek için önceden eğitilmiş CNN tabanlı bir model kullandılar. MobileNetV2 modelinden derin özellikler çıkarıldı. Sınıflandırma aşamasında rastgele vektör fonksiyonel bağlantı ağı algoritması %96.0 doğruluğa ulaştı. Talo ve ark. [14] MR görüntülerinden otomatik beyin tümörü tespiti için ResNet modeline dayalı bir transfer öğrenme yaklaşımı önerdiler. İkili sınıflandırma için sınıflandırma doğruluğu %95.0'ın üzerindedir. Talo ve ark. [15] beyin MRG sınıflandırması için AlexNet, VGG16, ResNet (18.34 ve 50) modellerini içeren önceden eğitilmiş beş ESA ağını çalıştırdı. En iyi doğruluk ResNet50 ile %95.23 idi. Kumar ve Mankame [16] beyin MRI sınıflandırması için çoklu süreçleri içeren yeni bir yaklaşım sundular. Segmentasyon işlemi sinüs kosinüs algoritmasına sahip karışım bulanık yapısı kullanılmıştır. Parçalara ayrılmış görüntülerden özellikleri çıkarmak için yerel ikili model ve istatistiksel bir teknik kullanıldı. Sınıflandırma sürecinde sıfırdan eğitilmiş derin bir ESA modeli çalıştırılmıştır. Bu yaklaşımla en iyi doğruluk %96.23 oldu. Raja ve Siva [17], beyin tümörü sınıflarını (düşük ve yüksek dereceli gliomalar) saptamak için derin bir otomatik kodlayıcı modeline dayalı bir mimari oluşturdu. İlk olarak MR görüntüleri medyan filtre ile ön işleme tabi tutuldu. İkinci olarak segmentasyon için Bayesian kümeleme algoritması kullanıldı. Son olarak MR görüntü örnekleri, uçtan uca öğrenmeye sahip derin bir otomatik kodlayıcı modeliyle sınıflandırıldı. Yöntemin doğruluğu %98.5'tir. Devi ve Gomathi [18] otomatik beyin tümörü tespiti için özel bir ESA modelini tercih etti. Ön işleme için Canny kenar algılama algoritmasından yararlanılmıştır. Daha sonra MR örneklerinin belirginlik haritası temsilleri oluşturuldu. Tahmin işlemi için %91.0 doğruluğa ulaşan 5 evrişim katmanına sahip bir ESA modeli çalıştırılmıştır. Alhassan ve Zainon [19] 3 sınıflı (glioma, menenjiyom ve hipofiz tümörü) beyin MRG sınıflandırması için sert swish tabanlı ReLU aktivasyon fonksiyonuna dayalı derin bir ESA yapısı önerdiler. Sert swish tabanlı ReLU aktivasyon fonksiyonu, sınıflandırma performansını %3.5 doğrulukla artırdı ve en iyi doğruluk %98.26 oldu. Kumar ve ark. [20] glioma, menenjiyom ve hipofiz sınıflarından oluşan beyin tümörü sınıflandırması için ResNet50 tabanlı bir tekniği tercih etti. Veri büyütme ve veri büyütmesiz doğruluk sonuçları sırasıyla %97.48 ve %97.08 idi. Kokkalla ve ark. [21] 3 sınıflı beyin tümörü sınıflandırması için yeni bir yaklaşım geliştirdiler. Glioma, menenjiyom ve hipofiz örneklerini tanımak için derin, yoğun bir başlangıç kalıntı ağı eğitildi. Model ortalama %99.26 doğruluğa ulaştı. Mesut ve ark. [41] 2 sınıflı beyin MR görüntüsü sınıflandırması için yeni bir yaklaşım önerdiler. Bu yaklaşımda, derin özellik çıkarımı için VGG16 ve AlexNet içeren önceden eğitilmiş iki ESA modeli kullanıldı. Ayrıca ESA modellerinin tüm evrişimsel katmanlarına Hypercolumn tekniği uygulanmıştır. Böylece derin özellik setine yerel ayırt edici özellikler de eklenmiştir. Özyinelemeli özellik algoritması ile çıkarılan 2000 özellik arasından temsil gücü yüksek 200 özellik seçilmiştir. En iyi doğruluk oranı SVM sınıflandırıcısında %96.77 idi. Kang ve ark. [42] 4 sınıflı beyin MR görüntülerinin sınıflandırılması için derin özellik çıkarımına dayalı bir yaklaşım önerdiler. Derin özellikler,

ResNet, DenseNet-169, VGGNet, AlexNet, Inceptionv3, ResNeXt, ShuffleNet, MobileNetV2 ve MnasNet'i içeren popüler önceden eğitilmiş ESA modellerinden çıkarıldı. En iyi özellik performansı DenseNet-169, ShuffleNet ve MnasNet modellerinin birleşimiyle elde edildi. Sınıflandırma aşamasında Adaboost, Gaussian Naïve Bayes, KNN, Random Forest ve DVM gibi birçok sınıflandırıcı algoritma kullanılmış ve en iyi sınıflandırma performansı DVM sınıflandırıcısı ile gerçekleştirilmiştir. En iyi doğruluk %93.72 olmuştur. Reyes ve ark. [44] beyin MR Görüntüsünde tümörleri sınıflandırmak için transfer öğrenmesi tabanlı bir yaklaşım benimsemişlerdir. MobileNet, ResNet ve VGGNet gibi modelleri denemişlerdir. Toplam 3 sınıflı bir veri seti üzerinde çalışılmıştır. Em iyi performans EfficientB3 modeli ile %98.3 olarak elde edilmiştir. Sharif ve ark. [45] Beyin tümörlerini sınıflandırmak için ESA tabanlı bir yaklaşım kullanmıştır. Sıfırdan eğitilmiş ESA modeli ile derin öznitelik çıkarmıştır. Bu öznitelikler kullanılarak DVM algoritması ile sınıflandırma yapılmıştır. Bu yaklaşım BRATS veri setlerinin dört farklı versiyonu üzerinde denenmiştir. Bütün veri setleri üzerinde %90 üzerinde sınıflandırma başarımları elde edilmiştir.


Literatüre genel olarak bakıldığında beyin tümörü ile yapılan çalışmaların çoğu hem 2 sınıflı hem de 4 sınıflı olarak değerlendirilmemiştir. Ayrıca bu çalışmaların çoğunda uçtan uca bir derin öğrenme modeli kullanmak yerine veri setine göre ayarlanmış öznitelikler ve makine öğrenmesi tabanlı sınıflandırıcılar kullanılmıştır. Dolayısıyla bu durum da model karmaşıklığını artırmaktadır. Önerilen yaklaşım sıfırdan eğitilmiş ve uçtan uca bir ESA tabanlı modeldir. Ayrıca model hafif ağırlıklı olarak ayarlanmıştır. Böylece gerçek zamanlı uygulama modellerine daha uyumlu hale getirilmiştir.

2. Veri Kümesi

Önerilen yaklaşım, alenen iki farklı veri seti üzerinde değerlendirilmiştir. İlk veri seti sağlıklı sınıfları ve beyin tümörü sınıflarını içeren MR görüntülerinden oluşuyordu [22]. 155 beyin tümörü vakasından ve 98 sağlıklı vakadan toplam 253 MR görüntüsü toplandı. MR görüntüleri farklı boyut ve dpi değerlerinde ve JPEG formatında kaydedildi. İkinci veri seti "glioma" tümör sınıflarını, "meningioma" tümör sınıflarını, "pituitary" tümörü sınıflarını ve sağlıklı sınıfları içeren MR görüntülerinden oluşmaktadır [23]. 926 "glioma" tümörlü vaka, 937 "meningioma" tümörlü vaka, 901 "pituitary" tümörlü vaka ve 500 sağlıklı vakadan toplam 3262 MR görüntüsü toplandı. MR görüntüleri JPEG formatında ve standart boyutlarda (512×512) 96 dpi çözünürlükte kaydedildi. Etiketlenen tüm işlemler uzman radyologlar tarafından gerçekleştirildi. 2 sınıflı ve 4 sınıflı veri kümeleri için her sınıftaki bazı örnekler Şekil 1 ve 2'de verilmiştir. Bununla birlikte model ağırlık parametrelerinin fazla olmaması için veri seti boyutu 224×224 boyutunda olacak şekilde yeniden boyutlandırılmıştır.



Şekil 1. 2 sınıflı veri setindeki her sınıf için bazı örnekler




Şekil 2. 4 sınıflı veri setindeki her sınıf için bazı örnekler

3. Metodoloji

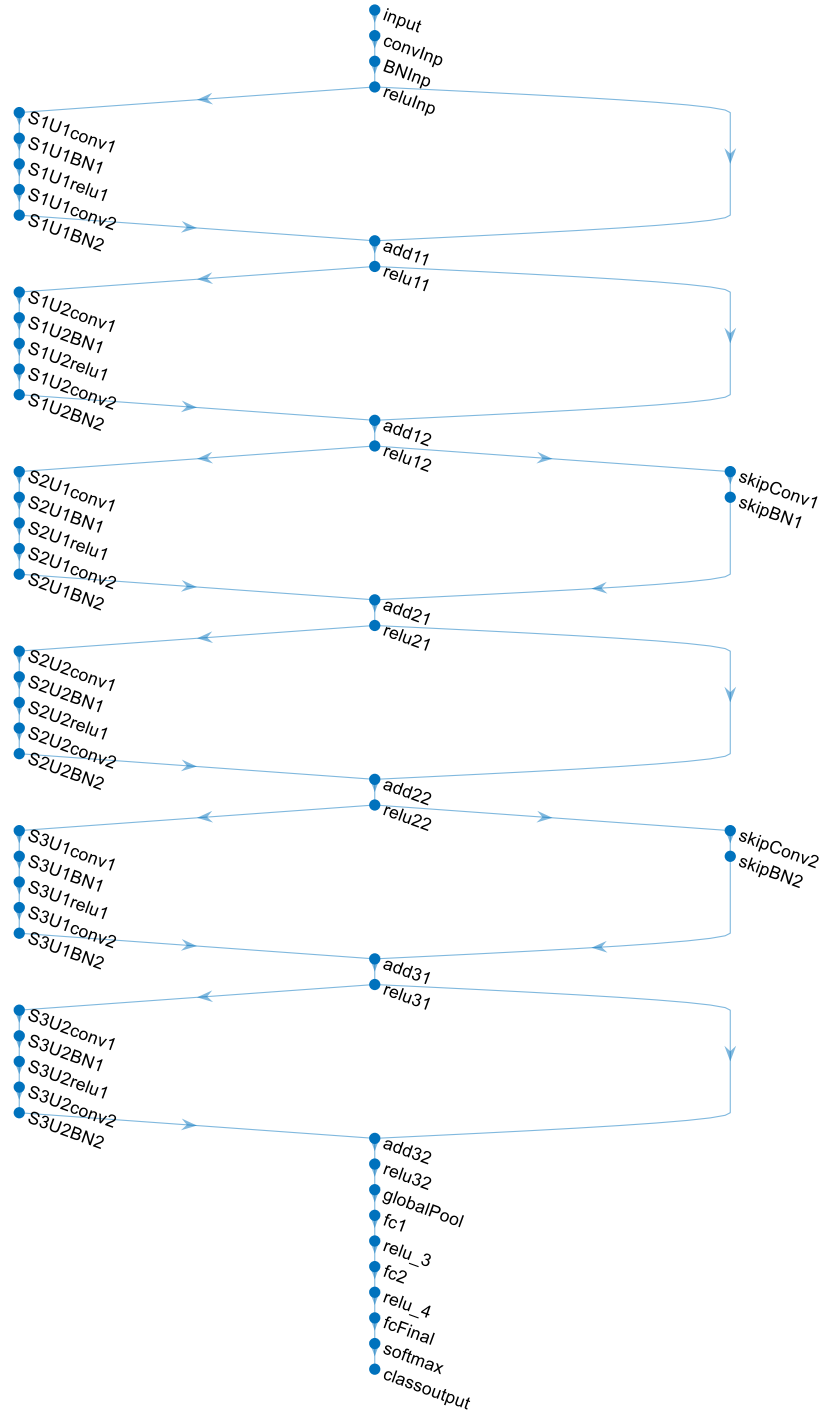
3.1. Önerilen Yaklaşım

Bu çalışmada MR görüntüleri kullanılarak beyin tümörünün tespitine yönelik yeni bir yaklaşım sunulmaktadır. Önerilen yaklaşımın çerçevesi Şekil 3'te verilmektedir. Önerilen yaklaşım iki farklı veri seti üzerinde değerlendirilmektedir. Derin öğrenme modeli olarak sıfırdan eğitilmiş yeni bir A-ESA (ing. R-CNN) mimarisi kullanılmıştır. Artık yapılar ESA modellerinde popüler bir uygulamadır. Artık yapıların kullanılması mimari boyunca gradyan akışını geliştirir ve daha derin modellerin öğrenilmesini sağlar.

Altı artık blok içeren A-ESA'nın sıralı gösterimi Şekil 4'te gösterilmektedir. Bir artık blok, iki evrişimli katmandan, iki toplu normalizasyon (BN) katmanından, bir düzeltilmiş doğrusal birim (ReLU) katmanından oluşur. Şekil 4'den de görüldüğü gibi 6 adet artık blok gözükmemektedir.



Şekil 3. Önerilen Yaklaşımın Çerçevesi



Şekil 4. Önerilen A-ESA Modelinin Mimarisi

3.2. Derin Öğrenme Teknikleri

ESA tabanlı derin öğrenme modellerindeki evrişim katmanı, genel matris çarpımlarından farklı olarak bir evrişim işlemi (*) kullanan çekirdek bloktur [24-26]. Evrişim filtresi ağırlıkları çekirdek adı verilen bir haritaya atanır. Evrişim filtresinin temel amacı, örneklerin yerel alanlarından önemli bilgiler çıkarmak ve en uygun özellik haritasını oluşturmaktır [27,28]. Ayrık değerler için 2 boyutlu evrişim fonksiyonu denklem 3.1'deki gibi ifade edilir.

$$(X * F)(i, j) = \sum_m \sum_n K(m, n) F(i - m, j - n) \quad (3.1)$$

Burada X ve F sırasıyla 2B verileri ve 2B filtre matrisini (çekirdek) temsil eder.

Toplu normalizasyon (BN) katmanı iki ana amaç için kullanılır. Bunlardan biri ağız öğrenme süresini azaltmak, diğeri ise model başlatma başarısını arttırmaktır [29]. Ayrıca, bu katman gradyan kaybolmasını azaltmak için kullanılır. BN katmanı değişkenleri aşağıdaki şekilde denklem 3.2-3.5 arasında hesaplanır.

$$\mathbf{m}_b = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (3.2)$$

$$\mathbf{v}_b = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \mathbf{m}_b)^2 \quad (3.3)$$

$$\hat{\mathbf{x}}_i = \frac{\mathbf{x}_i - \mathbf{m}_b}{\sqrt{\mathbf{v}_b + \epsilon}} \quad (3.4)$$

$$\mathbf{y}_i = \mathbf{c} \hat{\mathbf{x}}_i + \mathbf{d} \quad (3.5)$$

Burada, \mathbf{m}_b ve \mathbf{v}_b sırasıyla mini yığının ortalama değerlerini ve mini yığının varyans değerlerini temsil etmektedir. Normalleştirilmiş aktivasyon $\hat{\mathbf{x}}_i$ Eşitlik 4'te verildiği gibi hesaplanır. Sabit ϵ , \mathbf{v}_b çok küçükse sonucun çok büyük olmasını önler [30]. Denge faktörü c ve ölçek değeri d öğrenilebilir parametrelerdir ve öğrenme sırasında BN katmanının optimum çıktısını (\mathbf{y}_i) aramak için tekrarlanarak optimize edilirler [31-33].

Derin öğrenme ağlarında, evrişim katmanının çıktısı, doğrusal olmama özelliği için bir aktivasyon katmanına iletilir [34]. Derin öğrenme ağlarının gradyan patlaması ve gradyan kaybolma problemlerini ortadan kaldırmak için sigmoid ve teğet fonksiyonu yerine, aktivasyon fonksiyonu olarak düzeltilmiş doğrusal aktivasyon (ReLU) fonksiyonu kullanılmıştır. ReLU katmanı negatif girişleri sıfıra dönüştürür ve pozitif girişleri değiştirmez. Bu ifade denklem 3.6 ile ifade edilebilir.

$$f(x) = \max(0, x) \quad (3.6)$$

Maksimum ve ortalama gibi operatörlerin bulunduğu havuzlama katmanları alt örnekleme işlemini gerçekleştirir. Böylece ESA ağlarında aşırı uyumun önüne geçilmiş olur.

Tam bağlı katman, kendisinden önceki ve sonraki tüm ağırlıkları yapısındaki nöronlarla ilişkilendirir. Her nöron hangi sınıfla ne ölçüde eşleştiğine dair ipuçları verir [35]. Softmax katmanı, derin öğrenme ağlarında örnekler için tüm sınıfların olasılık puanlarını hesaplamak ve örnekleri bir sınıf etiketine atamak için kullanılır. Uçtan uca öğrenme özelliğine sahip ESA ağlarında yalnızca softmax katmanı kullanılır. Softmax aktivasyon fonksiyonu denklem 3.7'de belirtilmiştir.

$$O^k = \frac{e^{x^k}}{\sum_{i=1}^n e^{x^i}}$$

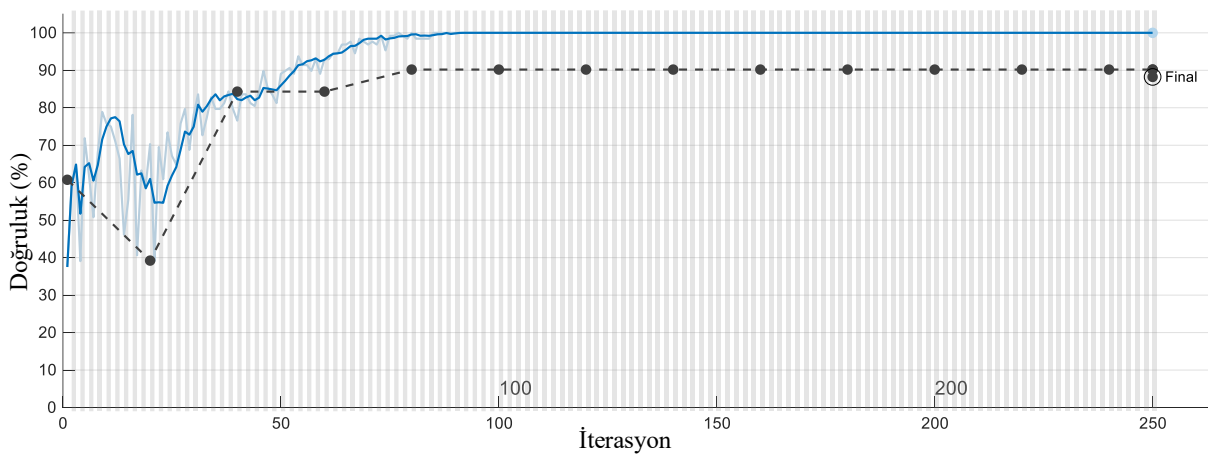
(3.7)

Burada, x ve O sırasıyla giriş ve çıkış vektörleridir. Softmax fonksiyonunda, tüm çıktılarının toplamı birdir [36].

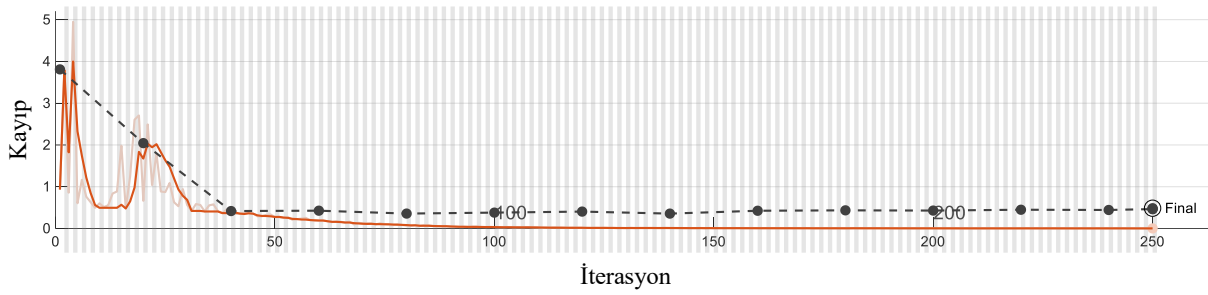
4. Deneysel Çalışmalar

Bu çalışmada kodlamalar MATLAB'da gerçekleştirilmiştir. Tüm kodlamayı yürütmek ve donanım gereksinimini azaltmak için, veri kümesindeki görüntüler 224×224 piksel olarak yeniden boyutlandırılmıştır. A-ESA (Adaptif Eşik Seçici Algoritma) modelinin eğitim parametreleri olarak 250 Epoch, 128 mini parti boyutu ve 0.001 başlangıç öğrenme oranı seçilmiştir. Mini Parti boyutu ekran kartının (NVIDIA RTX 4090) izin verdiği en yüksek limit olduğundan bu sayı seçilmiştir. Başlangıç öğrenme oranı lokal minimum noktalardan kaçınmak için küçük ayarlanmıştır. Epoch sayıları, kararlı duruma ulaşma durumlarına göre yaklaşık olarak deneme yanılma yöntemiyle belirlenmiştir. Optimizasyon çözümleyicisi olarak momentumlu stokastik gradyan inişi (MSGİ) seçilmiştir. MSGİ, hızlı olduğu ve literatürde en çok kullanılan yöntemlerden biri olduğu için tercih edilmiştir. Kayıp hesaplaması için çapraz entropi fonksiyonu kullanılmıştır.

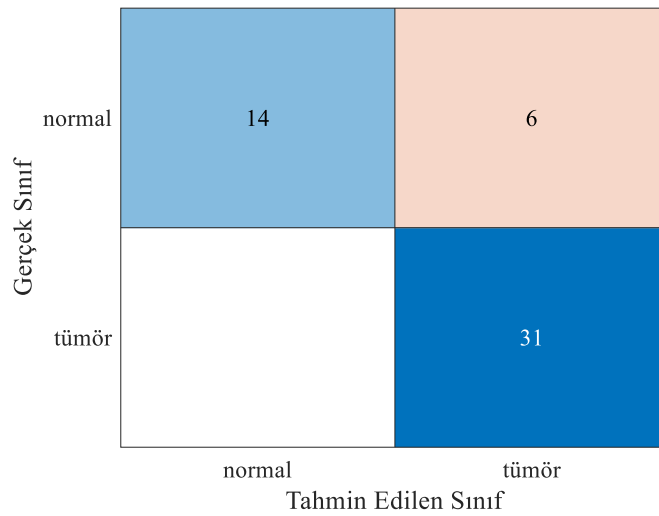
A-ESA modelinin eğitimi sırasında, 2 sınıflı veri kümesi için eğitim-doğrulama doğrulukları ve eğitim-doğrulama kayıp değerleri Şekil 5 ve 6'da verilmiştir. Her iki veri seti için eğitim ve doğrulama oranları sırasıyla %80 ve %20 oranında ayarlanmıştır. Bu oranlar, modelin genel geçerliliğini korumak için tercih edilmiştir. Daha yüksek oranlarda, 250 iterasyon sonunda 2 sınıflı sınıflandırma problemi için doğrulama kaybı ve doğruluk değerleri 0.0025 ve %100, doğrulama kaybı ve doğruluk değerleri ise 0.4858 ve %88.23 olarak gerçekleşmiştir. Doğrulama verileri için elde edilen karmaşıklık matrisi sonuçları Şekil 7'de verilmiştir.



Şekil 5. İki sınıflı veri seti için A-ESA modelinin eğitim ve doğrulama için doğruluk değişim grafiği (sürekli çizgi → eğitim değişimi, kesikli çizgi doğrulama değişimi)



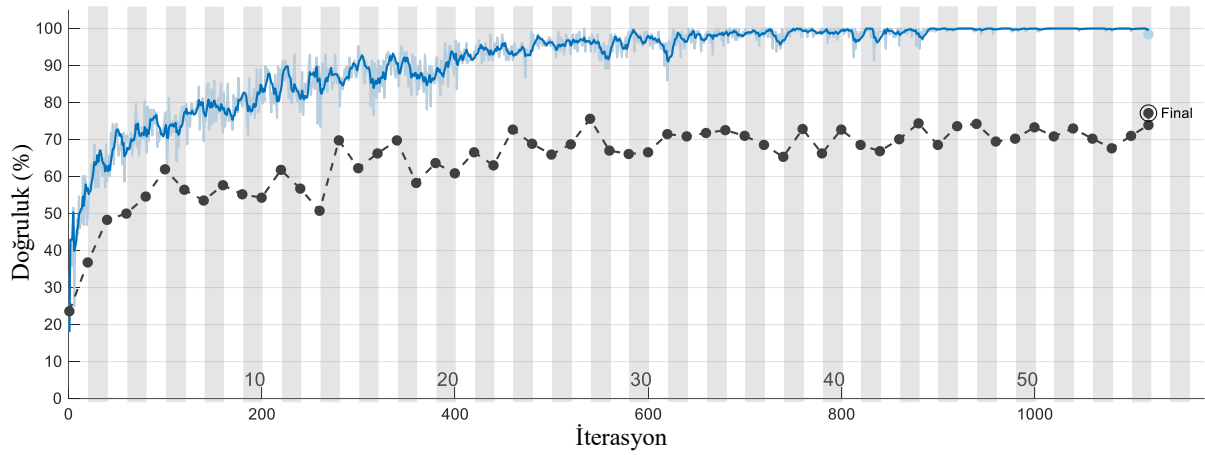
Şekil 6. İki sınıflı veri seti için A-ESA modelinin eğitim ve doğrulama için kayıp değişim grafiği (sürekli çizgi → eğitim değişimi, kesikli çizgi doğrulama değişimi)



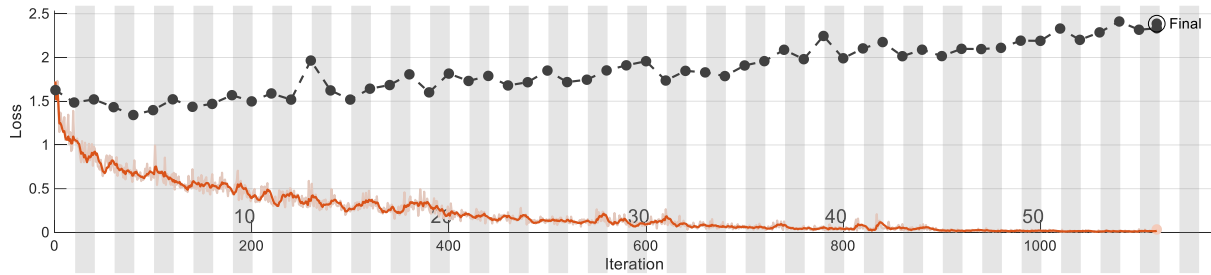
Şekil 7. İki sınıflı veri seti için A-ESA modelinin karmaşıklık matrisi

R-CNN modelinin eğitimi sırasında 4 sınıflı veri kümesi için eğitim-doğrulama doğrulukları ve eğitim-doğrulama kayıp değerleri Şekil 8 ve 9'da verilmiştir. 1138 iterasyon sonunda 4-sınıflı sınıflandırma problemi için doğrulama kaybı ve doğruluk değerleri 0.0341 ve %100, doğrulama kaybı ve doğruluk değerleri ise 2.38 ve %77.14 olarak gerçekleşmiştir. Doğrulama verileri için elde edilen karmaşıklık matrisi sonuçları Şekil 10'da verilmiştir.

İki sınıflı ve dört sınıflı veri seti için bakıldığında başarımlar üst düzeyde olmamıştır. Bunun en büyük nedenlerinden biri uçtan uca bir model kullanılmasıdır. Diğer nedeni ise hafif ağırlıklı bir yaklaşım kullanılmasıdır. Bu seçimde gerçek zamanlı uygulamalar için tercih edilmiştir.



Şekil 8. Dört sınıflı veri seti için A-ESA modelinin eğitim ve doğrulama için doğruluk değişim grafiği (sürekli çizgi → eğitim değişimi, kesikli çizgi doğrulama değişimi)



Şekil 9. Dört sınıflı veri seti için A-ESA modelinin eğitim ve doğrulama için kayıp değişim grafiği (sürekli çizgi → eğitim değişimi, kesikli çizgi doğrulama değişimi)

Gerçek Sınıf	Tahmin Edilen Sınıf			
	glioma_tumor	meningioma_tumor	no_tumor	pituitary_tumor
glioma_tumor	96	36	38	15
meningioma_tumor	30	152	1	4
no_tumor		8	86	6
pituitary_tumor		9	2	169

Şekil 10. Dört sınıflı veri seti için A-ESA modelinin karmaşıklık matrisi

5. Tartışma

Tablo 1'e bakıldığında çalışmada kullanılan aynı veri seti ile yapılan makine öğrenmesi tabanlı diğer çalışmaların sonuçlarına yer verilmiştir. Mesut ve ark. [41] AlexNet ve VGG16 mimarileri ile öz nitelik çıkarımı yapmış Hypercolumn yöntemi ile de öz nitelik temsil gücü artırılmıştır. En son olarak da öz nitelik seçimi için RFE algoritmasını kullanılmış ve 200 adet öz nitelik seçilmiştir. Bundan sonraki adımda DVM algoritması ile sınıflandırma işlemi yapılmış ve %96.77 sınıflandırma doğruluğu elde edilmiştir. Fatih ve ark. [42] R-CNN işlemi ile öz nitelik çıkarma işlemi yapmış sonraki adımda LINSR algoritması ile 100 adet öz nitelik çıkarmıştır. İkili sınıflandırma için %98.80 ve dörtlü sınıf sınıflandırması için %96.60 doğruluk değerine ulaşılmıştır. Kang ve ark. [43] DenseNet-169, Shufflenet, Mnas-Net isimli üç farklı ön eğitilmiş modelden 3024 adet öz nitelik çıkarmıştır. DVM algoritması ile %93.72 doğruluk değeri elde edilmiştir. Genel olarak bakıldığında varolan tüm yöntemler önerilen yöntemden daha iyi başarımlar sağlamıştır. Fakat bu yöntemler incelendiğinde bu yöntemlerin hiçbiri uçtan uca yöntemler değildir. Dolayısıyla gerçek dünya uygulamalarına uyarlanmaları zordur. Önerilen yöntem uçtan uca bir strateji içermektedir ve gerçek zamanlı sistemlere %100 uyumludur.

Tablo 1. Mevcut yöntemlerin performansı

Yazar	Sınıfların		Öz nitelik			
	Sayısı	Öz nitelik Çıkarma	Seçme	Öz nitelik Sayısı	Sınıflandırıcı	Doğruluk (%)
Önerilem Model	2,4	-	-	-	-	88.23, 77.14
Mesut ve ark. [41]	2	AlexNet + VGG16 + Hypercolumn	RFE	200	DVM	96.77
Fatih ve ark. [42]	2	R-CNN DenseNet-169 + Shufflenet +	LINSR	100	DVM	98.80
Kang ve ark. [43]	4	MnasNet	-	3024	DVM	93.72
Fatih ve ark. [42]	4	R-CNN	LINSR	100	DVM	96.60

Tablo 2'de Tablo 1'de verilen yöntemler ile test performansları süre kriteri açısından karşılaştırılmıştır. Bu test işlemi gerçekçi olması açısından NVIDIA Jetson Orin Nano geliştirme kartı ile yapılmıştır. Ayrıca mevcut diğer yöntemlerde oluşturulmuş ve bu karta ağırlıkları kaydedilmiştir. Tablo 2'den de görüldüğü gibi gerçek zamanlı test işleminin yapılma sürelerinde diğer yöntemler ile ciddi derecede farklılıklar bulunmaktadır. Bunun nedeni mevcut yöntemlerde kullanılan modellerde hiperparametre ve işlem sayısının çok olmasıdır. Ayrıca gerçek zamanlı çalışan modüllerin işlem gücünün fazla olmaması da bu test sürelerinin elde edilmesinde önemli bir faktör olmuştur.

Tablo 2. *Mevcut yöntemler ile test sürelerinin karşılaştırılması*

Yazar	Sınıfların		Öznitelik			Test Süresi (saniye (sn))
	Sayısı	Model	Seçme	Öznitelik Sayısı	Sınıflandırıcı	
Mesut ve ark. [41]	2	AlexNet + VGG16 + Hypercolumn	RFE	200	DVM	385
Fatih ve ark. [42]	2	R-CNN	LINSR	100	DVM	180
Kang ve ark. [43]	4	DenseNet-169 + Shufflenet + MnasNet	-	3024	DVM	494
Fatih ve ark. [42]	4	R-CNN	LINSR	100	DVM	182
Önerilen Yaklaşım	2,4	Uçtan uca R-CNN	-	-	-	2

5. Sonuçlar

Bu çalışmada, otomatik beyin tümörü tespiti için etkili ve sağlam bir derin öğrenme modeline dayanan yeni bir yaklaşım önerilmiştir. Bu yaklaşımda artık stratejisi içeren A-ESA modeli sıfırdan eğitilecek biçimde tasarlanmıştır. Artık stratejisi ile klasik bir ESA modeli ilk katman değerleri sonraki katmanlara aktarılmıştır ve sınıflandırma başarımı artırılmıştır. Sınıflandırma başarımını ölçmek için hem 2 sınıflı hem de 4 sınıflı veri setleri üzerinde önerilen model değerlendirilmiştir. 2 sınıflı model için doğrulama başarımı %88.23 olmuştur. 4 sınıflı model için ise sınıflandırma başarımı %77.14 olmuştur. Her iki veri kümesi içinde belirli oranlarda aşırı öğrenme problemine rastlanmıştır. Bu problemi önlemek için residual katmanlarda ve normal katmanlarda havuzlama katmanlarının ve “dropout” katmanlarının olacağı yeni bir tasarım modeli eklenecektir. Ayrıca artık katmanlarla paralel çalışabilen “attention” katmanları da model yapısında bulunacaktır.

Sonuç olarak bakıldığında önerilen yaklaşım sınıflandırma başarımı açısından var olan çalışmaların üzerinde bir performans sergilememiştir. Bununla birlikte gerçek zamanlı uygulamalar için idealdir. Gelişen donanım teknolojisi ile birlikte daha derin katmanlara sahip modeller daha hızlı sonuçlar verecektir. Böylece sınıflandırma başarımı yüksek modeller gerçek dünya uygulamalarına uygun hale gelecektir.

Teşekkür

Desteklerinden dolayı değerli hocam Prof. Dr. Abdulkadir Şengür’e ve değerli hocam Doç. Dr. Fatih Demir’e teşekkür ederim.

Çıkar Çatışması

Yazarlar bu makaleyle ilgili herhangi bir çıkar çatışması olmadığını bildirir.

Araştırma ve Yayın Etiği Beyanı

Yazarlar bu çalışmanın araştırma ve yayın etiğine uygun olduğunu beyan eder.

Kaynaklar

- [1] Havaei, M., vd. (2017). Brain tumor segmentation with Deep Neural Networks. *Medical Image Analysis*, 35, 18–31.
- [2] American Society of Clinical Oncology. (2021).

- [3] Petruzzi, A., Finocchiaro, C. Y., Lamperti, E., & Salmaggi, A. (2013). Living with a brain tumor. *Supportive Care in Cancer*, 21(4), 1105–1111.
- [4] Mohammed, M., Nalluru, S. S., Tadi, S., & Samineni, R. (2019). Brain tumor image classification using convolutional neural networks. *International Journal of Advanced Science and Technology*, 29(5), 928–934.
- [5] Islam, K., Ali, S., Miah, S., Rahman, M., Alam, S., & Hossain, M. A. (2021). Brain tumor detection in MR image using superpixels, principal component analysis and template-based K-means clustering algorithm. *Machine Learning with Applications*, 5, 100044.
- [6] Usman, K., & Rajpoot, K. (2017). Brain tumor classification from multi-modality MRI using wavelets and machine learning. *Pattern Analysis and Applications*, 20(3), 871–881.
- [7] Othman, M. F., & Basri, M. A. M. (2011). Probabilistic Neural Network for brain tumor classification. *Proceedings - 2011 2nd International Conference on Intelligent Systems, Modelling and Simulation*, 136–138.
- [8] Toğaçar, M., Cömert, Z., & Ergen, B. (2021). Intelligent skin cancer detection applying autoencoder, MobileNetV2 and spiking neural networks. *Chaos, Solitons & Fractals*, 144, 110714.
- [9] Loh, H. W., Ooi, C. P., Aydemir, E., Tuncer, T., Dogan, S., & Acharya, U. R. (2021). Decision support system for major depression detection using spectrogram and convolutional neural network with EEG signals. *Expert Systems*, e12773.
- [10] Karadal, C. H., Kaya, M. C., Tuncer, T., Dogan, S., & Acharya, U. R. (2021). Automated classification of remote sensing images using multileveled MobileNetV2 and DWT techniques. *Expert Systems with Applications*, 185, 115659.
- [11] Demir, F. (2021). DeepCoroNet: A deep LSTM approach for automated detection of COVID-19 cases from chest X-ray images. *Applied Soft Computing*, 103, 107160.
- [12] Demir, F. (2021). DeepBreastNet: A novel and robust approach for automated breast cancer detection from histopathological images. *Biocybernetics and Biomedical Engineering*, 41(3), 1123–1139.
- [13] Lu, S. Y., Wang, S. H., & Zhang, Y. D. (2020). A classification method for brain MRI via MobileNet and feedforward network with random weights. *Pattern Recognition Letters*, 140, 252–260.
- [14] Taló, M., Baloglu, U. B., Yildirim, O., & Acharya, U. R. (2019). Application of deep transfer learning for automated brain abnormality classification using MR images. *Cognitive Systems Research*, 54, 176–188.

- [15] Talo, M., Yildirim, O., Baloglu, U. B., Aydin, G., & Acharya, U. R. (2019). Convolutional neural networks for multi-class brain disease detection using MRI images. *Computerized Medical Imaging and Graphics*, 78, 101673.
- [16] Kumar, S., & Mankame, D. P. (2020). Optimization driven Deep Convolution Neural Network for brain tumor classification. *Biocybernetics and Biomedical Engineering*, 40(3), 1190–1204.
- [17] Raja, P. M. S., & Rani, A. V. (2020). Brain tumor classification using a hybrid deep autoencoder with Bayesian fuzzy clustering-based segmentation approach. *Biocybernetics and Biomedical Engineering*, 40(1), 440–453.
- [18] Devi, K. U., & Gomathi, R. (2020). Brain tumour classification using saliency driven nonlinear diffusion and deep learning with convolutional neural networks (CNN). *Journal of Ambient Intelligence and Humanized Computing*, 12(6), 6263–6273.
- [19] Alhassan, A. M., & Zainon, W. M. N. W. (2021). Brain tumor classification in magnetic resonance image using hard swish-based RELU activation function-convolutional neural network. *Neural Computing and Applications*, 33(15), 9075–9087.
- [20] Kumar, R. L., Kakarla, J., Isunuri, B. V., & Singh, M. (2021). Multi-class brain tumor classification using residual network and global average pooling. *Multimedia Tools and Applications*, 80(9), 13429–13438.
- [21] Kokkalla, S., Kakarla, J., Venkateswarlu, I. B., & Singh, M. (2021). Three-class brain tumor classification using deep dense inception residual network. *Soft Computing*, 25(13), 8721–8729.
- [22] Toğaçar, M., Cömert, Z., & Ergen, B. (2020). Classification of brain MRI using hyper column technique with convolutional neural network and feature selection method. *Expert Systems with Applications*, 149, 113274.
- [23] Kang, J., Ullah, Z., & Gwak, J. (2021). MRI-based brain tumor classification using ensemble of deep features and machine learning classifiers. *Sensors*, 21(6), 2222.
- [24] Chakrabarty, N. Brain MRI images for brain tumor detection.
- [25] Bhuvaji, S., Kadam, A., Bhumkar, P., Dedge, S., & Kanchan, S. Brain Tumor Classification (MRI).
- [26] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 1097–1105.
- [27] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv Preprint arXiv:1409.1556*.

- [28] Demir, F., Abdullah, D. A., & Sengur, A. (2020). A new deep CNN model for environmental sound classification. *IEEE Access*, 8, 66529–66537.
- [29] Petmezas, G., vd. (2021). Automated atrial fibrillation detection using a hybrid CNN-LSTM network on imbalanced ECG datasets. *Biomedical Signal Processing and Control*, 63, 102194.
- [30] Kucharski, A., & Fabijańska, A. (2021). CNN-watershed: A watershed transform with predicted markers for corneal endothelium image segmentation. *Biomedical Signal Processing and Control*, 68, 102805.
- [31] Hashemzahi, R., Mahdavi, S. J. S., Kheirabadi, M., & Kamel, S. R. (2020). Detection of brain tumors from MRI images base on deep learning using hybrid model CNN and NADE. *Biocybernetics and Biomedical Engineering*, 40(3), 1225–1232.
- [32] Shahabi, M. S., Shalbaf, A., & Maghsoudi, A. (2021). Prediction of drug response in major depressive disorder using ensemble of transfer learning with convolutional neural network based on EEG. *Biocybernetics and Biomedical Engineering*, 41(3), 946–959.
- [33] Li, T., Qing, C., & Tian, X. (2018). Classification of heart sounds based on convolutional neural network. *Communications in Computer and Information Science*, 819, 252–259.
- [34] Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *32nd International Conference on Machine Learning (ICML)*, 1, 448–456.
- [35] Demir, F., Ismael, A. M., & Sengur, A. (2020). Classification of lung sounds with CNN model using parallel pooling structure. *IEEE Access*, 8, 105376–105383.
- [36] Demir, F., Demir, K., & Sengur, A. (2022). DeepCov19Net: Automated COVID-19 disease detection with a robust and effective technique deep learning approach. *New Generation Computing*, 1–23.
- [37] Demir, F., Akbulut, Y., Taşcı, B., & Demir, K. (2023). Improving brain tumor classification performance with an effective approach based on new deep learning model named 3ACL from 3D MRI data. *Biomedical Signal Processing and Control*, 81, 104424.
- [38] Demir, F., Siddique, K., Alswaitti, M., Demir, K., & Sengur, A. (2022). A simple and effective approach based on a multi-level feature selection for automated Parkinson's disease detection. *Journal of Personalized Medicine*, 12(1), 55.
- [39] Demir, K., Berna, A. R. I., & Demir, F. (2020). Detection of brain tumor with a pre-trained deep learning model based on feature selection using MR images. *Firat University Journal of Experimental and Computational Engineering*, 2(1), 23–31.

- [40] Demir, K., Ay, M., Cavas, M., & Demir, F. (2023). Automated steel surface defect detection and classification using a new deep learning-based approach. *Neural Computing and Applications*, 35(11), 8389–8406.
- [41] Toğaçar, M., Cömert, Z., & Ergen, B. (2020). Classification of brain MRI using hyper column technique with convolutional neural network and feature selection method. *Expert Systems with Applications*, 149, 113274.
- [42] Demir, F., & Akbulut, Y. (2022). A new deep technique using R-CNN model and L1NSR feature selection for brain MRI classification. *Biomedical Signal Processing and Control*, 75, 103625.
- [43] Kang, J., Ullah, Z., & Gwak, J. (2021). MRI-based brain tumor classification using ensemble of deep features and machine learning classifiers. *Sensors*, 21(6), 2222.
- [44] Reyes, D., & Sánchez, J. (2024). Performance of convolutional neural networks for the classification of brain tumors using magnetic resonance imaging. *Heliyon*, 10(3).
- [45] Sharif, M. I., Li, J. P., Khan, M. A., Kadry, S., & Tariq, U. (2024). M3BTCNet: Multi-model brain tumor classification using metaheuristic deep neural network features optimization. *Neural Computing and Applications*, 36(1), 95–110.