

LSTM-ESA HİBRİT MODELİ İLE MR GÖRÜNTÜLERİNDEN BEYİN TUMÖRÜNÜN SINIFLANDIRILMASI

Emrah ASLAN^{1*}

¹Dicle Üniversitesi, Silvan Meslek Yüksekokulu, Bilgisayar Programcılığı Bölümü, Diyarbakır, 21640, Türkiye

Geliş Tarihi/Received Date: 15.11.2023 Kabul Tarihi/Accepted Date: 19.03.2024 DOI: 10.54365/adyumbd.1391157

ÖZET

Beyin tümörlerinin erken teşhisi, etkili bir tedavi için hayati öneme sahiptir. Manyetik rezonans (MR) görüntüleme, beyin tümörlerini tespit etmede temel bir araç olarak öne çıkmaktadır. Glioma, meningioma, pituitary gibi birçok tümör türü bulunmaktadır. Tümör türünü doğru bir şekilde belirlemek ve bu tespiti yapmak, beyin tümörlerini sınıflandırmanın en zorlu yönlerinden biridir. Geleneksel yöntemlerle hastalık tespiti yerine, yapay zekâ temelli bilgisayar uygulamalarının kullanılması, beyin tümörlerinin tespitinde uzmanlara önemli katkılar sağlayabilir. Özellikle derin öğrenme yöntemleri, medikal görüntülerin işlenmesine dayalı hastalık tespitinde etkili olmaktadır. Literatürde, beyin tümörlerini kategorize etmek için birçok derin öğrenme tabanlı yaklaşım bulunmaktadır. Bu çalışmada, MR görüntüleri ile beyin tümörlerini tespit etmek için bir ESA (Evrişimli Sinir Ağı) ve bir LSTM (Uzun Kısa Süreli Bellek) derin öğrenme katmanının birleştirilmiş olduğu bir model sunulmaktadır. LSTM'nin, ESA'nın özellik çıkarma yeteneklerini destekleyebileceği öne sürülmektedir. Yapılan deneylerde, önerilen LSTM-ESA modelinin standart ESA modelinden daha iyi performans gösterdiği belirlenmiştir. Bu modelin kullanılmasıyla, beyin tümörlerinin tespitinde %98,1 doğruluk skoru elde edilmiştir. Bu sonuç, literatürdeki benzer çalışmalarla karşılaştırıldığında daha yüksek bir başarı elde ettiğini göstermektedir.

Anahtar Kelimeler: LSTM, Tümör, MR, ESA

CLASSIFICATION OF BRAIN TUMOR FROM MR IMAGES WITH LSTM-CNN HYBRID MODEL

ABSTRACT

Early detection of brain tumours is vital for effective treatment. Magnetic resonance imaging (MRI) is a fundamental tool for detecting brain tumours. There are many types of tumours such as glioma, meningioma, pituitary. Accurately determining the tumour type and making this determination is one of the most challenging aspects of classifying brain tumours. The use of artificial intelligence-based computer applications instead of traditional methods of disease detection can make significant contributions to experts in the detection of brain tumours. Especially deep learning methods are effective in disease detection based on the processing of medical images. In the literature, there are many deep learning-based approaches for categorising brain tumours. In this study, a model combining a CNN (Convolutional Neural Network) and a LSTM (Long Short Term Memory) deep learning layer is presented to detect brain tumours with MRI images. It is suggested that LSTM can support the feature extraction capabilities of CNN. In the experiments, it is found that the proposed LSTM-CNN model outperforms the standard CNN model. Using this model, an accuracy score of 98.1% was obtained in the detection of brain tumours. This result shows that it achieves a higher success compared to similar studies in the literature.

Keywords: CNN, LSTM, Tumour, MRI

* e-posta¹ : emrah.aslan@dicle.edu.tr ORCID ID: <https://orcid.org/0000-0002-0181-3658> (Sorumlu Yazar)

1. Giriş

Beyin tümörlerinin teşhisi, genellikle MRG ve Bilgisayarlı Tomografi (BT) gibi görüntüleme teknikleriyle gerçekleştirilmektedir. Ancak, bu tekniklerle beyin tümörlerini diğer nörolojik hastalıklardan ayırmak, değerlendiren uzmanın tecrübesine ve subjektif değerlendirmesine bağlı olarak zorlu bir süreçtir. Beyin tümörlerinin oluşumu, diğer hastalıklardan farklı metabolitlerin ortaya çıkmasına neden olabilir ve bu metabolitlerin ölçümü, teşhis ve ayırıcı tanı süreçlerinde önemli bir rol oynayabilir. Glioma, meningioma ve pituitary tümörü gibi önemli tümör türleri, beyin tümörlerinin heterojen yapısını temsil etmektedir. Gliomlar, çeşitli beyin sinir sistemi bölgelerinde ortaya çıkabilen tümörlerdir ve farklı semptomlara neden olabilir [1]. Meningioma tümörü, beyinde meninkslerden kaynaklanan ve sıklıkla görülen bir tümör türüdür. Beyin tümörlerinin erken teşhisi, tedavi stratejilerinin belirlenmesi açısından hayati önem taşır. Bu nedenle, tümör teşhisine yönelik stratejiler, özellikle görüntü işleme ve yapay zeka alanlarında yapılan araştırmalarda büyük bir öneme sahiptir. Bu çalışmalar, bilgisayar destekli teşhis yöntemlerinin, özellikle derin öğrenme ve yapay zeka algoritmalarının entegrasyonunun, beyin tümörlerinin teşhisi ve sınıflandırılmasında gelişmiş doğruluk ve etkinlik sağlayabileceğini göstermektedir [2].

Tümörlerin erken aşamalarda otomatik olarak tespiti, günümüz sağlık teknolojisinin önemli bir hedefidir. Bu süreç, tümörlerin sağlıklı dokulardan ayrıştırılması ve tanımlanması, tıbbi tedavi sürecinde özel bir yer tutar [3]. Erken aşamada tümörün izole edilip boyutu ve yayılma derecesinin değerlendirilmesi, tedavi sürecini daha etkili hale getirebilir. Ancak, beyin tümörlerinin boyut ve çözünürlüğünü erken aşamada kesin olarak belirlemek karmaşık bir süreçtir. Çünkü bu tür tespitler genellikle tam olarak yapılamaz [4]. Eğer, bir tümör erken aşamada tespit edilir ve tedavi uygulanırsa, hastanın iyileşme olasılığı yüksektir. Çünkü tümör tedavisi genellikle erken teşhisle ilişkilidir. Tıbbi inceleme için genellikle BT veya MRG gibi yöntemler kullanılır. MRG, hassas beyin görüntüleri üretir ve beyin hasarını tespit etmek ve değerlendirmek için en yaygın kullanılan yöntemlerden biridir. MRG, insan yumuşak dokularını en kesin şekilde tahmin etme yeteneğine sahiptir [5]. Son yıllarda, bu alanda makine öğrenimi teknikleri ve özel modeller kullanılarak önemli ilerlemeler kaydedilmiştir.

Makine Öğrenimi (ML), Yapay Zekâ (YZ) alanında önemli bir rol oynamaktadır. Makine öğrenimi tabanlı sistemler artık özel programlamaya gerek duymadan işlev gösterebilmektedir. Son zamanlarda, araştırmacılar bu alanda derin öğrenme adı verilen önemli bir teknolojik gelişmeyi sunmuşlardır. Görüntü sınıflandırma ve tanımlama uygulamalarının geniş bir yelpazesi, bu görevleri yüksek doğrulukla gerçekleştirebilen gelişmiş öğrenme yöntemlerini ve tasarımlarını gerektirir [6]. Görüntü segmentasyonu genellikle tam ve kısmi olarak sınıflandırılabilir. Tam ve doğru segmentasyon, giriş görüntü elemanlarını belirgin şekilde ayırarak bölgeleri net bir şekilde tanımlar. Ancak kısmi segmentasyon sırasında elde edilen bölgeler artık giriş görüntüsüyle tam olarak örtüşmez. Bu nedenle, görüntü segmentasyonu, tipik olarak bir piksel sınıflandırması gerektiği için yaygın bir zorluk olarak kabul edilir.

Bu çalışmada, beyin tümörlerini tanımak ve sınıflandırmak için ESA ve LSTM katmanlarını içeren yeni bir derin öğrenme yaklaşımı önerilmektedir. Önerilen derin öğrenme tabanlı ESA tasarımının performansını değerlendirmek amacıyla, toplam 3264 görüntü içeren bir Kaggle veri seti kullanılmıştır. Bu veri seti 394 test görüntüsü ve 2870 eğitim görüntüsü içermektedir. Ayrıca, önerilen modelin diğer mevcut modellerle karşılaştırması yapılarak etkinliği doğrulanmıştır.

Bu çalışma, beyin tümörlerinin tanınması alanında önemli bir ilerleme sunmaktadır. MRG verileri üzerine odaklanarak, bilgisayar destekli bir çözüm geliştirilmiş ve geleneksel görüntüleme tekniklerine alternatif bir yaklaşım önerilmiştir. Önerilen model, önceki öğrenmeleri hatırlama yeteneği ve özellik çıkarma süreçlerinde etkinliğiyle birleşerek beyin tümörlerinin yüksek doğrulukla tanınabilmesini sağlamaktadır. Elde edilen sonuçlar, önerilen modelin kullanıldığı durumda beyin tümörlerinin etkili bir

şekilde sınıflandırılabilceğini göstermektedir. Bu çalışma, tıbbi görüntüleme ve derin öğrenme alanındaki araştırmalara katkıda bulunarak, hastalıkların teşhisi ve sınıflandırılmasında yeni perspektifler sunmaktadır.

Makalenin geri kalanı şu bölümlere ayrılmıştır: İkinci bölümde, MRG kullanılarak beyin tümörlerini tanıma ve sınıflandırmaya yönelik literatür taraması sunulmakta ve beyin tümörü tespitinin kritik önemi vurgulanmaktadır. Bölüm 3'te beyin tümörü tanımlama ve sınıflandırma yöntemleri ayrıntılı olarak açıklamaktadır. Bölüm 4'te deneysel veriler ve yorumları sunulmuştur. Son olarak, Bölüm 5'te çalışmanın sonuçları verilmiştir.

2. İlgili Çalışmalar

Beyin tümörlerinin MRG ile tespit edilmesine yönelik birçok araştırma yapılmıştır. Günümüzde, tıbbi görüntüleme büyük ölçüde derin öğrenme tekniklerine dayanmaktadır. İnsan beyninin karmaşık yapısını sadece basit görüntüleme teknikleriyle tespit etmek oldukça önemlidir. B. Srikanth ve ekibi, beyin tümörlerinin merkezi sinir sistemi olan beyaz hücre kümelerinden oluştuğunu öne sürmüştür [7]. Beyin tümörleri, hücrelerin hızlı çoğalması sonucu ortaya çıkan ve erken teşhis edilmezse ölümcül olabilen anormal hücre büyümesinin bir türüdür. Meningioma, glioma, pituitary ve iyi huylu beyin tümörleri, en yaygın görülen türler arasında yer almaktadır. Beyin tümörlerini manuel olarak tanımlamak ve kategorize etmek, doktorlar ve klinik uzmanlar için zorlu bir görevdir ve doğrulukları genellikle deneyime dayanmaktadır. Bu sınırlamaları aşmak için bilgisayar destekli teknolojilere olan ihtiyaç giderek artmaktadır. YZ, modern tıbbi standartlar geliştikçe beyin dokularını tanıma ve kategorize etme konusunda giderek daha fazla fayda sağlamaktadır. Bu konu araştırmacılar arasında büyük bir ilgi konusu olmuş ve çeşitli makine öğrenimi ve derin öğrenme mimarileri kullanılarak çeşitli çalışmalar gerçekleştirilmiştir.

Geçmişte, tümörleri tanımlamak ve MRG kullanarak sınıflandırmak için Destek Vektör Makinaları (DVM), K-En Yakın Komşuluk (K-EYK) ve ESA gibi farklı makine öğrenimi teknikleri kullanılmıştır. Ancak bu algoritmalar her zaman en iyi sonuçları vermemiştir. Bu nedenle, beyin tümörlerini MRG çoklu sınıflandırmak için derin sinir ağı tabanlı bir VGG-16 ağı önerilmiştir. Raheleh Hashemzahi ve diğerleri, MRG beyin kanserini sınıflandırmak için özellikleri çıkarmak ve veri dağılımını otomatik olarak hesaplamak için Evrişimli Sinir Ağı (ESA) ve sinirsel oto-regresif dağılım tahmininden oluşan bir hibrit yaklaşım önermişlerdir. Önerdikleri yaklaşımın %95 sınıflandırma doğruluğuna sahip olduğunu göstermişlerdir [8].

Halimeh ve diğerleri, beyin tümörleri ve multipl skleroz gibi beyin bozukluklarının tespit edilmesi için temel bir yaklaşım olan MRG kullanımını önermiştir. Beyin tümörü hastalığı, anormal beyin hücrelerinin büyümesi sonucu ortaya çıkar. Multipl skleroz (MS), kronik bir durum olup beyin ve nörolojik sisteme zarar verir. Hem MS hem de tümörler, en iyi MRG kullanılarak tespit edilir ve teşhis edilir. Benzerlikleri nedeniyle, yanlış teşhisler hastanın zarar görmesine ve hatta ölümüne neden olabilir. Yazarlar, beyin tümörü ve MS aynı anda teşhis etmek için bir ESA kullanmışlardır. Sonuç olarak, bu yöntemle tümör ve MS teşhisinde %96 doğruluk elde etmişlerdir [9].

Ameer ve arkadaşlarının önerdiği çalışma, beyin tümörlerinin sınıflandırılması ve bilgisayar destekli teşhis konusunda önemli bir katkı sunmaktadır. Bu makalede, gliomlar, meningiomlar, iyi huylu ve pituitary tümörleri için üç sınıflı bir sınıflandırma sistemi ele alınmıştır. Önerilen yöntem, beyin MRG'den özellikler çıkarmak için önceden eğitilmiş bir GoogleNet kullanmış ve ardından bu özellikleri sınıflandırmak için derin transfer öğrenme yöntemi uygulanmıştır. Sınıflandırma işlemi için sertifikalı sınıflandırıcılar kullanılmıştır [10].

Mohsen ve diğerleri, derin öğrenmenin son yıllarda hızla popülerlik kazanan, nispeten genç bir makine öğrenimi alanı olduğunu vurgulamışlardır. Derin öğrenme, çeşitli uygulamalarda başarıyla

kullanılan ve karmaşık sorunların üstesinden gelmede önemli bir makine öğrenimi tekniği olarak kabul edilmektedir. Araştırmacılar, 66 adet beyin MRG taramasını dört farklı kategoride sınıflandırmak için derin sinir ağı sınıflandırıcısını kullanmışlardır. Bu sınıflandırıcı, özellikleri çıkarmak için ayrık dalgacık dönüşümü ve temel bileşen analizi gibi güçlü teknikleri bir araya getirerek, yaygın kullanılan tüm performans ölçümleri için son derece başarılı sonuçlar üretmiştir [11].

Sobhaninia ve diğerleri tarafından belirtilmiştir ki derin öğrenme, bilgisayarlı görüş alanında önemli bir rol oynamaktadır. Bu, hastalık teşhis süreçlerinde insan çabasını azaltma potansiyeli taşımaktadır. Özellikle beyin tümörü analizi, küçük hataların düşünce süreçlerinde felakete yol açabileceğinden, en üst düzey hassasiyeti gerektiren bir alandır. Bu nedenle, beyin tümörü segmentasyonu, bilimsel uygulamalar için sağlam bir yaklaşım olarak öne çıkmaktadır. Farklı tekniklerin kullanıldığı beyin tümörü segmentasyonu için mevcut yöntemler, genellikle maksimum hassasiyeti sağlamada yetersiz kalmaktadır. Bu bağlamda, yazarlar, derin öğrenmeyi kullanarak beyin tümörlerini segmente etmek amacıyla bir yöntem geliştirmişlerdir. Yaptıkları araştırmada, özel MRG pikselleri ile çalışmışlar ve çeşitli segmentasyon ağlarını uygulamışlardır. Ayrı bir ağı kullanılmasının etkisi, tek bir sonuç ağı ile karşılaştırılarak incelenmiştir. Gerçekleştirilen deneyler, tek ağ durumunda 0.73 ve birden fazla ağ kullanıldığında 0.79 olan skorlar elde edilmiştir [12]. Sajid ve diğerleri, gliomların oldukça yaygın ve hızla ilerleyen tümörler olduğunu vurgulamışlardır. Gliomların bölünmesi, bilgisayar destekli analizle, anormal şekil ve tümörün ince sınırlamaları nedeniyle zorlu bir görevdir. Bu çalışmada, özel MRG kullanılarak beyin tümörünü segmentlere ayırmak için derin öğrenmeye dayalı saf bir yöntem sunulmaktadır. Ayrıca, ESA ile ileri beslemeyi atlayarak ve önyargı alanını ele alarak küçük yanlış pozitifleri azaltmak için özel bir işleme adımı kullanılmıştır. Önerilen teknik, BRATS 2013 veri seti üzerinde test edilmiş ve tüm tümör bölgesi için 0.86 hassasiyet ve 0.86 özgüllük elde etmiştir [13].

Hussain, S. ve Majid, gliomların en yaygın ve tehlikeli beyin tümörü türü olduğunu belirtmişlerdir. Bu tür tümörlerin doğru bir şekilde tespiti, sorunun devamı için kritik öneme sahiptir. Ancak, tümörlerin garip bir şekle sahip olmaları ve hızlı dağılımları, tıbbi amaçlar için ölçeklemeyi zorlaştırmaktadır. Bu makale, derin evrişimli sinir ağlarına dayalı bir yaklaşım önererek otomatik beyin tümörü segmentasyon sistemini ele almaktadır. Derin ağlar, önemli sayıda parametre içerdiğinden, özellikle sınırlı kaynaklarla çalışıldığında aşırı yüklenme sorunu ortaya çıkmaktadır. Bu sorunu çözmek için, maksimum ve sızdıran katmanları kullanarak aşırı yüklemeleri en aza indirmişlerdir. Ayrıca, modelde 37x37 ve 19x19 eşit ortalama piksel düzeltme türlerini belirleyerek ve tüm düzeltme tabanlı okul eğitimi tekniğini kullanarak önerilen yaklaşımı geliştirmişlerdir. Önerilen teknik, BRATS 2013 veri seti üzerinde değerlendirilmiş ve temel genel performans etiketlerinde mevcut teknolojilere göre daha iyi bir performans sergilemiştir [14].

Pereira ve arkadaşları, gliomlar olarak adlandırılan beyin tümörlerinin alışılmadık ve rekabetçi bir tür olduğunu vurgulayarak, genellikle daha uzun bir ortalama yaşam süresine neden olduğunu belirtmişlerdir. Bu durum, onkoloji hastaları için etkili bir yaşam kalitesi geliştirme açısından tedavi planlamasının büyük öneme sahip olduğunu ortaya koymaktadır. MRG kullanılarak teşhis konulan beyin tümörü hastalarının farklı evrelerinde Doğrusal Ayırma Analizi (DAA) ve DVM sınıflandırma yöntemleri kullanılarak yapılan bir çalışmada, Doğrusal Ayırma Analizi yöntemi %65 başarı elde ederken, DVM yöntemi kullanarak %94 başarı sağlamıştır [15]. Nagorive ve Joshi'nin çalışmalarında MR spektroskopisi ile elde edilen veriler kullanılarak beyin tümörünün evresinin tahmin edilmesi üzerine odaklanılmıştır [16]. Carlos, Cr ve Naa değerleri MR spektroskopisi aracılığıyla okunmuş ve farklı hastanelerden alınan 88 beyin tümörü hastasının bilgileri kullanılarak, DVM yöntemiyle veri setine yazılan veriler %67 sınıflandırma başarısı elde etmiştir. Bir diğer çalışmada, beyin tümörü teşhisi konulan hastaların evrelerinin tahmin edilmesi amacıyla MRS spektral görüntülerinin kullanıldığı belirtilmiştir [17]. Yapılan çalışmada, Gaussian Ayırıştırma ve YSA teknikleriyle elde edilen başarı oranının %94 olduğu rapor edilmiştir.


Çalışmada önerilen LSTM tabanlı derin öğrenme tekniği, biyomedikal uygulamalarda kullanılacak güncel bir sınıflandırma tekniği olarak öne çıkmaktadır. Şeker hastalığının tip 2 teşhisi ve bu hastalığın neden olduğu kalp hastalığını önleme önemine vurgu yapan bir başka çalışmada, EKG sinyalleriyle yapılan sınıflandırmada, ESA yöntemi %90 başarı elde ederken, ESA+LSTM yöntemi %95 başarı sağlamıştır [18].

Yüksek tansiyon ve düşük tansiyon, ölümcül sonuçlar doğurabilecek hastalıklardır; bu nedenle kan basıncının düzenli olarak ölçülmesi, bu hastalıkların erken teşhisi açısından kritik bir öneme sahiptir. Bu konuda yapılan bir çalışmada, Elektrokardiyografi (EKG) ve fotopleitizmografi (FPG) sinyallerinden elde edilen özellikler kullanılarak yüksek ve düşük tansiyon tahmini yapılmıştır [19]. Toplam 39 hasta verisi, EKG ve FPG sinyallerinden çıkarılan özelliklerin yapay sinir ağı ve LSTM derin öğrenme ile sınıflandırılmasıyla değerlendirilmiştir. Çalışmanın başarısı, Adaboost veri madenciliği ve LSTM derin öğrenme yöntemleriyle hesaplanan ortalama mutlak hata (mean absolute error / MAE) ve kök ortalama mutlak hata (root mean absolute error / RMAE) hata oranları karşılaştırılarak belirlenmiştir. Çalışmada önerilen ESA-LSTM modelinin, daha düşük hata oranlarına sahip olduğu gözlemlenmiştir.

3. Materyal ve Metod


3.1 Beyin Tümörü Mrg Veri Seti

Veri seti, toplamda 3264 MRG'den oluşmaktadır ve bu görüntüler glioma, meningioma, pituitary tümörleri ve iyi huylu tümör durumlarını içermektedir. Görüntülerin 394 tanesi test verisi olarak kullanılırken, 2870 tanesi eğitim verisi olarak değerlendirilmiştir. Veri setine Kaggle üzerinden açık erişimli olarak <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri> url adresinden erişim sağlanmaktadır [20].



Şekil 1. Veri setinden örnek görüntüler


Veri kümesi, Şekil 1'de veri setinden örnek beyin MR görüntüleri verilmiştir. Şekil 2'de test ve eğitim setinin verilerinin dağılımı gösterilmektedir. Eğitim seti, modelin öğrenme sürecini güdüleyen ve parametrelerini ayarlamak için kullanılan verileri içerirken, test seti modelin genelleme yeteneğini değerlendirmek amacıyla ayrılmıştır. Şekil 3 ve 4'te dört farklı sınıfa ait veri dağılımı sunulmuştur.



Şekil 2. Test ve Eğitim setinin örneklem sayıları




Şekil 3. Eğitim sınıfı örneklem sayıları



Şekil 4. Test sınıfı örneklem sayıları

3.2 Evrişimli Sinir Ağı

ESA, bilgisayarlı görüş, desen tanıma ve diğer görsel bilgi işleme görevlerinde başarılı bir şekilde kullanılan derin öğrenme modellerinden biridir. Temelde, evrişim katmanları, havuzlama katmanları ve tam bağlantılı katmanlardan oluşan bir mimariye sahiptir. Evrişim katmanları, giriş verisindeki özellikleri vurgular ve evrişim işlemleriyle bu özellikleri çıkararak özellik haritalarını oluşturur. Havuzlama katmanları, özellik haritalarındaki boyutu azaltarak işlem yükünü hafifletirken önemli bilgileri korur. Tam bağlantılı katmanlar, elde edilen özellik haritalarını kullanarak nihai sınıflandırmayı gerçekleştirir. ESA'ler, özellikle görüntü sınıflandırma, nesne tespiti ve yüz tanıma gibi uygulamalarda yüksek başarı elde etmiştir. Ayrıca, transfer öğrenme, batch normalization, dropout gibi optimizasyon teknikleri ve çeşitli aktivasyon fonksiyonları kullanarak performanslarını artırmak için sürekli olarak geliştirilmektedir. Bu modeller, geniş veri setlerinden öğrenerek, karmaşık ilişkileri keşfetme yetenekleriyle öne çıkar ve özellikle büyük veri tabanlı görsel analiz uygulamalarında etkili bir şekilde kullanılabilirler. Gelişen donanım ve yazılım altyapısıyla birlikte, ESA'ler, gelecekteki akademik araştırmalar ve endüstriyel uygulamalar için önemli bir rol oynamaya devam edecektir. Şekil 5'te ESA mimarisi verilmiştir.



Şekil 5. ESA mimarisi

3.3 Uzun Kısa Süreli Bellek (Long Short-Term Memory / LSTM) Ağı,

Sıra ilişkilerini öğrenme yeteneğine sahip bir tür tekrarlayan sinir ağıdır. LSTM'ler, sıra tahmin problemlerinde ve karmaşık zaman serileri analizlerinde yaygın olarak kullanılır. Özellikle konuşma tanıma, makine çevirisi ve hisse senedi fiyat tahminleri gibi alanlarda başarılı sonuçlar elde edilir. LSTM'ler, geleneksel Tekrarlayan Sinir Ağlarına (TSA) göre daha uzun zaman aralıklarını hatırlayabilme yeteneğine sahiptir. Bu, geçmiş bilgilerin gelecekteki tahminlerde daha fazla ağırlığa sahip olduğu durumlar için oldukça önemlidir. LSTM, bu uzun vadeli bağımlılıkları daha iyi yakalayabilme yeteneği ile bilinir. Çift yönlü LSTM'ler, giriş verisini hem ileri hem de geri yönde işleyen ağlardır. Bu, özellikle sıra tahmin problemleri için yararlıdır çünkü hem geçmiş hem de gelecek bilgilere erişim sağlar. Diziden diziye LSTM modelleri, bir giriş sırasını başka bir çıkış sırasına dönüştürmek için kullanılır. Örneğin, İngilizce bir cümleyi Almanca'ya çevirmek için bir diziden diziye modeli kullanılabilir. LSTM denklemleri, ağın iç işleyişini matematiksel olarak açıklar. Bu denklemler, ağın hafıza hücresinin nasıl güncellendiğini ve bilgilerin nasıl iletim edildiğini tanımlar. Bu denklemler, LSTM'nin karmaşıklığını ve etkinliğini anlamak için önemlidir. LSTM, derin öğrenme alanında oldukça önemli bir konudur ve birçok uygulama alanında başarıyla kullanılır. LSTM'nin çalışma prensipleri ve denklemleri, uzmanlar tarafından daha iyi açıklanabilir ve anlaşılabilir olabilir, ancak genel bir

kavramsal anlayış, bu güçlü sinir ağı türünün nasıl çalıştığını anlamak için yeterlidir [6]. Şekil 6'da LSTM çalışma prensibi şeması verilmiştir.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$


$$\tilde{C} = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t * \tanh(C_t) \quad (6)$$


Burada b bias vektörü, W ağırlık matrisi, σ sigmoid fonksiyonu, t zamanı, Rd vektör koleksiyonunu İt girişleri, Ct bellek hücrelerini, Ot çıkışı, ht gizli katmanı ve d hafızanın boyutunu ifade etmektedir.



Şekil 6. LSTM çalışma prensibi

3.4 LSTM-ESA Mimarisi

Toplu Normalleştirme katmanı, normalleştirme nedeniyle aktivasyon fonksiyonunun birdeki karakteristik çarpıklığını ve sıfıra yakın ortalama aktivasyon ortalamasını koruyarak önceki katmana dönüşümü uygular. Normalleştirmeyi her işlem için kullanılır. Böylece her bir girdi özellik haritası tek tek normalleştirilir. Eksen seçeneği, yerleşimin hangi eksen üzerinde sonlandırılması gerektiğini tanımlar. Eğitim sırasında verileri normalleştirmek için, her grup için bilgileri yönettik ve eğitim aşamasında bir noktada hesaplanan ortalamaları kullanılmıştır [19]. Şekil 7'de önerilen ESA-LSTM mimarisi verilmiştir.



Şekil 7. ESA-LSTM mimarisi.


Toplu Normleştirme katmanının çıkış katmanı giriş katmanı ile aynı olduğu için LSTM hücresiyle birlikte kullanılamaz. LSTM katmanından önce, şekli yeniden şekillendirmek için bir Reshape katmanı kullanılabilir. Girdi katmanının boyutları yeniden boyutlandırıldığında LSTM hücresinden aktarılır. LSTM hücresi bir tanh veya hiperbolik tanjant tarafından etkinleştirilir. Ek olarak, LSTM hücresi, bilginin aşırı uyumunu önlemeye yardımcı olan bir bırakma oranı içerir. Bu sayede LSTM'nin özellikleri, giriş görüntüsünün uzun vadeli yapısını ve biçimini benzersiz bir düzende öğrenecektir. Ek olarak, evrişim katmanı LSTM katmanının çıktısını anında alır. Evrişim çekirdekleri, katmanın girdisiyle tek bir zamansal boyutta evrişim yaparak bir sonuç tensörü oluşturan bir evrişim katmanı kullanılarak oluşturulur. Evrişim katmanı en önemli yerel özellikleri çıkaracaktır. Bu evrişimsel katmanda aktivasyon fonksiyonu olarak Doğrultulmuş Doğrusal Birim kullanılmıştır. ESA'de daha sonra yer alan evrişimsel katman, nöronların mükemmel bağlantısı nedeniyle bir ayrılma katmanı olasılığını önler. Karışık sınıfları içeren sınıflandırma problemleri LSTM-ESA ağlarından oluşan bir model kullanılarak çözülebilir [21].

3.5 Önerilen ESA-LSTM Yaklaşımı

Önerilen hesaplama mimarisi, Derin Öğrenme (DÖ) için bir ESA ve LSTM içermektedir. Bu yaklaşım, beyin tümörlerini tanımak ve kategorize etmek için MRG kullanarak insan hayatını kurtarmak veya iyileştirmek amacıyla büyük öneme sahiptir. Beyin tümörlerinin erken teşhisi, tedavi seçenekleri ve hayatta kalma beklentileri açısından önemli bir rol oynayabilir. Araştırmacılar, beyin tümörlerini tespit etmek ve sınıflandırmak için farklı sınıflandırma yöntemleri önermiş olsa da tespit doğruluğu konusunda sınırlamalar vardır. Bu bağlamda, DÖ, görüntü işleme alanında çeşitli işlemleri gerçekleştirmek için kullanılan modern bir teknolojidir [22]. Derin Öğrenme stratejileri içinde, özellikle

beyin tümörlerinin sınıflandırılmasında, evrimsel sinir ağı (ESA) en yaygın kullanılan sınıflandırıcıdır ve bu alandaki önemli bir rol oynamıştır [23]. ESA'ler, zaman serilerini tahmin etmek için son derece uygundur. Bu, artan evrişimleri veya tek hücreler arasındaki ilişkileri ölçmek için filtreleri kullanabilme yetenekleri sayesinde mümkün olur. Her bir hücrenin yapısı ve boyutu, sinir ağının farklı ve çeşitlendirilmiş zaman serisi gözlemleri arasındaki ilişkileri tam olarak anlayabilmesini sağlar [24].

Zaman serilerini belirlerken, ESA ve LSTM katmanları genellikle bir araya getirilir. LSTM katmanı, zaman serilerindeki sonraki bağımlılıkları hesaba katabilirken, ESA katmanı bu süreci genişletilmiş evrişimler aracılığıyla ek bilgilerle zenginleştirir. Bu yaklaşım, beyin tümörlerini tanıma ve sınıflandırmada daha gelişmiş bir yöntem sunar. Önerilen modelin blok diyagramı Şekil 8'de verilmiştir.



Şekil 8. Önerilen modelin blok diyagramı


Ön işlemenin temel amacı, MRG kalitesini artırmak ve daha sonra insanlar veya bilgisayarlar tarafından daha iyi işlenebilir hale getirmektir. Özellikle beyin tümörlerinin manyetik rezonans görüntülerini işlerken, ön işleme adımları görüntülerin benzerliğini artırır ve bu görüntüleri tıp uzmanları için daha uygun hale getirir. Ön işleme, bir dizi prosedürü içerebilir ve bu amaçla çeşitli yöntemler sunmaktadır. Gürültü azaltma, ön işlemenin kritik bir adımıdır [25]. Bu adım, görüntülerin netliğini ve anlaşılabilirliğini artırmaya yardımcı olur. Özellikle beyin tümörlerini teşhis etmek gibi kritik bir görevde, net ve gürültüsüz görüntüler, doğru teşhis ve değerlendirmenin temelini oluşturur. Bu amaçla, Python, Java, C gibi programlama dilleri ve OpenCV kütüphanesi, birçok ön işleme aşamasında kullanılabilir. Örneğin, OpenCV kütüphanesi ile bir görüntüye filtreler uygulanıp gürültüler azaltılabilir. Ya da görüntüden kenarlar belirginleştirilebilir. Bu işlemler, görüntülerin daha iyi işlenebilir olmasını sağlar ve sonuçta tıp uzmanlarının veya görüntüleme algoritmalarının doğru analiz yapmasına yardımcı olur.

MRG, beyin görüntülerinin karmaşık yapısını içeren farklı dokuların görüntülerini elde etmek için kullanılır. Bu nedenle beyin tümörlerini teşhis etmek gibi önemli görevler için, bu görüntülerin analizi büyük bir öneme sahiptir. Tümörlerin evresini belirlemek ve tedavi yanıtını değerlendirmek için metinsel gözlemler, analizler ve terapötik yanıtların değerlendirilmesi gibi yöntemler en faydalı yaklaşımlardan biridir [26]. Ayrıca, görüntülerden avantajlı özellikler elde etmek için matematiksel yöntemler kullanılabilir [27]. Bu yöntemler, görüntülerin işlenmesi ve özelliklerin çıkarılması için kullanılan hesaplamalı teknikleri içerebilir.

Bir beyin tümörü tespitinde görüntüleri verimli bir şekilde sınıflandırmak için önerdiğimiz ESA-LSTM modeli kullanılmıştır. Görüntüleri işlemek için 4 adet LSTM katmanı, ardından dropout katmanı kullanılmıştır. Aktivasyon fonksiyonu olarak ReLU tercih edilmiştir. Son olarak veriyi düzleştirmek için 1 flatten katmanı ve 1 Dense katmanı kullanılmıştır. Çıkış katmanı için Softmax aktivasyon fonksiyonu uygulanmıştır. Önerilen yöntem ile ilgili detaylı bilgiler Çizelge 1’de verilmiştir. Çizelge 1 incelendiğinde elde edilen toplam parametre sayısı 207.605.764’tür. Bu parametrelerin tamamının eğitildiği görülmektedir. Ayrıca önerilen modelin Keras Visualization özelliği kullanılarak şematik olarak gösterimi Şekil 9’da sunulmuştur.

Çizelge 1. Önerilen yöntemin ayrıntıları

Katman (Layer)	Çıktı Biçimi (Output Shape)	Parametre (Parameter)
Lstm (LSTM)	(None, 1, 512)	206571520
Dropout (Dropout)	(None, 1, 512)	0
Lstm_1 (LSTM)	(None, 1, 256)	787456
Dropout_1 (Dropout)	(None, 1, 256)	0
Lstm_2 (LSTM)	(None, 1, 128)	197120
Dropout_2 (Dropout)	(None, 1, 128)	0
Lstm_3 (LSTM)	(None, 64)	49408
Dropout_3 (Dropout)	(None, 64)	0
Flatten (Flatten)	(None, 64)	0
Dense (Dense)	(None, 4)	260
Toplam parametreler (Total parameters):		207605764 (791.95 MB)
Eğitilebilir parametreler (Trainable parameters):		207605764 (791.95 MB)
Eğitilemeyen parametreler (Non-trainable parameters):		None (0.00 Byte)



Şekil 9. Önerilen modelin şematik gösterimi

3.6 Kullanılan Değerlendirme Ölçütleri

Önerilen teşhis yöntemi, genel performans değerlendirmesi için yaygın olarak kullanılan bir matris içermektedir. Bu matris, temel ölçümleri içerir ve doğruluk, geri çağırma, F1-skoru ve kesinlik gibi önemli metrikleri kapsar. Bu ölçümler, teşhis yönteminin genel performansını değerlendirmek ve gerçek dünya uygulamalarında nasıl performans gösterebileceğini anlamak için kullanılır. Genellikle, ikili sınıflandırma durumlarında sınıflandırıcının performansını değerlendirmek için tek bir metrik,

örneğin doğruluk puanı kullanılır. Ancak, bu yaklaşım, sınıflandırıcının gerçek dünya uygulamalarında nasıl performans gösterdiğini tam olarak yansıtmayabilir, çünkü bu durumda diğer önemli ölçütler göz ardı edilmiş olabilir. Bu nedenle, önerilen teşhis yöntemi, ikili sınıflandırmadan ziyade doğru bir değerlendirme yapabilmek için çeşitli değerlendirme ölçütlerini içermektedir. Bu çoklu metrikler, sınıflandırıcının etkinliği hakkında daha kapsamlı bir görünüm sunarak daha güvenilir sonuçlar elde etmeyi amaçlamaktadır. ESA-LSTM modeli farklı sınıflandırma ölçütleri kullanılarak değerlendirilmiştir: kesinlik (Precision), Geri Çağırma (Recall), F1 puanı (F1) ve doğruluk (Accuracy) [28]. Tüm değerlendirme metriklerinin hesaplanması için, eğitilen tüm modeller için bir karışıklık matrisi oluşturulur. Bu bölümde kullanılan tüm değerlendirme metriklerinin hesaplanması için gerekli olan doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP), yanlış negatif (FN) değerlerini sağlar. Şekil 10'da bu değerlerin yer aldığı karışıklık matrisi gösterilmiştir.

		GERÇEK (TRUE) DEĞER	
		Positive	Negative
TAMİN EDİLEN (PREDICATED) DEĞER	Positive	TP	FP
	Negative	FN	TN

Şekil 10. Karışıklık Matrisi Örneği

Her hücre türüne göre doğru şekilde sınıflandırılan test örneklerinin sayısının toplam test örnekleri sayısına oranı, accuracy gösterilir ve Denklem (7)'teki gibi hesaplanır.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (7)$$

Her bir hücre türü tarafından doğru bir şekilde sınıflandırılan pozitif örneklerin sayısının gerçek gözlenen pozitif örneklerin sayısına oranı, recall ile belirtilir ve Denklem (8)'teki gibi hesaplanır.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (8)$$

Her bir hücre türü tarafından doğru şekilde sınıflandırılan pozitif örneklerin sayısı ile pozitif örnekler olarak sınıflandırılan örneklerin sayısı Precision tarafından belirlenir ve Denklem (9)'daki gibi hesaplanır.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (9)$$

F1-skor, kesinlik ve duyarlılık oranının harmonik ortalamasına karşılık gelir. F1-skoru, 0-1 arasında bir değer alır, her bir hücre sınıflandırma modelinin daha iyi performansı, daha yüksek bir F1-skoruna karşılık gelir ve Denklem (10)'deki gibi hesaplanır.


$$\mathbf{F1 - skor} = 2 \times \frac{\mathbf{Precision} \times \mathbf{Recall}}{\mathbf{Precision} + \mathbf{Recall}} \quad (10)$$

4. Deneysel Sonuçlar ve Tartışmalar

Bu bölümde, MR görüntülerinde beyin tümörlerini tespit etme ve sınıflandırma amacıyla önerilen ESA-LSTM modelinin deneysel sonuçları ve karşılaştırmalı analizleri sunulmaktadır. Önerilen model, veri kümesini kullanarak farklı tümör türlerini otomatik olarak tanıma ve sınıflandırmada kullanılmıştır. Bu modelin performansı diğer yöntemlerle karşılaştırılarak etkinliği değerlendirilmiştir. Sonuçlar, modelin beyin tümörlerini tespit etme ve sınıflandırmada başarılı olduğunu gösteriyorsa, tıbbi görüntüleme alanında önemli bir ilerleme sağlayabilir.

4.1 Deneysel Sonuçlar

Deneysel çalışmada, glioma, meningioma, pituitary tümörleri ve iyi huylu olmak üzere dört farklı türde beyin tümörünü içeren bir MRG veri kümesi kullanıldı. Veri seti, deney için gerekli tüm kütüphaneler içe aktarıldı. Beyin tümörlerinin tespiti, farklı türlerdeki beyin tümörlerini tanımlamayı amaçlayan önerilen ESA-LSTM modeli kullanılarak gerçekleştirildi. Bu adımlar, deneysel sürecin temelini oluşturarak, modelin beyin tümörlerini sınıflandırma performansını değerlendirmeye yönelik bir çerçeve sağlamaktadır. Eğitim ve doğrulama doğruluğu ile eğitim ve doğrulama kaybı, önerilen modelin performansını değerlendirmek için kullanılmıştır. Yapılan çalışmalar sonucunda önerdiğimiz model için karışıklık matrisi Şekil 11'de verilmiştir.




Şekil 11. Önerilen Modelin Karışıklık Matrisi

Önerilen görüntü sınıflandırma yönteminin sınıflandırma performansı, Çizelge 2'de gösterildiği gibi doğruluk, kesinlik, duyarlılık ve F1-skor açısından önceden eğitilmiş ESA tabanlı yöntemler ile karşılaştırılmıştır. Karışıklık matrisine göre modellerin, doğruluk, kesinlik, duyarlılık ve F1-skor değerleri Çizelge 2'de verilmiştir.


Çizelge 2. Model sonuçlarının değerlendirilmesi

	Precision (%)	Recall (%)	F1-Score (%)	Support
Glioma	98	98	98	198
No_Tumor	97	97	97	79
meningioma	97	97	97	192
pituitary	99	99	99	184
Accuracy			98	653
Macro Avg	98	98	98	653
Weighted Avg	98	98	98	653


Önerilen modelin yüksek bir doğruluk seviyesine ulaştığı görülmüştür. Eğitim-doğrulama (validation) doğruluğu Şekil 12'de ve eğitim- doğrulama kaybı (loss) 50 epoch için Şekil 13'te verilmiştir. Epoch değeri arttıkça hem eğitim seti hem de doğrulama setindeki doğruluk değerleri artmaktadır. Eşzamanlı olarak, eğitim ve doğrulama kayıp eğrileri, epoch değeri arttıkça düşüş göstermektedir. Bu sonuçlar, önerilen ESA-LSTM modelinin beyin tümörü tespiti ve sınıflandırması için etkili bir yaklaşım olduğunu göstermektedir. Şekil 14'de rastgele seçilen bir görüntünün hangi tümör grubunda olduğunu tahmin edildiği bir ekran görüntüsü verilmiştir.



Şekil 12. Eğitim-doğrulama doğruluğu eğrisi



Şekil 13. Eğitim- doğrulama kaybı eğrisi



Şekil 14. Rastgele seçilmiş görüntülerden tümör türünün tahmin edilmesi.

4.2 Önerilen Modelin Literatürdeki Mevcut Çalışmalarla Karşılaştırılması

Bu bölümde, önerilen ESA-LSTM modeli, beyin tümörü sınıflandırmasında yapılan bazı yeni çalışmalarla karşılaştırılmıştır. Çizelge 3, bu önceki çalışmalar ile bizim önerdiğimiz yaklaşım arasındaki doğruluk karşılaştırmasını göstermektedir. Daha önce de belirtildiği gibi, birleştirilmiş veri seti üzerinde eğitilen önerilen ESA-LSTM modeli, %98,1'lik bir doğruluk elde ederek çalışmamızdaki en iyi sonuçlara sahiptir. Çizelge 3'deki sonuçların çoğu %85-%97 aralığında olup önerdiğimiz modelden daha düşüktür. Önerilen ESA-LSTM modelimiz %98,1 test doğruluğu ile tüm bu çalışmalardan daha iyi performans göstermektedir. Bu birleşik veri kümesi üzerinde eğitim, eğitim sürecini daha az zaman alıcı hale getirmekte ve yüksek detaylı görüntüler, sınıflandırıcının beyin tümörleri arasında ayırım yapmasını kolaylaştırmaktadır. Büyük bir harici test veri seti, modelin oluşturulmasında ablasyon tedavi yöntemi ile modelin uygun şekilde test edilmesini sağlayarak önerilen yaklaşımın sağlamlığının sağlıklı bir şekilde değerlendirilmesine katkıda bulunmaktadır. Önerilen bu yaklaşımla, birleşik veri kümesi üzerinde eğitilen ESA-LSTM, eğitim için daha az episode gerektiren diğer tüm çalışmalardan daha iyi performans gösterebilmiştir. Bu da önerilen yaklaşımın MRG taramalarından beyin tümörlerinin sınıflandırılmasındaki potansiyelini göstermektedir.

Çizelge 3. Önerilen modelin literatür sonuçları ile karşılaştırılması

Çalışmalar	Sınıflandırıcı	Veri Seti	Doğruluk (%)
Zhuge et al. [23]	3DConvNet	T1-T1-Gd, T2 weighted contrast-enhanced MRI Segmentation(BraTS) Benchmark	97,1
Badža et al. [28]	ESA	T1-weighted contrast-enhanced MRI (Figshare dataset)	96.56
Afshar et al. [29]	CapsNet	T1-weighted contrast-enhanced MRI (Figshare dataset)	86.56
Gumaei et al. [30]	ESA	T1-weighted contrast-enhanced MRI (Figshare dataset)	94.23
Pashaei et al. [31]	ESA	T1-weighted contrast-enhanced MRI (Figshare dataset)	93.68
Abiwinanda et al.[32]	ESA	T1-weighted contrast-enhanced MRI (Figshare dataset)	84.19
Hemanth et al. [33]	Modifed Deep ESA	T1-weighted contrast-enhanced MRI (Figshare dataset)	96,49
Mzoughi et al. [34]	Deep ESA	T1, and T2-weighted contrast-enhanced MRI (Devaki Scan Centre dataset)	96,4
Propoded Method	ESA-LSTM	T1-weighted contrast-enhanced MRI (Figshare dataset)	98,1

5. Sonuçlar

Beyin tümörünün tespiti ve sınıflandırılması, hastaları iyileştirmek veya hastaların ömürlerini uzatmak için kritik bir öneme sahiptir. Bu çalışmada, manyetik rezonans görüntülerinde beyin tümörlerini otomatik olarak tespit etmek ve sınıflandırmak amacıyla bir ESA-LSTM modeli geliştirilmiştir. Modelin etkinliğini doğrulamak için açık erişimli beyin tümörü MRG veri setleriyle karşılaştırmalar yapılmıştır. Önerilen model, beyin tümörü türlerini sınıflandırmada önemli bir gelişme sağlamıştır. Bu çalışmanın amacı, tıbbi uzmanların kanseri belirlemek için tek bir hastanın tüm MRG sekanslarını analiz etme sürecini, en yüksek doğruluk ve en düşük hesaplama karmaşıklığına sahip bir derin öğrenme yaklaşımını önermektir. Bu araştırmada, beyin tümörlerini sınıflandırmak amacıyla

geliştirilen ESA-LSTM adlı tamamen otomatik hibrit bir ESA modeli önerilmiştir. Giriş katmanı, bir hastanın MRG dizisinin tamamının tek bir giriş verisi olarak işlenebilmesine olanak tanımaktadır. Bu yöntem, ESA ve LSTM'in birleştirilmesi sayesinde zaman içindeki bilgilerin tutarlı bir şekilde değerlendirilmesini sağlayarak sınıflandırma doğruluğunu artırmıştır. Elde edilen sonuçlar yapılandırılmış ESA-LSTM ağının %98.01'lik en yüksek doğruluğa ulaştığını göstermektedir. MRG sekanslarını birleştirip analiz etmek, en düşük zaman karmaşıklığını korurken en yüksek doğruluğu elde etmek amacıyla yapılan ablasyon tedavi yöntemi, geliştirilen ESA-LSTM modeli için önemli bir yöntemi temsil ediyor. Deneysel sonuçlar, bu modelin doğruluk, kesinlik ve geri çağırma oranları açısından önceki ESA tekniklerinden daha iyi performans sağladığını göstermektedir. Ayrıca beyin tümörü teşhisi ve sınıflandırılmasında bu tür derin öğrenme yöntemlerinin kullanımının gelecekteki tıbbi uygulamalarda potansiyel olarak büyük bir katkı sağlayabileceğini de kanıtlamaktadır.

Çıkar Çatışması Beyanı

Makale yazarları herhangi bir kurum, kuruluş, kişi ile kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] S. Abbas et al., "BCD-WERT: a novel approach for breast cancer detection using whale optimization based efficient features and extremely randomized tree algorithm," *PeerJ Computer Science*, 2021.
- [2] C. Dhananjaya et al., "Identification of malnutrition and prediction of BMI from facial images using real-time image processing and machine learning," *IET Image Processing*, 2021.
- [3] T.R. Gadekallu et al., "Hand gesture classification using a novel CNN-crow search algorithm," *Complex & Intelligent Systems*, 2021, pp. 1–14.
- [4] E.F. Badran et al., "An algorithm for detecting brain tumors in MRI images," in *The 2010 International Conference on Computer Engineering & Systems*, Cairo, Egypt, 2010, pp. 368–373.
- [5] İ. Çetiner, "Konvolüsyonel Sinir Ağı Kullanılarak Sıtma Hastalığı Sınıflandırılması," *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, c. 9, no. 17, pp. 273–286, Ağu. 2022.
- [6] H. Çetiner, "Multi-Label Text Analysis With A Cnn And Lstm Based Hybrid Deep Learning Model," *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, c. 9, no. 17, pp. 447–457, Ağu. 2022.
- [7] B. Srikanth and S. Venkata Suryanarayana, "Multi-Class classification of brain tumor images using data augmentation with deep neural network," in *Materials Today: Proceedings*, 2021.
- [8] R. Hashemzahi et al., "Detection of brain tumors from MRI images base on deep learning using hybrid models CNN and NADE," *Biocybern. Biomed. Eng.*, vol. 40, no. 3, pp. 1225–1232, 2020.
- [9] S. Halimeh Sinar and M.D. Teshnehab, "Diagnosing and Classification Tumor and M.S. Simultaneous Magnetic Resonance Images Using Convolution Neural Network," *CFIS*, 2019.
- [10] P.M. Ameer and S. Deepak, "Brain tumor classification using deep CNN features via transfer learning," *Computers in Biology and Medicine*, vol. 111, 2019, Art. no. 103345.
- [11] H.E.S.M. Mohsen and A.B.M. Salem, "Classification using deep learning neural networks for brain tumors," *FCIJ*, 2018, pp. 68–71.
- [12] Z. Sobhaninia et al., "Brain tumor segmentation using deep learning by type-specific sorting of images," *Computer Science*, 2018.
- [13] S. Sajid et al., "Brain tumor detection and Segmentation in M.R. images using deep learning," *Arabian Journal for Science and Engineering*, vol. 44, no. 11, pp. 9249–9261, 2019.
- [14] S. Hussain and M. Majid, "Brain tumor segmentation using cascaded deep convolutional neural network," in *39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Jeju, Korea (South), 2017, pp. 1998–2001.
- [15] S. Pereira, "Brain tumor segmentation using convolutional neural networks in MRI images," *IEEE transactions on medical imaging*, vol. 35, no. 5, pp. 1240–1251, 2016.

- [16] M. Nagori and M. Joshi, "Methods and algorithms for extracting values from MRS Graph for brain tumor detection," in 2013 International Conference on Electronic Engineering and Computer Science (EECS 2013), Beijing, China, 2013, pp. 331–336.
- [17] A. Carlos et al., "Automated classification of brain tumors from short echo time in vivo MRS data using gaussian decomposition and bayesian neural networks," *Expert Syst. Appl.*, vol. 41, pp. 5296–5307, 2014.
- [18] G. Swapna, K.P. Soman, and R. Vinayakumar, "Automated detection of diabetes using ESA and ESA-LSTM network and heart rate signals," *Procedia Comput. Sci.*, vol. 132, pp. 1253–1262, 2018.
- [19] S. Tanveer et al., "Cuffless blood pressure estimation from electrocardiogram and photoplethysmogram using waveform based ANN-LSTM network," *Biomed. Signal Process. Control*, vol. 51, pp. 382–392, 2019.
- [20] B. Sartaj, "Kaggle Dataset, Brain Tumor Classification (MRI)," 7 April 2019 [Online]. Available: <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>.
- [21] A.I. Tawk and W.H. Kamr, "Diagnostic value of 3D-FLAIR magnetic resonance sequence in detection of white matter brain lesions in multiple sclerosis," *Egyptian J. Radiol. Nucl. Med.*, vol. 51, no. 1, pp. 1–9, Dec. 2020.
- [22] Y. Özüpak, "Evrişimli Sinir Ağı (ESA) Mimarileri ile Hücre Görüntülerinden Sıtmanın Tespit Edilmesi," *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, vol. 39, no. 1, pp. 197–210, 2024.
- [23] Y. Zhuge et al., "Automated glioma grading on conventional MRI images using deep convolutional neural networks," *Med. Phys.*, vol. 47, no. 7, pp. 3044–3053, Jul. 2020.
- [24] E. Aslan and Y. Özüpak, "Classification of Blood Cells with Convolutional Neural Network Model," *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, vol. 13, no. 1, pp. 314–326, 2024.
- [25] I. Shahzadi et al., "CNN-LSTM: Cascaded framework for brain tumour classification," in *Proc. IEEE-EMBS Conf. Biomed. Eng. Sci. (IECBES)*, Dec. 2018, pp. 633–637.
- [26] S.B. Jiang et al., "An efficient fault diagnostic method for three-phase induction motors based on incremental broad learning and non-negative matrix factorization," *IEEE Access*, vol. 7, pp. 17780–17790, 2019.
- [27] A.A. Novikov et al., "Deep sequential segmentation of organs in volumetric medical scans," *IEEE Trans. Med. Imag.*, vol. 38, no. 5, pp. 1207–1215, May 2019.
- [28] M.M. Badža and M.Č. Barjaktarović, "Classification of brain tumors from MRI images using a convolutional neural network," *Appl Sci.*, vol. 10, no. 6, Art. no. 1999, 2020.
- [29] P. Afshar, A. Mohammadi, and K.N. Plataniotis, "Brain tumor type classification via capsule networks," in 2018 25th IEEE international conference on image processing (ICIP), IEEE, 2018, pp. 3129–3133.
- [30] A. Gumaedi et al., "A Hybrid feature extraction method with regularized extreme learning machine for brain tumor classification," *IEEE Access*, vol. 7, pp. 36266–36273, 2019.
- [31] A. Pashaei, H. Sajedi, and N. Jazayeri, "Brain tumor classification via convolutional neural network and extreme learning machines," in 2018 8th international conference on computer and knowledge engineering (ICCKE), IEEE, 2018.
- [32] N. Abiwinanda et al., "Brain tumor classification using convolutional neural network," in *World congress on medical physics and biomedical engineering 2018*, Singapore: Springer, 2019, pp. 183–189.
- [33] D.J. Hemanth et al., "A modified deep convolutional neural network for abnormal brain image classification," *IEEE Access*, vol. 7, pp. 4275–4283, 2018.
- [34] H. Mzoughi et al., "Deep multi-scale 3D convolutional neural network (CNN) for MRI gliomas brain tumor classification," *J. Digit. Imag.*, vol. 33, no. 4, pp. 903–915, Aug. 2020.