

Alzheimer ve Parkinson Hastalıklarının Derin Öğrenme Teknikleri Kullanılarak Sınıflandırılması

Esra YÜZGEÇ^{1,2*}, Muhammed TALO³

¹ Yazılım Mühendisliği, Fen Bilimleri Enstitüsü, Fırat Üniversitesi, Elazığ, Türkiye

² Bilgisayar Mühendisliği, Mühendislik ve Mimarlık Fakültesi, Bingöl, Türkiye

³ Yazılım Mühendisliği, Mühendislik Fakültesi, Elazığ, Türkiye

*^{1,2} eyuzgec@firat.edu.tr, ³ mtalo@firat.edu.tr

(Geliş/Received: 15/01/2023;

Kabul/Accepted: 16/05/2023)

Öz: Bilgisayar destekli cihazların ve sistemlerin sağlık alanında kullanımı oldukça yaygınlaşmıştır. Bu cihaz ve sistemlerin hastalıkların daha hızlı ve erken teşhisine katkısı yüksekti. Özellikle Manyetik Rezonans Görüntüleme (MRI), Bilgisayarlı Tomografi (BT) gibi görüntüleme cihazları; erken teşhisin önemli olduğu hastalıklar özelinde oldukça büyük bir rol oynamaktadır. Nörolojik hastalıklarda da MR ve BT görüntülerinin derin öğrenme modellerinde girdi görüntüsü olarak kullanımı giderek yaygınlaşmaktadır. Bu çalışmada Kaggle sitesi üzerinden elde edilen Alzheimer ve Parkinson hastalıkları teşhisi için "Alzheimer Parkinson 3 Class Data Set" veri setindeki MRI görüntüleri kullanılmıştır. Bu veri seti içerisinde 2561 Alzheimer, 906 Parkinson ve 3010 adet Kontrol (Normal) olmak üzere üç sınıf bulunmaktadır. Bu çalışmada; Alzheimer, Parkinson ve Normal sınıfları, ResNet-18, VGG-16 ve ConvNext mimarisi ile eğitildiğinde sırasıyla %96,2, %95,4 ve %98,9 doğruluk oranı elde edilmiştir. Bunun yanında; Alzheimer ve Parkinson hastalıkları normal sınıfı üzerinde ikili sınıflandırıcılar ile test edilmiştir. Alzheimer- Normal ve Parkinson - Normal sınıfları için eğitilen modellerden ResNet-18 mimarisi sırası ile %82,0 ve %96,1, VGG-16 mimarisi sırası ile %95,4 ve %89,4, ConvNext mimarisi ise %99,4 ve %99,5 başarı oranlarına ulaşılmıştır.

Anahtar kelimeler: Alzheimer, Parkinson, Derin Öğrenme, Nörodejeneratif, Manyetik Rezonans

Classification of Alzheimer's and Parkinson's Diseases Using Deep Learning Techniques

Abstract: The use of computer-aided devices and systems in the field of health has become quite widespread. These devices and systems contributed to faster and earlier diagnosis of diseases. Especially imaging devices such as Magnetic Resonance Imaging (MRI) and Computed Tomography (CT) play a major role in diseases where early diagnosis is important. In neurological diseases, the use of MRI and CT images as input images in deep learning models is becoming increasingly common. In this study, MRI images from the "Alzheimer's Parkinson's 3 Class Data Set" dataset obtained from the Kaggle website were used to diagnose Alzheimer's and Parkinson's diseases. There are three classes in this data set: 2561 Alzheimer's, 906 Parkinson's and 3010 Control (Normal). In this study, when Alzheimer's Parkinson's and Normal classes were trained with ResNet-18, VGG-16 and ConvNext architecture, accuracy rates of 96.2%, 95.4% and 98.9% were obtained respectively. In addition, Alzheimer's and Parkinson's diseases were tested with binary classifiers on the normal class. Among the models trained for Alzheimer's - Normal and Parkinson's - Normal classes, ResNet-18 architecture achieved 82.0% and 96.1%, VGG-16 architecture achieved 95.4% and 89.4%, and ConvNext architecture achieved 99.4% and 99.5% success rates, respectively.

Key words: Alzheimer's, Parkinson's, Deep Learning, Neurodegenerative, Magnetic Resonance

1. Giriş

Sağlık alanında özellikle nörolojik hastalıklar üzerinde bilgisayar destekli sistemlerin kullanımı gittikçe yaygınlaşmaktadır. Günümüzde hastanelerde ve birçok sağlık kuruluşunda hastalık tespiti veya süreç izlenmesi için MR ve BT gibi cihazların kullanımı kaçınılmazdır. Özellikle Nörolojik hastalıklar için de beyin MRI ve BT görüntüleri kullanılarak erken teşhise olanak sağlanmaktadır.

Nörolojik hastalıklarda erken teşhisin önemi hayati boyutta değerlendirilir. Bilhassa zamanla ilerlemeye devam eden Nörodejeneratif hastalıkların erken teşhisi hayati boyuttadır. Demans türleri olarak tanımlanan Alzheimer ve Parkinson hastalıkları; Nörodejeneratif olarak nitelendirilen hastalıklardır [1]. Her iki hastalığın da ilk belirtilerini göstermeden yıllar öncesinde ilerlemelerini sürdürerek beyinde ciddi tahribata yol açtığı tahmin edilmektedir [2].

* Sorumlu yazar: eyuzgec@firat.edu.tr. Yazarların ORCID Numarası: ^{1,2} 0000-0003-2914-2603, ³ 0000-0002-1595-5681

Parkinson hastalığının, beynin dopamin hormonu üretmekten sorumlu hücrelerinde meydana gelen hasar ile başladığı tanımlanır. Hücrelerde meydana gelen bu hasar; hastanın motor yeteneklerini etkileyen zihinsel fonksiyonlarına etki edecek kadar ilerler [3]. Beyinde gerçekleşen bu biyolojik hasar ciddi boyutlara ulaşmadığı sürece belirti göstermez ve bu sebeple hastalık teşhisi ciddi derecede güçleşir. Parkinson hastalığının ilerlemesinin ciddi boyuta gelmesi ile titreme, hareket etmede zorluk, depresif duygu durum bozukluğu gibi belirtiler ortaya çıkmaya başlar [4].

Parkinson hastalarının ilk belirtileri ortaya çıktıktan sonra, teşhis için genellikle motor becerilerinde meydana gelen hasarı ölçmek amacı ile tıbbi gözlemler yapılır. Hastalığın kesin teşhisi; zamana ve semptom yoğunluğuna bağlı klinik testler ile gerçekleştirilir [5]. İlk olarak kişinin temel motor becerileri ve hareket kısıtlılığına sebep olacak belirli semptomlar ile gözlenen hastalığın erken evresinde bu durumların yaşlılığa bağlı semptomlar olarak değerlendirilip göz ardı edilme ihtimali yüksektir. Bu durumda hastalık teşhisi zorlaşır ve hastanın yaşam kalitesi tamamıyla düşmeden tespit edilemez hale gelir [6].

Parkinson hastalığına benzer olarak Alzheimer hastalığı da geri döndürülebilir bir tedavisi bulunmayan Nörodejeneratif bir hastalık türüdür [7]. Alzheimer hastalığının erken teşhisi; hafıza bozuklukları, temel ve günlük hayat becerilerinde gerileme, konuşma güçlüğü gibi belirgin semptomlar ortaya çıkmadan gerçekleştirilememektedir [8].

Alzheimer hastalığının beyinde yol açtığı hasar içerisinde ilk olarak zarar gören nöronlar beynin hafıza, konuşma ve düşünme bölümlerinde gerçekleşmektedir. İlk hasar gören nöronların bulunduğu bu bilişsel işlevler hastalarda belirlenen ilk semptomların bu alanlarda olmasına sebebiyet verir. Belirtiler; hastada yeni fark edilmiş olsa da beyin üzerindeki tahribatin 20 yıl veya daha erken bir süre içerisinde başladığı tahmin edilmektedir [9].

2021 Alzheimer Disease International (ADI) raporunda klinik olarak Alzheimer tespiti üzerine çalışan birçok klinisyen, bunama hastaları ve hasta yakınları (bakıcılar) ile yapılan ankete göre; hastaların bir kısmı yerel bölgelerdeki uzman hekim eksikliği, hastalığın teşhisinin zorluğu, tedavi imkanının bulunmaması ve bunama tanısı koyulması endişesi ile teşhis güçlüğü yaşandığını ifade etmiştir [10]. Alzheimer hastalığının son aşamaya gelmeden semptom göstermemesinin yanında bu gibi insani faktörler de teşhisi giderek güçlendirmektedir. Bu gibi erken teşhis problemlerinin önüne geçmek, hastaların ve hasta yakınların yaşam kalitesini iyileştirmek ve alanda uzman sağlık çalışanlarına ikinci bir bakış açısı ile destek olmak amacı ile Bilgisayar Destekli Sistemler kullanılabilir.

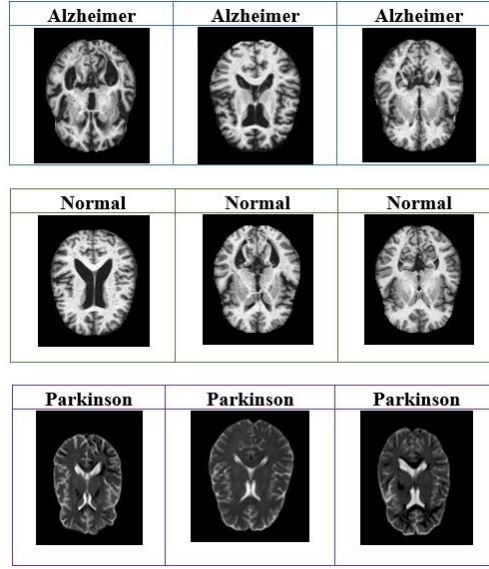
Dünyada robotik, endüstriyel çözümler, ses işleme-tanıma, güvenlik kontrolü, meteorolojik tahminler ve finansal çalışmalar gibi birçok alanda derin öğrenme teknolojileri kullanılmaktadır. Sağlık alanında da bu alanlara benzer olarak derin öğrenme ve görüntü işleme teknolojilerinden faydalanılması giderek yaygınlaşmaktadır. Özellikle meme kanseri, akciğer kanseri, diyabetik retinopati ve Alzheimer gibi erken teşhisin hayati olduğu hastalıklar üzerine yapılan çalışmalar bulunmaktadır [11]. Bu çalışmada da erken teşhisi oldukça güç demans türleri olan Alzheimer ve Parkinson hastalıklarının MRI görüntüleri üzerinden derin öğrenme teknikleri kullanılarak sınıflandırılması gerçekleştirilmiştir. Her bir hastalığın normal sonuçlu kontrol hastaları ile sınıflandırılması işleminin yanında üç sınıflı olarak Alzheimer, Parkinson ve Normal grubu ile de çalışılarak Demans hastalıkları arasında bir sınıflandırma işlemi yapılmıştır.

Bu çalışmada, "Materyal ve Yöntem" bölümünde veri seti ve kullanılan modeller ayrıntılı olarak açıklanmaktadır. "Bulgular ve Tartışma" bölümünde, elde edilen sonuçlar detaylı olarak sunulup, bulguların analizi gerçekleştirilmektedir. Son olarak, "Sonuç" bölümünde elde edilen sonuçlar özetlenmekte ve çalışmanın önemi vurgulanmaktadır.

2. Materyal ve Yöntem

2.1 Veri Seti

Gokul Ramasamy tarafından Kaggle platformunda paylaşılan üç sınıflı bir veri seti kullanılmıştır [12]. Bu veri seti içerisinde Şekil 1'de gösterildiği gibi Alzheimer, Parkinson ve Normal sınıfı olmak üzere üç sınıf bulunmaktadır. Bu sınıflar ayrıca veri seti içerisinde "Eğitim" ve "Test" olmak üzere iki ayrı klasör olarak verilmiştir.



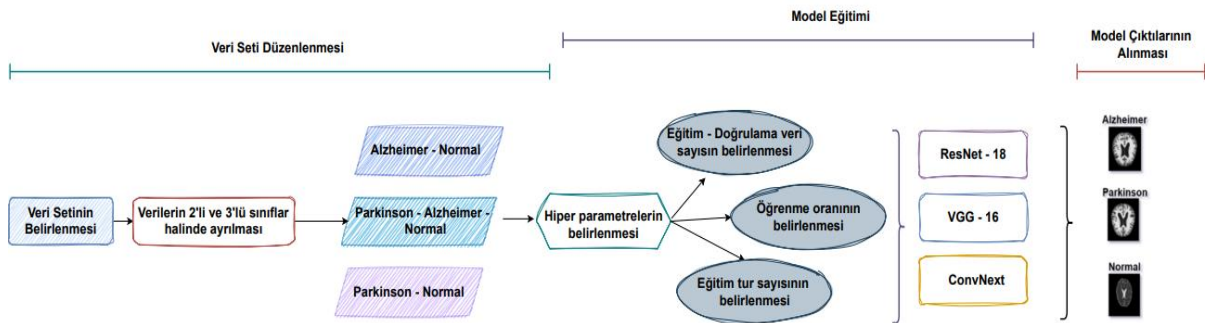
Şekil 1. Veri seti örnek görüntüleri.

Bu ayırım ile eğitilen modellerin, daha önce kullanılmayan hasta görüntüleri ile test edilmesi sağlanmıştır. Eğitim klasöründe Alzheimer, Parkinson ve Normal sınıfları için sırasıyla Tablo 1’de verildiği gibi 2561, 906 ve 3010 görüntü bulunmaktadır. Bu sayılar Test klasöründe sırasıyla 639, 61 ve 662 olarak bulunmaktadır.

Tablo 1. Veri seti görüntü sayıları

Sınıf Adı	Eğitim Görüntü Sayısı	Test Görüntü Sayısı
Alzheimer	2561	639
Parkinson	906	61
Normal	3010	662


Elde edilen veri seti üç sınıflı olarak ResNet-18, VGG-16 ve ConvNext mimarileri ile eğitilmiş ve test görüntüleri üzerinde modellerin başarımları elde edilmiştir. Bu sayede hastalıkların ve hasta olmayan kişilerin kendi aralarında ayırımlarının bilgisayar destekli sistemler yardımı ile hangi doğrulukta başarı elde ettiği test edilmiştir. Bunun yanında Şekil 2’de gösterildiği gibi Alzheimer - Normal ve Parkinson - Normal sınıfları kendi aralarında ayrıştırılarak iki sınıflı problemler halinde ele alınmıştır. Bu sayede hastalık özelinde de Bilgisayar Destekli Sistemlerin doğruluk oranı test edilmiştir.



Şekil 2. Veri seti ayrıştırılması ve model eğitimi süreci

2.2 ResNet-18

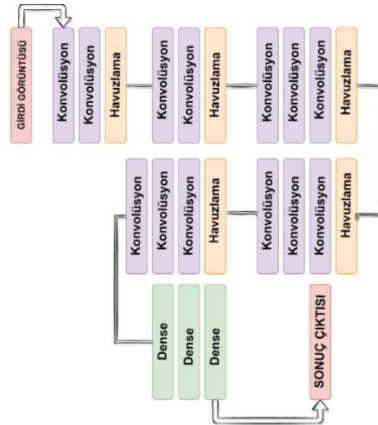
Eğitilen modeller için seçilen mimarilerden ilki ResNet – 18 mimarisidir. Artık Ağlar olarak isimlendirilen ResNet mimarisi ilk olarak 2015 yılında Kaiming He ve arkadaşları tarafından geliştirilmiş bir sinir ağıdır. ResNet mimarisi; katılmış olduğu ILSVRC ve COCO2015 yarışmalarında birçok alanda birincilik elde edecek başarılarla ulaşmış bir sinir ağıdır [13]. Derin öğrenme mimarilerinin ortaya çıktığı yıllardan itibaren, bir sinir ağı ne kadar çok katmana sahipse o kadar başarılı olur, bakış açısı ile geliştirilmekteydi [14]. Ancak belirli bir süre sonra geliştirilen mimarilere bakıldığında katman sayısı arttıkça başarımın belirli bir seviyeye kadar artırılabilirdiği ve bu seviyeden sonra eğitilen modelin, gördüğü verileri ezberleyerek aşırı öğrenme gibi uyum problemlerine yol açtığı görüldü [15]. ResNet mimarisi bu problemlere çözüm olarak artık blok yapısı ortaya koymuştur. Artık blok yapısı; kısa yol bağlantılarının geliştirildiği bir modeldir. Geliştirilen kısa yol bağlantıları sayesinde bir veya birden fazla katman atlanarak eğitim gerçekleştirilmektedir. Bu sayede aşırı uyum problemlerinin giderilmesine olanak sağlanmaktadır. Gerçekleştirilen bu çalışmada ResNet-18 mimarisi kullanılmıştır. ResNet-18 mimarisinin katman gösterimi Şekil 3’ de gösterildiği gibidir.



Şekil 3. ResNet-18 mimarisinin içeriği

2.3 VGG-16

VGG-16; en temel anlamı ile bir Evrişimli Sinir Ağı (ESA) olarak tanımlanır. 16 evrişim katmanından oluşan bu model; Şekil 4’te gösterildiği gibi kendi içerisinde beş adet havuzlama ve üç adet tam bağlı katmandan meydana gelmektedir. Modelin sahip olduğu her bir evrişim katmanının çıkışında farklı ağırlıklara sahip olan filtreler hesaplanır. Eklenen katman arttıkça filtreler ve ifade ettikleri derinlik değerleri de değişkenlik gösterir [16].




Şekil 4. VGG-16 mimarisinin katman yapısı.

VGG-16; "Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağlar" isimli bir çalışmada yayınlamışlardır [17]. Bu makalede Oxford Üniversitesinden K. Simonyan ve A. Zisserman tarafından öne sürülen bir Evrişimsel Sinir Ağı modelidir. Bu model ImageNet isimli büyük ölçekli bir veri seti üzerinde test edilmiştir. Bu veri seti üzerinden gerçekleştirilen test sonucu %92,7 doğruluk oranına ulaşmışlardır. 14 milyondan fazla görüntü içeren ve 1000 sınıftan oluşan bir veri seti olan ImageNet ile yapılan Büyük Ölçekli Görsel Tanıma yarışmasının 2014 yılında sunulan en popüler modellerinden biri olarak VGG-16 modeli ortaya çıkmıştır [18].

2.4 ConvNext

Bu çalışmada kullanılan modellerden biri olan ConvNext modeli; Liu ve arkadaşlarının 2022 yılında ortaya çıkardıkları ve 2020'ler için bir ConvNext olarak yayınlanan bir çalışmada önerilen modeldir [19]. Önerilen modelin Vision Transformers (ViT) olarak bilinen mimari yapısından esinlenerek gerçekleştirildiği öne sürülmüştür [20]. Bu yapının ViT mimarilerinden daha başarılı sonuçlar elde ettiği çalışmada ConvNext saf bir ESA modeli olarak sınıflandırılmıştır. ConvNext modeli; mimari yapısı açısından ResNet modeli ile ViT mimari ailesinin tasarım ve teknikleri ile harmanlanarak geliştirilen ve çağdaştırılan biçimi olarak tanımlanmaktadır. Geliştirilen bir ESA modelinde doğrusallık sorununun önüne geçmek adına aktivasyon fonksiyonları kullanılır. Bu modelde geleneksel aktivasyon fonksiyonlarından olan ReLU aktivasyon fonksiyonu yerine GeLU (Gauss Hatası Doğrusal Birimi) kullanarak mimari açıdan bir güncellemeye gidilmiştir. Benzer şekilde ESA mimarilerinde kullanılan normalizasyon fonksiyonu olan Toplu Normalleştirme yerine Katman Normalleştirme kullanılarak mimari tasarımında özgün bir çalışma gerçekleştirilmiştir.

ConvNext, mimari başarılarının ölçülmesinde etkili rol oynayan ImageNet-1K veri setini sınıflandırmada birçok güçlü mimari arasından birinci olmuştur [21]. Ayrıca COCO veri seti ile nesne algılama, ADE20K görüntü bölütleme (segmentasyon) çalışmalarında ise Swin Transformers mimarisini geride bırakmıştır [22]. Bu çalışmada da oldukça güçlü ve güncel bir model olan ConvNext mimarisi kullanılmıştır. ConvNext modeli mimari yapısı Şekil 5'te gösterildiği gibidir.



Şekil 5. ConvNext mimarisinin katman yapısı.


3. Bulgular ve Tartışma

Bu çalışmada, üçlü sınıflandırma görevi için ResNet-18, VGG-16 ve ConvNext modelleri sırası ile %96,2, %95,4 ve %98,9 doğruluk, %97,0, %94,0, %98,0 hassasiyet ve %94,0, %92,0, %99,0 kesinlik oranlarına ulaşmışlardır. Bu oranların yanında, hata oranlarının sayısal olarak ifade edildiği Karmaşıklık Matrisleri Şekil 6'da gösterildiği gibidir.

	VGG-16 Eğitim Sonucu Karmaşıklık Matrisi			ConvNext Eğitim Sonucu Karmaşıklık Matrisi			ResNet-18 Eğitim Sonucu Karmaşıklık Matrisi		
	Alzheimer	Normal	Parkinson	Alzheimer	Normal	Parkinson	Alzheimer	Normal	Parkinson
Alzheimer	223	18	0	264	0	0	259	5	0
Normal	20	296	8	0	284	2	4	286	13
Parkinson	0	1	81	0	3	94	0	2	78

Şekil 6. Üçlü sınıflandırma modellerinin doğrulama verileri karmaşıklık matrisi sonuçları.

Bunun yanında hatalı tahmin edilen doğrulama verilerinin, hata oranlarının temsil edildiği kayıp grafikleri Şekil 7’de olduğu gibi elde edilmiş ve incelendiğinde ResNet-18 ve VGG-16 modellerine oranla ConvNext mimarisi daha yüksek doğruluk göstermiştir.



Şekil 7. Üçlü sınıflandırma modelleri doğrulama verileri için kayıp grafikleri.


Yukarıda verilen karmaşıklık matrisleri ve kayıp grafikleri üçlü sınıflandırma modellerinin eğitimi esnasında alınan sonuçlardır. Bu sonuçlar eğitim verilerinin %10’luk bir kısmının doğrulama verilerine dönüştürülmesi ile gerçekleştirilmiştir. Elde edilen veri seti içerisinde Tablo 1’de gösterildiği gibi önceden ayrılmış bir test klasörü oluşturulmuştur. Eğitilen modeller daha önce görmediği test verileri üzerinde çalıştırıldığında, en başarılı test doğruluğu oranını %99,5 ile ConvNext mimarisi sağlamıştır. Bu mimarinin Test verilerine ait elde edilen Karmaşıklık matrisi Şekil 8 ‘de gösterildiği gibidir.

ConvNext Test Sonucu Karmaşıklık Matrisi

	Alzheimer	Normal	Parkinson
Alzheimer	639	0	0
Normal	1	661	0
Parkinson	0	4	57


Şekil 8. ConvNext modelinin üçlü test verileri üzerindeki karmaşıklık matrisi.

Bu çalışmada; Alzheimer, Parkinson ve Normal sınıflarını temel alan modellerin yanında, hedef alınan hastalıkların Kontrol sınıfı ile ikili sınıflar olarak ele alındığında elde edilecek sonuçlar da incelenmiştir. Bu amaçla Alzheimer-Normal ve Parkinson – Normal olmak üzere iki ayrı veri seti daha oluşturulmuştur. Alzheimer – Normal sınıfında ResNet-18 ve VGG-16 ve ConvNext modelleri sırası ile %82,0, %95,4 ve %99,4 doğruluk, %72,0, %95,0, %99,0 hassasiyet %74,0, ve %95, %99 kesinlik oranına ulaşılmıştır. Bu modellere ait kayıp grafikleri Şekil 9’ da verilmiştir.




Şekil 9. Eğitilen modellerin Alzheimer-Normal sınıfları doğrulama verileri için kayıp grafikleri.

Şekil 10'daki; modellere ait karmaşıklık matrisleri de incelendiğinde ConvNext modelinin Alzheimer-Normal sınıfı için eğitilen mimariler arasında yalnızca 4 hatalı tahminde bulunarak daha doğru sonuç elde ettiği görülmüştür.




Şekil 10. Alzheimer-Normal modellerine ait karmaşıklık matrisleri.

Alzheimer – Kontrol sınıfı için gerçekleştirilen model eğitimlerinde ConvNext modeli orantılı şekilde azalan kayıp oranları ile herhangi bir aşırı uyum veya yetersiz uyum problemine uğramadan, yüksek doğruluk oranına ulaşmıştır. Bu doğruluk oranının gerçekliğinin ölçülebilmesi adına model; daha önce karşılaşmadığı 1301 hasta görüntüsü ile test edilmiştir. Gerçekleştirilen test işleminde görüntülerin %99,9 oranında doğru tahminde bulunmuştur. Bu test görüntüleri ile yapılan tahminlerden elde edilen karmaşıklık matrisi Şekil 11'te gösterildiği gibidir.




Şekil 11. ConvNext mimarisinin Alzheimer-Normal sınıfı test görüntüleri üzerindeki karmaşıklık matrisi.

Ayrıca, Parkinson-Normal sınıfı olarak elde edilen ek veri seti de benzer olarak VGG-16, ResNet-18 ve ConvNext modelleri ile eğitilmiştir. Eğitilen modellerden sırası ile %89,4, %96,1 ve %99,5 doğruluk, %81,0, %92,0, %99,0 hassasiyet ve %89,0, %97,0, %99,0 kesinlik oranlarına ulaşılmıştır. Eğitilen modellerin Şekil 12'de gösterilen kayıp grafikleri incelendiğinde bütün modeller için aşırı uyum veya yetersiz uyum problemi gözlenmemiştir.




Şekil 12. Modellerin Parkinson-Normal sınıflarının doğrulama verileri için kayıp grafikleri.

Eğitilen modeller öncelikle Eğitim – Doğrulama verileri olmak üzere sırası ile %90 ve %10 oranında bölünerek eğitim aşaması gerçekleştirilmiştir. Her bir model için 463 adet doğrulama verisi kullanılan modellerin karmaşıklık matrisleri çıktı olarak elde edilmiştir. Elde edilen karmaşıklık matrisleri Şekil 13'te gösterildiği gibidir.




Şekil 13. Modellerin Parkinson-Normal sınıfları üzerindeki karmaşıklık matrisleri.

Parkinson – Kontrol sınıfları için eğitilen modellerden elde edilen karmaşıklık matrisleri ve kayıp grafikleri incelendiğinde ConvNext modelinin daha yüksek doğruluk ile çalıştığı görülmektedir. ResNet-18 modelinin doğruluk oranının test edilebilmesi için modelin daha önce karşılaşmadığı, 723 Parkinson-Kontrol sınıfı görüntü kullanılarak test işlemi gerçekleştirildi. ConvNext modeli bu görüntüler üzerinde %99,7 oranında doğru tahmin gerçekleştirmiştir. Bu sonuçlar ile elde edilen karmaşıklık matrisi Şekil 14’de gösterildiği gibidir.




Şekil 14. ConvNext modelinin Parkinson-Normal test görüntüleri üzerindeki karmaşıklık matrisi.

Elde edilen sonuçlar değerlendirildiğinde 2022 yılında ortaya çıkan ConvNext mimarisinin her üç veri seti için de daha yüksek doğruluk oranı gösterdiği görülmektedir. Bu çalışmada eğitilen derin öğrenme modellerinden elde edilen kayıp grafikleri incelendiğinde, özellikle yüksek başarı sergileyen ConvNext modelinde herhangi bir aşırı uyum veya yetersiz uyum problemi ile karşılaşmadığı gözlemlenmiştir. Ayrıca elde edilen eğitim doğruluklarının kanıtlanabilirliği adına, en başarılı test sonuçları sağlayan modellerin karmaşıklık matrislerine çalışmada yer verilmiştir. Bunun yanında açıklanabilir yapay zekâ tekniklerinden biri olarak nitelendirilen Isı Haritası (Gradcam) yöntemi kullanılarak Alzheimer ve Parkinson hastalıklarının beyin görüntü üzerinde, hangi bölgeler baz alınarak sınıflandırıldığına açıklanması mümkün kılınabilmektedir. ConvNext mimarisinin başarılı olarak sınıflandırdığı bir Alzheimer hastasından alınan test görüntünün ısı haritası Şekil 15’te verilmiştir. Şekilde verilen ilk görüntü, modele verilen test görüntüsüdür, ikinci görüntüde verilen ısı haritası modelin normal sınıfı için baktığı alanları temsil etmektedir, son görüntü ise ilgili hastalığın model tarafından teşhis edildiği bölgeleri belirtmektedir.



Şekil 15. Alzheimer etiketli test görüntüsünün ısı haritası.

Bunun yanında Alzheimer-Normal sınıfları için ayrılan veri seti kullanıldığında ConvNext mimarisi yüksek doğruluk oranına ulaşmıştır. Bu eğitim doğruluğunun kanıtlanabilmesi adına test görüntüleri ile sınıflandırma işlemi gerçekleştirilmiş ve modelin daha önce karşılaşmadığı görüntüler üzerinde %99.7 oranında doğruluk sağladığı görülmüştür. Bu model ile sınıflandırılan test görüntülerinin ısı haritası alınarak beyin görüntüsünün hangi bölgeleri temel alınarak bir sınıflandırma gerçekleştirdiği incelenmiştir. Şekil 16'da verilen görüntüler bir Parkinson hastasına ait olup eğitilen model tarafından doğru sınıflandırılmıştır.



Şekil 16. Parkinson etiketli test görüntüsünün ısı haritası.

4. Sonuç

Alzheimer ve Parkinson hastalığı insan hayatını önemli oranda etkileyen ve ölümle sonuçlanan nörolojik hastalıklardır. Bu hastalıkların tedavisi henüz bulunmamaktadır. Alzheimer ve Parkinson hastalıklarının beyinde yol açtıkları tahribat ile hastaların temel hayati ihtiyaçlarını yerine getirmeleri oldukça zor bir hal alır. Bu duruma bağlı olarak hastaların ve hasta yakınlarının hayat kalitelerini oldukça düşmekte ve büyük oranda ölümle sonuçlanmaktadır. Alzheimer ve Parkinson hastalıklarının yol açtığı zorluklara engel olunabilmesi adına erken teşhis edilmesi ve hastalıkların ayrımı oldukça büyük önem taşımaktadır. Sonuç olarak elde edilen model sonuçları ve ısı haritaları incelendiğinde en yeni mimarilerden olan ConvNext'ten alınan sonuçların bütün sınıflar için daha iyi sonuçlar verdiği görülmektedir. Kaggle sitesinden alınan görüntüler üzerinde yapılan çalışmalarda elde edilen test sonuçları ileride yapılması hedeflenen çalışmalar için umut vericidir.

Model eğitimlerinin gerçekleştirilmesi aşamasında ikili ve üçlü sınıflar arasındaki bu sınıflandırma başarısının VGG16 ve ResNet18 sınıfları için farklı olduğu gözlenmektedir. Bu durum önünde bulundurulduğunda ikili sınıflandırmalarda ayrı ayrı kullanılan Alzheimer ve Parkinson görüntüleri üzerindeki hastalık farklarının daha yoğun ve ayırt edilebilir olması muhtemeldir. Bu sebeple üçlü sınıflandırma başarısının Alzheimer ve Parkinson hastalıklarının görüntüleri arasındaki farktan kaynaklı ikili sınıflandırmalardan daha yüksek olabileceği değerlendirilmiştir.

Çalışmada hazır bir veri seti olarak Kaggle sitesinden elde edilmiş ve veri dağılımları eğitim ve test olarak önerildiği hali kullanılmıştır. Veri seti içerisinde Parkinson sınıfı için kullanılan eğitim ve test verisinin, diğer sınıflara oranla az olması bir kısıt olarak kullanılmıştır. Bir sonraki çalışmada bu kısıtların ortadan kaldırılması ve Alzheimer ve Parkinson hastalıkları özelinde ADNI ve OASIS gibi büyük çaplı veri setlerinden alınan görüntüler ile çalışılması hedeflenmektedir [23, 24]. Hastalıkların teşhisi ve ayrımı için daha geniş çaplı bir çalışma ile umut verici sonuçlar elde edilmesi amaçlanmaktadır.

Kaynaklar

- [1] Kalia, L. V., & Lang, A. E. (2015). Parkinson's disease. *The Lancet*, 386(9996), 896-912.
- [2] Wang, X., Zheng, W., Xie, J., & Wang, T. (2019). Neuroinflammation-mediated microglial activation in Alzheimer's disease and Parkinson's disease. *Progress in Neurobiology*, 179, 1-19.
- [3] Grover, S., Bhartia, S., Yadav, A., & Seeja, K. R. (2018). Predicting severity of Parkinson's disease using deep learning. *Procedia computer science*, 132, 1788-1794.
- [4] Wroge, T. J., Özkanca, Y., Demiroglu, C., Si, D., Atkins, D. C., & Ghomi, R. H. (2018, December). Parkinson's disease diagnosis using machine learning and voice. In *2018 IEEE signal processing in medicine and biology symposium (SPMB)* (pp. 1-7). IEEE.
- [5] Mei, J., Desrosiers, C., & Frasnelli, J. (2021). Machine learning for the diagnosis of Parkinson's disease: a review of literature. *Frontiers in aging neuroscience*, 13, 633752.

- [6] Caliskan, A., Badem, H., Basturk, A., & YUKSEL, M. (2017). Diagnosis of the parkinson disease by using deep neural network classifier. *IU-Journal of Electrical & Electronics Engineering*, 17(2), 3311-3318.
- [7] Alzheimer's Disease Fact Sheet. (t.y.). National Institute on Aging. Geliş tarihi 31 Mart 2023, gönderen <https://www.nia.nih.gov/health/alzheimers-disease-fact-sheet>
- [8] Liu, S., Liu, S., Cai, W., Pujol, S., Kikinis, R., & Feng, D. (2014, April). Early diagnosis of Alzheimer's disease with deep learning. In 2014 IEEE 11th international symposium on biomedical imaging (ISBI) (pp. 1015-1018). IEEE.
- [9] Helaly, H. A., Badawy, M., & Haikal, A. Y. (2022). Deep learning approach for early detection of Alzheimer's disease. *Cognitive computation*, 14(5), 1711-1727.
- [10] (2022) Alzheimer's Disease International. [Online]. Available: <https://www.alzint.org/>
- [11] Demyanchuk, A., Pushkina, E., Russkikh, N., Shtokalo, D., & Mishinov, S. (2019). Hydrocephalus verification on brain magnetic resonance images with deep convolutional neural networks and "transfer learning" technique. arXiv preprint arXiv:1909.10473.
- [12] Gokul Ramasamy (2019). "Parkinson's Disease Detection". Kaggle. <https://www.kaggle.com/gokulramesh/parkinsons-disease-detection>
- [13] Yu, X., & Wang, S. H. (2019). Abnormality diagnosis in mammograms by transfer learning based on ResNet18. *Fundamenta Informaticae*, 168(2-4), 219-230.
- [14] Khan, H. A., Jue, W., Mushtaq, M., & Mushtaq, M. U. (2020). Brain tumor classification in MRI image using convolutional neural network. *Math. Biosci. Eng*, 17(5), 6203-6216.
- [15] He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep residual learning. *Image Recognition*, 7.
- [16] Tammina, S. (2019). Transfer learning using vgg-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), 143-150.
- [17] Simonyan, K., & Zisserman, A. (2015). "Very deep convolutional networks for large-scale image recognition". In *International Conference on Learning Representations (ICLR)*.
- [18] Sharma, S., Guleria, K., Tiwari, S., & Kumar, S. (2022). A deep learning based convolutional neural network model with VGG16 feature extractor for the detection of Alzheimer Disease using MRI scans. *Measurement: Sensors*, 24, 100506.
- [19] Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A convnet for the 2020s. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11976-11986).
- [20] Zhai, X., Kolesnikov, A., Hounsby, N., & Beyer, L. (2022). Scaling vision transformers. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 12104-12113).
- [21] Beyer, L., Zhai, X., & Kolesnikov, A. (2022). Better plain ViT baselines for ImageNet-1k. arXiv preprint arXiv:2205.01580.
- [22] Yang, Z., Qiu, Z., & Xie, H. (2022). An Image Classification Method Based on Self-attention ConvNeXt. In *International Conference on Computer Engineering and Networks* (pp. 657-666). Springer, Singapore.
- [23] "ADNI | Alzheimer's Disease Neuroimaging Initiative". Erişim 6 Ocak 2022. <https://adni.loni.usc.edu/>.
- [24] Marcus, Daniel S., Anthony F. Fotenos, John G. Csernansky, John C. Morris, ve Randy L. Buckner. "Open Access Series of Imaging Studies: Longitudinal MRI Data in Nondemented and Demented Older Adults". *Journal of Cognitive Neuroscience* 22, sy 12 (01 Aralık 2010): 2677-84. <https://doi.org/10.1162/jocn.2009.21407>.