

Derin Öğrenme Yöntemiyle Alzheimer Hastalığının Tespiti

Gözde Sena KARABAY^{1*}, Mehmet ÇAVAS²

^{1,2} Mekanik Mühendisliği, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

*¹ senakarabay@hotmail.com, ² mcavas@firat.edu.tr

(Geliş/Received: 28/06/2022;

Kabul/Accepted: 07/09/2022)

Öz: Alzheimer hastalığı yaygın olarak görülen bir demans türü olup, ilerleyen ve tedavisi bulunmayan nörodejeneratif bir hastalıktır. Hastalığı teşhis edebilmek için birçok görüntüleme tekniği kullanılmaktadır. Bu tekniklerden biri Manyetik Rezonans Görüntüleme (MRG) tekniğidir. Erken teşhis edilmesi hastalığın ilerlemesini yavaşlatmak ve gerekli önlemleri alma konusunda hasta ve ailesi için büyük önem taşımaktadır. Erken ve doğru teşhis için derin öğrenme yöntemleriyle bu konuda destekleyici çalışmalar gerçekleştirilmiştir. Aynı zamanda hastalığın seyrini takip etmek için de derin öğrenme yöntemleri kullanılmaktadır. Bu çalışmada hastalığın teşhisi için AlexNet, MobileNetV2 mimarileri ve ESA (Evrişimsel Sinir Ağları) modeli kullanılarak gerçekleştirilmiştir. Toplamda 6400 adet MR görüntüsü kullanılarak her iki mimariden özellik çıkarma işlemi yapılarak bu özellikler birleştirilmiştir. KBA (Komşuluk Bileşen Analizi) algoritması kullanılarak özellik seçimi yapılmış ve DVM (Destek Vektör Makineleri) ile sınıflandırma işlemi gerçekleştirilmiştir. Çalışılan modelde %100 doğruluk değeri hesaplanmıştır.

Anahtar kelimeler: Alzheimer hastalığı tespiti, Derin öğrenme, ESA, DVM.

Detection of Alzheimer's Disease with Deep Learning Method

Abstract: Alzheimer's disease is a common type of dementia that is a progressive neurodegenerative disease with no cure. Many imaging techniques are used to diagnose the disease. One of these techniques is Magnetic Resonance Imaging (MRI). Early diagnosis is of great importance for the patient and his family in slowing the progression of the disease and taking the necessary precautions. Supportive studies have been carried out on this subject with deep learning methods for early and accurate diagnosis. At the same time, deep learning methods are used to follow the course of the disease. This study was carried out using AlexNet and MobileNetV2 architectures and CNN (Convolutional Neural Network) model. These features were combined by extracting features from both architectures using a total of 6400 MR images. Feature selection was made using the NCA (Neighbourhood Components Analysis) algorithm and classification were performed with SVM (Support Vector Machine). 100% accuracy value was calculated in the studied model.

Keywords: Alzheimer's disease detection, Deep learning, CNN, SVM.

1. Giriş

Teknoloji geliştikçe insan yaşamı daha kolay ve sürdürülebilir hale gelmektedir. Bu anlamda yapay zekâ büyük önem taşımaktadır. Günümüzde neredeyse her alanda yapay zekâ uygulamalarını görmek mümkün hale gelmiştir. Özellikle sağlık alanında bu anlamda çok ciddi çalışmalar yapılmaktadır. Hastalıkların teşhisi, hastaların takip edilmesi ve tedavi süreçleri ile ilgili önemli destekleyici kolaylıklar sağlamaktadır. Bu açıdan değerlendirildiğinde erken teşhis hastalığın etkili bir şekilde tedavi edilebilmesi için büyük önem arz etmektedir. Yapay zekâ bu anlamda hem hastalığın teşhis edilmesinde hem de tedavi sürecinde önemli bir etkiye sahiptir. Geliştirilen algoritmalar sayesinde hastalıkların teşhisinde büyük başarımlar elde edilmiş ve sağlık alanına önemli katkılar sağlamıştır.

Yapay zekânın alt dalı makine öğrenmesi, makine öğrenmesinin alt dalı ise derin öğrenmedir. İki yöntemin de ayrı ayrı avantajları ve dezavantajları bulunmaktadır. Derin öğrenmenin en büyük avantajı dışarıdan özellik çıkarımının yapılmasına ihtiyaç duyulmadan bu özellikleri kolaylıkla kendisinin çıkarabilmesidir. Ayrıca birden fazla katmandan oluştuğu için yapılan çalışmalarda başarı oranının daha yüksek olduğu görülmüştür. Hastalıkların teşhisini yapabilmek ve hastalıkların seyrini takip edebilmek için tespit edilmesi istenilen hastalığa yönelik verilere ihtiyaç duyulmaktadır. Bu verilerin sayısı arttıkça başarı oranı da buna bağlı olarak artmaktadır.

Alzheimer hastalığının teşhisi zordur. 2021 yılında yayınlanan rapora göre insanların %30'unun yanlış teşhis edildiği belirtilmektedir. Ayrıca Alzheimer hastalığının teşhisinin yapılmasının diğer bir zorluğu da maliyetli olmasıdır. Özellikle düşük gelirli ülkelerde testler yapılırsa bile bunları inceleyebilecek yeterli uzmanın olmayışı

* Sorumlu yazar: senakarabay@hotmail.com Yazarların ORCID Numarası: ¹ 0000-0001-6640-9245, ² 0000-0002-0130-1644

ciddi problemlere neden olmaktadır [1]. Bu vb. olumsuzluklardan dolayı derin öğrenme yöntemiyle hastalığın teşhis edilmesinin önemli faydalar sağlayacağı düşünülmektedir.

Alzheimer hastalığı, ilk olarak 1907 yılında Dr. Alois Alzheimer tarafından tanımlanmıştır. Frankfurt am Main akıl hastanesine yatırılan 51 yaşındaki bir kadın hastada tespit edilmiştir. Hastalık ilerledikçe hastada karmaşık semptomlar görülmüş ve bu semptomlar arasında ciddi hafıza kaybının yer aldığı tespit edilmiştir. Bir takım nesnelere gösterildiğinde onları doğru şekilde adlandırmakta ancak hemen ardından her şeyi unuttuğu tespit edilmiştir. Bunların yanı sıra hastada anlayamama problemi, halüsinasyonlar, okumada zorluk çekme gibi durumların yaşandığı ve hastanın dört buçuk yıllık hastalık sürecinden sonra vefat ettiği görülmüştür [2].

Hastalık genellikle 60 yaşından sonra ortaya çıkmakta, nadir de olsa 30 yaş grubunda da görülebilmektedir. Hastalık sürekli ve kademeli bir şekilde ilerlemekte ve semptomların başlangıcından itibaren hastanın 8-10 yıl arası yaşam sürdürmesi beklenmektedir [3]. 2021 yılına ait verilere göre demans, dünyadaki ölüm nedenleri arasında 7. sıradadır. Dünyada demansla yaşayan 55 milyon insan bulunmaktadır. 2030 yılında bu sayının 78 milyona ulaşabileceği tahmin edilmektedir. Alzheimer's Disease International (ADI), dünya genelinde demans hastası olan kişilerin tahmini olarak %75'inin teşhis edilmediğini belirtmektedir. Bunun en büyük nedenlerinden biri bu hastalığın maliyetinin yüksek olmasıdır [1]. Alzheimer hastalığının 65 yaş ve üzerindeki kişilerde görülme oranı %3-11, 85 yaş ve üzerindeki kişilerde görülme oranı ise %20-47 arasındadır. Yaş ilerledikçe Alzheimer riski de artmaktadır [4].


Alzheimer hastalığını tespit etmek için bazı tıbbi görüntüleme tekniklerinden faydalanılmaktadır. Bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRG), pozitron emisyon tomografi (PET) gibi görüntüleme yöntemleriyle Alzheimer hastalığı teşhis edilmektedir.

Liu ve arkadaşlarının yapmış olduğu çalışmada [5], 4 sınıflı bir veri seti kullanılarak Alzheimer hastalarına ait 311 adet MR görüntüsünden faydalanılmıştır. Çoklu sınıflandırma problemi için DVM'nin one-against-one yöntemi kullanılarak alınan sonuçlar değerlendirildiğinde 4 sınıf için %47,42 başarı elde edilmiştir. Islam ve Zhang'ın yapmış olduğu çalışmada [6], OASIS veri seti kullanılmış ve bu veri setindeki Alzheimer hastalarına ait 4 sınıflı, 416 adet MR görüntülerinden faydalanılarak Inception-V4 mimarisi kullanılmış ve elde edilen sonuçlar değerlendirildiğinde %73,75 başarı elde edilmiştir. Ramzan ve arkadaşlarının yapmış olduğu çalışmada [7], ADNI veri tabanı kullanılmış ve Alzheimer hastalarına ait rs-fMRI görüntülerinden faydalanılarak bu veri setinde 6 sınıfa ait 138 adet görüntü kullanılmış ve alınan sonuçlar değerlendirildiğinde %97,92 başarı elde edilmiştir. Subramoniam ve arkadaşlarının yapmış olduğu çalışmada [8], 4 sınıflı veri seti kullanılarak Alzheimer hastalarına ait 6400 adet MR görüntüsünden faydalanılmış ve VGG-16, VGG-19, ResNet-18, ResNet-34, ResNet-50, ResNet-101 mimarileri sırasıyla kullanılırken en iyi sonuçlar ResNet-101 mimarisinden %99,70 başarı elde edilmiştir. Ghazal ve arkadaşlarının yapmış olduğu çalışmada [9], 4 sınıflı veri seti kullanılmıştır. Alzheimer hastalarına ait 6400 adet MR görüntüsünden faydalanılarak ADDTLA sistem modeli önerilmiş ve %91,70 başarı elde edilmiştir. Guerrero ve arkadaşlarının yapmış olduğu çalışmada [10], ADNI ve ADNI-GO veri setleri kullanılmıştır. ADNI veri setinde 4 sınıfa ait 511 adet görüntü, ADNI-GO veri setinde 2 sınıfa ait 363 görüntü bulunmaktadır. ADNI veri setinde %71, ADNI-GO veri setinde %65 başarı elde edilmiştir.

Bu çalışmada evrimsel sinir ağları (ESA), özellik çıkarımı için AlexNet ve MobileNetV2 mimarileri ve destek vektör makinesi (DVM) sınıflandırma yöntemi kullanılmıştır. Alzheimer hastalığı tespitinin zor ve maliyetli olması göz önünde bulundurulduğunda bu çalışmanın hem hastalık teşhisinde hem de hastalığın evrelerini belirlemede faydalı olacağı düşünülmektedir.

2. Materyal ve Yöntem

Bu çalışmada MATLAB programı ve derin öğrenme modellerinden biri olan evrimsel sinir ağları kullanılarak MR görüntülerinin analizleri yapılmıştır. Analizler için derin öğrenme mimarilerinden AlexNet ve MobileNetV2 mimarileri ve 10-k çapraz doğrulama kullanılarak 6400 adet görüntü 270x270 boyutuna yükseltilmiştir. Çalışmanın başarı oranını arttırmak için özellik çıkarma işlemi gerçekleştirilerek MobileNetV2 mimarisinden 1000 adet özellik, AlexNet mimarisinden 4096 adet özellik çıkarılmıştır. Bu özellikler birleştirilerek 6400x5096 boyutunda özellik matrisi elde edilmiş ve KBA (Komşuluk Bileşen Analizi) algoritmasıyla ilk 1000 özellik seçilerek DVM ile sınıflandırma işlemi yapılmıştır. Şekil 1'de çalışmaya ait akış diyagramı verilmektedir.



Şekil 1. Çalışmaya ait akış diyagramı


2.1. Derin öğrenme

Derin öğrenme, insanların çözebildiği karmaşık problemleri çözmeyi hedefleyen, veri, algoritma ve donanım bilgisi gerektiren sistemlerin tasarlanması üzerine geliştirilmiş disiplinler arası bir çalışma alanıdır. Birden fazla katman içerir ve özellik çıkarımını kendisi yapmaktadır. Günümüzde kullanılan farklı derin öğrenme modelleri bulunmakla birlikte çalışma alanına ve verilere göre değişiklik göstermektedir. Görüntü verileri için evrimsel sinir ağları kullanılmaktadır. Yinelemeli sinir ağları (YİSA), genellikle sesten yazıya, yazıdan sese dönüştürmek için kullanılmaktadır. Ayrıca borsada veya zaman serisi verileri için de kullanılmaktadır. Çekişmeli üretici ağlar (Generative Adversarial Networks - GAN) ise resim, müzik ve şiir gibi verilerin yeni örneklerle üretilmesi için kullanılmaktadır. GAN'lar bunların yanı sıra düşük çözünürlüklü görüntüleri iyileştirmek için ve sentetik veri üretimi için de kullanılmaktadır. Derin öğrenme, görüntü sınıflandırmada, ses tanıma ve sorulan sorulara cevap verebilme yeteneğinde insan seviyesine kadar yaklaşmıştır.


2.1.1. Yapay sinir ağları

Yapay sinir ağları (YSA), biyolojik sinir ağlarının matematiksel modelidir. Yapay sinir ağının temel taşı yapay nöronlardır. Biyolojik sinir ağları davranışlarını ve tepkilerini çevrelerinden aldıkları girdilere göre öğrenmektedir. Yapay sinir ağları da tıpkı biyolojik sinir ağları gibi öğrenebilmektedir. Burada üç farklı öğrenme yöntemi kullanılmaktadır ki, bunlar denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir. Yapay sinir ağları öğrenme verileri ve öğrenme kuralları doğrultusunda girdilere göre uygun çıkışı üretebilmektedir. Yapay sinir ağları örüntü tanıma, regresyon analizi, zaman serisi, sınıflandırma, fonksiyon yaklaşımı, veri işleme, filtreleme, kümeleme ve karar verme gibi problemlerde kullanılabilir [11].

Biyolojik nöronlar, Şekil 2'deki gibi üç ana bölümden oluşmakta ve bunlar dendritler, hücre gövdesi (soma) ve aksonlardır. Yapay nöronlar ise Şekil 3'teki gibi girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış değerinden oluşmaktadır [12].



Şekil 2. Biyolojik nöron [12]



Şekil 3. Yapay nöron [12]

Yapay nöronun her girdi değeri ağırlıklarla çarpılmakta ve bir sonraki adımda bu değerler toplama fonksiyonunda toplanmaktadır. Belirli eşik değerinden geçirildikten sonra aktivasyon fonksiyonundan geçirilmekte ve çıkış elde edilmektedir. Öğrenme yöntemlerinden hangisi kullanılırsa kullanılsın öğrenmenin görevi, maliyet fonksiyonunu düşürmek için öğrenme verilerine bağlı olarak ağırlık ve bias değerlerini ayarlamaktır [11].

Geri yayılım algoritması, sürekli çıktılı ileri beslemeli ağlarda kullanılmaktadır. Eğitim sırasında ağıdaki tüm ağırlıklar rastgele sayılara ayarlanmakta ve ağ, her girdi için rastgele çıktı üretmektedir. İstenilen çıktı ile bu çıktı arasındaki kare farkı ölçülerek eğitimdeki tüm bu kare farklarının toplamına ağırlık toplam hatası denilmektedir. Geri yayılımdaki temel amaç toplam hatanın en aza indirgenmesi için gerekli ağırlık değerlerinin bulunmasıdır. Geri yayılımda her defasında ağırlıklar ve eşik değerleri değiştirilmekte ve bu şekilde hata değeri giderek küçültülerek problemin çözümü için en iyi sinir ağı elde edilmektedir [13].


2.1.2. Evrişimsel sinir ağları

Evrişimsel sinir ağları, görüntüler içerisinde örüntü tanıma da kullanılmaktadır. Görüntüye ait özelliklerin mimariye kodlanmasına izin vererek ağı görüntü odaklı görevler için daha uygun hale getirirken aynı zamanda daha az parametre kullanılmasını sağlamaktadır. Bazı durumlarda overfitting (aşırı uyuma) yaşanmaktadır. Overfitting, ağı etkili bir şekilde öğrenmeyi engellemeye sebep olur ve bu durumun önüne geçmek için daha az parametre kullanılmaktadır [14].

Giriş katmanına görüntü verisi eklenmekte ve evrişim katmanında özellik haritaları denilen yeni görüntüler elde edilmektedir. Bu katmanda ağırlıklar ve ağırlıklı toplamlar yerine görüntüleri dönüştüren filtreler kullanılmaktadır. Bunlara evrişim filtreleri denilmektedir. Evrişim katmanının içerdiği filtre sayısı kadar özellik haritası oluşturularak [16] modelin karmaşıklığını azaltmak için depth (derinlik), stride (adım kaydırma) ve zero-padding (sıfır ekleme) işlemleri uygulanmaktadır [14]. ESA'nın performansını artırmak için en uygun aktivasyon fonksiyonu seçilmekte ve bu yapıda genellikle ReLU aktivasyon fonksiyonu kullanılmaktadır [17]. Bir sonraki katman olan pooling (havuzlama) katmanı boyut azaltmak için kullanılırken bu katmanda belli filtreler tanımlanarak belirli stride (adım kaydırma) değeriyle görüntü üzerinde gezdirme işlemi yapılabilmektedir. Piksellerin maksimum değerlerini (maksimum havuzlama) veya ortalama değerini (ortalama havuzlama) alarak bu işlem gerçekleştirilerek boyut küçültülmektedir. Dropout katmanı ise ezberleme katmanıdır ve büyük veriler kullanıldığı için ağ ezberleme işlemi yapmaktadır. Bunun önüne geçmek için bu katmanda ağıdaki bazı düğümler kaldırılmaktadır [18]. Tam bağlantılı katmanda ise bir önceki katmandaki tüm nöronlar alınmakta ve bu katmanın her bir nöronuna bağlanmaktadır. Son tam bağlantılı katmanın ardından bir çıktı katmanı gelmekte ve burada sınıflandırma işlemi için genellikle softmax sınıflandırıcısı kullanılmaktadır. Bir diğer sınıflandırma yöntemi olarak DVM kullanılmaktadır [19].

2.2. Çalışmada kullanılan veri seti

Bu veri seti Alzheimer hastalarının MR görüntülerinden oluşmaktadır ve toplamda 6400 adet görüntü bulunmaktadır. Bu çalışmada kullanılan bütün görüntüler açık erişimi bulunan Kaggle sitesinden alınmıştır. Şekil 4'te gösterildiği gibi veriler, hafif seviye, orta seviye, Alzheimer bulunmayan ve çok hafif seviye olmak üzere toplamda dört sınıftan oluşmaktadır.



Şekil 4. (a) hafif seviye, (b) orta seviye, (c) Alzheimer bulunmayan, (d) çok hafif seviye [20]

3. Bulgular ve Tartışma

Çalışma, Intel(R) Core(TM) i5-4210U CPU @ 1.70GHz ~ 2.40 GHz işlemci, 8 GB Ram'e sahip Windows 10 işletim sistemi ile MATLAB 2021b sürümünün classification learner toolbox'ı kullanılarak gerçekleştirilmiştir. Tablo 1'de sınıflandırıcılara göre tahmin değeri ve başarı oranları verilmiştir.

Tablo 1. Çalışılan modelin sınıflandırıcılara göre tahmin değeri ve başarı oranı

Sınıflandırıcı	Doğru Tahmin	Yanlış Tahmin	Başarı Oranı (%)
Karar Ağaçları	3863	2537	60,4
Lineer Diskriminant	5304	1096	82,9
Naif Bayes	3791	2609	59,2
DVM	6355	45	99,3
K- En Yakın Komşuluk	6398	2	100
Topluluk	6397	3	100
Nöral Ağlar	6064	336	94,8
Çekirdek	6111	289	95,5

Tablo 1'de görüldüğü gibi Karar Ağaçları (Fine Tree) sınıflandırıcısı ile %60,4 doğruluk değeri hesaplanmıştır. Lineer Diskriminant sınıflandırıcısı ile %82,9 doğruluk değeri hesaplanmıştır. Naif Bayes (Kernel Naive Bayes) sınıflandırıcısı ile %59,2 doğruluk değeri hesaplanmıştır. DVM (Cubic SVM) sınıflandırıcısı ile %99,3 doğruluk değeri hesaplanmıştır. K- En Yakın Komşuluk (Fine KNN) sınıflandırıcısı ile %100 doğruluk değeri hesaplanmıştır. Topluluk (Subspace KNN) sınıflandırıcısı ile %100 doğruluk değeri hesaplanmıştır. Nöral Ağlar (Wide Neural Network) sınıflandırıcısı ile %94,8 doğruluk değeri hesaplanmıştır. Son olarak Çekirdek (SVM Kernel) sınıflandırıcısı ile %95,5 doğruluk değeri elde edilmiştir. Buna göre en iyi sonuçlar K- En Yakın Komşuluk ve Topluluk sınıflandırıcısı ile elde edildiği görülmektedir. Şekil 5'te K- En Yakın Komşuluk hata matrisi sonucu ve Şekil 6'da Topluluk hata matrisi sonucu verilmiştir. Tablo 2'de sınıflandırıcıların bir adet görüntü üzerinde harcadığı eğitim ve test sürelerinin yaklaşık değerleri verilmektedir.

Tablo 2. Bir adet görüntüye ait performans süreleri

Sınıflandırıcı	Eğitim Süresi (sn)	Test Süresi (sn)
Karar Ağaçları	0,028	0,006
Lineer Diskriminant	0,003	0,001
Naif Bayes	0,6	0,137
DVM	0,253	0,058
K- En Yakın Komşuluk	0,440	0,102
Topluluk	0,525	0,123
Nöral Ağlar	0,159	0,042
Çekirdek	0,45	0,103

		Tahmini Sınıf			
		1	2	3	4
Gerçek Sınıf	1	896			
	2		64		
	3			3200	
	4			2	2238

Şekil 5. K- En Yakın Komşuluk hata matrisi sonucu

Şekil 5'e göre K- En Yakın Komşuluk sınıflandırıcısında dördüncü sınıfa ait 2 adet görüntüyü üçüncü sınıfa ait olarak tespit etmiştir.

		Tahmini Sınıf			
		1	2	3	4
Gerçek Sınıf	1	896			
	2		64		
	3			3200	
	4	1		2	2237

Şekil 6. Topluluk hata matrisi sonucu

Şekil 6'ya göre Topluluk sınıflandırıcısında dördüncü sınıfa ait 1 adet görüntüyü birinci sınıfa ait olarak, 2 adet görüntüyü ise üçüncü sınıfa ait olarak tespit etmiştir. Çalışılan modelde sınıflandırıcılara ait performans sonuçları 4 sınıfın ortalama değerleri alınarak Tablo 3'te verilmiştir.

Tablo 3. Sınıflandırıcılara ait performans sonuçları

Sınıflandırıcı	MCC	Duyarlılık	Özgüllük	Hassasiyet	F1-Skor
Karar Ağaçları	0,255	0,460	0,836	0,402	0,411
Lineer Diskriminant	0,787	0,864	0,928	0,853	0,859
Naif Bayes	0,439	0,548	0,842	0,659	0,576
DVM	0,989	0,994	0,996	0,990	0,992
K- En Yakın Komşuluk	0,999	0,999	0,999	0,999	0,999
Topluluk	0,999	0,999	0,999	0,999	0,998
Nöral Ağlar	0,924	0,953	0,978	0,939	0,946
Çekirdek	0,895	0,971	0,983	0,866	0,908

Alzheimer hastalığının tespiti üzerine çalışmalar günümüzde hâlâ devam etmektedir. Derin öğrenme yöntemleri geliştikçe hastalığın teşhis edilmesinde de başarılı sonuçlar elde edilmektedir. Tablo 4'te yapılan çalışma ile literatürdeki bazı çalışmalar karşılaştırılmıştır.

Tablo 4. Çalışılan model ile literatürdeki sonuçların karşılaştırılması

Çalışma	Veri Sınıf Sayısı	Veri Sayısı	Başarı Oranı (%)
Liu ve arkadaşları [5]	4	311	47,42
Islam ve Zhang [6]	4	416	73,75
Ramzan ve arkadaşları [7]	6	138	97,92
Subramoniam ve arkadaşları [8]	4	6400	99,70
Ghazal ve arkadaşları [9]	4	6400	91,70
Guerrero ve arkadaşları [10]	4	511	71
	2	363	65
Çalışılan Model	4	6400	100

Tablo 4’te görüldüğü gibi Liu ve arkadaşlarının yaptığı çalışmada [5], 4 sınıftan oluşan 311 adet görüntüden %47,42 doğruluk değeri elde edilmişken, Islam ve Zhang yapmış oldukları çalışmada [6], 4 sınıftan oluşan 416 adet görüntüden %73,75 doğruluk değeri elde etmişlerdir. Ramzan ve arkadaşlarının yapmış olduğu çalışmada [7], 6 sınıftan oluşan 138 görüntüden %97,92 doğruluk değeri elde edilmişken, Subramoniam ve arkadaşlarının yapmış olduğu çalışmada [8], 4 sınıftan oluşan 6400 adet görüntüden %99,70 doğruluk değeri elde etmişlerdir. Ghazal ve arkadaşlarının yapmış olduğu çalışmada [9], 4 sınıftan oluşan 6400 adet görüntüden %91,70 doğruluk değeri elde edilmiştir. Guerrero ve arkadaşlarının yapmış olduğu çalışmada [10], 4 sınıftan oluşan 511 adet görüntüden %71 doğruluk değeri elde edilmişken, 2 sınıftan oluşan 363 görüntüden %65 doğruluk değeri elde edilmiştir. Yapılan çalışma literatürdeki çalışmalar ile karşılaştırıldığında elde edilen sonuçların başarılı olduğu görülmektedir.

4. Sonuçlar

Yapay zekâ her geçen gün farklı alanlarda farklı uygulamalar için kullanılmakta ve her geçen gün kullanım alanı ve kullanıcı sayısı artmaktadır. Özellikle sağlık alanında yapılan çalışmalar neticesinde gelinen noktada insan hayatına katkısı inanılmaz seviyeye ulaşmıştır. Bu gelişim özellikle hastalıkların tanı ve tedavisinde, hastaların takip edilmesinde vb. birçok alanda doktorlara ve hastalara büyük avantajlar sağlamaktadır. Özellikle kanser başta olmak üzere birçok hastalığın erken teşhisi hastalığın etkili bir şekilde tedavi edilebilmesinde hayati önem arz etmektedir. Bu vb. hususlar dikkate alındığında yapay zekâ ile birlikte geliştirilen algoritmalar sayesinde önemli katkılar sağlamaktadır.

Yapılan bu çalışmada 4 sınıfa ait 6400 adet MR görüntüsü kullanılmış, AlexNet ve MobileNetV2 mimarileri ile özellik çıkarma işlemi ile birlikte DVM sınıflandırma yöntemi kullanılarak en yüksek başarı değeri %100 olarak elde edilmiştir.

Alzheimer hastalığının teşhisi, tedavisi, tedavi maliyeti vb. dikkate alındığında bu çalışmanın katkı sağlayacağı düşünülmekle birlikte aynı zamanda hastalara uygulanan tedavilerde de yardımcı olabileceği öngörülmektedir.

Kaynaklar

- [1] Alzheimer's Disease International & McGill University. World Alzheimer Report 2021, 2021.
- [2] Stelzmann R., Schnitzlein HN, Murtagh FR. An English Translation of Alzheimer's 1907 Paper, "Über eine eigenartige Erkankung der Hirnrinde". Clinical Anatomy 1995; 8(6): 429-431.
- [3] Small GW, Rabins PV, Barry PP, Buckholtz NS, Dekosky ST, Ferris SH, Finkel SI, Gwyther LP, et al. Diagnosis and treatment of Alzheimer disease and related disorders: consensus statement of the American Association for Geriatric Psychiatry, the Alzheimer's Association, and the American Geriatrics Society. The Journal of the American Medical Association 1997; 278(16): 1363-1371.
- [4] Alzheimer Hastalığı Nedir?. <https://www.alzheimerderneği.org.tr/alzheimer-hastaligi-nedir/>. Erişim tarihi: Nisan 2022
- [5] Liu S, Liu S, Cai W. Early Diagnosis of Alzheimer's Disease with Deep Learning, IEEE, 2014.
- [6] Islam J, Zhang Y. A Novel Deep Learning Based Multi-class Classification Method for Alzheimer's Disease Detection Using Brain MRI Data. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics) 2017; 10654: 213-222.
- [7] Ramzan F, Khan MUG, Rehmat A, Iqbal S, Saba T, Rehman A, Mehmood Z. A Deep Learning Approach for Automated Diagnosis and Multi-Class Classification of Alzheimer's Disease Stages Using Resting-State fMRI and Residual Neural Networks. Journal of Medical Systems 2020; 44(2): 1-16.
- [8] Subramoniam M, Aparna TR, Anurenjan PR, Sreeni KG. Deep Learning-Based Prediction of Alzheimer's Disease from Magnetic Resonance Images. Intelligent Vision in Healthcare 2022: 145-151.
- [9] Ghazal TM, Abbas S, Munir S, Khan MA, Ahmad M, Issa GF, Zahra SB, Khan MA, Hasan MK. Alzheimer disease detection empowered with transfer learning, Computers, Materials Continua 2022; 70: 5005-5019.
- [10] Guerrero R, Wolz R, Rao AW, Rueckert D. Manifold population modeling as a neuro-imaging biomarker: Application to ADNI and ADNI-GO, Neuroimage 2014; 94: 275-286.
- [11] Suzuki K. Artificial Neural Networks: Methodological Advances and Biomedical Applications. London: IntechOpen, 2011.
- [12] Da Silva IN, Spatti DH, Flauzino RA, Liboni LHB, dos Reis Alves SF. Artificial Neural Networks. Switzerland: Cham: Springer International Publishing, 2017.
- [13] Krogh A. What are artificial neural networks?. Nature Biotechnology 2008; 26(2): 195-197.
- [14] O'Shea K, Nash R. An Introduction to Convolutional Neural Networks. arXiv Prepr. arXiv151108458. 2015.
- [15] Convolutional Neural Network | Deep Learning | Developers Breach. <https://developersbreach.com/convolutional-neural-network-deep-learning/>. Erişim: 13 Mayıs 2022

- [16] Kim P. MATLAB Deep Learning. California: Apress Berkeley, 2017.
- [17] Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, Liu T, Wang X, et al. Recent advances in convolutional neural networks. *Pattern Recognition* 2018; 77: 354-377.
- [18] İnik Ö, Ülker E. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpasa Journal of Scientific Research* 2017; 6(3): 85-104.
- [19] Guo T, Dong J, Li H, Gao Y. Simple convolutional neural network on image classification. 2017 IEEE 2nd International Conference on Big Data Analysis, ICBDA 2017; 10-12 March 2017; Beijing, China. pp. 721-724.
- [20] Alzheimer's Dataset (4 class of Images). <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images>. Erişim: 2 Eylül 2022