



MR görüntülerinden Alzheimer tespitinde boyut azaltma ve derin öğrenme yaklaşımlarının karşılaştırılması

Comparison of dimension reduction and deep learning approaches to detect Alzheimer from MR images

Ömer Türk*

Mardin Artuklu Üniversitesi, Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, omerturk@artuklu.edu.tr

ORCID: <https://orcid.org/0000-0002-0060-1880>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 6 Temmuz 2022
Revizyon 16 Ağustos 2022
Kabul 2 Eylül 2022
Online 30 Eylül 2022

Anahtar Kelimeler:

MR, Alzheimer, BBA, TBA, YDG, k-EYK

ÖZ

Her yıl milyonlarca insana Alzheimer teşhisi konulmaktadır. Alzheimer, nörodejeneratif bir hastalıktır. Kliniklerde bu hastalığın en doğru tespiti için biyopsi işlemi uygulanmaktadır. Ancak bu işlem beyin üzerinden gerçekleştirildiğinden hasta için büyük bir risk teşkil etmektedir. Bundan dolayı bu tür hastalıkların tespit edilmesinde daha çok nörogörüntüleme teknikleri tercih edilmektedir. Bu nörogörüntüleme tekniklerinden biri de Manyetik Rezonans (MR) görüntülemidir. MR invazif olmayan bir araç olup kliniklerde çokça tercih edilmektedir. Bunun yanında mühendislik alanında MR görüntüleri kullanılarak bilgisayar destekli tanı sistemleri de geliştirilmektedir. Bu çalışmada dört farklı Alzheimer sınıfı içeren MR görüntüleri kullanılarak, bu hastalığın demans seviyesi tespit edilmeye çalışılmıştır. Veri kümesi; orta demans, hafif demans, çok hafif demans ve demans olmayan sınıflardan oluşmaktadır. Çalışmada ilk önce, MR görüntüleri ham olarak matrislere dönüştürülmüştür. Elde edilen matrislere dağılımın normale yaklaştığı, standart sapmanın bir değerini aldığı standardizasyon işlemi uygulanmıştır. Daha sonra veri kümesi Evrişimsel Sınır Ağında (ESA) sınıflandırılmıştır. Aynı zamanda Temel Bileşen Analizi (TBA), Bağımsız Bileşen Analizi (BBA) ve Yerel Doğrusal Gömme (YDG) yöntemleri ayrı ayrı uygulanarak, öznelik vektörü elde edilmiştir. Elde edilen öznelik vektörü k-en Yakın Komşu (k-EYK) algoritması ile sınıflandırılmıştır. Sınıflandırma sonucunda, ESA, k-EYK-TBA, k-EYK-BBA ve k-EYK-YDG yöntemlerinde sırasıyla, %88.44, %95.52, %98.22 ve %91.14 sınıflandırma doğruluğu bulunmuştur. Çalışma sonucunda en iyi performansın BBA tabanlı k-EYK sınıflandırıcı ile elde edildiği görülmüştür.

ARTICLE INFO

Article history:

Received 6 July 2022
Received in revised form 16 August 2022
Accepted 2 September 2022
Available online 30 September 2022

Keywords:

MR, Alzheimer, ICA, PCA, LLE, k-NN

Doi: 10.24012/dumf.1141233

* Sorumlu Yazar

ABSTRACT

Millions of people are diagnosed with Alzheimer's each year. Alzheimer's is a neurodegenerative disease. In clinics, biopsy is performed for the most accurate detection of this disease. However, since this procedure is invasive, it poses a great risk for the patient. Therefore, non-invasive such as neuroimaging techniques are preferred more in the detection of such diseases. One of these neuroimaging techniques is Magnetic Resonance Imaging (MRI). MRI is a non-invasive tool and is widely preferred in clinics. In addition, computer-aided diagnosis systems are being developed by using MRI images in the field of engineering. In this study, the dementia level of this disease was tried to be determined by using MRI images containing four different Alzheimer's classes. The data set consists of moderate dementia, mild dementia, very mild dementia and non-dementia classes. In the study, firstly, MRI images were converted into matrices raw. The standardization process was applied to the obtained matrices, in which the distribution approached normal and the standard deviation took the value of 1. Then the data set was classified in Convolutional Neural Network (CNN). At the same time, the feature vector was obtained by applying the Principal Component Analysis (PCA), Independent Component Analysis (ICA) and Local Linear Embedding (LLE) methods individually. The resulting feature vector was classified with the k-NN classifier. As a result of the classification, classification accuracy was found to be 88.44%, 95.52%, 98.22% and 91.14% in CNN, k-NN-PCA, k-NN-ICA and k-NN-LLE methods, respectively. As a result of the study, it was seen that the best performance was obtained with the ICA-based k-NN classifier.

Giriş

Alzheimer hastalığı (AH) kronik nörodejeneratif bir hastalıktır [1]. Günümüze kadar AH nedeni anlaşılamamıştır [1]. Bundan dolayı tam bir tedavisi bulunmamaktadır [1]. Yapılan tedaviler bu hastalığın yavaş ilerlemesini sağlamak amaçlıdır [1-2]. AH'nın erken tespiti sayesinde, hastalığın ilerlemesi yavaşlatılabilir [2]. Bu sayede hastanın yaşam kalitesi artırılabilir. Kliniklerde, AH'nın en doğru tespiti için biyopsi işlemi gerekmektedir [3]. Ancak bu işlem doğrudan beyin üzerinde yapılması gerektiğinden, hasta için büyük bir risk teşkil etmektedir [3]. Bu bakımdan farklı nörogörüntüleme araçları kullanılarak bu risk giderilebilmektedir. Bu nörogörüntüleme araçları arasında, Manyetik Rezonans görüntüleme (MR), Dinlenme Durumu Fonksiyonel Manyetik Rezonans görüntüleme (rs-fMR) ve Pozitron Emisyon Tomografisi (PET) gibi çeşitli görüntüleme araçları sayılabilir [3]. Özellikle MR görüntüleri, daha kesin beyin dokusu tasviri sağlayan çeşitli doku parametrelerini belirtmesi ve insan vücudunun yapısı hakkında kapsamlı bilgiler sunması açısından, önemli bir tıbbi görüntüleme aracı haline gelmiştir [4]. MR invazif olmayan (herhangi bir cerrahi müdahale gerektirmeyen) tıbbi bir görüntüleme aracıdır [4]. MR özellikle beyin araştırmalarında (Tümör, Alzheimer vs.) klinisyenler için vazgeçilmez bir araçtır [4]. Mühendislik anlamında, özellikle görüntü işleme alanında bu araçlar kullanılmaktadır. Bu tür nörogörüntüleme araçlarına dayalı bilgisayar destekli tanı sistemleri ayrı bir araştırma alanı olmuştur. Bu alan klinisyenlere fikir ve karar vermede değerli araçlar sunmaktadır.

Literatürde bilgisayar destekli tanı sistemleri genel olarak iki şekilde modellenmektedir [5]. Bunlardan birincisi konvansiyonel yöntemlerdir. Bu yöntemde görüntüler matrislere dönüştürülür. Elde edilen matrislerden öznelik elde edilir. Öznelik çıkarma yöntemlerinin iki temel amacı vardır: Bunlardan ilki, farklı hedef türlerinin birbirinden ayrılabilmesi için hedefler arasında en ayırt edici özellikleri bulmaktır; diğeri ise verinin sahip olduğu özellikleri koruyarak hedef verilerin boyutsallığını azaltmaktır [6]. Bu yöntem için geliştirilmiş birçok teknik mevcuttur. Bunlar arasında; Temel Bileşen Analizi (TBA), Bağımsız Bileşen Analizi (BBA) ve Yerel Doğrusal Gömme (YDG) teknikleri sayılabilir. İkinci bilgisayar destekli tanı sistemi ise derin öğrenme mimarilerine dayalı modeldir [5]. Bu modelde görüntülerin ham hali kullanılarak, derin öğrenme mimarilerinde değerlendirilmektedir. Bu iki modele ait, aşağıda bilgisayar destekli tanı sistemleri için tasarlanmış literatür çalışmaları verilmiştir.


Shanmugam ve arkadaşları tarafından yapılan çalışmada, MR görüntüleri, transfer öğrenme yaklaşımı kullanılarak sınıflandırılmıştır. Çalışmada, GoogleNet, AlexNet ve ResNet-18'in AH'yi tespit etmedeki doğruluğu sırasıyla %96.39, %94.08 ve %97.51 olarak bulunmuştur [7]. Park

ve arkadaşları, büyük ölçekli gen ekspresyonu ve DNA metilasyon verilerini kullanarak AH'yi tahmin edebilen derin öğrenmeye dayalı bir model önermiştir. Farklı bir öznelik seçme yöntemi kullanılarak, başarımları artırılmıştır. Çalışma sonucunda %82.3 doğrulama performansı elde edilmiştir [8]. Liu ve diğerleri, Siyem ağları (Siamese Networks) kullanarak MR görüntülerinden AH'yi tespit etmişlerdir. Çalışmada farklı boyut indirgeme yöntemlerini kullanarak %92.80 başarımları elde edilmiştir [9]. Lee ve arkadaşları, derin sinir ağları tarafından öğrenilen her bölgedeki vokseller arasındaki karmaşık doğrusal olmayan ilişkileri kullanarak, bir bölgesel anormallik temsili çıkarmışlardır. Çalışmada %88.52 sınıflandırma doğruluğu bulunmuştur [10]. Goenka ve diğerleri, alzheimer tespitini için alt küme seçimi, tek biçimli seçim ve interpolasyon yakınlaştırma yöntemlerini kullanmıştır. Çalışmada alzheimer hastalığının tespitinde 3-boyutlu derin öğrenme mimarisi ile % 98.26 başarımları elde edilmiştir [11]. Öziç ve diğerleri voksel tabanlı bilgisayar tanı sistemi önermiştir. Çalışmada normal kontrol ve AH hastaları sınıflandırılmıştır. Elde edilen öznelikler Destek Vektör Makinesinde (DVM) %92.85 başarımla sınıflandırılmıştır [12]. Oh ve diğerleri, MR görüntülerinden AH tespiti için derin öğrenmeye dayalı bir yöntem önermiştir. Dört sınıf içeren MR görüntüleri, Evrişimsel Siniri Ağına (ESA) verilerek, %86.60 sınıflandırma başarımları elde edilmiştir [13]. Johannes Rieke ve diğerleri, 3-boyutlu ESA mimarisi kullanarak, MR görüntülerinden AH tespiti yapmıştır. Çalışmada normal kontrol ve AH MR görüntüleri sınıflandırmıştır. 3-boyutlu ESA mimarisinden AH % 77.00 başarımları ile tespit edilmiştir [14].

Yukarıda verilen çalışmalarda önerilen bilgisayar destekli tanı modellerinin amacı MR temelli AH hastalığının tespitidir. Bu çalışmada Orta Demans (OD), hafif demans (HD), çok hafif demans (ÇHD) ve demans olmayan (DO) MR görüntülerinin bir derin öğrenme mimarisi olan hem ESA'da hem de öznelik elde etme ve veri boyutu azaltma yöntemleri kullanılarak k-en Yakın Komşu (k-EYK) algoritmasında sınıflandırılması amaçlanmıştır. Öznelik elde etme ve veri boyutu azaltma yöntemi olarak TBA, BBA ve YDG teknikleri kullanılmıştır. Çalışmada MR görüntülerinden demans tespitinde TBA, BBA ve YDG tekniklerinin kullanımı ve bu tekniklerin, bu çalışma için oluşturulan ESA mimarisi ile karşılaştırılması, çalışmanın özgün tarafı olmaktadır. Elde edilen sonuçlar doğrultusunda derin öğrenme mimarisi ve öznelik elde etme yöntemleri karşılaştırılmış ve sonuçların bilgisayar destekli tanı başarımları karşılaştırılmıştır.

Materyal ve Metot

Bu bölümde çalışmada kullanılan veri kümesi ve yöntemlerden bahsedilecektir. AH tanısı için önerilen modelin akış diyagramı Şekil 1'de verilmiştir.



Şekil 1. AH tanısında önerilen modelin akış diyagramı

Çalışmada, veri kümesi ön işlem aşamasında matrislere dönüştürülmüştür. Elde edilen matrislere dağılımın normale yaklaştığı, standart sapmanın bir değerini aldığı standardizasyon işlemi uygulanmıştır. Bu işlemden sonra veri kümesi ESA ağına verilmiştir. K-EYK sınıflandırmada ise veri boyutunu azaltma ve öznelik elde etme teknikleri kullanılarak sınıflandırılmıştır.

Veri Kümesi

Çalışmada kullanılan MR görüntüleri kaggle platformundan alınmıştır [15]. Bu MR görüntülerin boyutu 128x128 pikselden oluşmaktadır. Veri kümesi 4 farklı sınıftan oluşmakta ve toplam 6400 MR görüntüsü içermektedir. Bu sınıflara ait birer örnek MR görüntüsü Tablo 1'de verilmiştir.

Tablo 1. Çalışmada kullanılan sınıflara ait örnek MR görüntüleri

Sınıf	MR Görüntüsü
DO	
ÇHD	
HD	
OD	

Bu görüntülerden; 896 görüntü HD, 64 görüntü OD, 3200 görüntü DO ve 2240 görüntü de ÇHD grubundan oluşmaktadır.

Temel Bileşen Analizi

TBA bir boyut azaltma ve öznelik elde etme yöntemidir. TBA yönteminde veri ortalaması hesaplanır. Hesaplanan ortalama değer veriye ait elemanlardan çıkarılarak merkezleme işlemi gerçekleştirilir. Sonraki aşamada rastgele değişken kümeleri arasındaki korelasyonun ölçüsü için kovaryans matrisi hesaplanır [16-18].

Temel bileşen analizinde, X vektörü için, ortalama vektörünün hesaplanması;

Burada; $i=1, 2, 3, \dots, N$ olmak üzere ve $X=[x_1, x_2, x_3, \dots, x_n]$ olmak üzere;

Ortalama Denklem (1):

$$O = \frac{1}{N} \sum_{i=1}^N X_i \quad (1)$$

Burada O , X vektörünün ortalamasıdır.

Kovaryans matrisi Denklem (2):

$$Q = \frac{1}{N} \sum_{i=1}^N (X_i - O)(X_i - O)^T \quad (2)$$

olarak hesaplanır. Burada T transpoz, Q matrisi ise kovaryans matris ile tanımlanan öz vektörleri gösterir.

Bağımsız Bileşen Analizi

BBA, verilerin doğrusal bir koordinat sisteminde istatistiksel olarak birbirinden bağımsız olmasını sağlar. Aynı zamanda veriler arasındaki istatistiksel bağımlılığı azaltmak için doğrusal dönüşümler gerçekleştirir [16-18]. Bu dönüşümler sonucunda veri boyutu azaltılır ve öznelik vektörü oluşturulur. BBA'nın temel amacı, karışık verilerden, kaynak verileri bulmaktır. Karışıklık vektörü Denklem (3) kullanılarak elde edilir.

K , ikinci dereceden bir kare matris olan karıştırma matrisi olsun.

$$X = KxV \quad (3)$$

Burada, X karışık piksel vektörü, V kaynak piksel vektörüdür.

Yerel Doğrusal Gömme

YDG veri boyutunu azaltmak için kullanılan bir algoritmadır. Bu algoritma gözetimsiz öğrenme temellidir. Bu algoritmada ilk önce komşu hesaplaması gerçekleştirilir. Bunun için veri kümesinde bulunan elemanlar arasındaki uzaklıklar hesaplanır. Bu işlem sonucu k en yakın komşu belirlenir. Sonraki adımda her veri için belirlenen k komşu değerleri kullanılarak kovaryans matrisi hesaplanır. Elde edilen kovaryans matrisinden ağırlık matrisi elde edilir [16,20].

Burada; $i=1, 2, 3, \dots, n$ olmak üzere X verisi n -boyutlu olmak üzere $X=[x_1, x_2, x_3, \dots, x_n]$, ve Y verisi m -boyutlu olmak üzere $Y=[y_1, y_2, y_3, \dots, y_m]$, X verisinden Y verisini hesaplamak için aşağıdaki denklem (4) ve denklem (5) kullanılır.

$$\varepsilon(W) = \sum_i |x_i - \sum_j w_{ij}x_j|^2 \quad (4)$$

Burada W bütünsel ağırlık, ε oluşturma hatasıdır. Daha sonra özvektörler hesaplanır.

$$\partial(Y) = \sum_i |y_i - \sum_j w_{ij}y_j|^2 \quad (5)$$

Burada $\partial(Y)$, X matrisinden elde edilen öz vektörleri temsil etmektedir.

Evrişimsel Sinir Ağı

Derin öğrenme ağları büyük verileri ham olarak işleyen ve bu verilerden otomatik olarak öznelik elde eden mimarilerdir. Bu özellikleri sayesinde günümüzde hemen hemen her alanda uygulama alanı bulmuştur. Bir derin öğrenme mimarisi olan ESA, genel olarak, evrişim, aktivasyon, havuzlama ve tam bağlı katmanlardan oluşur [21-22].

Evrişim katmanında veriler, belirlenen bir filtre ile evrişim işlemine tabi tutulur. Evrişim işleminde bir pikselin çıkış değeri, kendisinin ve komşu piksellerin değerlerinin bir ağırlıklı toplamı olarak elde edilir [20-21]. Evrişim işleminden sonra aktivasyon işlemi gerçekleştirilir. Genellikle ESA mimarisinde negatif değerleri sıfırlayan ReLu aktivasyon fonksiyonu kullanılır [21-22]. Bir sonraki katmanda havuzlama işlemi gerçekleştirilir. Havuzlama işleminde verinin alt bölgeleri oluşturulur [21-22]. Bu alt bölgelerden verilerin en büyüğü veya ortalaması alınır. Tam bağlı katman klasik bir yapay sinir ağı modelidir [21-22]. Elde edilen özneliklerin vektörizasyonu gerçekleştirilir. Bu katmanda, oluşturulan vektör boyutu kadar girdisi ve sınıf sayısı kadar çıktısı olan bir ağ oluşturulur [21-22].

K-En Yakın Komşu Algoritması

K-EYK sınıflandırıcı algoritması, örüntü tanıma alanında yaygın olarak kullanılmaktadır. K-EYK sınıflandırıcı algoritması denetimli bir makine öğrenme yöntemidir [23-

24]. K-EYK sınıflandırıcı algoritması, bir test verisini karşılaştırarak, test verisinin özellikleri ile en yakın sınıfların özellikleri arasındaki k mesafe metriğini hesaplar [23-24]. Bu çalışmada deneme yöntemiyle optimum k değeri 3 olarak belirlenmiştir.

Sınıflandırma Yaklaşımı

Çalışmada kullanılan veri kümesi 128×128 piksel boyutundadır. ESA mimarisi girişine veri kümesi $6400 \times 128 \times 128$ boyutlu olarak verilmiştir. Sınıflandırma için oluşturulan ESA mimarisinde 5 adet 2-boyutlu evrişim katmanı kullanılmıştır. Bu evrişim katmanlarının ilk ikisinde 5×5 boyutlu, diğerlerinde ise 3×3 boyutlu filtreler kullanılmıştır. Bu evrişim katmanlarında sırasıyla; 16, 32, 32, 64, 64 adet öznelik haritaları oluşturulmuştur. Evrişim katmanlarından sonra ReLu aktivasyon fonksiyonu kullanılmıştır. Havuzlama katmanında 2×2 'lik boyut kullanılmış ve en yüksek değer (MaxPooling) seçilmiştir. Tam bağlı katman 500 nöron olarak oluşturulmuştur. Sınıflandırıcı olarak Softmax fonksiyonu tercih edilmiştir. Önerilen ESA mimarisinde, 20 epok, bir iterasyon da dikkate alınan örüntü sayısı 32, her bir epok için 128 iterasyon ve ilk öğrenme oranı 0.001 olarak belirlenmiştir. Yukarıda verilen ESA ağ yapısı ve parametreleri, birbirinden farklı ESA ağları üzerinde yapılan denemeler sonucu, en iyi sonucu verdikleri için seçilmiştir.

Boyut azaltma ve öznelik seçme tekniklerinde ise ilk önce $6400 \times 128 \times 128$ olan veri boyutu, 6400×16384 boyutuna dönüştürülmüştür. Bu teknikler için farklı sayıda öznelik sayıları denenmiş ve iyi sonucun 80 olduğu görülmüştür. Bundan dolayı veri kümesi sınıflandırıcıya 6400×80 olarak verilmiştir.

Çalışmada veri kümesinin %80 oranı eğitim, %20 oranı ise test için kullanılmıştır. Eğitim verisinin %20 oranı doğrulama verisi olarak kullanılmıştır. Sınıflandırma performansının daha güvenilir olarak değerlendirilmesi için 5 katlı çapraz doğrulama uygulanmıştır. Sınıflandırıcılar her sınıflandırma katında 5 kez çalıştırılarak, ortalama performans değeri hesaplanmıştır.

Model Başarım Metrikleri

Çalışmanın güvenilirliğinin ölçütü olarak model başarım metrikleri hesaplanmıştır. Model başarım metriklerine ait hesaplama denklemleri(6-9) arasında verilmiştir [25].

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \quad (6)$$

$$\text{Duyarlılık(Recall)} = \frac{DP}{DP + YN} \quad (7)$$

$$\text{Kesinlik} = \frac{DP}{DP + DN} \quad (8)$$

$$f1 - skor = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (9)$$

Burada, DP-doğru pozitif, YP-yanlış pozitif, DN-doğru negatif ve YN-yanlış negatif'i ifade etmektedir. Model başarımlar ölçümlerinde çoklu sınıf için kullanılan örnek bir karışıklı matrisi Tablo-2'de verilmiştir.


Tablo 2 Çoklu sınıf karışıklı matrisi

Tahmin Edilen Sınıf	Doğru Sınıf		
	X	Y	Z
X	DP _X	H _{YX}	H _{ZX}
Y	H _{XY}	DP _Y	H _{ZY}
Z	H _{XZ}	H _{YZ}	DP _Z

Tablo 2 çok sınıflı bir sınıflandırma için karışıklı matrisini göstermektedir. Tabloda verilen DP_X, X sınıfındaki Doğru Pozitif (DP) sayısını göstermektedir [25]. H_{XY} ise X sınıfında olup, Y sınıfı olarak yanlış sınıflandırılanların sayısını göstermektedir [25]. Burada X sınıfı için Yanlış Negatif (YN) sayısı, H_{XY} ve H_{XZ} toplamıdır [25]. X sınıfı için Yanlış Pozitif (YP) sayısı, H_{XY} ve H_{ZX} toplamıdır [25]. X sınıfı için Doğru Negatif (DN) sayısı ise DP_Y, H_{ZY}, H_{YZ} ve DP_Z toplam sayısına eşittir.

Sınıflandırma Sonuçları

Bu çalışmada, AH farklı demansları ve demans içermeyen MR görüntüleri, ESA mimarisinde ve farklı boyut azaltma ve öznetelik elde etme teknikleri kullanılarak ayrı ayrı sınıflandırılmıştır. Önerilen modellerden elde edilen sınıflandırma doğruluğu performansları Şekil 2'de verilmiştir.



Şekil 2. Sınıflandırma doğruluğu

Sınıflandırma başarımlarını olarak en düşük performans bu çalışmada önerilen ESA mimarisinden elde edilmiştir. Diğer taraftan k-EYK sınıflandırıcı algoritması ile yapılan sınıflandırmada doğruluğu en yüksek k-EYK-BBA modeli olduğu görülmüştür. Bu doğruluk başarımlarına en yakın sonuç k-EYK-TBA modelidir. Boyut azaltma ve öznetelik elde etme yöntemlerinden en düşük doğruluk başarımlarını k-EYK-YDG modeli ile bulunmuştur.

Bu sınıflandırmalar sonucu elde edilen model başarımlar metrikleri Tablo 3, Tablo 4, Tablo 5 ve Tablo 6'da verilmiştir.

Tablo 3. ESA Mimarisi için Başarımlar Metrikleri

Sınıf	Kesinlik	Duyarlılık	F1-skor
HD	0.96	0.86	0.91
OD	0.79	1.00	0.88
DO	0.79	0.91	0.84
ÇHD	0.82	0.91	0.86

ESA mimarisi başarımlar metrikleri değerlendirildiğinde, kesinlik ve f1-skor metrik değerleri en yüksek HD sınıfında, duyarlılık metrik değerinin ise OD sınıfında elde edildiği görülmüştür.

Tablo 4. K-EYK-BBA için Başarımlar Metrikleri

Sınıf	Kesinlik	Duyarlılık	F1-skor
HD	1.00	0.97	0.98
OD	0.95	1.00	0.97
DO	0.98	0.99	0.98
ÇHD	0.99	0.97	0.98

k-EYK-BBA modeli ile yapılan sınıflandırmada elde edilen metrik değerlerinden kesinlik metrik değeri en yüksek HD sınıftan, duyarlılık metrik değeri en yüksek OD sınıftan ve f1-skorun ise üç sınıf için aynı olduğu görülmüştür.

Tablo 4. K-EYK-TBA için Başarımlar Metrikleri

Sınıf	Kesinlik	Duyarlılık	F1-skor
HD	0.95	0.93	0.94
OD	0.90	1.00	0.95
DO	0.96	0.98	0.97
ÇHD	0.95	0.94	0.94

k-EYK-TBA modelinde elde edilen metrik değerlerinden, kesinlik ve f1-skor metrik değerlerinin en yüksek DO sınıftan, duyarlılık metrik değeri ise en yüksek OD sınıftan elde edilmiştir.

Tablo 5. K-EYK-YDG için Başarımlar Metrikleri

Sınıf	Kesinlik	Duyarlılık	F1-skor
HD	0.86	0.89	0.87
OD	0.95	1.00	0.97
DO	0.93	0.93	0.93
ÇHD	0.90	0.89	0.89

k-EYK-YDG modelinden yapılan sınıflandırmada elde edilen metrik değerlerinden kesinlik, duyarlılık ve f1-skor metrik değerleri en yüksek OD sınıfında bulunmuştur.

ESA, TBA, BBA ve YDG temelli yapılan k-EYK sınıflandırma başarımlar metriklerinden duyarlılık metrik değeri OD sınıf için 1.00 olarak bulunmuştur. Kesinlik ve f1-skor metrik değerleri ise en yüksek BBA temelli k-EYK sınıflandırmasında elde edilmiştir.

Literatürde farklı makine öğrenme yöntemleri kullanarak, MR görüntülerinden AH tespiti ile ilgili birçok çalışma

mevcuttur. Bu çalışmada kullanılan veri kümesine benzer çalışmaların karşılaştırılması Tablo 6 da verilmiştir.

Tablo 6. Literatür karşılaştırılması

Çalışma	Veri Kümesi	Doğruluk(%)
Öziç ve ark.[12]	140 görüntü, 2 sınıf	92.85
Oh ve ark.[13]	694 görüntü, 4 sınıf	86.60
Rieke ve ark.[14]	969 görüntü, 2 sınıf	77.00
Gupta ve ark. [26]	4315 görüntü, 3 sınıf	94.74
Jain ve ark.[27]	4800 görüntü, 3 sınıf	95.73
Liu ve ark.[28]	449 görüntü, 3 sınıf	88.90
Goenka ve ark. [29]	2206 görüntü, 3 sınıf	86.49-98.26
Bu çalışma	6400 görüntü,4 sınıf	88.44-98.22

Tablo 6 incelendiğinde, bu çalışmada kullanılan veri kümesinin diğer çalışmalara göre daha fazla görüntü içerdiği görülmektedir. Sınıflandırma başarımı bakımından bu çalışmanın kabul edilebilir bir model önerdiği söylenebilir.

Sonuç

Bu çalışmada dört farklı sınıf içeren MR görüntüleri farklı teknikler kullanılarak sınıflandırılmıştır. Bu sınıflandırma sonucu elde edilen başarımların performansları ve önerilen modellere ait başarımların metrikleri hesaplanmıştır. Çalışmada en yüksek sınıflandırma başarımı BBA temelli k-EYK sınıflandırıcı ile bulunmuştur. En düşük sınıflandırma başarımı ise önerilen ESA mimarisinden elde edilmiştir. ESA mimarisi için elde edilen sonuçlar, bu çalışmada önerilen ESA mimarisi katmanları ve parametrelerine özgüdür. Ancak farklı ESA mimarileri kullanılarak, farklı sonuçlar elde edilebilir.

Çalışmada boyut azaltma ve öznelik elde yöntemlerinin AH demans tespitinde etkili yöntemler olduğu görülmüştür. MR görüntülerinden, BBA tekniği kullanılarak diğer tekniklere göre daha iyi öznelik elde edilmektedir. Bu çalışmaya dayanarak MR görüntülerinden AH demans tespiti için BBA temelli k-EYK sınıflandırıcının daha iyi sonuç verdiği görülmektedir.

Sonraki çalışmalarda, AH demans tespiti için, ön-egitimli ESA mimarileri kullanılarak sınıflandırma yapılabilir. Bunun yanısıra, farklı mimarilerin performansları ile bu mimarilerden elde edilen öznelikler, klasik sınıflandırıcılarda değerlendirilebilir.

Kaynaklar

- [1] Alzheimer's Association. (2019). 2019 Alzheimer's disease facts and figures. *Alzheimer's & dementia*, 15(3), 321-387.
- [2] Beach, T. G., Monsell, S. E., Phillips, L. E., & Kukull, W. (2012). Accuracy of the clinical diagnosis of Alzheimer disease at National Institute on Aging Alzheimer Disease Centers, 2005–2010. *Journal of neuropathology and experimental neurology*, 71(4), 266-273.
- [3] van Maurik, I. S., Zwan, M. D., Tijms, B. M., Bouwman, F. H., Teunissen, C. E., Scheltens, P., ... & Alzheimer's Disease Neuroimaging Initiative. (2017). Interpreting biomarker results in individual patients with mild cognitive impairment in the Alzheimer's biomarkers in daily practice (ABIDE) project. *JAMA neurology*, 74(12), 1481-1491.
- [4] Wadhwa, A., Bhardwaj, A., & Verma, V. S. (2019). A review on brain tumor segmentation of MRI images. *Magnetic resonance imaging*, 61, 247-259.
- [5] Khojaste-Sarakhsi, M., Haghighi, S. S., Ghomi, S. F., & Marchiori, E. (2022). Deep learning for Alzheimer's disease diagnosis: A survey. *Artificial Intelligence in Medicine*, 102332.
- [6] Janecek, A., Gansterer, W., Demel, M., & Ecker, G. (2008, September). On the relationship between feature selection and classification accuracy. In *New challenges for feature selection in data mining and knowledge discovery* (pp. 90-105). PMLR.
- [7] Shanmugam, J. V., Duraisamy, B., Simon, B. C., & Bhaskaran, P. (2022). Alzheimer's disease classification using pre-trained deep networks. *Biomedical Signal Processing and Control*, 71, 103217.
- [8] Park, C., Ha, J., & Park, S. (2020). Prediction of Alzheimer's disease based on deep neural network by integrating gene expression and DNA methylation dataset. *Expert Systems with Applications*, 140, 112873.
- [9] Liu, C. F., Padhy, S., Ramachandran, S., Wang, V. X., Efimov, A., Bernal, A., ... & Alzheimer's Disease Neuroimaging Initiative. (2019). Using deep Siamese neural networks for detection of brain asymmetries associated with Alzheimer's disease and mild cognitive impairment. *Magnetic resonance imaging*, 64, 190-199.
- [10] Lee, E., Choi, J. S., Kim, M., Suk, H. I., & Alzheimer's Disease Neuroimaging Initiative. (2019). Toward an interpretable Alzheimer's disease diagnostic model with regional abnormality representation via deep learning. *Neuroimage*, 202, 116113.

- [11] Goenka, N., & Tiwari, S. (2022). AlzVNet: A volumetric convolutional neural network for multiclass classification of Alzheimer's disease through multiple neuroimaging computational approaches. *Biomedical Signal Processing and Control*, 74, 103500.
- [12] Öziç, M. Ü., & Özşen, S. (2020). 3B alzheimer MR görüntülerinin hacimsel kayıp bölgelerindeki voksel değerleri kullanılarak sınıflandırılması. *El-Cezeri Journal of Science and Engineering*, 7(3), 1152-1166.
- [13] Oh, K., Chung, Y. C., Kim, K. W., Kim, W. S., & Oh, I. S. (2019). Classification and visualization of Alzheimer's disease using volumetric convolutional neural network and transfer learning. *Scientific Reports*, 9(1), 1-16.
- [14] Rieke, J., Eitel, F., Weygandt, M., Haynes, J. D., & Ritter, K. (2018). Visualizing convolutional networks for MRI-based diagnosis of Alzheimer's disease. In *Understanding and Interpreting Machine Learning in Medical Image Computing Applications* (pp. 24-31). Springer, Cham.
- [15] <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images>
- [16] Mita, J. H., Babu, C. G., & Shankar, M. G. (2021, March). Performance analysis of dimensionality reduction using PCA, KPCA and LLE for ECG signals. In *IOP Conference Series: Materials Science and Engineering* (Vol. 1084, No. 1, p. 012005). IOP Publishing
- [17] Abdi, H., & Williams, L. J. (2010). Principal component analysis. *Wiley interdisciplinary reviews: computational statistics*, 2(4), 433-459.
- [18] Liu, X., & Zhao, C. (2022). Research on Image Feature Extraction Algorithm of the Egg and Egg White Protein Thermal Gelation Based on PCA/ICA. *Computational Intelligence and Neuroscience*, 2022.
- [19] Hyvärinen, A. (1999). Survey on independent component analysis.
- [20] Roweis, S. T., & Saul, L. K. (2000). Nonlinear dimensionality reduction by locally linear embedding. *science*, 290(5500), 2323-2326.
- [21] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- [22] Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In *2017 international conference on engineering and technology (ICET)* (pp. 1-6). Ieee.
- [23] Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883.
- [24] Liao, Y., & Vemuri, V. R. (2002). Use of k-nearest neighbor classifier for intrusion detection. *Computers & security*, 21(5), 439-448.
- [25] Tharwat, A. (2020). Classification assessment methods. *Applied Computing and Informatics*, 17(1), 168-192.
- [26] Gupta, A., Ayhan, M., & Maida, A. (2013, May). Natural image bases to represent neuroimaging data. In *International conference on machine learning* (pp. 987-994). PMLR.
- [27] Jain, R., Jain, N., Aggarwal, A., & Hemanth, D. J. (2019). Convolutional neural network based Alzheimer's disease classification from magnetic resonance brain images. *Cognitive Systems Research*, 57, 147-159.
- [28] Liu, M., Li, F., Yan, H., Wang, K., Ma, Y., Shen, L., ... & Alzheimer's Disease Neuroimaging Initiative. (2020). A multi-model deep convolutional neural network for automatic hippocampus segmentation and classification in Alzheimer's disease. *Neuroimage*, 208, 116459.
- [29] Goenka, N., & Tiwari, S. (2022). AlzVNet: A volumetric convolutional neural network for multiclass classification of Alzheimer's disease through multiple neuroimaging computational approaches. *Biomedical Signal Processing and Control*, 74, 103500.