

Alzheimer Hastalığının Manyetik Rezonans Görüntülerden Hibrit Derin Öğrenme Yaklaşımı ile Otomatik Tespiti

Öznur ÖZALTIN^{1*}, Sezgi ÇOBANBAŞ², Yasemin SIRAKAYA³, Yuşa GÜNEŞ^{4,5}

¹ Aktüerya Bilimleri Bölümü, Fen Fakültesi, Hacettepe Üniversitesi, Ankara, Türkiye

² Matematik Bölümü, Veri Bilimi Ana Bilim Dalı, Università Degli Studi di Padova, Padova, İtalya

³ Adli Veri Analitiği, Ernst & Young Global Limited Şirketi, İstanbul, Türkiye

⁴ İstatistik Bölümü, Lisans Programı, Fen Fakültesi, Hacettepe Üniversitesi, Ankara, Türkiye

⁵ Veri Bilimi, ITECH Bilgi Teknolojileri Tıbbi Cihazlar Elektronik Sanayi ve Ticaret Limited Şirketi, Ankara, Türkiye

*¹ oznurozaltin@hacettepe.edu.tr, ² sezgicobanbas@gmail.com, ³ yaseminsr656@gmail.com,
^{4,5} yusagunes36@gmail.com

(Geliş/Received: 26/09/2024;

Kabul/Accepted: 16/12/2024)

Öz: Alzheimer hastalığı, çağın en ciddi hastalıkları arasında yer almaktadır. Tedavisinin neredeyse bulunmadığı bu hastalıkta erken teşhis çok önemlidir. Erken teşhis edilmesi durumunda bu hastalığın ilerlemesi yavaşlayacaktır. Bu çalışmada, Alzheimer hastalığının derin öğrenme aracılığı ile Manyetik Rezonans (MR) görüntüler üzerinden tespit edilmesi amaçlanmıştır. Derin öğrenme algoritmalarından olan Evrişimli Sinir Ağları (ESA), görüntülerden otomatik özellik çıkarabilme yeteneğine sahiptir. Bu çalışmada, Alzheimer hastalığını MR görüntülerinden tespit etmede sekiz farklı ESA mimarisi kullanılmıştır. Bu mimarilerden en başarılı test sonucu veren NasNetMobile, otomatik özellik çıkarıcı olarak kullanılmış ve son katmanından 1056 özellik elde edilmiştir. Bu özellikler makine öğrenme algoritmalarından Derin Sinir Ağı (DSA), Destek Vektör Makinesi (DVM), Karar Ağacı, K-En Yakın Komşu, Yapay Sinir Ağı (YSA) ile sınıflandırılmıştır. Çalışmanın bu aşamasında yüksek doğruluk oranı elde edilse de sağlam sonuçlar için özellik seçim yöntemlerinden minimum Artıklık Maksimum İlişki (mRMR) yaklaşımından yararlanılmıştır. Böylece 1056 özellik 250'ye indirgenmiştir. Sonuç olarak, makine öğrenme algoritmalarının sınıflandırma performansı artmıştır. Alzheimer hastalığının tespitinde %90,68'lik doğruluk oranı ile en başarılı sonuç veren NasNetMobile-mRMR-DSA hibrit algoritması olmuştur.

Anahtar kelimeler: Alzheimer Hastalığı, Derin Öğrenme, Makine Öğrenmesi, Özellik Seçimi, Sınıflandırma.

Automatic Detection of Alzheimer's Disease from Magnetic Resonance Images Using a Hybrid Deep Learning Approach

Abstract: Alzheimer's disease is one of the most serious diseases of our age. Early diagnosis is very important in this almost incurable disease. The progress of this disease will be slowed down by early diagnosis. This study goals to identify Alzheimer's disease based on deep learning from Magnetic Resonance (MR) images. Convolutional Neural Networks (CNN), one of the deep learning algorithms, can automatically extract features from images. In this study, eight different CNN architectures were used to detect Alzheimer's disease from MR images. NasNetMobile, the most successful of these architectures, was used as an automatic feature extractor, and 1056 features were extracted from its last layer. These features were classified through machine learning algorithms: Deep Neural Network (DNN), Support Vector Machine (SVM), Decision Tree, K-Nearest Neighbor, and Artificial Neural Network (ANN). Although high accuracy was achieved at this stage of the study, the minimum Redundancy Maximum Relevance (mRMR) approach was used for selecting features and robust results. Thus, 1056 features were reduced to 250. As a result, the classification performance of machine learning algorithms improved. The NasNetMobile-mRMR-DNN hybrid algorithm was the most successful in the detection of Alzheimer's disease with an accuracy rate of 90.68%.

Key words: Alzheimer's Disease, Deep Learning, Machine Learning, Feature Selection, Classification.

1. Giriş

Alzheimer, demans türleri arasında yer alan özellikle de yaşlı bireylerde görülen nörodejeneratif bir beyin hastalığıdır [1, 2]. Demans, gelişmiş ve gelişmekte olan ülkelerde yaşlanan nüfusun hızla artmasının sonucu olarak önemli bir halk sağlığı sorunu haline gelmiştir [3, 4]. Alzheimer hastalığının artma nedenleri arasında yaşlanma,

* Sorumlu yazar: oznurozaltin@hacettepe.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0001-9841-1702, ² 0009-0007-2630-4001, ³ 0009-0000-6718-6151, ⁴ 0009-0008-1416-8556

kolinerjik yollar, çevresel faktörler, kafa travması ve genetik faktörler yer almaktadır [3, 5]. Demansın en yaygın görülen şekli Alzheimer'dır ve bu hastalıktan kaynaklı ölümler %145'ten fazla artmıştır [3, 6]. Yapılan en son tahminlere göre demans prevalansının 2050 yılına kadar Avrupa'da iki kat, dünyada ise üç kat artması beklenmektedir [3, 7].

Alzheimer hastalığı olan bir bireyin beyinde boşluk (ventricle) boyutlarının büyüdüğü gözlenir [7, 8]. Bu durum çeşitli görüntüleme teknikleriyle kolayca ayırt edilebilmektedir. Manyetik Rezonans (MR) görüntüleme aracılığı ile beyin sağlıklı olup olmadığı ayırt edilebilmektedir [8]. Fakat sağlık çalışanlarının yükü her geçen gün artarken bu görüntülerin manuel olarak incelenmesi oldukça zaman almaktadır [7]. Dolayısıyla, görüntülerin otomatik olarak sınıflandırılması, hem sağlık çalışanlarının iş yükünü azaltacak hem de erken teşhis ile tedavi sürecini hızlandıracaktır.

Bu çalışmada, Alzheimer hastalığını MRI görüntüler üzerinden ayırt edilmesini sağlayan en iyi yaklaşımın bulunması hedeflenmiştir. Burada son dönemlerde oldukça yaygın olarak kullanılan ESA ve makine öğrenme algoritmalarından yararlanılmıştır. Bu çalışma için öncelikle yapılandırılmamış ADNI (Alzheimer's Disease Neuroimaging Initiative) veri setinden yararlanılarak üç sınıflı veri seti oluşturulmuştur. Bu üç sınıf şu şekildedir: Alzheimer Hastalığı (Alzheimer Disease, AD), Hafif bilişsel bozukluk (mild cognitive impairment, MCI) ve bilişsel olarak normal (cognitively normal, CN). Hafif bilişsel bozukluğu olan hastaların sağlıklı bireylere göre daha küçük bir entorinal korteks ve hipokampüse sahiptir. Ancak Alzheimer hastalığı olan hastalarda entorinal korteks ve hipokampüste belirgin bir azalma olabilir [9]. MRI görüntüler üzerinden doğru teşhis konulması tedavi süreci açısından oldukça önemlidir. Hafif bilişsel bozukluğu olan hastaların erken teşhis edilebilmesi Alzheimer hastalığına yakalanma süresini uzatacaktır. Dolayısıyla, bu sınıfları en iyi ayırt eden, aşırı öğrenmeden kaçınan NasNetMobile-mRMR-DSA algoritması tasarlanmıştır. Bu çalışma ile sağlanan katkılar şu şekildedir:

- ADNI veri seti üç sınıflı olarak oluşturulmuştur. Veri seti toplamda 3220 görüntüden oluşmaktadır. Görüntüler rastgele biçimde %80'i eğitim, %20'si ise test olarak ayrılmıştır.
- Önceden eğitilmiş AlexNet, InceptionResNet, InceptionV3, NasNetMobile, ResNet18, ResNet50, SqueezeNet ve Xception mimarilerden yararlanılmıştır.
- Eğitim veri setine mimarilerin aşırı öğrenmemesi için 5 katlı çapraz doğrulama uygulanmıştır.
- Mimarilerin performans sonuçları, doğruluk, duyarlılık, özgüllük, kesinlik, F1-skoru ve AUC (area under curve, eğri altında kalan alan) üzerinden değerlendirilmiştir.
- Eğitilen mimarilerin ilk olarak SoftMax katmanı ile sınıflandırma performansları test edilmiştir. Bu aşamada en iyi test performansı veren NasNetMobile mimarisi olmuştur.
- Daha iyi performans elde etmek için NasNetMobile derin özellik çıkarıcı olarak kullanılmış ve DSA, DVM, Karar Ağacı, KNN ve YSA ile birleştirilmiştir.
- NasNetMobile mimarisinin son katmandan elde edilen 1056 özellik minimum artıklık maksimum ilişki (mRMR) algoritması aracılığı ile 250'ye düşürülmüştür. İndirgenen bu özellikler tekrar aynı makine öğrenme algoritmaları ile sınıflandırılmış ve sonuçlar karşılaştırılmıştır. Bu aşamada elde edilen performanslarda artış görülmüş ve en yüksek performans DSA ile elde edilmiştir.

Sonuç olarak, önerilen yöntem, Alzheimer hastalığının teşhisinde hem sağlık çalışanlarının iş yükünü azaltacak hem de erken teşhis ile hastalık sürecinin yavaşlatılmasına olanak tanıyacaktır. Bu nedenle çalışma, Alzheimer teşhisine yönelik literatürde önemli bir boşluğu doldurarak daha güvenilir ve etkin bir yöntem sunmaktadır.

1.2. Literatür Araştırması

Alzheimer hastalığı, bireylerin yaşam kalitesini ciddi ölçüde etkileyen ve global sağlık sisteminde önemli bir yük oluşturan ilerleyici bir nörodejeneratif bozukluktur. Bu hastalığın erken teşhisi, tedaviye yönelik stratejilerin geliştirilmesi ve hastalık sürecinin yavaşlatılması açısından kritik bir öneme sahiptir. MRI gibi ileri görüntüleme teknikleri ve yapay zeka destekli sınıflandırma yöntemleri, Alzheimer hastalığının farklı aşamalarını ayırt etmede etkin araçlar olarak öne çıkmaktadır. Literatürde, geleneksel makine öğrenmesi algoritmalarından derin öğrenme tabanlı modeller ve hibrit yaklaşımlara kadar geniş bir yöntem çeşitliliği bulunmaktadır.

Bu çalışmada, Alzheimer hastalığını MRI görüntüleri üzerinden sınıflandırmayı amaçlayan mevcut literatür incelenmiş ve modern tekniklerin avantajları ve sınırlamaları değerlendirilmiştir. Örneğin, Öziç ve Özşen [10] çalışmalarında voksel tabanlı bilgisayar tanı sistemi ile çalışmıştır. Alzheimer hastaları ve normal kontrol MR görüntüleri, hacimsel kayıp bölgelerindeki voksel değerleri kullanılarak sınıflandırılmıştır. Destek Vektör Makinesi (DVM) kullanarak %92,857 ile en yüksek doğruluk oranını elde etmişlerdir. Türk [11] çalışmasında,

Alzheimer hastalığının demans seviyesini dört farklı sınıf içeren MR görüntüleri kullanılarak tespit etmiş ve sonuç olarak en iyi performansın Bağımsız Bileşen Analizi tabanlı K-En Yakın Komşu sınıflandırıcı ile elde edildiğini ifade etmiştir. Aslan [12] çalışmasında Alzheimer hastalığının *elektroansefalogram* (EEG) sinyallerinden direkt olarak gerçekleştirilmesini amaçlayan bilgisayar destekli tanı sistemi oluşturmuştur. Elde ettiği özellikleri k-En Yakın Komşu algoritması ile sınıflandırmış ve sonuç olarak %91,12 doğruluk oranı elde etmiştir. Karabay ve Çavaş [13] toplamda 6400 adet MR görüntüsü kullanılarak AlexNet ve MobileNetV2 mimarilerinden özellik çıkarma işlemini gerçekleştirmişlerdir. Özellik seçim aşamasında ise Komşuluk Bileşen Analizi (NCA) algoritmasından yararlanarak önemli özellikleri elde etmişlerdir. Son olarak bu özellikleri DVM ile sınıflandırmışlar ve çalışmanın sonucunda %100 doğruluk oranı elde etmişlerdir. Özkaya ve Cebeci [14] çalışmalarında Alzheimer hastalığını ve hastalığın teşhisinde kullanılan teknikleri incelemiş, başarılı bir model geliştirmek için çalışmışlardır. DenseNet121 modeli değiştirilebilen bir yapıda sunulmuştur. 3 boyutlu MR görüntülerini bu model doğrudan kullanabilmektedir. Böylece çeşitli uzaysal bilginin kaybının önüne geçilmiştir. Sadık [15] çalışmasında Alzheimer hastalığına ait belirlenen 5 öznetelik ile 4 farklı derin öğrenme algoritmasını karşılaştırmış ve Gradient Boosting Sınıflandırıcısı algoritması ile %96,43 doğruluk oranı elde etmiştir. Karakaya ve diğerleri [16] çalışmalarında Alzheimer hastalığının analizi için sınıflandırma ve segmentasyon işlemlerini uygulamış, bilgisayarlı görme destekli bir karar destek sistemi oluşturmuşlardır. Çalışmalarında 7 farklı mimariyi kullanmışlar ve GoogleNet mimarisi ile %94,67 doğruluk, %94,74 duyarlılık, %98,11 özgüllük ve 0,9467 F1 skoru elde etmişlerdir. Eren ve diğerleri [17] fonksiyonellik doğrulama testlerinde 3 boyutlu Evrişimli Sinir Ağı (ESA) kullanarak %81 doğruluk oranı elde etmişlerdir. Okyay [18] çalışmasında sadece sınıflandırıcıya bağlı olmamak amacı ile filtreleme metodunu kullanmayı tercih etmiştir. Sınıflandırma parametrelerinin optimize edilmesinden sonra sınıflandırıcıları 10 katlı çapraz doğrulama ile değerlendirmiştir. Sertkaya ve Ergen [19] sundukları çalışmada MRI görüntüleri ve genetik veriler kullanılarak yapay sinir ağlarıyla Alzheimer hastalığının ilerlemesini tespit etmeye çalışmışlardır ve bu hastalığın tespitinde %72-%90 arasında başarı elde etmişlerdir. Bhardwaj ve diğerleri [20] transfer öğrenme yoluyla InceptionResNetv2 mimarisini Alzheimer hastalığını tespit etmek için kullanmışlardır. Çalışmalarında beş sınıflı görüntü veri seti kullanmışlar ve %97,3 doğruluk oranı elde etmişlerdir. Mathew ve diğerleri [21] MRI görüntülerinden Alzheimer hastalığını tespit etmek için yeni bir yöntem önermişlerdir. Üç sınıflı görüntülerin özelliklerini çıkararak (şekil, renk, homojenlik, korelasyon vb.) önerdikleri yöntem olan Olasılıksal Sinir Ağını, DVM ve K-En Yakın Komşu algoritmaları ile doğruluk, özgüllük ve duyarlılık açısından performanslarını karşılaştırmıştır. Bu alanda yapılan araştırmalar sunulan çalışmalarla sınırlı değildir. Son teknolojik yöntemlerle Alzheimer hastalığı ve diğer hastalıklar tespit edilmeye devam etmektedir [22-27]. Tablo 1’de sunulan literatür araştırmasının özeti yer almaktadır.

Tablo 1’de sunulan çalışmalar arasında ADNI veri seti yaygın olarak kullanılan bir kaynak olmuştur. Örneğin, Özkaya ve Cebeci [14], Bhardwaj ve diğerleri [20], Sadık [15], Karakaya ve diğerleri [16] ile Sertkaya ve Ergen [19] çalışmalarında ADNI veri setinden faydalanmışlardır. Bu veri setini kullanan çalışmalarda, transfer öğrenme ve derin öğrenme tabanlı mimariler genellikle yüksek performans sağlamıştır. Bu durum, modern mimarilerin sınıflandırma yeteneklerini artırmada önemli bir rol oynadığını göstermektedir.

Bu çalışma, Alzheimer hastalığının manyetik rezonans görüntülerden otomatik olarak sınıflandırılmasına yönelik literatürdeki yaklaşımlardan farklı olarak hibrit bir yöntem olan NasNetMobile-mRMR-DSA algoritmasını önermektedir. Literatürde genellikle tekil derin öğrenme mimarileri veya standart makine öğrenmesi algoritmaları kullanılmakta iken, bu çalışmada önceden eğitilmiş NasNetMobile mimarisi ile mRMR algoritması kullanılarak en anlamlı özellikler seçilmiş ve DSA sınıflandırıcısı ile bu özelliklerin performansı optimize edilmiştir. Bu yapı hem aşırı öğrenmenin önlenmesine hem de sınıflandırma başarısının artırılmasına olanak tanımaktadır. Ayrıca, ADNI veri setinden oluşturulan üç sınıflı veri seti üzerinde kapsamlı bir analiz gerçekleştirilmiş ve duyarlılık, özgüllük, F1-skoru gibi performans ölçütleri açısından yüksek başarı oranlarına ulaşılmıştır. Bu özellikleri ile önerilen yöntem, Alzheimer hastalığının erken teşhisi için literatürdeki diğer çalışmalara kıyasla daha etkin ve güvenilir bir yaklaşım sunmaktadır.


Bu çalışmanın devamında, 2. Materyal ve Yöntem bölümünde kullanılan veri seti, önceden eğitilmiş mimariler, sınıflandırıcılar, özellik seçim yöntemi, performans ölçütleri ve çapraz doğrulama sunulmuştur. 3. Bölümde, deneysel sonuçlardan bahsedilmiştir. Son olarak, çalışmada elde edilen bulgular, çalışmanın sınırları ve performans değerlendirmesi 4. Tartışma ve Sonuç bölümünde yapılmıştır.

Tablo 1. Alzheimer hastalığını MRI görüntüleri üzerinden sınıflandırmayı amaçlayan çalışmalar.

Çalışma	Kullanılan Veri Seti	Model/Mimari	Öznitelik Çıkarımı/Seçimi	Doğruluk (%)	Yöntemin Öne Çıkan Özellikleri
Öziç ve Özşen [10]	-	DVM	Voksel tabanlı özellikler	92,86	MRI'deki hacimsel kayıp bölgelerinin voksel analizi
Türk [11]	-	KNN	Bağımsız Bileşen Analizi (ICA)	-	Demans seviyesini sınıflandırmaya yönelik detaylı analiz
Aslan [12]	-	KNN	EEG sinyalleri	91,12	EEG tabanlı özelliklerle erken teşhis
Karabay ve Çavaş [13]	-	AlexNet, MobileNetV2 + DVM	NCA	100	Derin öğrenme tabanlı özellik çıkarımı ve önemli öznitelik seçimi
Özkaya ve Cebeci [14]	ADNI	DenseNet121	Uzaysal bilginin korunması	-	3 boyutlu MRI görüntülerini doğrudan kullanan bir model
Bhardwaj ve diğerleri [20]	ADNI	Inception-ResNetv2	Transfer öğrenme	97,3	Beş sınıflı sınıflandırma
Mathew ve diğerleri [21]	-	Olasılıksal Sinir Ağı, DVM, KNN	Renk, şekil, homojenlik gibi özellikler	-	Önerilen yöntemle performans karşılaştırması
Sadık [15]	ADNI	Gradient Boosting Sınıflandırıcısı	Belirlenen 5 özellik	96,43	Farklı algoritmaların performans karşılaştırması
Karakaya ve diğerleri [16]	ADNI	GoogleNet	Bilgisayarlı görme tabanlı öznitelikler	94,67	Yedi farklı mimarinin performans karşılaştırması
Eren ve diğerleri [17]	-	3 Boyutlu ESA	MRI veri seti	81,00	Fonksiyonellik doğrulama testi
Okyay [18]	-	DVM, KNN, ESA	Filtreleme metotları	-	10 katlı çapraz doğrulama ile performans değerlendirme
Sertkaya ve Ergen [19]	ADNI	YSA	MRI ve genetik veriler	72-90	Alzheimer ilerlemesini tespit etme

2. Materyal ve Yöntem

Bu çalışmanın hazırlanmasında ilk olarak çalışma konusunun özgünlüğünü ortaya koyabilmek için ADNI veri tabanından yararlanılmıştır. MR görüntülerinden Alzheimer hastalığının tespiti için önceden eğitilmiş evrişimli sinir ağlarından yararlanılmış ve sekiz farklı mimari ile eğitim işlemi gerçekleştirilmiştir. Aşırı öğrenmenin olmaması için eğitim setine 5 katlı çapraz doğrulama uygulanarak eğitim sonuçları elde edilmiştir. Eğitilen mimarilerin daha önce hiç görmediği ilk başta ayrılmış olan test seti ile sınıflandırma performansları ölçülmüştür. Bu aşamada mimariler sınıflandırıcı olarak kullanılmıştır. Elde edilen sonuçları iyileştirmek için mimarilerin otomatik özellik çıkarma gücünden yararlanılmıştır. En yüksek test performansı veren NasNetMobile'ın son katmanından elde edilen özellikler, literatürde sıkça kullanılan mRMR özellik seçim yöntemi ile indirgenmiştir. En önemli özelliklerin elde edilmesi ile sınıflandırma aşamasına geçilmiştir. Sınıflandırma aşamasında ise en yüksek doğruluğa DSA ulaşılmıştır. Sonuçlar aynı zamanda özellik seçimi uygulanmadan da elde edilerek performans sonuçları karşılaştırılmıştır. Bu çalışmada önerilen NasNetMobile-mRMR-DSA algoritmasının grafik özeti ise Şekil 1'de sunulmuştur.



Şekil 1. Alzheimer hastalığının otomatik tespiti için akış grafiği.

2.1. Veri Seti

Bu çalışmada, Alzheimer Hastalığı Nörogörüntüleme Girişimi (ADNI) veri tabanından (<https://adni.loni.usc.edu>) yararlanılmıştır. Görüntüler yapılandırılmamış halde olduğundan ilk olarak nhii formatından png formatına dönüştürülmüştür. Elde edilen görüntüler Alzheimer Hastalığı (AD), Hafif Bilişsel Bozukluk (MCI) ve Bilişsel olarak Normal (CN) sınıflarına aittir. Toplamda 3220 görüntü olmak üzere, 1073'ü AD, 1025'i CN ve 1122'si MCI sınıfında yer almaktadır. Veri setinde yer alan 2576 MRI görüntü eğitim ve 644 MRI görüntü test için kullanılmıştır. Tablo 2'de veri setindeki her sınıf için görsellere ve görüntü sayılarına yer verilmiştir.




2.1.1. Veri Ön İşleme Adımları

ADNI veri setine uygulanan ön işlem adımları şu şekildedir:

- Veri setinde yer alan MRI görüntüleri, tamamlanmış ve eksiksiz şekilde alındığı için herhangi bir eksik veri ile karşılaşılmamıştır. Ancak, bazı görsellerin hasar görmüş veya bozulmuş olduğu durumlar, görüntü işleme adımında kontrol edilmiştir.

- MRI görüntü formatı dönüşümü sırasında görüntü boyutları sabitlenmiş ve tüm görüntüler 256x256x3 boyutlarına getirilmiştir.
- MRI görüntülerinin pixel değerleri 0 ile 255 arasında değişmektedir. Bu değerler, modelin daha verimli öğrenebilmesi için 0 ile 1 arasında normalize edilmiştir. Normalizasyon işlemi, her pikselin değerinin 255'e bölünmesiyle gerçekleştirilmiştir. Bu adım, modelin daha hızlı ve sağlıklı bir şekilde eğitim almasını sağlamaktadır.
- Veri setindeki sınıflar arasında belirgin bir dengesizlik bulunmamaktadır; ancak, herhangi bir dengesizliğin olabileceği durumlar için SMOTE (Synthetic Minority Over-sampling Technique) gibi teknikler kullanılması düşünülmüştür. Ancak, bu çalışmada her sınıf için yeterli sayıda örnek bulunduğundan, bu aşama uygulamaya alınmamıştır.
- Görüntülerin çeşitliliğini artırmak ve modelin genelleme yeteneğini güçlendirmek amacıyla veri artırma teknikleri kullanılmıştır. Bu teknikler, döndürme, yansıma, kesme, ölçekleme gibi çeşitli görsel modifikasyonlarla artırılmıştır. Bu sayede modelin, daha fazla farklı veri ile karşılaşması sağlanmıştır

Tablo 2. ADNI veri seti detayları.

Sınıf	Açıklama	Örnek Sayısı	Eğitim Verisi	Test Verisi
AD 	Bu sınıftaki görüntüler, Alzheimer hastalığına özgü beyin küçülmesi belirtileri gösterir. Bu sınıfta yaş ortalaması $75,875 \pm 8,234$ olan toplam 40 bireyden alınan MRI görüntüleri yer almaktadır.	1073	860	213
CN 	Bu sınıftaki görüntüler, normal bilişsel fonksiyonları olan beyni temsil eder. Bu sınıfta yaş ortalaması $76,66 \pm 4,06$ olan toplam 77 bireyden alınan MRI görüntüleri yer almaktadır.	1025	819	206
MCI 	Bu sınıftaki görüntülerde, genellikle hafif düzeyde yapısal değişiklikler gözlemlenebilir. Bu sınıfta yaş ortalaması $73,79 \pm 8,28$ olan toplam 100 bireyden alınan MRI görüntüleri yer almaktadır.	1122	897	225
Toplam	Yaş ortalaması $75,17 \pm 7,15$ olan 217 bireyden alınan MRI görüntüleri yer almaktadır.	3220	2576	644

Yukarıda bahsedilen adımlar, veri setinin daha sağlıklı ve modelin verimli çalışabileceği şekilde hazırlanmasına olanak tanımıştır.

2.2. Önceden Eğitilmiş Mimariler

AlexNet [28], ilk çıkan önceden eğitilmiş mimarilerdendir. AlexNet'in 5 evrişim katmanı, 3 tam bağlantılı katmanı, 1 bırakma katmanı (dropout) ve 1 SoftMax katmanı vardır. Girdi boyutu $227 \times 227 \times 3$ olan AlexNet'in toplam parametre sayısı 62,3 milyondur. Bununla birlikte, düşük hesaplama kapasiteli cihazlarda kullanımının sınırlı olduğu gözlemlenmiştir.

InceptionResNet [29] Google tarafından önerilen bir mimaridir. Inception-ResNet modülü, Inception bloğu ve ResNet [30] yapısının bir kombinasyonudur. ResNet modülü, daha derin sinir ağlarını eğitmeyi mümkün kılan artık bağlantıları ilkel olarak tanıtmıştır. Inception bloğu, giriş görüntülerinin değişen ölçeklerinden daha fazla bilgi alabilir ve ResNet, önemli ölçüde artan derinlikten doğruluk kazanabilir durumdadır. Inception bloğu ve ResNet modülünün kombinasyonu, mimarinin performansını büyük ölçüde iyileştirmiştir [31]. InceptionResNet'in girdi boyutu $299 \times 299 \times 3$ ve toplam parametre sayısı yaklaşık 55 bindir. Bu mimari, düşük parametre sayısına rağmen yüksek performans sunmaktadır. Ancak, bu mimarinin eğitimi daha uzun sürebilir ve GPU desteği gerektirebilir.

Inceptionv3 [32], GoogleNet [33]'in ileri versiyonlarından biridir. 48 katman derinliğine sahip bir evrişimli sinir ağı olan bu mimari, ImageNet (<http://www.image-net.org>) veri tabanından bir milyondan fazla görüntü üzerinde eğitilmiştir. $299 \times 299 \times 3$ giriş boyutuna sahip olan mimari, optimize edilmiş bir hesaplama yükü ile yüksek doğruluk sağlamaktadır. Mimarinin toplam parametre sayısı, performansı ve eğitim süresi, modern projelerde sıkça tercih edilmesini sağlamaktadır.

NASNetMobile [34], Google Beyin ekibi tarafından geliştirilmiştir. Pekiştirmeli öğrenme tekniği aracılığıyla optimum evrişimli sinir ağı mimarisi bulmayı amaçlamıştır [35]. NASNetMobile'ın girdi boyutu $224 \times 224 \times 3$ ve toplam parametre sayısı yaklaşık 4,5 milyondur. Taşınabilir cihazlar ile uyumlu çalışması için tasarlanan bu mimarinin eğitim süresi oldukça kısa olup enerji verimliliği ön plandadır.

ResNet-18 [30], ResNet ailesinin 18 derin katmana sahip bir mimarisidir. ResNet ailesinin hedefi, atlama yoluyla kısayol bağlantıları gerçekleştirmektir. Mimarinin daha hızlı öğrenmesi için bu atlama işleminde bağlantılar mimariye baskı yapar. Bu mimari, çok sayıda evrişim katmanından yararlanarak etkin bir şekilde öğrenmeyi gerçekleştirmektedir. $224 \times 224 \times 3$ giriş boyutuna ve 11 milyondan fazla parametreye sahip olan mimari, orta düzey bir hesaplama yüküne sahiptir. Eğitim süresi modern GPU'larda oldukça hızlıdır.

ResNet-50 [30], 50 katmanlı ResNet mimarilerinden biridir. Katmanların ağırlıklarını %50 azaltabilme özelliği sayesinde tercih edilen mimarilerdendir. Toplamda 23 milyondan fazla parametreye sahiptir. Parametre optimizasyonu ve artık bloklarının varlığı, modeli klasik evrişimli sinir ağlarından ayırmaktadır. Eğitim süresi ResNet-18'e kıyasla daha uzundur, ancak doğruluk açısından önemli kazançlar sağlamaktadır.

SqueezeNet [36], ateşleme modülüne sahip farklı bir önceden eğitilmiş mimaridir. On evrişim katmanından, maksimum havuzlama katmanlarından ve bir SoftMax katmandan oluşan SqueezeNet'in girdi boyutu $227 \times 227 \times 3$ 'tür. Toplam parametre sayısı oldukça düşüktür, bu da hafif yapısını desteklemektedir. Eğitim süresi kısa ve hesaplama yükü düşüktür, bu nedenle mobil cihazlar için uygun bir mimari olarak öne çıkmaktadır.

Xception [37], InceptionV3'ün gelişmiş versiyonu olarak tanıtılmıştır. Bu mimarinin temel özelliği, derinlemesine ayrılabilen evrişimleri (konvolüsyonları) kullanmasıdır. $299 \times 299 \times 3$ giriş boyutuna sahip bu model, toplam parametre sayısını sabit tutarak daha yüksek performans sağlamaktadır. Eğitim süresi, kullanılan donanıma bağlı olarak değişmekle birlikte, yüksek doğruluk oranı nedeniyle tercih edilmektedir.

Bu çalışmada kullanılan bu mimariler Alzheimer hastalığının tespitinde hem sınıflandırıcı hem de özellik çıkarıcı olarak kullanılmıştır. Her bir modelin parametre sayıları ve eğitim süreleri Tablo 3' te özetlenmiştir. Modellerin farklı özellikleri, Alzheimer hastalığının tespitinde hesaplama yükü ve doğruluk açısından detaylı bir karşılaştırmaya olanak sağlamaktadır.

2.3. Sınıflandırıcılar

Bu bölümde kısaca Destek Vektör Makinesi (DVM), Yapay Sinir Ağı (YSA), Derin sinir Ağı (DSA), Karar Ağacı ve K- En Yakın Komşu sınıflandırıcıları sunulmaktadır.

2.3.1. Destek Vektör Makinesi (DVM)

Destek Vektör Makinesi (DVM), Vapnik ve Cortes [38] tarafından iki sınıflı veriler için geliştirilmiştir. Daha sonra DVM, doğrusal olmayan ve çok sınıflı veri setleri için geliştirilmiş ve genelleştirilmiştir. DVM sadece sınıflandırma problemleri için kullanılmamıştır. Aynı zamanda regresyon (tahmin) problemlerin çözümünde de

sıklıkla kullanılmaktadır. Veri setini sınıflandırma/regresyon problemi için çekirdek tabanlı bir yöntemle ayırabilen etkili bir algoritmadır.

Tablo 3. Mimarilerin özellikleri.

Mimari	Parametre Sayısı	Giriş Boyutu	Eğitim (saniye)	Süresi	Kullanım Amacı
AlexNet	62,3 milyon	227x227x3	120		Sınıflandırıcı/Özellik Çıkarıcı
InceptionResNet	55 bin	299x299x3	150		Sınıflandırıcı/Özellik Çıkarıcı
Inceptionv3	24 milyon	299x299x3	180		Sınıflandırıcı/Özellik Çıkarıcı
NASNetMobile	4,5 milyon	224x224x3	90		Sınıflandırıcı/Özellik Çıkarıcı /Mobil Uygulamalar
ResNet-18	11 milyon	224x224x3	100		Sınıflandırıcı/Özellik Çıkarıcı
ResNet-50	23 milyon	224x224x3	200		Sınıflandırıcı/Özellik Çıkarıcı
SqueezeNet	1,2 milyon	227x227x3	80		Sınıflandırıcı/Özellik Çıkarıcı/Mobil ve Hafif Uygulamalar
Xception	20 milyon	299x299x3	170		Sınıflandırıcı/Özellik Çıkarıcı

2.3.2. Karar Ağacı

Makine öğrenme algoritmalarından biri olan Karar Ağacı, genellikle regresyon veya sınıflandırma problemleri için tercih edilmektedir [39, 40]. 1970’lerin sonlarında başlanan algoritma, Ross Quinlan tarafından C4.5 programıyla tasarlanmış ve sonrasında 20 yıl boyunca geliştirilmiştir [41]. Sınıflandırma problemleri için karar ağacı hiyerarşik bir sisteme sahip olmaktadır. Bu yapısı sayesinde karmaşık miktardaki bilgiyi basit karar verme mekanizması ile alt gruplara bölebilmektedir. Karar ağacının yapısının anlaşılabilir olması, kolay yorumlanabilmesi ve diğer algoritmalarla uyumlu çalışabilmesinden dolayı sıklıkla tercih edilmektedir [42, 43].

2.3.3. K-En Yakın Komşu

K-En Yakın Komşu algoritması, seçilen bir girdinin kendine en yakın olanlarla arasındaki uzaklıkları ölçen, yaygın olarak kullanılan makine öğrenme algoritmalarındandır [44, 45]. Bu çalışmada uzaklık metriği olarak Öklid kullanılmıştır. Komşuların sayısı ise 5 olarak seçilmiştir.

2.3.4. Yapay Sinir Ağı (YSA)

Yapay Sinir Ağı (YSA), McCulloch ve Pitts [46] tarafından 1943 yılında tanıtılmıştır. YSA, hayvanların ve insanların nöron ağlarından esinlenerek ortaya çıkarılmış ve matematiksel teori ile desteklenmiştir [39]. Esnek yapısı ve kullanım kolaylığı sayesinde makine öğrenmesinde, özellikle de denetimli öğrenmede tercih edilen YSA, doğrusal olmayan bir modeldir. Bu çalışmada 5 nöronlu tek gizli katmanlı YSA modeli tercih edilmiştir.

2.3.5. Derin Sinir Ağı (DSA)

Derin Sinir Ağı (DSA), YSA’ nın iki veya daha çok katmanlı versiyonu olarak ifade edilebilir. Tıpkı YSA gibi kullanım kolaylığının olması, büyük boyutlu verilerde oldukça yaygın kullanılması sebebiyle bu çalışmada DSA sınıflandırıcı olarak tercih edilmiştir. İki saklı katmandan oluşan DSA, ilk katmanda 5 nöron ikinci katmanda ise 10 nöron kullanılmıştır. Nöron sayıları deneme yanılma ile belirlenmiştir. Hem YSA hem de DSA da aktivasyon fonksiyonu olarak ReLU tercih edilmiştir ve optimizasyon algoritması olarak “Sınırlı Bellek Broyden–Fletcher–Goldfarb–Shanno (L-BFGS)”, hesaplama karmaşıklığı olmaması sebebiyle tercih edilmiştir [47]. Çalışmada kullanılan diğer parametrelerin değerlerine ise Tablo 4’te yer verilmiştir.

Tablo 4. YSA/DSA parametreleri.

YSA/DSA parametreleri	Değerleri
Ağırlık Başlatıcı	glorot
Bias Başlatıcı	zeros
İterasyon limiti	1000
Gradyan toleransı	1.0000e-06
Kayıp toleransı	1.0000e-06
Adım toleransı	1.0000e-06
Lamda	0

2.4. Özellik Seçim Yöntemi: minimum Artıklık Maksimum İlişki (mRMR)

Minimum Artıklık Maksimum İlişki (mRMR) yöntemi ile mevcut özellikler arasından en iyisi seçilmeye çalışılır. Bu sayede hesaplama maliyetleri azaltılır. mRMR özellik seçme yönteminde değişkenler ve özellikler arasındaki korelasyonun maksimum olması hedeflenmektedir. Aynı zamanda özellikler arasındaki bağımlılığın da minimum olması hedeflenir [48]. Böylece, gereksiz ve birbirine benzer özellikler elenerek daha anlamlı ve özgün özellikler seçilir, bu da modelin genel performansını artırırken aşırı uyumu önlemektedir.

mRMR yönteminin işlem adımları aşağıdaki gibi sıralanabilir:

1. Verinin her bir özelliği ile hedef değişken arasındaki karşılıklı bilgi değeri hesaplanır.
2. Özellikler arasındaki bağımlılık hesaplanır.
3. İlk olarak, hedef değişkenle en yüksek ilişki değerine sahip özellik seçilir.
4. Seçilen özellik ile diğer özellikler arasındaki bağımlılık değerleri hesaplanır.
5. Her yeni özellik, ilişki- bağımlılık farkına göre seçilir.
6. Bu adım, istenilen sayıda özellik seçilene kadar devam eder.

mRMR yöntemi, biyoinformatik, görüntü işleme, doğal dil işleme ve diğer yüksek boyutlu veri setlerinde sıklıkla kullanılmaktadır [49-51]. Bu çalışmada, Alzheimer hastalığının tespitinde, ESA ile MRI görüntülerinden çıkarılan özelliklerin indirgenmesi mRMR yöntemi ile sağlanmıştır.

2.5. Performans Ölçütleri

Sınıflandırma performansı, doğruluk, duyarlılık, özgüllük, kesinlik, F1 skoru ve AUC değeri gibi ölçütlere göre değerlendirilmiştir [52, 53]. Bu ölçütler, çok sınıflı (multi-class) sınıflandırma bağlamında one-vs-rest (bir sınıfın geri kalan sınıflardan ayrılması) stratejisi kullanılarak her bir sınıf için ayrı ayrı hesaplanmış ve genel değerlendirme için ortalama değerleri Eşitlik (1-5)' te sunulmuştur.

1. Doğruluk (Accuracy)

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

Doğruluk, modelin doğru tahmin ettiği sınıfların oranını gösterir. Burada, *DP*: Gerçek Pozitif (True Positive) ve *DN*: Gerçek Negatif (True Negative) doğru tahminlerin toplamını ifade eder. *YP*: Yanlış Pozitif (False Positive) ve *YN*: Yanlış Negatif (False Negative) yanlış tahminlerdir.

2. Duyarlılık (Sensitivity / Recall)

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (2)$$

Duyarlılık, modelin, ilgili sınıfa ait tüm örnekleri doğru bir şekilde tanıyıp tanımadığını gösterir. Yani, gerçek pozitiflerin doğru tespit edilme oranıdır.

3. Özgüllük (Specificity)

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (3)$$

Özgüllük, modelin negatif sınıfları doğru bir şekilde sınıflandırma yeteneğini gösterir. Yani, negatif örneklerin doğru şekilde negatif olarak etiketlenme oranıdır.

4. Kesinlik (Precision)

$$Kesinlik = \frac{DP}{DP+YP} \quad (4)$$


Kesinlik, modelin gerçek pozitif olarak sınıflandırdığı örneklerin, gerçekten doğru olup olmadığını gösterir. Başka bir ifade ile modelin pozitif olarak tahmin ettiği sınıf örneklerinin ne kadarının doğru olduğunu ölçer.

5. F1-Skoru (F1 Score)

$$F1 - Skoru = \frac{2 \times Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (5)$$

F1-Skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır ve her iki metriği dengeleyerek, her ikisini de dikkate alır. Modelin hem doğru pozitifleri bulmada hem de yanlış pozitifleri önlemede ne kadar başarılı olduğunu gösterir.

Çok sınıflı bir problemde, AUC (Area Under the Curve) ölçütü de one-vs-rest yaklaşımı kullanılarak hesaplanmıştır. Bu yaklaşımda, her bir sınıf için ayrı bir ROC (Receiver Operating Characteristic) eğrisi oluşturulur. ROC eğrisi, modelin doğru sınıflandırmalarını (gerçek pozitifler) ve yanlış sınıflandırmalarını (yanlış pozitifler) analiz eder. AUC, bu eğri altındaki alanı ifade eder ve modelin sınıflandırma doğruluğunun bir ölçüsüdür. AUC değeri 0 ile 1 arasında bir değeri alır; 1, mükemmel bir sınıflandırıcıyı, 0.5 ise rasgele tahmin yapan bir modelin performansını gösterir. Her bir sınıf için hesaplanan AUC değerlerinin ortalaması alındığında, genel sınıflandırma performansına dair bir değerlendirme yapılmış olur. Şekil 2’de her sınıf için DP, DN, YP ve YN değerlerinin karmaşıklık matrisi üzerinde görselleştirilmiş hali sunulmuştur. Bu matris yardımıyla sınıflandırma performansına dair ayrıntılı analiz yapılmıştır [54].




Şekil 2. ADNI veri setinin sınıflandırmasında kullanılan karmaşıklık matrisi.

3. Deneysel Sonuçlar

Bu çalışmada, Alzheimer hastalığının otomatik tespiti için 8 farklı önceden eğitilmiş mimarilerden yararlanılmıştır. Çalışmada, AD, CN ve MCI sınıfları bulunan ADNI veri setinden yararlanılmıştır. Veri setinde toplam 3220 MRI görüntüsü bulunmaktadır. Bu görüntülerin %80’i eğitim %20’si ise test için ayrılmıştır. Rastgele olarak seçilen MRI görüntülerinden bir kesit Şekil 3’te gösterilmiştir. Analiz aşamasında MATLAB 2022b

programı kullanılmıştır. 5 katlı çapraz doğrulama ile eğitim aşaması tamamlanarak sonuçlar Tablo 5'te sunulmuştur.



Şekil 3. ADNI veri setinden örnekler.

Tablo 5. 5 katlı çapraz doğrulama uygulanan önceden eğitilmiş mimarilerin eğitim sonuçları.

Sınıflandırıcı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Skoru	AUC
Alexnet	0,8750	0,8727	0,9366	0,8879	0,8753	0,9703
InceptionResNet	0,9950	0,9949	0,9975	0,9948	0,9949	0,9999
Inceptionv3	0,9950	0,9950	0,9975	0,9949	0,9949	1,0000
NasNetMobile	0,9926	0,9927	0,9963	0,9925	0,9926	0,9999
ResNet-18	0,9852	0,9853	0,9925	0,9857	0,9855	0,9995
ResNet-50	0,9938	0,9937	0,9969	0,9938	0,9938	0,9999
SqueezeNet	0,9786	0,9787	0,9892	0,9791	0,9789	0,9980
Xception	0,9973	0,9973	0,9987	0,9972	0,9973	0,9998

Tablo 5'e göre, en yüksek performans %99,73'lük doğruluk oranı ile Xception mimarisi ile elde edilmiştir. Bu mimarinin, duyarlılık, özgüllük, kesinlik, F1-Skoru ve AUC değeri sırasıyla %99,73, %99,87, %99,72, %99,73 ve 0.9998'dir. Burada AUC değeri haricinde koyu renkle gösterilenler Xception mimarisi ile elde edilmiştir. AUC değerinde koyu renkle ifade edilen en yüksek değer Inceptionv3 ile elde edilmiştir. Diğer mimarilerinde doğruluk oranları şu şekildedir: AlexNet, %87,50, InceptionResNet %99,50, Inceptionv3, %99,50, NasNetMobile, %99,26, ResNet-18, %98,52, ResNet-50, %99,38, SqueezeNet, %97,86. Eğitilen 8 mimarinin ortalama eğitim doğruluk oranları oldukça başarılı olmuştur. Bu mimarilerin test aşamasından sonra elde edilen sonuçları Tablo 6'da gösterilmiştir.

Tablo 6. Önceden eğitilmiş mimarilerin test sonuçları.

Sınıflandırıcı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Skoru	AUC
Alexnet	0,8463	0,8484	0,9232	0,8696	0,8473	0,9716
InceptionResNet	0,8711	0,8710	0,9350	0,8810	0,8736	0,9763
Inceptionv3	0,8758	0,8774	0,9380	0,8824	0,8776	0,9759
NasNetMobile	0,8866	0,8874	0,9433	0,8918	0,8877	0,9839
ResNet-18	0,8463	0,8469	0,9225	0,8644	0,8491	0,9869
ResNet-50	0,8602	0,8602	0,9295	0,8681	0,8627	0,9572
SqueezeNet	0,8370	0,8374	0,9179	0,8543	0,8403	0,9519
Xception	0,8773	0,8789	0,9385	0,8787	0,8783	0,9560

Tablo 6'ya göre, Alzheimer hastalığının tespitinden en yüksek test doğruluğu veren mimari %88,66'lık performans ile NasNetMobile olmuştur. Yine diğer metriklerde (AUC değeri hariç) bu mimari en yüksek değerleri elde etmiş ve Tablo 2'de koyu renk ile gösterilmiştir. NasNetMobile, %88,74 duyarlılık, %94,33 özgüllük, %89,18 kesinlik, %88,77 F1-skoru ve 0.9839 AUC değeri elde etmiştir. AUC değerinin 1'e yakın olması oldukça önemlidir. Bu değer yüksek olması, modelin ne ölçüde sınıfları ayırabildiğini göstermektedir. Alzheimer hastalığının tespiti için MRI görüntülerin sınıflandırılmasında AlexNet %84,63, InceptionResNet %87,11,

Inceptionv3 %87,58, ResNet-18 %84,63, ResNet-50 %86,02, SqueezeNet %83,70 ve Xception %87,73 test doğruluğu elde etmiştir. Şekil 4, bu mimarilerin test sonrası elde edilen karmaşıklık matrislerini göstermektedir.


NasNetMobile mimarisi ile en yüksek test doğruluğu elde edilmiştir. Fakat son yıllarda yapılan çalışmalar gösteriyor ki önceden eğitilmiş mimarilerin derin özellik çıkarıcı olarak kullanılması ve makine öğrenme algoritmaları ile entegre edilmesi sonucunda performans artmaktadır [49]. Bu sebeple performansı daha iyi hale getirmek için NasNetMobile mimarisinin global average pooling katmanından 1056 özellik elde edilmiştir. Çıkarılan bu özellikler herhangi bir özellik seçim yöntemi uygulanmadan makine öğrenme algoritmaları ile sınıflandırılmıştır. Sınıflandırma sonucu Tablo 7’de gösterilmiştir.

Tablo 7. NasNetMobile mimarisinin özellik çıkarıcı olarak kullanılması ile oluşturulan hibrit algoritmaların sınıflandırma sonuçları.


Sınıflandırıcı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Skoru	AUC
DSA	0,9037	0,9049	0,9522	0,9066	0,9043	0,9913
DVM	0,8960	0,8971	0,9482	0,8981	0,8965	0,9908
Karar Ağacı	0,8960	0,8964	0,9481	0,8968	0,8956	0,9602
K-En yakın Komşu	0,8944	0,8954	0,9473	0,8962	0,8949	0,9383
YSA	0,8929	0,8940	0,9466	0,8955	0,8935	0,9933

Tablo 7’ye göre, NasNetMobile mimarisinin son katmanından elde edilen özelliklerin DSA ile sınıflandırılması sonucunda %90,37’lik test doğruluk oranı elde edilmiştir. NasNetMobile-DSA yapısı ile bu aşamada en yüksek performans elde edilmiştir. Tablo 6’da elde edilen sonuçla karşılaştırıldığında, başka bir ifade ile NasNetMobile sınıflandırıcı olarak kullanıldığında, %88,66’lık doğruluk oranı elde edilmiştir. Tablo 7’de yer alan tüm sınıflandırıcıların performansının bu orandan fazla olduğu açıkça görülmektedir. Diğer sınıflandırıcılar ile elde edilen test doğruluk oranları sırasıyla şöyledir: NasNetMobile-DVM ile %89,6, NasNetMobile- Karar Ağacı ile %89,6, NasNetMobile- K-En Yakın Komşu ile %89,44, ve NasNetMobile-YSA ile %89,29’dur.

Bu sonuçlara bakıldığında algoritmanın yüksek performans gösterdiği görülmüştür. Fakat NasNetMobile mimarisinin son katmanından elde edilen özellik sayısı her bir görüntü için 1056’dır. Eğitim için kullanılan görüntü sayısının toplamda 2576 olduğu düşünüldüğünde 1056x2576 boyutlu bir matrisin hesaplamasını ilgili algoritma ve makine yapacaktır. Her bir görüntü için önemli olan özellik sayısı 1056’dan daha az olabilir. Bu düşünce ile özellik seçim algoritmalarından mRMR kullanılmıştır. Özelliklerin önem skorlaması Şekil 5’te gösterilmiştir.



Şekil 5. mRMR yöntemi ile özelliklerin önem skoru.



Şekil 4. (a) AlexNet, (b) InceptionResNet, (c) Inceptionv3, (d) NasNetMobile, (e) ResNet-18, (f) ResNet-50, (g) SqueezeNet ve (h) Xception karmaşıklık matrisi.

Şekil 5 incelendiğinde özelliklerin tamamının yüksek önem derecesinde olmadığı açıkça görülmektedir. Algoritmaların hesaplama yükünü hafifletmek için özellik seçimi yapmanın Alzheimer hastalığının teşhisi için önemli olacağı düşünülmüştür. Böylece mRMR özellik seçim yönteminin işaret ettiği önemli 250 özellik deneme yanılma ile seçilmiştir. 1056'dan indirgenen özellik sayısı sonrası sınıflandırma performansları Tablo 8' de sunulmuştur. Yapılan işlemin performansını ölçmek ve adil karşılaştırma için aynı özellikteki sınıflandırıcılar kullanılmıştır.

Tablo 8. mRMR yöntemi kullanılarak seçilen özellikler ile elde edilen sınıflandırma sonuçları.

Sınıflandırıcı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Skoru	AUC
DSA	0,9068	0,9078	0,9535	0,9072	0,9071	0,9908
DVM	0,9006	0,9014	0,9503	0,9013	0,9011	0,9894
Karar Ağacı	0,8991	0,8996	0,9496	0,8999	0,8988	0,9624
K-En yakın Komşu	0,8991	0,9001	0,9497	0,9028	0,9000	0,9453
YSA	0,9022	0,9031	0,9512	0,9045	0,9029	0,9935

Tablo 8 incelendiğinde, özellik seçiminin performanslara yansıdığı görülmektedir. Bir önceki aşamada artan performans burada da yükseldiği söylenebilir. NasNetMobile-mRMR-DSA hibrit algoritmasının %90,68 ile en yüksek doğruluk oranı elde ettiği görülmüştür. Bu sonuç, tüm aşamalarda elde edilen test sonuçlarının en yükseğidir. Diğer metrikler bakımından da aynı artış söz konusudur. Tablo 8'de en yüksek değerler koyu renkle gösterilmiştir. Sonuç olarak bu hibrit algoritma ile %90,78 duyarlılık, %95,35 özgüllük, %90,72 kesinlik, %90,71 F1 skoru ve 0,9908 AUC değeri elde edilmiştir. AUC değerinin en yüksek olduğu sınıflandırıcı 0,9935 ile YSA olmuştur. DSA'nın elde ettiği AUC değeri ile en yüksek AUC değeri arasında anlamlı bir fark bulunmamaktadır. Bu sebeple bu çalışmada hemen hemen tüm metriklerde en yüksek performansı elde eden NasNetMobile-mRMR-DSA hibrit algoritması önerilmektedir. Şekil 6 hibrit algoritmaların ve önerilen hibrit algoritmanın karmaşıklık matrislerini göstermektedir. Şekil 7 de ise DSA sınıflandırıcısının kayıp (loss) grafiği sunulmuştur. Ayrıca önerilen hibrit algoritmanın sınıf bazındaki başarısı Tablo 9'da sunulmuştur.

Tablo 9. NasNetMobile-mRMR-DSA algoritması ile elde edilen sınıf bazlı performans sonuçları.

Sınıf	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Skoru
AD	0,9302	0,9302	0,9744	0,9479	0,9390
CN	0,9317	0,9317	0,9385	0,8762	0,9031
MCI	0,8616	0,8616	0,9476	0,8977	0,8793

NasNetMobile-mRMR-DSA algoritması, Alzheimer hastalığı tespiti için yüksek doğruluk oranları elde etmiştir. AD sınıfı için %93,02 doğruluk, %93,02 duyarlılık, %97,44 özgüllük, %94,79 kesinlik ve %93,90 F1 skoru sağlanmıştır. CN sınıfı ise %93,17 doğruluk, %93,17 duyarlılık, %93,85 özgüllük, %87,62 kesinlik ve %90,31 F1 skoru ile başarılı performans sergilemiştir. MCI sınıfı ise %86,16 doğruluk, %86,16 duyarlılık, %94,76 özgüllük, %89,77 kesinlik ve %87,93 F1 skoru ile daha düşük bir performans göstermiştir. Genel olarak, algoritma üç sınıf için de yüksek performans sergileyerek güçlü bir sınıflandırma yeteneği ortaya koymuştur. Sonuç olarak, bu algoritmanın MRI görüntülerinden Alzheimer hastalığının teşhisi için kullanılabileceği söylenebilir.

True Class	AD	200	2	13
	CN	5	191	9
	MCI	6	25	193
		AD	CN	MCI

Predicted Class

(a)

True Class	AD	195	4	16
	CN	5	190	10
	MCI	7	22	195
		AD	CN	MCI

Predicted Class

(b)

True Class	AD	205	3	7
	CN	13	183	9
	MCI	15	18	191
		AD	CN	MCI

Predicted Class

(c)

True Class	AD	193	6	16
	CN	2	192	11
	MCI	1	29	194
		AD	CN	MCI

Predicted Class


(d)

True Class	AD	196	4	15
	CN	3	191	11
	MCI	2	28	194
		AD	CN	MCI

Predicted Class

(e)

Şekil 6. (a) NasNetMobile-mRMR-DSA, (b) NasNetMobile-mRMR-DVM, (c) NasNetMobile-mRMR-Karar Ağacı, (d) NasNetMobile-mRMR-K En Yakın Komşu ve (e) NasNetMobile-mRMR-YSA karmaşıklık matrisi.



Şekil 7. DSA sınıflandırıcısının kayıp grafiği.

4. Tartışma

NasNetMobile-mRMR-DSA algoritması, Alzheimer hastalığının tespitinde yüksek doğruluk oranlarıyla başarılı bir sınıflandırma performansı sergilemiştir. Bu başarının ardında, NasNetMobile modelinin derin öğrenme mimarisinin sunduğu çeşitli avantajlar bulunmaktadır. NasNetMobile, derin ağ yapısı ve mobil odaklı tasarımı sayesinde hem yüksek sınıflandırma yeteneği hem de düşük hesaplama maliyeti sağlar. Modelin global average pooling ve convolutional block yapıları, görüntüdeki önemli özellikleri etkili bir şekilde çıkarırken, başlangıçtaki katmanlarında öğrenilen temel özelliklerin, daha karmaşık yapıları tanımada nasıl kullanıldığına dikkat edilmiştir. Ayrıca, mRMR algoritması ile yapılan özellik seçimi, önemli bilgilere odaklanarak modelin karmaşıklığını azaltmış ve aşırı uyum riskini minimize etmiştir. Önerilen NasNetMobile-mRMR-DSA algoritmasının sınıflandırma performansı ile diğer son teknoloji çalışmalarının karşılaştırması Tablo 10’da sunulmuştur. Önerilen algoritma, bazı sınırlamalar olmasına rağmen üstün performans göstermiştir.

NasNetMobile’ın bu yapısal avantajları, yüksek doğruluk oranları elde edilmesine katkı sağlamıştır. Ancak, MCI sınıfındaki daha düşük performans, modelin hafif nörolojik değişiklikleri tespit etmede zorluk yaşadığını göstermektedir. Bu durum, MCI’nın Alzheimer’dan önceki aşama olması nedeniyle, benzer özelliklerin sağlıklı bireylerle (CN) karışmasının bir sonucu olabilir. Ayrıca, sınıf dengesizliği ve veri setindeki bazı görsellerin kapsayıcılığının yetersiz olması, modelin bu sınıfı doğru şekilde sınıflandırma yeteneğini sınırlamış olabilir. Bu tür yanlış sınıflandırmaların önlenmesi için daha fazla veri çeşitliliği ve sınıf dengesizliği iyileştirmeleri yapılması gerekebilir.

Tablo 10. NasNetMobile-mRMR-DSA algoritması ile son teknoloji çalışmalarının karşılaştırması.

Çalışma	Veri Seti	Sınıflar	Kullanılan Yöntem	Doğruluk Oranı (%)
Sertkaya ve Ergen [56]	ADNI	AD-CN AD-MCI MCI-CN	Görüntü Dönüştürücü (Vision Transformer, ViT)	79,8 80,3 89,3
Toshkhujaev ve diğerleri [57]	ADNI	AD-CN	DVM-RBF (radyal temelli fonksiyon, radial basis function)	90,45
Suganth ve diğerleri [58]	ADNI+ Kaggle	AD CN MCI	Hibrit Inception-ResNet	79,12
Oh ve diğerleri [59]	ADNI	AD-MCI	ESA	90,09
Önerilen algoritma	ADNI	AD CN MCI	NasNetMobile-mRMR-DSA	90,68

5.Sonuç ve Öneriler

Alzheimer, son yılların en hızlı artan ve tedavisinin neredeyse bulunmadığı bir hastalıktır [3]. Bu hastalık için yapılabilecek en uygun yaklaşım, erken teşhis ederek hastalığın hızlanmasını önlemek olacaktır. Hastalığın erken teşhisi için genellikle beyin görüntüleme yöntemleri kullanılmaktadır. Uzmanlar görüntüler üzerinden Alzheimer hastalığının olup olmadığını, hastalık var ise hangi safhada olduğunu tespit etmektedir. Fakat bu oldukça zaman alan bir işlemdir. Bu çalışmada, yapay zekâ ile görüntüler üzerinden Alzheimer hastalığının otomatik tespit edilmesi hedeflenmiştir. Görüntülerin analiz edilmesinde son dönemlerde yaygın olarak ESA algoritmaları tercih edilmektedir. Bu çalışmada ESA olarak önceden eğitilmiş sekiz farklı mimari tercih edilmiştir. Transfer öğrenme ile daha hızlı öğrenebilen bu mimarilerde yararlanmak zaman kazandırmaktadır.

Çalışmada ESA'yı kullanan bir hibrit algoritma önerilmiştir. Fakat önerilen algoritma sadece mevcut ADNI veri setinde yer alan MR görüntüleri üzerinde eğitilmiş ve test edilmiştir. Daha fazla veri seti ve çeşitli görüntüleme tekniklerinden elde edilebilecek görüntülere çalışmada yer verilememiştir. Bunlar çalışmanın sınırları arasında yer almaktadır.

Bu çalışmanın orijinalliğini ortaya koymak için yapılandırılmamış ADNI veri setinden yararlanılmıştır. Bu veri setinde bulunan üç sınıf: AD, CN, MCI bulunmaktadır. Bu çalışmada herhangi bir ön işlem yönteminden yararlanılmamıştır. Veri seti eğitim ve test olarak bölünmüştür. Eğitim aşamasında 5-katlı çapraz doğrulama uygulanmış ve sonuçlar Tablo 5'te sunulmuştur. Bu aşamada %99'un üzerinde doğruluk performansı elde edilmiştir. Eğitilen mimarinin test sınıflandırma sonucunda %88,66'lık doğruluk oranı NasNetMobile mimarisi ile elde edilmiştir. Daha iyi performans elde etmek için hibrit bir algoritma geliştirilmiştir. Burada NasNetMobile mimarisi özellik çıkarıcı olarak kullanılmıştır. Bu mimarinin son katmanından elde edilen özellikler mRMR yöntemi ile indirgenmiştir. Sınıflandırıcılar olarak DSA, DVM, Karar Ağacı, K-En Yakın Komşu ve YSA tercih edilmiş ve indirgenen özellikler bu sınıflandırıcılar ile sınıflandırılmıştır. Performans sonuçları Tablo 8'de sunulmuş ve karmaşıklık matrislerine Şekil 6'da yer verilmiştir. Tüm sonuçlarda Alzheimer hastalığının MRI görüntülerden tespitinde en yüksek test performansı elde eden %90,68 doğruluk oranı ile NasNetMobile-mRMR-DSA hibrit algoritması olmuştur. Bu sayede uzman görüşüne ihtiyaç duyulmaksızın özellikler elde edilmiş ve daha sonra elde edilen bu özellikler güçlü mRMR yöntemi indirgenerek sınıflandırma başarısının artırılması gerçekleştirilmiştir.

Gelecek çalışmalarda, hiperparametre optimizasyonu ve ızgara araması (grid search) yöntemi kullanılması ile en az hatayla otomatik özellik seçimi yapabilen bir hibrit algoritma tasarlanması hedeflenmektedir. Böylece kullanıcı seçimine veya deneme yanılmaya gerek duyulmadan anlamlı özellikler görüntülerden tespit edilebilecektir.

Sonuç olarak bu çalışma ile yapay zekâ algoritmaları kullanılarak yüksek başarı performansı ile Alzheimer hastalığının görüntülerden tespit edilebildiği gösterilmiştir. Böylece birçok araştırmacıya bu çalışmanın ışık tutacağı düşünülmektedir.

Teşekkür

Bu çalışma, TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı 2022 yılı 2. dönem kapsamında 1919B012222024 numaralı proje ile desteklenmiştir. Yazarlar, bu destek için TÜBİTAK kurumuna teşekkürlerini sunar.

Kaynaklar

- [1] Aydın S, Taşyürek M, Öztürk C. MR Görüntüleri Ön İşlenerek Derin Ağlar ile Alzheimer Hastalık Tespiti. In: International Conference On Emerging Sources In Science, 2022.
- [2] Brun A, Liu X, Erikson C. Synapse loss and gliosis in the molecular layer of the cerebral cortex in Alzheimer's disease and in frontal lobe degeneration. *Neurodegeneration* 1995; 4(2): 171-177.
- [3] Wang S, Kong X, Chen Z, Wang G, Zhang J, Wang J. Role of Natural Compounds and Target Enzymes in the Treatment of Alzheimer's Disease. *Molecules* 2022; 27(13): 4175.
- [4] Noetzli M, Eap CB. Pharmacodynamic, pharmacokinetic and pharmacogenetic aspects of drugs used in the treatment of Alzheimer's disease. *Clin Pharmacokinet* 2013; 52(4): 225-241.
- [5] Armstrong RA. What causes Alzheimer's disease?. *Folia Neuropathol* 2013; 51(3): 169-188.
- [6] Gaugler J, James TB, Reimer J, Weuve J. Alzheimer's Association. 2021 Alzheimer's Disease Facts and Figures. *Alzheimers Dement* 2021; 17: Chicago, IL, USA.
- [7] Subasi A, Subasi TN, Ozaltin O. Artificial intelligence in diagnosis of neural disorders using biosignals and imaging. In: *Advances in Artificial Intelligence: Elsevier*, 2024; 523-560.

- [8] Bağcı U, Bai L. Manyetik Rezonans Beyin İmgelerinden Alzheimer Hastalığı Tanısında Gabor Dalgacıkları Kullanımı Detecting Alzheimer Disease in Magnetic Resonance Brain Images Using Gabor Wavelets.
- [9] Yin C, Li S, Zhao W, Feng J. Brain imaging of mild cognitive impairment and Alzheimer's disease. *Neural Regen Res* 2013; 8(5): 435-444.
- [10] Öziç MÜ, Özşen S. 3B Alzheimer MR Görüntülerinin Hacimsel Kayıp Bölgelerindeki Voksel Değerleri Kullanılarak Sınıflandırılması. *El-Cezeri J Sci Eng* 2020; 7(3): 1152-1166.
- [11] Türk Ö. MR Görüntülerinden Alzheimer Tespitinde Boyut Azaltma ve Derin Öğrenme Yaklaşımlarının Karşılaştırılması. *Dicle Univ J Eng* 2022; 13(3): 485-491.
- [12] Aslan Z. EEG Sinyallerini Kullanarak Alzheimer Hastalığının Otomatik Tespiti İçin Bilgisayar Destekli Tanı Sistemi. *Dicle Univ J Eng* 2022; 13(2): 213-220.
- [13] Karabay GS, Çavaş M. Derin Öğrenme Yöntemiyle Alzheimer Hastalığının Tespiti. *Fırat Univ J Eng Sci* 2022; 34(2): 879-887.
- [14] Özkaya A, Cebeci U. A Model Suggestion For Alzheimer's Disease Diagnosis By Using Deep Learning. *Eur J Sci Technol* 2022; (37): 123-130.
- [15] Sadık EŞ. Comparison Of Machine Learning Algorithms In The Detection Of Alzheimer's Disease. *Eur J Sci Technol* 2022; (42): 1-5.
- [16] Karakaya F, Gurkan C, Budak A, Karataş H. Classification and Segmentation of Alzheimer Disease in MRI Modality using the Deep Convolutional Neural Networks. *Eur J Sci Technol* 2022; (40): 99-105.
- [17] Eren HA, Okyay S, Adar N. Adoken: MR İçin Derin Öğrenme Tabanlı Karar Destek Yazılımı. *J Eng Sci Design* 2021; 9(2): 406-413.
- [18] Okyay S. Beyin Görüntüleme Tekniklerinin Alzheimer Hastalığı Erken Tanı Tahmininde Kullanılması. *Anadolu Univ*, 2016.
- [19] Sertkaya ME, Ergen B. Alzheimer Hastalığının Erken Teşhisinin Çoklu Değişken Kullanarak Tespiti. *Eur J Sci Technol* 2022; (35): 306-314.
- [20] Bhardwaj S, Kaushik T, Bisht M, Gupta P, Mundra S. Detection of Alzheimer Disease Using Machine Learning. In: *Smart Systems: Innovations in Computing*; Springer, 2022; 443-450.
- [21] Mathew NA, Vivek R, Anurenjan P. Early diagnosis of Alzheimer's disease from MRI images using PNN. In: *2018 Int CET Conf Control Commun Comput:IEEE*, 2018; 161-164.
- [22] Shanmugam JV, Duraisamy B, Simon BC, Bhaskaran P. Alzheimer's disease classification using pre-trained deep networks. *Biomed Signal Process Control* 2022; 71: 103217.
- [23] Loddo A, Butta S, Di Ruberto C. Deep learning based pipelines for Alzheimer's disease diagnosis: a comparative study and a novel deep-ensemble method. *Comput Biol Med* 2022; 141: 105032.
- [24] Helaly HA, Badawy M, Haikal AY. Deep learning approach for early detection of Alzheimer's disease. *Cogn Comput* 2022; 14(5): 1711-1727.
- [25] Arslan NN, Ozdemir D. Analysis of CNN models in classifying Alzheimer's stages: comparison and explainability examination of the proposed separable convolution-based neural network and transfer learning models. *Signal Image Video Process* 2024; 1-15.
- [26] Tüzün BN, Özdemir D. Classification of Brain Tumors With Deep Learning Models. *J Sci Rep-A* 2023; (054): 296-306.
- [27] Dörterler S, Dumlu H, Özdemir D, Temurtaş H. Hybridization of Meta-heuristic Algorithms with K-Means for Clustering Analysis: Case of Medical Datasets. *Gazi J Eng Sci* 2024; 10(1).
- [28] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Adv Neur Inf Proc Syst* 2012; 25: 1097-1105.
- [29] Szegedy C, Ioffe S, Vanhoucke V, Alemi A. Inception-v4, inception-resnet and the impact of residual connections on learning. In: *Proc AAAI Conf Art Intell* 2017; 31(1).
- [30] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: *Proc IEEE Conf Comp Vis Pat Rec* 2016; 770-778.
- [31] Peng S, Huang H, Chen W, Zhang L, Fang W. More trainable inception-ResNet for face recognition. *Neurocomputing* 2020; 411: 9-19.
- [32] Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the inception architecture for computer vision. In: *Proc IEEE Conf Comp Vis Pat Rec* 2016; 2818-2826.
- [33] Szegedy C ve diğerleri. Going deeper with convolutions. In: *Proc IEEE Conf Comp Vis Pat Rec* 2015; 1-9.
- [34] Zoph B, Vasudevan V, Shlens J, Le QV. Learning transferable architectures for scalable image recognition. In: *Proc IEEE Conf Comp Vis Pat Rec* 2018; 8697-8710.
- [35] Addagarla SK, Chakravarthi GK, Anitha P. Real time multi-scale facial mask detection and classification using deep transfer learning techniques. *Int J* 2020; 9(4): 4402-4408.
- [36] Iandola FN, Han S, Moskewicz MW, Ashraf K, Dally WJ, Keutzer K. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*, 2016.
- [37] Chollet F. Xception: Deep learning with depthwise separable convolutions. In: *Proc IEEE Conf Comp Vis Pat Rec* 2017; 1251-1258.
- [38] Cortes C, Vapnik V. Support-vector networks. *Mach Learn* 1995; 20(3): 273-297.
- [39] Jiang H. *Machine Learning Fundamentals: A Concise Introduction*. Cambridge Univ Press
- [40] Quinlan JR. *C4. 5: Programs for Machine Learning*. Elsevier, 2014.

- [41] Subasi A, Balfağıh M, Balfagih Z, Alfawwaz K. A Comparative Evaluation of Ensemble Classifiers for Malicious Webpage Detection. *Procedia Computer Science* 2021; 194: 272-279.
- [42] Albayrak AS, Yılmaz SK. Veri Madenciliği: Karar Ağacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama. *Süleyman Demirel Univ J Fac Econ Adm Sci* 2009; 14(1).
- [43] Özaltın Ö. Biyomedikal Görüntülerin Sınıflandırılması İçin Yeni Bir Evrişimli Sinir Ağı Mimarisi. Doktora Tezi, Hacettepe Üniversitesi, Ankara, 2023.
- [44] Keller JM, Gray MR, Givens JA. A fuzzy k-nearest neighbor algorithm. *IEEE Trans Syst Man Cybern* 1985; (4): 580-585.
- [45] Cover T, Hart P. Nearest neighbor pattern classification. *IEEE Trans Inf Theory* 1967; 13(1): 21-27.
- [46] McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys* 1943; 5: 115-133.
- [47] Dolatabadi M, Zakariazadeh A, Borghetti A, Siano P. Distributed energy and reserve scheduling in local energy communities using L-BFGS optimization. *CSEE J Power Energy Syst* 2024.
- [48] Eroglu Y, Yildirim M, Cinar A. mRMR-based hybrid convolutional neural network model for classification of Alzheimer's disease on brain magnetic resonance images. *Int J Imaging Syst Technol* 2022; 32(2): 517-527.
- [49] Ozaltın O, Coskun O, Yeniay O, Subasi A. A deep learning approach for detecting stroke from brain CT images using OzNet. *Bioengineering* 2022; 9(12): 783.
- [50] Li BQ, Zheng LL, Feng KY, Hu LL, Huang GH, Chen L. Prediction of linear B-cell epitopes with mRMR feature selection and analysis. *Curr Bioinform* 2016; 11(1): 22-31.
- [51] Girgin ABA, Şahin S. Improving the Performance of Sentiment Analysis by Ensemble Hybrid Learning Algorithm With NLP And Cascaded Feature Extraction. *Int J Adv Eng Pure Sci* 2023; 35(1): 125-141.
- [52] Narin A. Detection of Focal and Non-focal Epileptic Seizure Using Continuous Wavelet Transform-Based Scalogram Images and Pre-trained Deep Neural Networks. *IRBM* 2020.
- [53] Xu X, Liu H. ECG heartbeat classification using convolutional neural networks. *IEEE Access* 2020; 8: 8614-8619.
- [54] Fawcett T. An introduction to ROC analysis. *Pattern Recognit Lett* 2006; 27(8): 861-874.
- [55] Başer BÖ, Yangın M, Sarıdaş ES. Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. *Süleyman Demirel Univ J Sci Inst* 2021; 25(1): 112-120.
- [56] Sertkaya ME, Ergen B. Alzheimer Hastalığının Teşhisinde Görüntü Dönüştürücü (Vision Transformer) Yaklaşımı: Yenilikçi Bir İnceleme. *Fırat Univ J Eng Sci* 2024; 36(2): 609-619.
- [57] Toshkhujaev S, Lee KH, Choi KY, Lee JJ, Kwon GR, Gupta Y, Lama RK. Classification of Alzheimer's disease and mild cognitive impairment based on cortical and subcortical features from MRI T1 brain images utilizing four different types of datasets. *J Healthc Eng* 2020; 2020(1): 3743171.
- [58] Suganthe R, Geetha M, Sreekanth G, Gowtham K, Deepakkumar S, Elango R. Multiclass classification of Alzheimer's disease using hybrid deep convolutional neural network. *NVEO Nat Volat Essent Oils J* 2021; 145-153.
- [59] Oh K, Chung YC, Kim KW, Kim WS, Oh IS. Classification and visualization of Alzheimer's disease using volumetric convolutional neural network and transfer learning. *Sci Rep* 2019; 9(1): 18150.