

MR Görüntülerinden Alzheimer Hastalığının Sınıflandırılması için Inception ve Sıkma-Uyarma Ağı Tabanlı Derin Öğrenme Modeli

Hüseyin FIRAT^{*1} ORCID 0000-0002-1257-8518

Hüseyin ÜZEN² ORCID 0000-0002-0998-2130

¹Dicle Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Diyarbakır

²Bingöl Üniversitesi, Mühendislik - Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü,
Bingöl

Geliş tarihi: 08.11.2023

Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: FIRAT, H., ÜZEN, H., (2024). MR Görüntülerinden Alzheimer Hastalığının Sınıflandırılması için Inception ve Sıkma-Uyarma Ağı Tabanlı Derin Öğrenme Modeli. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 555-567.

Öz

Alzheimer hastalığı (AH) ilerleyici bir beyin hastalığıdır ve yaşlı yetişkinlerde demansın önde gelen nedenidir. Hastalığın ilk aşamalarında tedavi daha etkili olduğu için erken teşhis hayati önem taşımaktadır. Derin öğrenme tekniklerinin, AH tespiti de dahil olmak üzere tıbbi görüntüleme için etkili olduğu kanıtlanmıştır. Bu çalışmada, manyetik rezonans görüntüleme görüntülerinden AH sınıflandırması için bir Inception modülü ile bir sıkma ve uyarma bloğunu birleştiren yeni bir yöntem tanıtılmaktadır. Inception modülü, farklı ölçeklerde çoklu paralel evrişimler kullanarak evrişimsel sinir ağı doğruluğunu arttırmaktadır. Sıkma ve uyarma bloğu, minimum ek parametre ile performansı arttırmaktadır. Dört sınıflı Kaggle veri seti üzerindeki deneysel sonuçlar ile %98,28'lik bir doğruluk değeri elde edilmiştir. Literatürdeki son çalışmalarla yapılan karşılaştırmalar, önerilen yöntemin AH'yi yüksek doğrulukla sınıflandırmadaki başarısını açıkça göstermektedir. Bu yaklaşım, tıbbi görüntülerden AH'yi doğru bir şekilde sınıflandırarak daha erken teşhis ve müdahaleye olanak sağlama konusunda umut vaat etmektedir.

Anahtar Kelimeler: Inception modülü, Sıkma-uyarma bloğu, Alzheimer hastalığı, Sınıflandırma

Inception and Squeeze-Excitation Network Based Deep Learning Model for Classification of Alzheimer's Disease from MRI Images

Abstract

Alzheimer's disease (AD) is a progressive brain disorder, the leading cause of dementia in older adults. Early identification is vital, as treatment is more effective in the disease's initial stages. Deep learning techniques have proven to be effective in medical imaging, including AD detection. This study introduces a novel method for AD classification from MRI images, combining an Inception module and a squeeze-and-excitation block. The Inception module increases convolutional neural network accuracy by using multiple parallel convolutions at different scales. The squeeze-and-excitation block enhances performance

*Sorumlu yazar (Corresponding Author): Hüseyin FIRAT, huseyin.firat@dicle.edu.tr

with minimal added parameters. The experimental results on the four-class Kaggle dataset yielded an accuracy of 98.28%. Comparisons with recent studies in the literature clearly demonstrate the success of the proposed method in classifying AD with high accuracy. This approach holds promise for accurately classifying AD from medical images, enabling earlier diagnosis and intervention.

Keywords: Inception module, Squeeze-and-excitation block, Alzheimer's disease, Classification

1. GİRİŞ

Alzheimer hastalığı (AH), geri dönüşü olmayan ve kronik nörodejeneratif bir hastalıktır ve yaşlılar arasında demansın önde gelen nedenidir [1]. Terapötik ilerlemenin başlaması ve etkili hasta tedavisi için AH prognozunun erken ve kesin analizi gereklidir. Dünya Sağlık Örgütü, AH'nin beşinci en önemli ölüm nedeni olarak kanseri geride bıraktığını ve 2050 yılına kadar AH hastalarının sayısının 152 milyona ulaşmasının beklendiğini bildirmiştir. Bu da 21. yüzyılda önemli bir sağlık sorunu teşkil edecektir [2]. AH, beyin hücrelerini kademeli olarak tahrip eden, hafıza kaybına ve bilişsel sorunlara neden olan ve nihayetinde gerçek yaşamın günlük aktivitelerini gerçekleştirme yeteneğinin kaybını hızlandıran uzun süreli nörolojik bir beyin hastalığıdır [3]. AH hastalığına yakalan insanlar yavaş yavaş hatırlama veya düşünme gibi bilişsel işlevlerini kaybedecek ve sonunda günlük aktiviteleri gerçekleştirme yeteneklerini kaybedeceklerdir. AH gelişimi bağlamında, hafif bilişsel bozukluk (HBB) normal bilişten AH'ye uzanan süreç boyunca zihinsel becerilerde hafif bir düşüşü temsil ederken, HBB olan bireylerin %33'ünden fazlası beş yıl veya daha uzun bir süre içinde AH'ye ilerleyecektir [2]. Bunun yanı sıra, AH'nin klinik öncesi bir aşaması olan HBB, normal yaşlanma ile AH arasında geçici bir durumdur.

Ne yazık ki AH'nin nedeni ve mekanizması hala tam olarak anlaşılammıştır ve iyileştirici bir tedavisi yoktur. Ancak hastalığın ilerlemesi ilaç tedavisi, egzersiz ve hafıza eğitimi yoluyla yavaşlatılabilmektedir. Bu konuda AH'nin erken tespiti ve HBB'nin doğru tanısı hastalığın ilerlemesini geciktirmek ve hastanın yaşam kalitesini arttırmak açısından büyük önem taşımaktadır. Bununla birlikte, doktorlar nöro görüntüleme ve bilgisayar destekli tanı yaklaşımlarını kullanarak AH'yi erken evrelerinde

önemli ölçüde daha az doğrulukla sınıflandırabilmektedirler. Bilgisayarlı Tomografi (BT) taraması, Pozitron Emisyon Tomografisi (PET) taraması ve özellikle Manyetik Rezonans Görüntüleme (MRG) taraması dahil olmak üzere nöro-görüntüleme, tıbbi tanıda hayati bir rol oynamaktadır [4]. İnsan vücudu hakkında bilgi sağlayan etkili bir non-invaziv yöntemdir. Tıbbi teşhis sürecinin ilerlemesi, günümüzde bilgisayar destekli teşhis alanında muazzam araştırma alanı oluşturmuştur [5].

Bilgisayar destekli teşhis sistemi, geleneksel ve derin öğrenme tabanlı olarak ayırt edebileceğimiz görüntü analiz tekniklerine dayanmaktadır. Bunlar: ön işleme, segmentasyon, özellik çıkarma ve sınıflandırma şeklindedir. Görüntü ön işleme, olası bozulmaları veya gereksiz verileri ortadan kaldırmak veya daha sonraki işlemler için önemli özellikleri vurgulamak ve geliştirmek için görüntüyü analiz etmeden önce hazırlamaktadır. Daha sonra, segmentasyon adımı önemli bölgeleri bir sonraki adımda çıkarılan renk, yoğunluk veya doku gibi ortak özelliklere sahip piksel gruplarına ayırmaktadır. Segmentasyonun amacı, görüntü temsili basitleştirmek ve daha anlamlı ve analiz edilmesi daha kolay bir hale getirmektir. Son adım, denetimli veya denetimsiz makine öğrenimi yaklaşımlarını kullanarak nesnelere bir etiket atamaktan oluşan sınıflandırmadır. Ancak son yıllarda, evrimsel sinir ağının (ESA) önerilmesinden bu yana derin öğrenme algoritmaları ortaya çıkmıştır. ESA'lar özellik tanımlayıcılarına veya belirli özellik çıkarma tekniklerine ihtiyaç duymadan özellikleri bağımsız olarak çıkarabilirler [6].

Derin öğrenme algoritmaları geleneksel makine öğrenme yöntemlerinden farklıdır. Görüntü ön işlemine çok az ihtiyaç duyarlar veya hiç ihtiyaç duymazlar. Önceden özellik seçimi gerektirmeden ham görüntülerden otomatik olarak optimum bir

veri temsili çıkarabilirler, bu da daha objektif bir süreçle sonuçlanmaktadır. Bu nedenle, derin öğrenme algoritmaları ince ve yaygın anatomik anormallikleri tespit etmek için daha uygundur. Son yıllarda tıbbi görüntü analizinde yaygın olarak kullanılmakta ve sınıflandırma, segmentasyon gibi çalışma alanlarında oldukça başarılı sonuçlar üretmektedir.

Literatürde son yıllarda AH'ın sınıflandırılması için çeşitli derin öğrenme tabanlı çalışmalar yapılmıştır. Bunlardan bazıları şu şekildedir: [3] nolu çalışmada, MRG görüntüleri kullanarak AH'ı tanımlamak için güvenilir ve verimli bir yöntem geliştirmek için derin ESA kullanmayı amaçlamaktadır. Bu doğrultuda, Alzheimer Hastalığı Tespit Ağı (Detection of Alzheimer's Disease Network - DADNet), parametreleri ve hesaplama maliyetlerini azaltırken Alzheimer hastalığının evrelerini doğru bir şekilde sınıflandırmak için sıfırdan geliştirilmiştir. Kaggle veri seti kullanılarak %90 doğruluk değeri elde etmişlerdir. [7] nolu çalışmada, MRG görüntüleri kullanılarak AH sınıflandırılması için hafif bir derin ESA geliştirdiler. Kaggle veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda %95,93 doğruluk değeri elde ettiler. [8] nolu çalışmada, AH sınıflandırılması için geliştirilen ESA tabanlı yöntem ile kaggle veri seti kullanarak %94,63 doğruluk elde ettiler. [9] nolu çalışmada, AH sınıflandırılması için önceden eğitilmiş ResNet kullanılarak kaggle veri seti ile %94,10 doğruluk elde ettiler. [10] nolu çalışmada, destek vektör makineleri (DVM) ile birlikte iki farklı ESA tabanlı yöntem kullanarak AH sınıflandırılması için deneysel çalışmalar yaptılar. İlk yöntemde AlexNet ile birlikte DVM kullanarak kaggle veri seti üzerinde %94,84 doğruluk değeri elde ederken, ikinci yöntemde ResNet ile birlikte DVM kullanarak aynı veri seti üzerinde %94,14 doğruluk değeri elde ettiler. [11] nolu çalışmada, Kaggle platformundan elde ettikleri MRG görüntülerinden AH sınıflandırılması için ESA tabanlı bir yöntem önerdiler. Önerilen bu yöntemi DEMentia NETwork (DEMNET) olarak adlandırdılar. Önerilen bu yöntem ile gerçekleştirilen kapsamlı deneysel çalışmalar sonucunda %95,23 doğruluk değeri elde ettiler.

Bu çalışmada, AH'ın MRG görüntülerinden çok sınıflı olarak sınıflandırılması için ESA tabanlı yeni bir yöntem önerilmiştir. Önerilen yöntem Inception modülü ve sıkma-uyarma bloğunun birleşiminden oluşmaktadır. Inception modülünün kullanımı ile farklı ölçeklerde çoklu paralel evrişimler gerçekleştirerek ESA'ların verimliliğini ve sınıflandırma performansını arttırmak amaçlanmıştır. Inception modülü ayrıca daha büyük filtreler uygulamadan önce giriş tensöründeki kanal sayısını azaltmak için kullanılan 1x1 evrişim katmanı içermektedir. Bu, sınıflandırma doğruluğunu korurken ağır hesaplama maliyetini azaltmaya yardımcı olmaktadır. Aynı zamanda bellekten verimli bir şekilde tasarruf edilmesi sağlanmaktadır. Sıkma-uyarma bloğunun ESA'nın temsil kalitesini arttırmak için tasarlandığı göz önüne alındığında, hem özellik çıkarma hem de sınıflandırma performansını arttırmak için bu araştırma kapsamında önerilen yöntem dahil edilmiştir. Sıkma-uyarma bloğunun önerilen yöntemle entegrasyonu, genel parametre sayısında yalnızca minimum artışla sınıflandırma performansını artırma yeteneklerinden kaynaklanmaktadır. Önerilen yöntemin sınıflandırma performansının analizi için Kaggle platformunda yer alan MRG görüntüleri kullanılarak deneysel çalışmalar yapılmıştır [12]. Deneysel çalışmalar sonucunda %98,28 doğruluk değeri elde edilmiştir.

Bu çalışmanın geri kalanında öncelikle veri seti, önerilen yöntem ve önerilen yöntemin arka planında kullanılan Inception modülü ile sıkma-uyarma bloğunun yer aldığı materyal ve metod bölümü Bölüm 2'de yer almaktadır. Ardından deneysel çalışmalar ve sınıflandırma sonuçlarının verildiği Bölüm 3 gelmektedir. Son olarak, çalışmanın genel bir özeti yer aldığı sonuç bölümü Bölüm 4'te bulunmaktadır.


2. MATERYAL VE METOT

2.1. Veri Seti

Bu çalışmada kullanılan veri seti, Manyetik Rezonans Görüntüleme (MRG) tarama görüntüleri ve ilgili sınıf etiketleri bilgilerine sahip halka açık

bir platform olan Kaggle'dan alınmıştır [12]. Bu veri seti 4 sınıf (hafif bunamış-mild demented, orta derece bunamış-moderate demented, bunak olmayan-non demented, çok hafif bunamış-very mild demented) ve toplam 6400 MRG görüntüsü içermektedir. Bu 4 sınıfta yer alan görüntüler ise şu

şekildedir: 896 hafif bunamış, 64 orta derece bunamış, 3200 bunak olmayan ve 2240 çok hafif bunamış. MRG görüntü örnekleri, dört farklı sınıfa ait 150 x 150 piksellik üç kanallı (RGB) görüntülerdir. Bu 4 sınıfa ait örnek MRG görüntüleri Şekil 1'de verilmiştir.



Şekil 1. Örnek MRG görüntüleri

2.2. Inception Modülü

Inception modülü, ESA'larda sınıflandırma ve nesne tanıma için kullanılan bir yapı taşıdır. Bu modül, 2014 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını kazanan GoogLeNet mimarisinde tanıtılmıştır. Bu modül, paralel olarak farklı boyutlarda (1x1, 3x3 ve 5x5) filtreler kullanarak birden fazla ölçek ve çözünürlükteki görüntülerden verimli bir şekilde özellik çıkarmak için tasarlanmıştır. Bu, ağın görüntüdeki hem ince taneli hem de kaba taneli ayrıntıları yakalamasını sağlamaktadır. Inception modülü ayrıca girdinin boyutluluğunu azaltmaya ve hesaplama performansını arttırmaya yardımcı olan 1x1 evrimsel katman içerir. Ayrıca modül, özellik haritalarını küçültmek için havuzlama işlemlerini kullanır, bu da aşırı öğrenmenin etkisini azaltmaya yardımcı olabilir. Inception modülü, derin ağlar oluşturmak için bir araya getirilebilmekte ve çeşitli görüntü tanıma görevlerinde son teknoloji

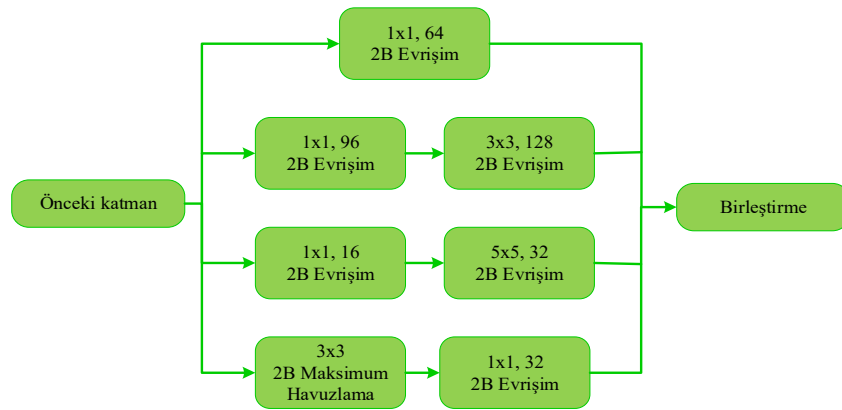
performans elde edebilmektedir [13,14]. Inception modülünün yapısı Şekil 2'de verilmiştir.

2.3. Sıkma-Uyarma (SU) Bloğu


SU bloğu, ESA'lar için hesaplama yükünü önemli ölçüde arttırmadan kanal ilişkilerini geliştiren bir çerçeve sunmaktadır. Bu blok, aldığı giriş özelliklerini yeniden kalibre ederek önemli özellik bilgilerini etkili bir şekilde geliştirir. SU bloğunun kullanılması, kanallar arasındaki karşılıklı bağımlılıkların geliştirilmesine katkıda bulunur ve böylece görüntü sınıflandırma görevleri için özellik bilgilerinin uygunluğunu artırır. Şekil 3'te SU bloğunun yapısal taslağını gösterilmektedir. Başlangıçta, SU bloğu mevcut kanal sayısı ile birlikte bir özellik haritası alır. Daha sonra, Global Ortalama Havuzlama (GOH) kullanılarak her kanal tek bir sayısal değere dönüştürülür ("sıkma" olarak adlandırılır). Bu süreçte, her kanalla ilişkili özellik haritaları, GOH gibi bir kanal tanımlayıcı tekniği

kullanılarak 1×1 özellik haritalarına yoğunlaştırılır. Bu aşama, genel kanal bilgilerini kapsayan bir skaler değer üretir. "Sıkma" işleminin birincil amacı küresel bir alıcı alan oluşturarak küresel bilginin alt ağ katmanları tarafından bile kullanılmasını kolaylaştırmaktır. "Sıkma" işleminin ardından "uyarma" süreci devreye girerek, belirlenen parametrelere dayalı olarak her bir özellik kanalı için ağırlıklar oluşturur. Bu parametreler, özellik kanalları arasında var olan korelasyonları yakalamak için açıkça eğitilir. Mimari, yöntemin karmaşıklığını yönetmek, geliştirmeyi kolaylaştırmak ve kanal korelasyonlarını modellemek için bir darboğaz yapısı sunmak üzere iki tam bağlantılı katman (Fully connected-FC) içerir. İlk FC katmanı, özellik boyutlarını azaltmaya yarar ve bu boyutlar daha sonra bir sonraki FC katmanında orijinal boyutlarına geri genişletilir. Bu iki FC katmanı arasında ReLU aktivasyon

fonksiyonu kullanılarak ağa doğrusal olmayan bir yapı kazandırılır ve böylece ağın karmaşık kanal korelasyonlarına daha iyi adapte olması sağlanır. Doğrudan bir FC katmanının aksine, iki FC katmanının kullanılması modelin doğrusal olmayan özelliklerini geliştirerek karmaşık kanal ilişkilerine daha iyi uyum sağlarken aynı zamanda hesaplama yükünü ve parametre sayısını azaltır. FC-ReLU-FC dizisinden sonra, 0 ile 1 arasında değişen normalleştirilmiş ağırlıkları hesaplamak için sigmoid fonksiyonu çağrılır. Daha sonra, normalleştirilmiş ağırlıkları her kanalın özelliklerine göre ayarlamak için bir ölçeklendirme prosedürü uygulanır. Daha da önemlisi, SU bloğundaki bu işlemler minimum ek hesaplama yüküne neden olur. Bu blok, sınıflandırma performansını artırma kabiliyeti nedeniyle çeşitli yöntemlere kolay bir şekilde entegre edilebilir [15-17].



Şekil 2. Inception modülü



Şekil 3. SU blok yapısı

2.4. Önerilen Yöntem

Önerilen yöntem Şekil 4'te gösterildiği gibi Inception modüllerinin ve sıkma-uyarma bloğunun birleşiminden oluşmaktadır. Önerilen yöntemde girdi MRG görüntüleri öncelikle 150x150x3 boyutuna yeniden boyutlandırılmıştır. Girdi MRG görüntülerine öncelikle 3x3 çekirdek boyutunda 64 filtrelili 2 boyutlu (2B) evrişim işlemi uygulanmaktadır. Ardından sırasıyla 3x3 çekirdek boyutunda maksimum havuzlama, 3x3 ve 1x1 çekirdek boyutunda ve 128 filtrelili 2B evrişim işlemi uygulanmaktadır. Bu işlemlerden sonra elde edilen özellik haritası ilk Inception modülünün girişine verilmektedir. Inception modülü Şekil 2'de gösterildiği gibi uygulanmaktadır. İlk Inception modülünün çıktısına sırasıyla 3x3 çekirdek boyutunda 64 filtrelili 2B evrişim, 3x3 çekirdek boyutunda maksimum havuzlama, 3x3 ve 1x1 çekirdek boyutunda ve 128 filtrelili 2B evrişim işlemleri uygulanmaktadır. Bu işlemlerin sonunda elde edilen özellik haritasına ikinci Inception modülü uygulanmaktadır. İkinci Inception modülünün çıktısına sırasıyla 3x3 çekirdek boyutu ve 128 filtreye sahip 2B evrişim, 3x3 çekirdek boyutuna sahip maksimum havuzlama ve 1x1 çekirdek boyutu ve 128 filtreye sahip 2B evrişim işlemleri uygulanmaktadır. Ayrıca, ReLU aktivasyon fonksiyonu tüm evrişim katmanlarına uygulanmaktadır. Tüm bu işlemlerin sonunda elde edilen özellik haritası SU bloğunun girişine verilmektedir. SU bloğu Şekil 3'te gösterildiği gibi sıkma, uyarma ve ölçeklendirme aşamalarından oluşmaktadır. SU bloğunda bu işlemler gerçekleştirildikten sonra GOH ve ardından toplu normalizasyon (Batch normalization) işlemleri gerçekleştirilmektedir. GOH, standart evrişimsel sinir ağlarında tam bağlantılı katmanları değiştirmek için tasarlanmış bir havuzlama işlemidir. GOH ile son katmandaki sınıflandırma görevinin karşılık gelen her sınıfı için bir özellik haritası oluşturulmaktadır. Özellik haritalarının üstüne tam bağlantılı katmanları eklemek yerine, her bir özellik haritasının ortalaması alınmakta ve elde edilen vektör doğrudan softmax katmanına aktarılmaktadır. Ayrıca önerilen yöntemde GOH'un kullanmanın avantajı, GOH'ta optimize edilecek bir parametre olmaması ve dolayısıyla bu katmanda aşırı öğrenmenin önlenmesidir. GOH'un çıktısı,

özellikleri sınıflandırmak için bir softmax fonksiyonuna verilmektedir. Bununla birlikte, softmax'tan önce, eğitim sürecini kolaylaştırmak ve hızlandırmak için toplu normalleştirme uygulanmaktadır. Son olarak, Softmax her sınıfa olasılık değerleri atamaktadır.

Önerilen yöntemin özgün katkısı, Inception modülü ile sıkma-uyarma bloğunu birleştirerek daha az parametre ile yüksek performans elde etmesidir. Evrişimsel sinir ağı tabanlı derin öğrenme modelleri kullanılan diğer çalışmalardan farklı olarak, bu yöntem, Inception modülü sayesinde, farklı evrişimsel çekirdek boyutları kullanılarak girdi görüntülerinden çeşitli ölçeklerde özellikler çıkarılmaktadır. Bu, modelin farklı detayları ve özellikleri yakalayabilmesini sağlamaktadır. Aynı zamanda, yöntemin zengin ve çok yönlü özellikler öğrenmesi açısından önemlidir. Bu modül ayrıca 1x1 evrişimler kullanarak çapraz kanal modelleri öğrenmekte ve çoklu evrişim katmanlarıyla modülün çok yönlü özellik çıkarma kapasitesinden faydalanmaktadır. Bu, ağıın genel özellik çıkarma yeteneklerine katkıda bulunarak yüksek doğruluk sağlamaktadır. Sıkma-uyarma bloğu, kanal dikkatini artırarak önemli özelliklerin daha iyi öğrenilmesinde etkilidir. Bu blok, ek işlem maliyeti neredeyse olmadan performans artışı sağlamak ve herhangi bir modele kolayca eklenebilmektedir. Bu iki yöntemin kombinasyonu, daha az parametre ile çalışarak hesaplama maliyetlerini düşürmekte ve daha verimli bir yöntem sunmaktadır.


3. DENEYSEL ÇALIŞMALAR

3.1. Parametre Detayları

Çalışma kapsamında deneysel çalışmalar kaggle platformunda python programlama dili ve keras ile tensorflow kütüphaneleri kullanılarak gerçekleştirilmiştir. Kaggle platformunda donanım hızlandırıcı olarak TPU kullanılmıştır. Deneysel çalışmalarda tüm görüntüler 150x150x3 boyutundadır. Veri setinde yer alan 6400 görüntü, eğitim, doğrulama ve test veri seti için sırasıyla %80, %10 ve %10'a bölünmüştür. Yani, 5120 görüntü eğitim, 640 görüntü doğrulama ve 640 görüntü test için kullanılmıştır. Önerilen yöntemi

eğitmek için kullanılan hiperparametreler şu şekildedir. Batch size değeri olarak 128 alınmıştır.

Yöntem 100 epok'ta eğitilmiştir. Optimizer olarak Adam kullanılmıştır.



Şekil 4. Önerilen yöntem

3.2. Değerlendirme Ölçütleri

Önerilen yöntemin performansını kıyaslamak için farklı değerlendirme ölçütleri kullanılmıştır. Aşağıdaki dört ölçüt, bir sınıflandırıcının çeşitli ölçütlerini gözlemlerken yaygın olarak kullanılmaktadır.

- Doğruluk, doğru tahminlerin yöntem tarafından yapılan toplam tahmin sayısına oranını temsil etmektedir. Doğruluk Eşitlik 1'deki gibi hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

- Çok sınıflı sınıflandırma bağlamında kesinlik, her sınıf için bir yöntem tarafından yapılan pozitif tahminlerin doğruluğunu değerlendiren

bir ölçüttür. Kesinlik, pozitif olarak tahmin edilen örneklerin kaçının gerçekten sınıfa ait olduğunu ölçmektedir. Eşitlik 2'deki gibi tanımlanmaktadır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

- Duyarlılık, yöntemin toplam gerçek pozitif örneklerden (gerçek pozitifler + yanlış negatifler) ilgili tüm örnekleri (gerçek pozitifler) doğru bir şekilde tanımlama yeteneğini değerlendirmek için sınıflandırmada kullanılan bir ölçüttür. Başka bir deyişle, yöntem tarafından doğru şekilde tanımlanan gerçek pozitif örneklerin yüzdesini ölçmektedir. Eşitlik 3'teki gibi tanımlanmaktadır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3)$$

- F1-skoru, çok sınıflı sınıflandırmada kesinlik ve duyarlılık arasında bir denge sağlamak için kullanılan bir ölçüttür. Hem kesinlik hem de duyarlılık tek bir değerde birleştirilerek bir yöntemin genel performansını değerlendirmek için kullanışlı bir ölçüt haline getirir. F1-skoru, kesinlik ve duyarlılığın harmonik ortalaması olarak hesaplanmakta ve yanlış pozitifler ile yanlış negatifler arasında bir denge bulmak istenildiğinde özellikle değerlidir. Eşitlik 4'teki gibi hesaplanmaktadır.

$$F1 - skoru = 2 * \frac{Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (4)$$

Eşitlik 1, 2, 3 ve 4'teki TN, TP, FN ve FP karışıklık matrisinden elde edilmektedir. Gerçek Negatifler (TN), model tarafından negatif sınıf (ör. "0" veya "hayır") olarak doğru şekilde tahmin edilen örneklerin sayısını temsil eder. Bunlar, modelin gerçekte ait olmadıkları halde örnekleri pozitif sınıfa ait değilmiş gibi doğru bir şekilde tanımladığı durumlardır. Gerçek Pozitifler (TP), model tarafından pozitif sınıf (örneğin, "1" veya "evet") olarak doğru tahmin edilen örneklerin sayısını temsil eder. Bunlar, modelin örnekleri gerçekten pozitif sınıfa ait olduklarında pozitif sınıfa ait olarak doğru şekilde tanımladığı durumlardır. Yanlış Pozitifler (FP), aslında negatif sınıfa ait oldukları halde model tarafından yanlışlıkla pozitif sınıf olarak tahmin edilen örneklerin sayısını temsil eder. Bunlar, modelin negatif bir tahminde bulunması gerekirken pozitif bir tahminde bulunduğu durumlardır. Yanlış Negatifler (FN), aslında pozitif sınıfa ait oldukları halde model tarafından yanlışlıkla negatif sınıf olarak tahmin edilen örneklerin sayısını temsil eder. Bunlar, modelin pozitif bir tahminde bulunması gerekirken negatif bir tahminde bulunduğu durumlardır.

3.2. Deneysel Sonuçlar

Deneysel çalışmalar sonucunda önerilen yöntemin karışıklık matrisi Şekil 5'te verilmiştir. Şekil 5'e

göre, 91 hafif bunamış görüntüsünden, 88 görüntünün doğru şekilde sınıflandırıldığı görülmektedir. Bu sınıfta 1 görüntü bunak olmayan ve 2 görüntü de çok hafif bunamış olarak yanlış tahmin edilmiştir. Orta derece bunamış sınıfında yer alan 8 görüntünün tamamı doğru bir şekilde tahmin edilmiştir. 319 bunak olmayan görüntüden 318'inin doğru, 1 görüntünün çok hafif bunamış olarak yanlış tahmin edildiği ve son olarak 222 çok hafif bunamış görüntüden 215'inin doğru, 7 görüntünün bunak olmayan görüntü olarak yanlış tahmin edildiği görülmektedir. Bu karışıklık matrisinden yola çıkarak sınıf bazlı doğruluk değerleri şu şekildedir: hafif bunamış sınıf %99,53, orta derece bunamış sınıf %100, bunak olmayan sınıf %98,59 ve çok hafif bunamış sınıf %98,44'tür. 4 sınıfın genel doğruluk değeri %98,28 iken, makro ortalama değeri %99,14'tür.

Hafif Bunamış	88	0	1	2
Orta Derece Bunamış	0	8	0	0
Bunak Olmayan	0	0	318	1
Çok Hafif Bunamış	0	0	7	215
	Hafif Bunamış	Orta Derece Bunamış	Bunak Olmayan	Çok Hafif Bunamış

Şekil 5. Önerilen yöntemin karışıklık matrisi

Literatürden aynı veri setini kullanan çalışmalar ile gerçekleştirilen karşılaştırma sonuçları Çizelge 1'de verilmiştir. Inception modülü ve SU bloğunun birleşiminden oluşan önerilen yöntem ile %98,28 doğruluk, %99,04 kesinlik, %98,31 duyarlılık ve %98,67 F1-skoru elde edilmiştir. Önerilen yöntem en yakın sonuçlar %95,93 doğruluk ve kesinlik, %95,88 duyarlılık ve %95,90 F1 skoru ile [7] nolu çalışmada geliştirilen hafif derin ESA yöntemi ile elde edilmiştir. Diğer yöntemlerden önerilen yöntem en yakın sonuçlar %95,23 doğruluk, %96

kesinlik, %95 duyarlılık ve %95,27 F1 skoru ile [11] nolu çalışmada önerilen ESA yöntemi ile elde edilmiştir. Bu yöntemlerin yanı sıra, [3] nolu çalışmada önerilen ESA yöntemi ile %90 doğruluk, %91,34 kesinlik, %87,34 duyarlılık, %88,09 F1 skoru, [8] nolu çalışmada geliştirilen ESA yöntemi ile %94,68 doğruluk, %94,75 kesinlik, duyarlılık ve F1 skoru, [9] nolu çalışmada önerilen önceden eğitilmiş ResNet50 mimarisi ile %94,10 doğruluk, %96,50 kesinlik, %94,75 duyarlılık, %95,5 F1 skoru elde edilmiştir. [10] nolu çalışmada iki farklı

yöntem önerilmiştir. İlk yöntemde AlexNet ve Destek vektör makineleri (DVM) kullanılarak %94,84 doğruluk, %93,02 kesinlik, %94,32 duyarlılık ve %93,66 F1 skoru elde edilirken, ResNet50 ve DVM'nin kullanıldığı ikinci yöntemde, %94,14 doğruluk, %91,41 kesinlik, %91,92 duyarlılık ve %91,66 F1 skoru elde edilmiştir. Karşılaştırmada kullanılan tüm yöntemler göz önüne alındığında önerilen yöntemin açık bir şekilde daha başarılı sonuçlar ürettiği görülmektedir.

Çizelge 1. Çoklu sınıflandırma görevi için önerilen yöntemin literatürde yer alan farklı yöntemler ile karşılaştırılması

Çalışma	Yöntem	Performans
[3]	ESA – DADNet	Doğruluk = %90 Kesinlik = %91,34 Duyarlılık = %87,34 F1-skor = %88,09
[7]	Hafif Derin ESA	Doğruluk = %95,93 Kesinlik = %95,93 Duyarlılık = %95,88 F1-skor = %95,90
[8]	ESA	Doğruluk = %94,63 Kesinlik = %94,75 Duyarlılık = %94,75 F1-skor = %94,75
[9]	Önceden eğitilmiş ResNet50	Doğruluk = %94,10 Kesinlik = %96,50 Duyarlılık = %94,75 F1-skor = %95,5
[10]	AlexNet+DVM	Doğruluk = %94,84 Kesinlik = %93,02 Duyarlılık = %94,32 F1-skor = %93,66
[10]	ResNet50+DVM	Doğruluk = %94,14 Kesinlik = %91,41 Duyarlılık = %91,92 F1-skor = %91,66
[11]	ESA - DEMNET	Doğruluk = %95,23 Kesinlik = %96 Duyarlılık = %95 F1-skor = %95,27
Önerilen yöntem	Derin ESA (Inception + SU)	Doğruluk = %98,28 Kesinlik = %99,04 Duyarlılık = %98,31 F1-skor = %98,67


Önerilen yöntemin farklı derin öğrenme tabanlı yöntemler ile karşılaştırılması Çizelge 2’de verilmiştir. Çizelge 2’de yer alan tüm yöntemler sıfırdan eğitilmiş ve sonuçları elde edilmiştir. Önerilen yöntem ile %98,28 doğruluk, %99,04 kesinlik, %98,31 duyarlılık ve %98,67 F1 skoru elde edilmiştir. Önerilen yönteme en yakın sonuçlar, %97,81 doğruluk, %98,50 kesinlik, %98,35 duyarlılık, %98,42 F1 skoru ile ResNet152, %97,66 doğruluk, %98,45 kesinlik, %98,13 duyarlılık, %98,29 F1 skoru ile InceptionV3, %97,81 doğruluk, %98,41 kesinlik, %94,80 duyarlılık, %96,57 F1 skoru ile InceptionResNetV2 yöntemlerinde elde edilmiştir. Diğer yöntemlerin doğruluk, kesinlik, duyarlılık ve F1 skorları incelendiğinde, VGG16 ile %87,81, %84,97, %81,81, %83,36, VGG19 ile %74,69, %72,03, %65,52, %68,62, ResNet101 ile %96,41, %97,32, %96,90, %97,11, MobileNet ile %89,69, %92,92, %86,63, %89,66, EfficientNetB0 ile %96,88, %97,92, %96,59, %97,25, EfficientNetB1 ile %97,03, %98,15, %91,13, %94,51 değerleri bulunmuştur. Tüm sonuçlar incelendiğinde, önerilen yöntem, en yakın değeri elde eden ResNet152’den %0,47 doğruluk, %0,54 kesinlik ve %0,25 F1 skoru daha başarılı değerler üretmiştir. Bunu yanı sıra ResNet152 yaklaşık 58 milyon

parametre içerirken, önerilen yöntem yaklaşık 1 milyon parametre içermektedir. Buradan da önerilen yöntemimiz ile daha az parametre ile daha başarılı sonuçların elde edildiği açık bir şekilde görülmektedir. Ayrıca önerilen yöntemin eğitim (train)-doğrulama (validation) doğruluk (accuracy) ve kayıp grafikleri Şekil 6’da verilmiştir. Şekil 6 incelendiğinde, eğitim doğruluğunun yaklaşık 40 epok’ta %100’e ulaştığı, doğrulama doğruluğunun yaklaşık 60 epok’a kadar dalgalanma gösterdiği görülmektedir. Kayıp (Loss) grafiğinde ise yaklaşık 20 epok’a kadar eğitim kaybı azalmakta ve 20 epok’tan sonra 0’a yaklaşmaktadır. Doğrulama kaybı ise yaklaşık 55 epok’a kadar dalgalanma göstermekte ve 55 epok’tan sonra 0’a yaklaşmaktadır.


Önerilen yöntemde kullanılan Inception modülleri ve SU bloğunun bileşen analizi yapılmış ve Şekil 7’de verilmiştir. Sadece Inception modülleri kullanıldığında %96,34, sadece SU bloğu kullanıldığında %97,28 doğruluk değeri elde edilmektedir. Her iki bileşeni içeren önerilen yöntem (Inception + SU) ise %98,28 doğruluk değeri elde etmiştir. Inception ve SU bloğunun birlikte kullanımının sınıflandırma doğruluğunu arttırdığı görülmektedir.

Çizelge 2. Önerilen yöntemin farklı derin öğrenme tabanlı yöntemler ile karşılaştırılması

Model	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skor (%)	Parametre sayısı
VGG16	87,81	84,97	81,81	83,36	14,718,788
VGG19	74,69	72,03	65,52	68,62	20,028,484
ResNet101	96,41	97,32	96,90	97,11	42,674,564
ResNet152	97,81	98,50	98,35	98,42	58,387,332
InceptionV3	97,66	98,45	98,13	98,29	21,819,172
MobileNet	89,69	92,92	86,63	89,66	3,237,060
InceptionResNetV2	97,81	98,41	94,80	96,57	54,349,028
EfficientNetB0	96,88	97,92	96,59	97,25	4,059,815
EfficientNetB1	97,03	98,15	91,13	94,51	6,585,483
Önerilen yöntem	98,28	99,04	98,31	98,67	943,397



Şekil 6. Önerilen yöntem için eğitim (train)-doğrulama (validation) grafikleri. Soldaki doğruluk ve sağdaki kayıp grafiği



Şekil 7. Önerilen yöntemin bileşen analizi

4. SONUÇLAR

Alzheimer Hastalığı (AH), yaşlı bireylerin yaşamlarını derinden etkileyen ciddi bir hastalıktır. AH'nin erken ve doğru teşhisi, hastalığın etkilerini

azaltmada kritik bir öneme sahiptir. Geleneksel yöntemlerle yapılan teşhislerin zorlukları göz önünde bulundurulduğunda, yapay zeka ve özellikle derin öğrenme yöntemleri AH'nin erken teşhisinde önemli bir rol oynamaktadır. Bu

çalışmada, MRG görüntüleri kullanılarak AH'yi tespit etmek ve sınıflandırmak için derin öğrenme tabanlı yeni bir yöntem geliştirilmiştir. Geliştirilen bu yöntem, Inception modülü ve sıkma-uyarma bloğunun birleşiminden oluşmaktadır. Inception modülü, (1) farklı evrimsel çekirdek boyutları kullanarak girdi görüntülerinden çeşitli ölçeklerde özellikler çıkarmaktadır. (2) 1x1 evrişim kullanarak ağın genel özellik çıkarma yeteneklerini arttırmakta ve çapraz kanal modelleri öğrenmektedir. Bu, sinir ağında yüksek doğruluk sağlamaktadır. (3) Çoklu evrimsel katmanlar kullanarak çok yönlü özellik çıkarmayı sağlamaktadır. Bu, ağın performansını arttırmakta ve yüksek doğruluk sağlamaktadır. Sıkma-uyarma bloğu ise neredeyse hiçbir ek işlem maliyeti gerektirmeden sınıflandırma görevlerinde performans artışı sağlamaktadır ve herhangi bir modele kolayca eklenebilmektedir. Önerilen yöntemin performansını değerlendirmek için, Kaggle platformunda halka açık dört sınıf içeren bir MRG veriseti üzerinde kapsamlı deneysel çalışmalar gerçekleştirilmiştir. Deneysel sonuçlarında, önerilen yöntem %98,28 doğruluk, %99,04 kesinlik, %98,31 duyarlılık ve %98,67 F1 skoru elde etmiştir. Önerilen yöntem, literatürde aynı verisetini kullanan son yıllardaki farklı çalışmalarla karşılaştırıldığında, performans açısından daha üstün sonuçlar vermiştir. Ayrıca literatürden farklı derin öğrenme tabanlı yöntemler ile yapılan kapsamlı değerlendirmeler sonucunda, önerilen yöntem daha düşük parametre sayısı ile daha başarılı sonuçlar elde etmiştir. Bu bulgular, önerilen yöntemin AH sınıflandırmasında yüksek doğruluk ve güvenilirlik sağladığını ortaya koymaktadır. Inception modülü ve sıkma-uyarma bloğunun birleşimi, modelin performansını arttırmış ve yöntemin etkili bir teşhis aracı olma potansiyelini göstermiştir. Bu, hem erken teşhis hem de tedavi sürecinde önemli katkılar sağlayabilmektedir. Bunun yanı sıra, önerilen yöntemin daha az parametre sayısı ile daha üstün sonuçlar elde etmesinin çeşitli olumlu etkileri bulunmaktadır. (1) Daha az parametre, yöntemin daha az hesaplama kaynağı gerektirmesi anlamına gelmektedir. Ayrıca, yöntemin depolama ve bellek kullanımını azaltarak kaynak tasarrufu sağlamaktadır. (2) Önerilen yöntemin daha hızlı eğitilmesini ve daha hızlı çıkarım yapmasını sağlar. Sonuç olarak, AH teşhisinde önerilen yöntem

erken teşhis için umut verici bir araç olarak kullanılabilir. Gelecek çalışmalarda, önerilen yöntemin farklı AH verisetleri üzerinde değerlendirilmesi ile ilgili çalışmalar yürütülmektedir. Ayrıca, doktorların Alzheimer hastalığını daha hızlı ve etkin bir şekilde teşhis etmesine yardımcı olacak gerçek zamanlı bir uygulamanın geliştirilmesi hedeflenmektedir.

5. KAYNAKLAR

1. Dadar, M., Pascoal, T.A., Manitsirikul, S., 2017. Validation of a Regression Technique for Segmentation of White Matter Hyperintensities in Alzheimer's Disease. *IEEE Transactions on Medical Imaging*, 36, 1758-1768.
2. Livingston, G., Sommerlad, A., Orgeta, V., 2017. Dementia Prevention, Intervention, and Care. *Lancet*, 390, 2673-2734.
3. Ahmed, G., Er, M.J., Muhammad, M., 2022. DAD-Net: Classification of Alzheimer's Disease Using Neural Network. *Molecules*, 27, 1-21
4. Tufail, Bin A., Ma, Y.K., Zhang, Q.N., 2020. Binary Classification of Alzheimer's Disease Using sMRI Imaging Modality and Deep Learning. *Journal of Digital Imaging*, 33, 1073-1090.
5. Tiwari, S., Venkata, A., Kaushik, A., 2019. Alzheimer's Disease Diagnostics and Therapeutics Market. *International Journal of Nanomedicine*, 14, 5541-5554
6. Loddo, A., Buttau, S., Di Ruberto, C., 2022. Deep Learning Based Pipelines for Alzheimer's Disease Diagnosis: A Comparative Study and a Novel Deep-ensemble Method. *Computers in Biology and Medicine*, 141, 105032.
7. El-Latif, A.A.A., Chelloug, S.A., Alabdulhafith, M., Hammad, M., 2023. Accurate Detection of Alzheimer's Disease Using Lightweight Deep Learning Model on MRI Data. *Diagnostics*, 13, 1-21.
8. Bangyal, W.H., Rehman, N.U., Nawaz, A., 2022. Constructing Domain Ontology for Alzheimer Disease Using Deep Learning Based Approach. *Electronics*, 11.
9. Balasundaram, A., Srinivasan, S., Prasad, A., 2023. Hippocampus Segmentation-Based Alzheimer's Disease Diagnosis and

- Classification of MRI Images. *Arabian Journal for Science and Engineering*, 48, 10249-10265.
10. Mohammed, B.A., Senan, E.M., Rassem, T.H., 2021. Multi-method Analysis of Medical Records and Mri Images for Early Diagnosis of Dementia and Alzheimer's Disease Based on Deep Learning and Hybrid Methods. *Electronics*, 10, 1-20.
 11. Murugan, S., Venkatesan, C., Sumithra, M.G., 2021. DEMNET: A Deep Learning Model for Early Diagnosis of Alzheimer Diseases and Dementia from MR Images. *IEEE Access*, 9, 90319-90329.
 12. Kumar, S., 2021. Alzheimer MRI Preprocessed Dataset. <https://www.kaggle.com/datasets/sachinkumar413/alzheimer-mri-dataset>. Access date: 12 October 2023.
 13. Firat, H., Emin, M., Mehmet, A., Hanbay, D., 2022 Hybrid 3D/2D Complete Inception Module and Convolutional Neural Network for Hyperspectral Remote Sensing Image Classification. *Neural Process Letters*, 1-44.
 14. Szegedy, C., Liu, W., Jia, Y., 2015. Going Deeper with Convolutions. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society, 1-9.
 15. Hu, J., Shen, L., Sun, G., 2018. Squeeze-and-Excitation Networks. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognition*, 7132-7141.
 16. Firat, H., 2023. Classification of White Blood Cells Using the Squeeze-Excitation Residual Network. *Bilişim Teknolojileri Dergisi*, 16, 189-205.
 17. Asker, M.E., 2023. Hyperspectral Image Classification Method Based on Squeeze-and-Excitation Networks, Depthwise Separable Convolution and Multibranch Feature Fusion. *Earth Science Informatics*, 1427-1448.

