

## Özel Blok Yapıları Kullanarak Tasarlanan Derin Öğrenme Mimarileri ile Alzheimer Hastalık Tespiti

Eyup HANBAY<sup>1\*</sup>, Ali ARI<sup>2</sup>

<sup>1,2</sup> Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, İnönü Üniversitesi, Malatya, Türkiye  
<sup>\*1</sup> eyup44@gmail.com, <sup>2</sup> ali.ari@inonu.edu.tr

(Geliş/Received: 12/06/2023;

Kabul/Accepted: 09/08/2023)

**Öz:** Bir demans türü olan Alzheimer hastalığı dünyada oldukça yaygın bir şekilde görülmektedir. Hastalığın farklı evreleri olup halen geçerli bir tedavisi yoktur. Güncel makine öğrenmesi yöntemleri ile hastalığın farklı evreleri tespit edilebilmektedir. Özellikle derin öğrenme tabanlı yöntemler ile hassas şekilde hastalık tespiti yapılabilmektedir. Bu çalışmada ResNet ve Inception mimarilerinin özel blok yapıları kullanılarak iki farklı derin öğrenme mimarisi geliştirilmiştir. Bu mimariler Alzheimer tespitinde etkin sonuçlar üretmiştir. Özel blok yapılarının tasarımı ile farklı mimarilerin birlikte çalışma yetenekleri ortaya çıkarılmıştır. Yapılan deneysel sonuçlarda önerilen mimarilerin etkin sonuçlar ürettiği görülmüştür.

**Anahtar kelimeler:** Alzheimer hastalığı tespiti, Derin öğrenme, Inception, ResNet.

### Alzheimer's Disease Detection with Deep Learning Architectures Designed Using Special Block Structures

**Abstract:** Alzheimer's disease, a type of dementia, is quite common in the world. The disease has different stages and there is still no cure. With current machine learning methods, different stages of the disease can be detected. Especially with deep learning-based methods, disease detection can be made sensitively. In this study, two different deep learning architectures have developed by using special block structures of ResNet and Inception architectures. These architectures have produced effective results in the detection of Alzheimer's. With the design of special block structures, the ability of different architectures to work together has been revealed. In the experimental results, it is seen that the proposed architectures produce effective results.

**Key words:** Alzheimers's disease detection, Deep learning, Inception, ResNet


#### 1. Giriş

İnsan hayatında yaş ilerledikçe buna bağlı olarak bilişsel gerileme önemli bir sağlık problemidir. Bunların başında gelen Demans (Bunama) bilişsel yetilerin günlük ve temel yaşam aktivitelerini bile yerine getirilemeyecek seviyede kaybedilmesidir. 65 yaş ve üstü insanlarda tespit edilen Demans vakalarının en az üçte ikisi Alzheimer Hastalığı (AH) türüdür. AH daha çok yaşlı insanları etkiler. Beyinde meydana getirdiği tahribatın tedavi edilmesi mümkün değildir [1]. Nörodejeneratif bir hastalık olan AH konuşma, hatırlamada güçlük, anlamada zorluk ve dikkat toplayamamak gibi bilişsel ve davranışsal yakınmalar ile başlar. İleriki aşamalarda AH etkileri kişinin başkalarının güç ve yardımı olmaksızın hayatlarını idame ettiremeyecek seviyeye ulaşır. AH'de Çok Hafif Demans, Hafif Demans, Orta dereceli Demans ve Demans olmak üzere dört evre bulunmaktadır. AH'nin belirtileri hastalık seviyesine göre değişkenlik gösterir.

AH'yi klinik olarak teşhis etmek için alanında uzman kişiler ve yüksek maliyetli bir dizi test gerekmektedir. Beyindeki yapısal ve kimyasal değişimler gözlemlenerek sağlıklı beyin ve AH'li beyin ayırt edilmektedir. Şekil 1'de sağlıklı ve AH'li beyin kesitleri verilmiştir. Beyin omurilik sıvısı tahlil yöntemi, PET (Pozitron Emisyon Tomografisi) yöntemi, plazma taramaları sayesinde ölçülebilen  $\beta$ -Amiloid molekülleri yöntemi, MRG (Manyetik Rezonans Görüntüleme) yöntemi gibi yöntemler AH teşhisi için başvurulan klinik yöntemlerdendir. Ancak uygulanabilirlik ve ulaşılabilirlik bu yöntemlerin bazı dezavantajları olarak öne çıkmaktadır [2]. AH'nin tespiti ve sınıflandırması için uzmanlar tarafından yapılan değerlendirmelere alternatif olarak tıbbi görüntüleme verileri üzerine makine öğrenmesinin alt algoritması olan derin öğrenme yöntemleri de kullanılmaktadır. BDTS (Bilgisayar destekli tespit sistemleri) olarak ön plana çıkan teknikler, alan uzmanlarına kitle tespiti için yardımcı olmaktadır [3]. Böylece matematiksel ve insan müdahalesine büyük ölçüde kapalı hastalık tespit yöntemleri

\* Sorumlu yazar: [eyup44@gmail.com](mailto:eyup44@gmail.com). Yazarların ORCID Numarası: <sup>1</sup> 0009-0004-2168-6221, <sup>2</sup> 0000-0002-5071-6790

geliştirilmiştir. Geliştirilen yöntemler ile medikal uzmanlara karar vermede katkı sunan akıllı sistemler sunulmuştur.



Şekil 1. Sağlıklı beyin ve AH'li beyin kesiti

Liu ve diğ. yapmış oldukları çalışmada yapısal MRG görüntüleri kullanarak hafif bilişsel bozukluk evresini sağlıklı bireylerden ayırt etmek için üç boyutlu derin Evrişimli Sinir Ağlarına (ESA) dayalı yeni bir model [4] önermişlerdir. Çalışmalarında % 85 doğruluk değerine ulaşmışlardır. Modellerini daha zorlu bir görev olan 12 normal bilişsel denek eklediklerinde doğruluk değerini % 62,45 olarak bulmuşlardır. Cheung ve diğ. [2] 3240 sağlıklı insan ile 648 Alzheimer hastası kişilerden aldıkları toplam 12949 retina görüntüsünü kullanarak yeni bir model geliştirmişlerdir. Önerdikleri yöntem ile Alzheimer hastalığı-demans tespitinde % 93,2 doğruluk başarı elde edilmiştir. Sathish Kumar ve diğ. [5] transfer öğrenme yöntemi uyguladıkları bir AlexNet ağı ile Açık Erişim Görüntüleme Çalışmaları Serisi (OASIS) elde ettikleri 5000 den fazla MRG verisi ile Alzheimer hastalığını hafif bilişsel bozukluk seviyesinde tespit etmeye çalışmışlardır. Önerdikleri model % 98,35 doğruluk değeri ile benzer çalışmalara göre üstün doğruluk değerine ulaşmıştır. Tian Bai ve diğ. [6] önermiş oldukları BSGAN-ADD isimli Üretken Çekişmeli Ağ (GAN) tabanlı yöntem ile ESA tabanlı mimarinin üstün yönleri kullanılarak Alzheimer hastalığını tespit etmeye çalışmışlardır. Alzheimer hastalık sınıflandırmada yeni üç bileşenli çekişmeli ağ tabanlı yöntemi önermişlerdir. Sunmuş oldukları yöntem beyin dilimi görüntü geliştirme ile ESA tabanlı Alzheimer tespit etme yöntemlerini birleştirir. BSGAN-ADD yönteminde öğrenme algoritması sınıflandırıcıdan elde ettikleri hastalık sınıfı geri bildirimlerini kullanarak, eğitim safhasında görüntüde iyileştirme yapmaktadır. Bu sayede 2 boyutlu beyin dilimi görüntüsü yeniden yapılandırma aşamasına dahil edilmiştir. Literatürde yapılmış olan diğer bir çalışma ise hiper parametre optimizasyon yöntemidir. Denetimli karşıt öğrenme ve denetimsiz karşıt öğrenme yöntemleri [7] ile Alzheimer tespitinde ortalama % 92 başarı elde edilmiştir. Çalışmalarında popüler olan derin öğrenme yöntemlerinden ResNet100 ve EfficientNetB2 mimarilerini de önermiş oldukları model ile kıyaslamada kullanmışlardır. Kong ve diğ. [8] PET ve MRG görüntülerine bir füzyon birleşme yöntemi uyguladıkları Alzheimer tespiti için yeni bir model önermişlerdir. Uyguladıkları füzyon tekniği beyinin anatomik ve metabolik verileri üzerine yoğunlaşarak verideki bozulmaları temizlemişlerdir. Tek boyutlu görüntü kullanarak sınıflandırma yapan diğer yöntemlere kıyasla önerdikleri görüntü birleştirme yöntemi ve üç boyutlu ESA ile daha başarılı sonuçlar elde etmişlerdir. Alzheimer tespiti için diğer bir yaklaşımda ise beyinin sağ ve sol hipokampus bölgelerine yoğunlaşmıştır. Bu yöntemde ön işleme adımlarından sonra 3 görüntü yaması verilen ESA mimarisi tasarlanmıştır [9]. Modelde özellik haritalarını çıkarmada ESA mimarisi tercih edilirken; sınıfların tespitinde Softmax sınıflandırıcı kullanılmıştır. Modelin eğitiminde kullanılan veri seti GARD veri tabanından alınmıştır. Yapılan çalışmanın zayıf yönü ise beyin sağ ve sol hipokampus bölgelerinin manuel bir şekilde işaretlenmesi işleminin zor ve maliyetli oluşudur. Bu eksikliğe rağmen sınıflandırmada % 90,05 doğruluk değerine ulaşılmıştır.


Bu çalışmada iki derin öğrenme mimarisi geliştirilerek ResNet ve Inception derin öğrenme model yapılarının özel blokları oluşturulmuştur. ResNet ve Inception modellerinin sadece özel blok yapılarının kullanıldığı çalışmada Alzheimer hastalığını tespit etmek için yeni bir yaklaşım geliştirilmiştir.

## 2. Materyal ve Metodoloji

Bu bölümde önerilen yöntemde kullanılan veri seti ve özel blok yapısına sahip ResNet ve Inception derin ağ mimarileri hakkında bilgiler verilmiştir. Bu mimarilerin temel özellikleri, katman yapıları ve üstün yönleri kısaca irdelenmiştir.

### 2.1. Önerilen modeller için kullanılan alzheimer veri seti

Bu çalışmada araştırmacı Sarvesh Dubey tarafından oluşturulan veri seti kullanılmıştır [9]. Veri setindeki 208×176 boyutundaki 6400 adet farklı çözünürlükte jpeg MRG verisi Kaggle veri tabanında paylaşılmıştır. Veri setine ait örnek görseller Şekil 2’de verilmiştir.



Şekil 2. Alzheimer veri seti örnek görselleri

Veri seti Alzheimer hastalığının 3 evresi olan Çok Hafif Demanslı (VMD), Hafif Demanslı (MID) ve Orta Demanslı (MOD) ile hastalık olmayan Demansız (NOD) olmak üzere 4 sınıf içermektedir. Veri tabanındaki Alzheimer hastalık sınıfları ile ilgili bilgiler Tablo 1’de verilmiştir.

Tablo 1. Veri setindeki sınıflar ve sınıflarda bulunan örnek sayıları

Sınıf	Veri sayısı	Yüzdellik oran
Demansız (NOD)	3200	50%
Çok Hafif Demanslı (VMD)	2240	35%
Hafif Demanslı (MID)	896	14%
Orta Demanslı (MOD)	64	1%
Veri Seti Toplam	6400	100%


Tablo 1’de sınıflarına ait bilgileri verilen veri seti birçok çalışmada kullanılmıştır. Bu literatür çalışmalarında derin öğrenme yöntemleri ve geleneksel yöntemler uygulanarak AH evreleri sınıflandırılmak istenmiştir. Alzheimer veri seti kullanılarak AH sınıflandırması yapılan bazı güncel çalışmalar Tablo 2’de verilmiştir.

Tablo 2. Alzheimer veri seti kullanılarak yapılmış çalışmalar

Referanslar	Yöntemler
Sharma ve diğ. [10]	Transfer öğrenme, DVM ve permütasyon tabanlı makine öğrenimi
Sharma ve diğ. [11]	Transfer öğrenme temelli Inception modeli
Zena ve diğ. [12]	Modifiye edilmiş VGG16 Modeli
Singh ve diğ. [13]	Önerilen CNN+Softmax Modeli
Toğaçar ve diğ.[14]	Geliştirilmiş VGG16 Modeli
Shu ve diğ. [7]	Denetimli ve denetimsiz karşıt (contrastive) öğrenme
liu ve diğ. [15]	ResNet+Dikkat mekanizmaları

## 2.2. ResNet mimarisi

Derin öğrenme modellerinde derinliğin artması daha fazla katmanın arka arkaya eklenmesi ile ağların daha iyi öğrenmesi hedeflenir. Ağ derinliği arttıkça doğruluk değeri doyuma ulaşarak hızla düşmeye başlar. Yakınsamayı engelleyen bu problem kaybolan/patlayan gradyan sorunudur. Bu problemin çözüm yöntemlerinden birisi de ResNet mimarisi (Artık Bağlantı) modelidir. Artık bağlantı modeli ile bir veya daha fazla katmanı atlayarak giriş verisinin, katmanlardan elde edilen çıkışla toplanması ile sonuç elde edilir. Bu sayede ileri ve geri yayılım sırasında hesaplamalarda özellik haritalarındaki bozulmaların önüne geçilmiş olur. Örnek artık bağlantı modeli deseni aşağıda Şekil 3'te verilmiştir.




Şekil 3. Artık bağlantı modeli

ResNet mimarileri katman sayısı esasına göre değişik türlere sahiptir. Örneğin ResNet50 modeli 50 katmandan oluşur. Aynı şekilde ResNet101 modeli 101 katmandan oluşmaktadır. Katmanlarda belli bir desen tekrar etmektedir [16]. ImageNet veri tabanı ile eğitilmiş olan ResNet50 mimarisi 2 tane evrişim katmanı kullanmak yerine  $1 \times 1$ ,  $3 \times 3$  ve  $1 \times 1$  şeklinde ardışık evrişim katman bulunmaktadır.

## 2.3. Inception mimarisi

Google mühendisleri tarafından geliştirilmiş olan Inception (Başlangıç) mimarileri derin öğrenme modellerindeki hesaplama karmaşıklığına ve işlem yükünün fazlalığına bir çözüm olarak geliştirilmiştir [17]. InceptionV3 mimarisi, ardışık olarak arka arkaya gelen evrişim katman yapısı kullanmak yerine Inception bloklarından oluşmaktadır [18]. Tasarlanmış olan Inception modelinde ağ yapısı modüler bir yapıdır. Farklı boyutlarda evrişim ve Max-Pooling işlemleri her modülde görülmektedir. Inception'da hesaplama maliyetini azaltılmak için her evrişim katmanından önce  $1 \times 1$  boyutunda evrişim katmanı kullanılmıştır. Temel Inception modülüne ait örnek yapı Şekil 4'te görülmektedir.



Şekil 4. Inception mimarisinin modül yapısı

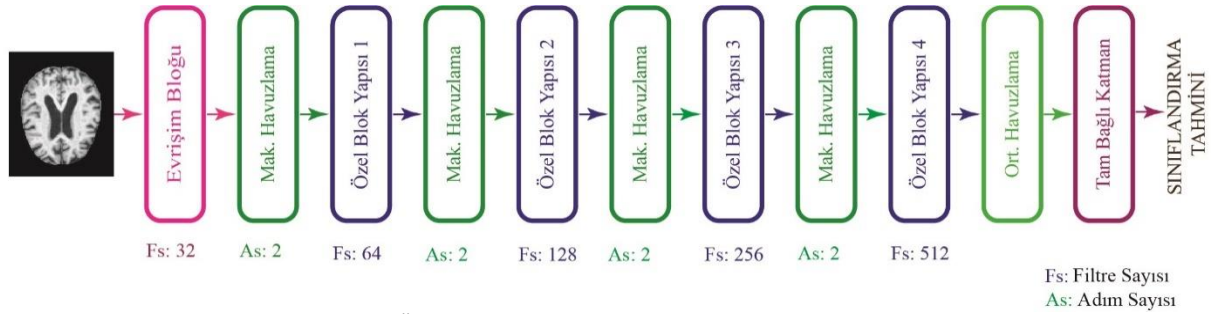
## 3. Önerilen Yöntem

Alzheimer hastalığı teşhis ve hastalık evreleri tespitinde yapılmış olan derin öğrenme tabanlı çalışmalarda; önerilen ESA mimarileri ya tamamen yeni bir mimari tasarımı yaparak ortaya çıkar, ya da mimarilerinin iyileştirilip, geliştirilmesine dayalı olarak kullanılmaktadır. Literatürde yapılmış olan çalışmalarda daha çok izlenen yol seçilmiş olan modeldeki evrişim katman yapısı, katmanların diziliş sırası ve bağlantı şekli üzerinde durulan en önemli konular arasındadır. Bunların yanında model eğitiminde kullanılmakta olan veri üzerinde verinin temsil gücü kaybı olmaksızın boyut indirgeme yöntemi de kullanılmaktadır. Ayrıca modellerin hesap

maliyetini azaltan bir mimari yapıda uygun katman yapısı kullanılarak ve bir diğer mimariyle birleştirilerek ortaya çıkan yeni mimarinin sınıflandırma doğruluk başarısını arttırması hedeflenmektedir.

Bu çalışmada önerilen model önceki bölümlerde kuramsal temelleri verilen ResNET50 mimarisindeki bağlantı deseni ve Inception V3 özel blok yapısını kullanmaktadır. Böylece farklı iki derin öğrenme modelinin özel blok yapılarının üstün yönlerinin birlikte kullanılması sağlanmıştır. Ayrıca bu mimarilerin birlikte çalışabilme yetenekleri irdelenmiştir. Mimarilerin sahip oldukları özel blok yapıları kendi içlerinde farklı evrişim, havuzlama ve bağlantı modelleri içermektedir. En az iki uygun mimarinin birlikte tasarımı ile yeni derin öğrenme mimarilerinin geliştirilmesi sağlanmıştır. Geliştirilen modelde Şekil 3'te verilen ResNET blok yapısı ve Şekil 4'te verilen Inception blok bağlantı modeli kullanılmıştır. Şekil 5'te gösterildiği gibi model klasik evrişim ve maksimum havuzlama katmanı ile başlamaktadır. Özel blok yapısı barındıran katmanlardan hemen sonra maksimum havuzlama katmanı gelmektedir. Havuzlama katmanlarında adım sayısı 2 olarak alınmıştır. Son olarak ortalama havuzlama ve tam bağlı katmandan sonra softmax sınıflandırıcı kullanılmıştır.

Önerilen yeni modelin AH tespitindeki etkinliği belirli bir veri tabanı üzerinde test edilmiştir. Geliştirilen bu farklı mimariye ait blok diyagram Şekil 5'te görülmektedir. Geliştirilen mimaride Şekil 5'teki sadece özel blok yapısı olarak adlandırılan dört kısımda ResNET ve inception V3 mimarilerin özel blok yapıları kullanılmıştır.



Şekil 5. Önerilen özel blok yapıları derin öğrenme modeli

### 3.1. Önerilen model 1: Inception-ResNet mimarisi

Önerilen modelde giriş görüntüsü klasik evrişim katmanından geçirildikten sonra Şekil 5'te verilen mimaride Özel Blok Yapısı-1 ve Özel Blok Yapısı-2 için Inception bağlantı modeli kullanılmıştır. Alzheimer verisi bu iki katmandan geçtikten sonra maksimum havuzlama işlemine tabi tutulmuştur. Özel Blok Yapısı-3 ve Özel Blok Yapısı-4'te ise ResNet50 bağlantı modeli tercih edilmiştir. Özel Blok Yapısı-4'ten sonra önceki katmanlardan farklı olarak ortalama havuzlama işlemi uygulanmıştır. Modelin sınıflandırma başarısını arttırmak için softmax sınıflandırıcı ile veriler sınıflandırılmıştır.

Önerilen bu model ile Inception mimarisindeki farklı boyutlardaki evrişim filtrelerinin olduğu özel blok yapısının ağırlık katmanlarında kullanılması ve veriyi soyutlaştırırken sınıflandırma performansına olan etkileri incelenmiştir. Şekil 4'te görüleceği üzere, ilk evrişim bloğu geleneksel evrişim yaptıktan sonra hemen devamında Özel Blok Yapısı-1 ve Özel Blok Yapısı-2 içerisindeki Inception bloklarına veriyi iletmektedir. Inception bağlantı modeli ile verinin aşırı soyutlaştırılması önlenmeye çalışılmıştır. Böylece MRG verisindeki hastalığa ait ayırt edici bilgilerin kaybolması engellenmiştir. Daha sonraki ResNet bloklarına yüksek özellik düzeyli MRG verisi iletilmiştir. ResNet ise artık bağlantılar evrişim işleminin aşırı soyutlama yapmasını kısıtlamıştır. Geliştirilen bu model ile her iki özel blok yapısının birlikte çalışma parametreleri ve davranışları somut şekilde irdelenebilmiştir.

### 3.2. Önerilen model 2: ResNet- Inception mimarisi

Önerilen ikinci modelde ResNet50 ve InceptionV3 bağlantı bloklarının Alzheimer sınıflandırma başarısı üzerindeki etkileri gözlemlenmiştir. Bunun için model 1'de önerilen özel blok yapılarının sıralamasının tersine; Özel Blok Yapısı-1 ve Özel Blok Yapısı-2 için ResNet50 bağlantı modeli, Özel Blok Yapısı-3 ve Özel Blok Yapısı-4'te ise Inception bağlantı modeli kullanılarak blok yapılarının yerleri değiştirilmiştir. Burada amaç ağırlık katmanlarında ResNet mimarisinin aşırı soyutlama ve gradyan kaybına sebep olup olmadığını gözlemlenmesidir. ResNet mimarisi artık bağlantı modeli ile verideki bilgi kaybını minimuma indirmiştir. Böylece gerçek giriş verisindeki ayırt edici bilgiler korunmuştur. Özel Blok 3 ve Özel Blok 4 ise Inception modeli ile ResNet özellikleri farklı sayı ve boyutta evrişim işlemlerinden geçirilerek yüksek seviyeli özellik

vektörleri hesaplanmıştır. Bu modelde kabul edilebilir sonuçlar elde edilmiştir. Dolayısıyla derin öğrenme modellerinin blok yapısı bağlamında birlikte kullanımlarının optimal maliyetler ile iyi sonuçlar üretecekleri anlaşılmıştır.

#### 4. Deneysel Sonuçlar ve Tartışma

Önerilen model Python programlama dilinde geliştirilen tensorflow kütüphanesi kullanılarak test edilmiştir. Tüm çalışmalar intel i7 işlemci, 32 GB Ram RTX 3080 ekran kartına sahip bir bilgisayarda yürütülmüştür. Geliştirilen iki model hem kendi aralarında hem de literatürdeki ResNet50 [16], ResNet101 [20], InceptionV3 [17], VGG16 [21], VGG19 [21] ve MobileNet [22] derin öğrenme mimarileri ile karşılaştırılmıştır. Böylece hem modellerin birbirlerine olan üstünlükleri hem de mevcut diğer yöntemlere olan güçlü/zayıf yönleri irdelenebilmiştir. Karşılaştırma metrikleri olarak F1-skor, sınıflandırma doğruluğu, duyarlılık ve hassasiyet kullanılmıştır.

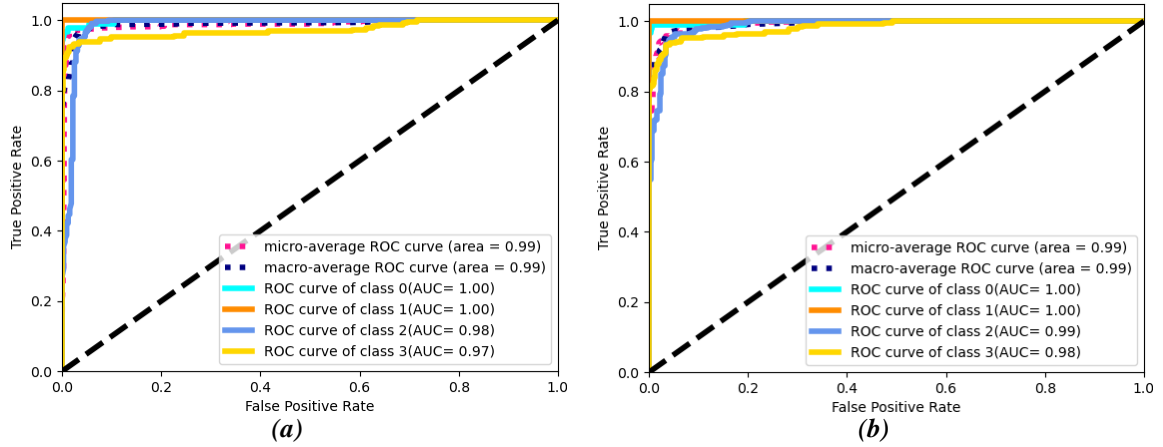
Geliştirilen modeller hem güncel akademik çalışmalar ile hem de bilinen derin öğrenme kütüphanelerinin orijinal mimarileri ile karşılaştırılmıştır. Tablo 3'te bu çalışmada kullanılan Alzheimer veri seti kullanılarak geliştirilen güncel 7 çalışma ile önerilen iki model karşılaştırılmıştır. Bazı çalışmalar önerilen iki modele göre daha iyi sonuçlar elde ederken bazıları ise daha kötü sonuçlar üretmişlerdir. [13] [14] ve [15] referans numaralı çalışmalar mevcut derin öğrenme mimarilerine oldukça güçlü katman güncellemesi yaptıkları için çok yüksek sonuçlara ulaşmışlardır. VGG16 modelinin evrişim ve diğer katman bileşenleri modifiye edilip güçlendirilerek çok başarılı sonuçlara ulaşılmıştır. Önerilen iki model ise bu modellere göre daha az derinlikte ve daha sade bir mimaridedir. Bu durum ağın öğrenme kabiliyetini etkilemiştir. Ancak farklı mimarilerin birlikte çalışma performanslarının gözlemlenmesine katkı sunulmuştur. Ayrıca sadece bir mimarinin özel blok yapısı alınarak farklı bir derin öğrenme metodolojisi sunulmuştur. Sınıflandırma sonuçları incelendiğinde önerilen iki modelin hibrit öğrenme mimarisi tasarımlarının umut verici olduklarını ortaya koymuştur.

**Tablo 3.** Önerilen modellerin ve diğer çalışmaların sınıflandırma sonuçlarının karşılaştırılması

Referanslar	Yöntemler	F1-skoru (%)	Doğruluk (%)
Sharma ve diğ. [10]	Transfer öğrenme, DVM ve permütasyon tabanlı makine öğrenimi	90,25	91,75
Sharma ve diğ. [11]	Transfer öğrenme temelli Inception modeli	94,75	94,92
Zena ve diğ. [12]	Modifiye edilmiş VGG16 Modeli	98	97,625
Singh ve diğ. [13]	Önerilen CNN+Softmax Modeli	97	98,59
Toğaçar ve diğ. [14]	Geliştirilmiş VGG16 Modeli	–	99,94
Shu ve diğ. [7]	Denetimli ve denetimsiz karşıt (contrastive) öğrenme	73	92
liu ve diğ. [15]	ResNet+Dikkat mekanizmaları	95	96,25
Önerilen Model 1	Inception-ResNet Mimarisi	95,76	95,78
Önerilen Model 2	ResNet- Inception Mimarisi	93,8	93,75

Önerilen Model 1, Model 2'ye göre daha iyi sınıflandırma sonuçları elde etmiştir. Elde edilen sonuçlar Tablo 3'te görülmektedir. Geliştirilen mimaride ağın ilk katmanlarında Inception blok yapılarının kullanılması daha yüksek sonuçlar üretmiştir. Inception blok yapısındaki dahili evrişim ve havuzlama katmanları Alzheimer verisi ile uyumlu çalışmıştır. Verinin ayırt edici özelliklerini çıkartabilmiştir. Bu özellikleri alan Özel Blok 3 ve Özel Blok 4'teki ResNet blokları ise aşırı soyutlama yapmadan özellikleri koruyabilmiş ve sınıflandırıcı katmanına iletmıştır.

Model 1 ile Inception-ResNet mimari tasarımı yapılarak ağa giren görüntü verisinin Inception bloklarında aşırı soyutlamaya uğraması ve veride bilgi kaybı oluşması engellenmiştir. Böylece ağın daha kararlı şekilde hata değerini azaltması ve öğrenme ağırlıklarını elde etmesi sağlanmıştır. Evrişim ve havuzlama işlemlerinin boyutları ve sayısının ayarlanması ile Alzheimer verilerindeki hastalık tespitini sağlayan piksel bölgelerinin özellikleri çıkartılabilmektedir. Bu nedenle model 2 ye göre daha iyi bir sınıflandırma elde edilebilmiştir. Önerilen iki model ile Alzheimer hastalık tespitinde geniş bir şekilde kullanılan mevcut veri tabanında etkin sonuçlar üretilmiştir. Bu iki modele ait ROC eğrileri Şekil 6'da verilmiştir.



**Şekil 6.** (a) Önerilen Model 1'e ait ROC eğrisi grafiği ve (b) Önerilen Model 2'ye ait ROC eğrisi grafiği

Önerilen Model 1 en iyi sonuçlara sahipken, önerilen Model 2 ise en iyi dördüncü sonuçlara sahiptir. Diğer altı literatür yönteminin aksine, önerilen her iki model sadece belirli özel blok yapıları içermektedir. Önerilen iki modeldeki ağların boyutları ve karmaşıklıkları diğer altı modele göre çok daha kabul edilebilir boyutlardadır. Tablo 4'ten de görüleceği üzere, güçlü modeller olan ResNet101, VGG16, VGG19 ve MobileNet modelleri her iki modele göre daha düşük sonuçlara sahiptirler. Önerilen modeller belirli blok yapıları ile özellikle aşırı soyutlama ve kaybolan gradyan problemlerine neden olmayacak şekilde tasarlanmışlardır. Böylece hem ağırlık boyutu sınırlı tutulmuş hem de güçlü modellerin birlikte çalışma yetenekleri ortaya çıkartılmıştır. Tablo 4'te ise geliştirilen iki modelin literatürdeki altı farklı derin öğrenme modeli ile karşılaştırmaları verilmiştir.

**Tablo 4.** Önerilen modeller ile güncel modellerinin sınıflandırma sonuçları

Model	Doğruluk (accuracy)	Hassasiyet (precision)	Duyarlılık (recall)	F1-Skoru
Önerilen Model 1	95,78	95,93	95,78	95,76
ResNet50	94,69	94,93	94,69	94,61
InceptionV3	94,06	94,13	94,06	94,08
Önerilen Model 2	93,75	94,03	93,75	93,8
ResNet101	93,12	93,26	93,12	93,09
VGG16	89,84	89,88	89,84	89,86
MobileNet	77,5	78,38	77,5	76,87
VGG19	50	25	50	33,33

## 5. Sonuç

Bu çalışmada Alzheimer hastalığını tespit etmek için ResNet ve Inception derin öğrenme modellerinin sahip oldukları özel blok yapılarını birlikte kullanan iki derin öğrenme mimarisi geliştirilmiştir. Her iki mimaride dört farklı özel blok yapısı tasarlanarak bu bloklarda ResNet ve Inception modellerinin sadece özel blok yapıları kullanılmıştır. Böylece farklı mimarilerin birlikte çalışma yetenekleri gözlemlenmiştir. Mimarilerin üstün yönlerinin birlikte kullanılması ile yüksek doğrulukta sonuçlar elde edilmiştir. Elde edilen sonuçlar farklı değerlendirme metrikleri ile karşılaştırılmıştır. Literatürdeki güncel derin öğrenme mimarileri ile yapılan karşılaştırmalarda önerilen modellerin Alzheimer hastalık tespitinde kullanılabileceğini göstermiştir.

Gelecekte yapılacak çalışmalar ile farklı özel blok yapılarını içeren daha az parametrelili ve daha hızlı çalışabilen esnek mimariler geliştirilmesi planlanmaktadır.



### Kaynaklar

- [1] Kumar A, Sidhu J, Goyal A, Tsao JW. Alzheimer Disease, StatPearls Publ, 2018; 1–27.
- [2] Cheung, CY, Ran, AR, Wang S, Chan, VTT, Sham K, Hilal S, Venketasubramanian N, Cheng CY, ve diğerleri. A deep learning model for detection of Alzheimer’s disease based on retinal photographs: a retrospective, multicentre case-control study. *The Lancet Digital Health* 2022; 4(11): 806–815.
- [3] Ari A, Alpaslan N, Hanbay D. Beyin MR görüntülerinden bilgisayar destekli tümör teşhisi sistemi. *Med Technol Natl Conf*; 15-18 Ekim 2015; Muğla, Türkiye. 1-4.
- [4] Liu S, Masurkar AV, Rusinek H, Chen J, Zhang B, Zhu W, Fernandez-Granda C, Razavian N. Generalizable deep learning model for early Alzheimer’s disease detection from structural MRIs. *Sci Rep* 2022; 12(1): 1–12.
- [5] Sathish K. L, Hariharasitaraman S, Narayanasamy K, Thinakaran K, Mahalakshmi J, Pandimurugan V. AlexNet approach for early stage Alzheimer’s disease detection from MRI brain images. *Mater Today Proc* 2021; 51: 58–65.
- [6] Bai T, Du M, Zhang L, Ren L, Ruan L, Yang Y, Qian G, Meng Z, ve diğerleri. A novel Alzheimer’s disease detection approach using GAN-based brain slice image enhancement. *Neural Comput.* 2022; 492: 353–369.
- [7] Shu F, Tian L. Deep Learning Methods for Alzheimer’s Disease Prediction. In *CS230: Deep Learn*, 2018, Stanford University. 1-10.
- [8] Kong Z, Zhang M, Zhu W, Yi Y, Wang T, Zhang B. Multi-modal data Alzheimer’s disease detection based on 3D convolution. *Biomed. Signal Process Control* 2022; 75: 1-8.
- [9] Ahmed S, Choi KY, Lee JJ, Kim BC, Kwon GR, Lee KH, Jung HY. Ensembles of Patch-Based Classifiers for Diagnosis of Alzheimer Diseases. *IEEE Access* 2019; 7: 73373–73383.
- [10] Dubey S. "Alzheimer’s Dataset four class of Images" <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images>, 2020.
- [11] Sharma S, Gupta S, Gupta D, Altameem A, Saudagar AKJ, Poonia RC, Nayak SR. HTLML: Hybrid AI Based Model for Detection of Alzheimer’s Disease. *Diagn* 2022; 12(8): 1-16.
- [12] Sharma S, Gupta S, Gupta D, Juneja S, Mahmoud A, El-Sappagh S, Kwak KS. Transfer learning-based modified inception model for the diagnosis of Alzheimer’s disease. *Front. Comput. Neurosci.* 2022; 16: 1-13.
- [13] Zena JI, Lucky E, Ellaine CG, Edbert IS, Suhartono D. Deep Learning Approach based Classification of Alzheimer’s Disease Using Brain MRI. 5th Int. Semin. Res of Inf Technol Intell Syst (ISRITI); 08-09 December 2022; Yogyakarta, Indonesia. 397–402.
- [14] Singh P, Mishra SK. (2022). Alzheimer’s detection and categorization using a deep-learning approach. 3rd Int Conf on Intell Comput, Instrum Control Technol: Comput Intell for Smart Syst. ICICICT; 11-12 August 2022; Kerala India. 727–734.
- [15] Toğaçar M, Cömert Z, Ergen B. Enhancing of dataset using DeepDream, fuzzy color image enhancement and hypercolumn techniques to detection of the Alzheimer’s disease stages by deep learning model. *Neural Comput Appl* 2021; 33(16): 9877–9889.
- [16] Liu Y, Tang K, Cai W, Chen A, Zhou G, Li L, Liu R. MPC-STANet: alzheimer’s disease recognition method based on multiple phantom convolution and spatial transformation attention mechanism. *Front Aging Neurosci* 2022; 14: 1-15.
- [17] He K, Zhang X, Ren, S, Sun, J. Deep residual learning for image recognition. *Proceedings of the IEEE Comput Soc Conf Comput Vision Pattern Recognit*; 2016; Las Vegas, NV, USA. 770–778.
- [18] Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the Inception Architecture for Computer Vision. *Proceedings of the IEEE Comput Soc Conf Comput Vision and Pattern Recognit*; 2016; Las Vegas, NV, USA. 2818–2826.
- [19] Üzen H, Türkoğlu M, Arı A, Hanbay D. Piksel seviyesinde yüzey hata tespiti için InceptionV3 tabanlı zenginleştirilmiş öznetelik entegrasyon ağ mimarisi. *J Faculty Eng Architect Gazi Univ* 2022; 38(2): 721–732.
- [20] Rao Y, He L, Zhu J. A residual convolutional neural network for pan-sharpening. *Int. Workshop on Remote Sens Intell Process*; 18-21 May 2017; Shanghai, China. 1-4.
- [21] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. 3rd Int Conf Learn Representations; 2015; 1-14.
- [22] Howard AG, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, Andreetto M, Adam H. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *Proceedings of the IEEE Comput Soc Conf Comput Vision and Pattern Recognit*; 2017; Honolulu, Hawaii: 1-9.