



# Senkrosıkıştırma dönüşümü ve derin transfer öğrenimi ile Alzheimer hastalığının EEG tabanlı otomatik tespiti

## *EEG-based automated detection of Alzheimer's disease by synchrosqueezing transform and deep transfer learning*

Hasan Polat<sup>1\*</sup>

<sup>1</sup> Bingöl Üniversitesi, Elektrik ve Enerji Bölümü, [hasanpolat@bingol.edu.tr](mailto:hasanpolat@bingol.edu.tr)

ORCID: <https://orcid.org/0000-0001-5535-4832>

### MAKALE BİLGİLERİ

#### Makale Geçmişi:

Geliş 1 Şubat 2023  
Revizyon 2 Mart 2023  
Kabul 3 Mart 2023  
Online 23 Mart 2023

#### Anahtar Kelimeler:

*Alzheimer hastalığı, Derin öğrenme, EEG, Senkrosıkıştırma, Sınıflandırma, Transfer öğrenimi*

### ÖZ

Alzheimer hastalığı, demansın en sık görülen türü olan ilerleyici bir nörodejeneratif bozukluktur. Hafıza kaybı, bilişsel kabiliyetlerde azalma ve davranışsal sorunlara yol açarak, günlük yaşamı derinden etkilemektedir. Hastalıkla mücadelede en önemli adımlardan biri hızlı ve doğru tanının konmasıdır. Dolayısıyla, bilgisayar destekli tanı sistemlerinin histopatolojik analizlere alternatif olarak geliştirilmesi önem arz etmektedir. Bu çalışmada, Alzheimer hastalığının otomatik olarak tespitinde EEG tabanlı bir sınıflandırma modeli tanıtılmıştır. Önerilen model EEG senkrosıkıştırma temsillerinin çeşitli uyarlanmış ön eğitilmiş derin evrişimsel sinir ağı mimariler ile sınıflandırılmasından oluşmaktadır. Senkrosıkıştırma yöntemi, EEG işaretlerini zamanla değişen salınım özelliklerine sahip görüntü örüntülerine dönüştürmek için kullanılmıştır. Akabinde ise EEG görüntüleri ön eğitilmiş SqueezeNet, ResNet, InceptionV3 ve MobileNet derin mimarilerine girdi olarak sunulmuş ve elde edilen sınıflandırma performansları karşılaştırılmıştır. Deneyler, 19 elektrottan (Fp1, Fp2, Fz, F3, F4, F7, F8, Cz, C3, C4, T3, T4, Pz, P3, P4, T5, T6, O1 ve O2) kayıt edilen EEG işaretlerinin her biri için ayrı ayrı uygulanmıştır. Bulgular P3 ve T5 kanallarının Alzheimer tespitinde en etkin serebral konumlar olduğunu ve en iyi sınıflandırma doğruluğunun InceptionV3 modeli ile elde edildiğini göstermiştir. InceptionV3 modeli ile her iki kanal için sınıflandırma doğrulukları sırasıyla %89.50 ve %90.57 olarak elde edilmiştir. Ayrıca serebral korteksteki elektriksel aktivitelerin hastalığa ilişkin karakteristik dinamikleri en belirgin olarak parietal ve temporal loblarda yansıtıldığı gözlemlenmiştir.

### ARTICLE INFO

#### Article history:

Received 1 February 2023  
Received in revised form 2 March 2023  
Accepted 3 March 2023  
Available online 23 March 2023

#### Keywords:

*Alzheimer's disease, Deep learning, EEG, Synchrosqueezing, Classification, Transfer learning.*

Doi: [10.24012/dumf.1246052](https://doi.org/10.24012/dumf.1246052)

\* Sorumlu Yazar

### ABSTRACT

Alzheimer's disease is a progressive neurodegenerative disorder that is the most common type of dementia. It profoundly affects daily life by causing memory loss, decreased cognitive abilities, and behavioral problems. In the fight against the disease, one of the most important steps is to make a rapid and accurate diagnosis. Therefore, it is crucial to develop computer-aided diagnosis systems as an alternative to histopathological analyzes. In this paper, an EEG-based classification model was introduced for the automatic detection of Alzheimer's disease. The proposed model is based on classifying EEG synchrosqueezing representations by various fine-tuned pretrained convolutional neural networks. The synchrosqueezing technique was used for converting EEG signals to image pattern that contains components with time-varying oscillatory characteristics. Then, EEG images were presented as input to the pre-trained deep architectures, including SqueezeNet, ResNet, InceptionV3, and MobileNet, and the classification performances obtained were compared. Experiments were performed separately for each of the EEG signals recorded from the 19 scalp electrodes (Fp1, Fp2, Fz, F3, F4, F7, F8, Cz, C3, C4, T3, T4, Pz, P3, P4, T5, T6, O1, and O2). The results showed that P3 and T5 channels are the most efficient cerebral regions for Alzheimer's detection and InceptionV3 revealed the best performance. The pre-trained InceptionV3 model achieved classification accuracies for both channels as 89.50% and 90.57%, respectively. In addition, it has been observed that the electrical activities in the cerebral cortex reflect characteristic dynamics of the disease most prominently in the parietal and temporal lobes.

## Giriş

Alzheimer hastalığı, demansın ana nedenlerinden biri olan nörolojik bir bozukluktur. Dünya üzerinde yaklaşık olarak 25 milyon insan bu hastalıktan mustarıdır [1]. Alzheimer hastalığı ile birlikte vuku bulan en yaygın semptomlar; dikkat eksikliği, hafıza kaybı ve dil becerileri gibi bilişsel kabiliyetlerde bozulmalar şeklinde kendini göstermektedir [2]. Hastalığın kesin tanısı ancak histopatolojik analizlerle mümkün olduğundan, çeşitli alternatif biyolojik markerlerin referans alınması ile tanıyı destekleyici sistemlerin geliştirilmesi önem arz etmektedir. Sistemlerin geliştirilmesinde invaziv olmayan tekniklerin uygulanması tercih edilmektedir. Bu kapsamda, beyin görüntüleme yöntemlerinden manyetik rezonans görüntüleme (MRI) ve elektroensefalografi (EEG) sıklıkla başvurulan tekniklerdir [3].

Beyin görüntüleme yöntemleri özellikle nörolojik hastalıklara ilişkin dinamiklerin irdelenmesinde yaygın bir şekilde uygulanmaktadır. Beynin karmaşık olan yapısında hastalıkla birlikte meydana gelen spesifik değişimler beyin görüntüleme yöntemleri ile etkin bir şekilde yansıtılabilir [4]. EEG yönteminin düşük maliyetli oluşu, hızlı bir şekilde erişilebilirliği ve yüksek temporal çözünürlük sunması diğer yöntemlere kıyasla daha popüler bir yaklaşım olmasında esas etkenlerdir [5]. EEG yöntemi ile beyin içerisinde gerçekleşen sinaptik aktiviteler saçlı deriden kayıt edilerek, hastalığın beyin içerisinde etkileri yorumlanabilir. Böylelikle, olası demans tanısının henüz kesinlik kazanmadığı durumlarda hekimler tarafından alternatif tanı yöntemlerinin önü açılabilir [6]. EEG işaretlerindeki salınımların yavaşlaması ve karmaşıklık düzeyinde azalmalar Alzheimer hastalığının neden olduğu en belirgin örüntülerdir [2]. Ancak, EEG işaretlerinin görsel olarak irdelenmesi zaman alıcı olmakla birlikte hata yapma potansiyelini artırır [7]. Manuel analizlere ilişkin söz konusu handikaplar, bilgisayar destekli analizleri elzem kılmaktadır. Bilgisayar destekli tanı sistemlerince ham EEG kayıtlarından hastalığa ilişkin karakteristik özelliklerin tespiti, otomatik ve doğru bir şekilde sağlanabilir. Böylelikle, hastalığın erken veya ilerleyen fazlarında hekimler tarafından yapılacak daha isabetli teşhislerin önü açılabilir.

Literatürde çeşitli makine öğrenimi yaklaşımları kullanarak Alzheimer hastalığının otomatik olarak tanı ve takibi için çok sayıda bilgisayar destekli tanı sistemlerinin geliştirildiği görülebilmektedir. Bu kapsamda önerilen başarılı modeller, konvansiyonel ve derin öğrenme tabanlı olarak kategorize edilebilir. Konvansiyonel modeller, EEG işaretlerinden hastalığa ilişkin ayırt edici özelliklerin manuel olarak ayıklanmasını ve çıkarılan özelliklerin temel sınıflandırıcı algoritmalar ile sınıflandırılmasından oluşmaktadır. EEG işaretlerinden anlamlı özelliklerin çıkarılmasında dalgacık dönüşümü tabanlı yöntemler [8], çeşitli spektral yaklaşımlar [9], [10] ve karmaşıklık analizi [3], [11] başvurulan başlıca tekniklerdir. Sınıflandırıcı algoritma olarak ise çoğunlukla destek vektör makineleri (DVM), k-en yakın komşu algoritması (KNN) ve lineer diskriminant analiz (LDA) gibi araçların kullanıldığı görülebilmektedir. Son yıllarda görüntü işleme, nesne algılama ve ses işaretlerinin analizi gibi birçok alanda büyük bir atılım gösteren derin öğrenme mimarilerinden Alzheimer hastalığının otomatik olarak

tanısında da istifade edilmiştir. Ham verilerden hastalıklara özgü karakteristik özelliklerin otomatik olarak çıkarılması, derin öğrenme mimarilerini güçlü ve popüler kılan en önemli kabiliyettir. Bu çalışmalarda öncelikle, EEG işaretleri görüntü matrisleri olarak yeniden temsil edilmeye çalışılmıştır. Bu kapsamda, İsmail ve ark. [12] EEG işaretlerinin görüntü formuna dönüştürülmesinde elektrot konumlarını ve alt frekans bilgilerini kullanmışlardır. Elde edilen görüntü matrisleri ESA mimarisi kullanılarak sınıflandırılmıştır. Rodrigues ve ark. [7] Granger nedensellik, Pearson korelasyonu ve Spearman korelasyon tekniklerini kullanarak EEG işaretlerini matris bağlantıları olarak görüntü formuna dönüştürmüşlerdir. Çok boyutlu EEG örüntüleri basit bir ESA modeli girişine verilerek, önerilen modelin Alzheimer tanısında sunmuş olduğu başarı gözlemlenmiştir. Son olarak, Polat [13] yeni bir zaman-frekans karmaşıklık temsil yöntemi önererek, çok boyutlu karmaşıklık haritalarından EEG tabanlı Alzheimer tespit modeli önermiştir. Mevcut çalışmalarda, derin öğrenme tabanlı yaklaşımların genel olarak klasik yöntemlere kıyasla önemli performans iyileştirmeleri sundukları rapor edilmiştir [14].

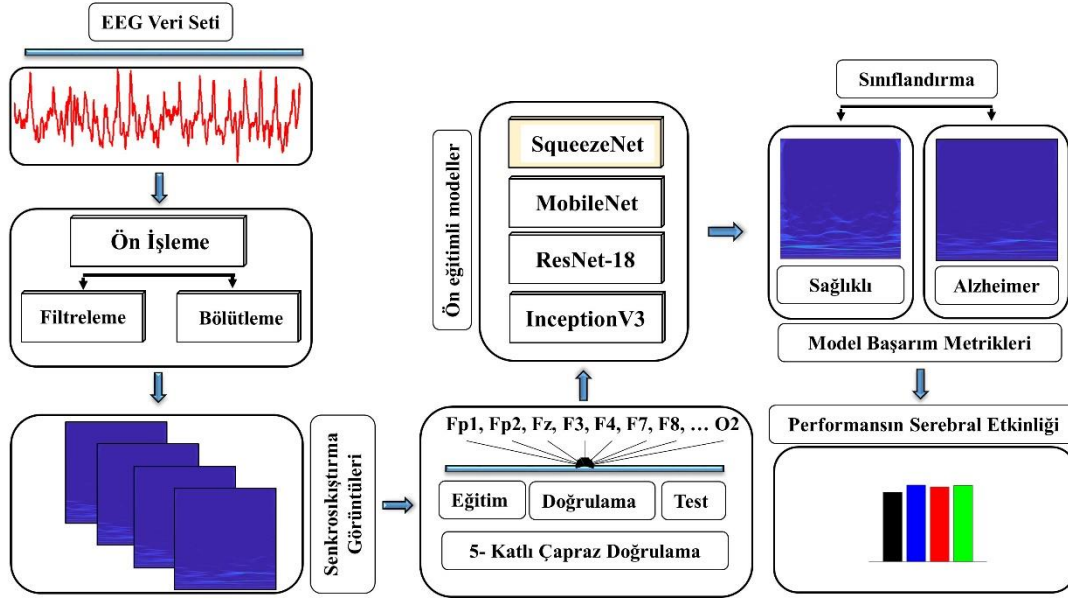
Bu çalışmada EEG işaretlerinden Alzheimer hastalığının tespiti amaçlanmıştır. Derin öğrenme mimarilerinin görüntü işleme üzerindeki üstün kabiliyetlerinden etkin şekilde istifade etmek için bir boyutlu zaman serileri olan EEG işaretleri, boyutları artırılarak görüntü matrislerine dönüştürülmüştür. EEG işaretlerine dalgacık tabanlı senkrosıkıştırma yöntemi uygulanarak, çok boyutlu yeni serebral aktivite temsilleri elde edilmiştir. Derin öğrenme yaklaşımları olarak, görsel nesne tanıma modellerinin geliştirilmesi kapsamında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) [15] için geliştirilen başarılı modellerin probleme özgü uyarlanmış modifikasyonları kullanılmıştır. Böylelikle, derin öğrenme mimarilerinin etkin bir şekilde eğitimi için gereken büyük ölçekli veri seti eksikliği dezavantajının üstesinden gelinmesi amaçlanmıştır. Ayrıca, beyin içerisinde hastalığa özgü aktivitelerin EEG üzerine yansımaları kapsamlı olarak irdelenerek, tanı sistemi için en verimli elektrot konumları ve hastalığın belirgin şekilde ayırt edilebildiği beyin lobları belirlenmiştir.

## Materyal ve metod

Bu çalışmada çok boyutlu EEG senkrosıkıştırma temsillerinden Alzheimer hastalığının serebral lob etkinliği ve tespiti amaçlanmıştır. Belirlenen amaçlar doğrultusunda uygulanan sınıflandırma çerçevesinin çekirdek yapıları ve kullanılan EEG verilerine ilişkin detaylar bu bölümde açıklanmaktadır. Önerilen EEG tabanlı otomatik tanı modelinin genel çerçevesi Şekil 1’de tasvir edilmektedir.

### Alzheimer veri Seti

EEG verileri Florida Üniversitesi araştırmacıları tarafından belirli bir paradigma doğrultusunda kayıt edilerek ve kamuya açık bir şekilde erişime sunulmuştur [16]. EEG kayıtlarının alınması, gözler açık ve kapalı olmak üzere iki farklı dinlenme durumunu içeren paradigmlar olarak yürütülmüştür. EEG kayıtları saçlı deri üzerine uluslararası 10-20 konumlandırma sistemi göre yerleştirilen 19 elektrottan (Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 ve O2) alınmıştır [2].



Şekil 1. Önerilen EEG tabanlı otomatik tanı ve değerlendirme modelinin genel çerçevesi

Elektrot etiketlerinde yer alan F, T, C, P ve O harfleri sırasıyla frontal, temporal, santral, parietal ve oksipital lobları ifade etmektedir. EEG kayıtları sağlıklı ve hasta olmak üzere iki gruba ayrıştırılmıştır. Sağlıklı grup, yaş ortalaması  $72 \pm 11$  olan ve daha önce herhangi bir nörolojik rahatsızlık öyküsü bulunmayan 12'sinin gözleri açık ve 12'sin gözleri kapalı olarak EEG kayıtları alınmış toplam 24 katılımcıdan oluşmaktadır. Hasta grup ise Ulusal Nörolojik ve İletişimsel Bozukluklar ve İnme Enstitüsü, Alzheimer Hastalığı ve İlişkili Bozukluklar Derneği (NINCDS ADRDA) kriterlerine uygun olarak Alzheimer tanısı konmuş, ortalama yaşları  $69 \pm 16$  olan 12'sinin gözleri açık ve 12'sin gözleri kapalı olarak EEG kayıtları alınmış 24 bireyden oluşmaktadır [7]. Her iki grupta yer alan bireylere ilişkin sekiz saniyelik EEG kayıtları, örnekleme hızı 128 Hz olarak bilgisayar ortamına aktarılmıştır.

### EEG işaretlerinin ön işlenmesi

EEG kayıtları göz hareketleri, kas hareketleri ve şebeke gürültüsünden kaynaklanan çeşitli artefaktlardan sıklıkla etkilenmektedir. Söz konusu girişimler, EEG kayıtlarının düşük sinyal gürültü oranına (SNR) sahip olmalarına yol açmaktadır. Bu çalışmada, EEG işaretleri Notch filtre kullanılarak 60 Hz şebeke frekansından arındırılmıştır. EEG işaretlerinden doğru akım (offset) gürültüsünün arındırılması ve önemli alt bantların elde edilmesi için 4. dereceden bant geçiren Butterworth filtresi uygulanmıştır.

Alzheimer hastalığının EEG görüntüleme yöntemi ile analizinde literatürde çoğunlukla 2 saniyelik dönemlerin dikkate alındığı görülmektedir [17]. Bu çalışmada önerilen EEG tabanlı otomatik tanı modeli için 2 saniyelik bölütlerin (epoch) kullanılması uygun bulunmuştur. Böylelikle, her bir katılımcı için sekiz saniyelik kayıtlarından dört EEG bölütü elde edilmiştir. Bölütleme işlemi sonucunda veri seti boyutu dört kat artırılarak, her bir EEG kanalı için 96 sağlıklı ve 96 hasta olmak üzere toplam 192 örüntü dikkate alınmıştır.

### Senkrosıkıştırma yöntemi

Senkrosıkıştırma dönüşümü (SSD) salınım karakteristikleri zamanla değişen çok bileşenli sinyaller için kullanışlı bir zaman-frekans analizi yöntemidir [18]. Birçok farklı uygulama için sinyallerin zamanla değişen spektral özellikleri önem taşımaktadır [19]. Bu kapsamda, kısa zaman Fourier dönüşümü (KZFD), sürekli dalgacık dönüşümü (SDD), Wigner-Ville dağılımı (WVD) gibi çeşitli zaman-frekans analiz yöntemleri ön plana çıkmaktadır. Önerilen yöntemlerdeki lineer kaynaklı kısıtlamalar senkrosıkıştırma fikrini ortaya çıkarmıştır. SSD tekniği kullanılarak bir zaman-frekans temsil modülünden anlık frekans tahmininin yapılması ile yeniden zaman-frekans temsiline düzenlenmesi gerçekleştirilebilir. Böylelikle, SDD ve KZFD yöntemlerindeki mevcut lineer kısıtlamaların üstesinden gelinebilir. Dalgacık senkrosıkıştırma tekniği SDD ile yürütülen süreci devam ettirerek, lokalize zaman-frekans temsillerini sunmaktadır. Örnek olarak, sayısız bilimsel ve mühendislik uygulamaları için genel bir form olan  $x(t)$  sinyali aşağıdaki Eşitlik 1'deki gibi ifade edilebilir.


$$x(t) = \sum_{k=1}^k x_k(t) + e(t) \quad (1)$$

Burada her bir  $x(t)$  bileşeni  $x_k(t) = A_k(t) \cos(2\pi\phi_k(t))$  muhtemelen zamanla değişen genlik ve frekans ile Fourier benzeri bir salınım modudur.  $e(t)$  ise gürültü veya ölçüm hatasını temsil etmektedir. SSD yöntemi her bir  $k$  değeri için genlik ( $A_k(t)$ ) ve anlık frekansın ( $\phi_k(t)$ ) elde edilme işlemidir. İşlem üç adımla neticelendirilir. İlk olarak  $x(t)$  sinyalinin sürekli dalgacık dönüşümü alınır. SDD yönteminin matematiksel ifadesi Eşitlik 2'de verilmiştir.

$$W_x(a, b) = \int a^{-1/2} \psi\left(\frac{t-b}{a}\right) x(t) dt \quad (2)$$

Burada a ve b sırasıyla ölçekleme ve öteleme parametrelerini,  $W_x(a, b)$  ise SDD fonksiyonunu ifade eder.

SDD yöntemi ile elde edilen zaman-frekans temsillerinin başlangıç değerleri tahmin edilir. Akabinde ise tahmin edilen başlangıç değerleri yeniden atanma yöntemi ile  $W_x(a, b)$  'i sıkıştırmak için yeniden kullanılır [19]. Bu çalışmada, ilk etap olan başlangıç değerlerinin tahmininde Morlet dalgacığı kullanılmıştır. Analizlerin uyguladığı Matlab programlama ortamı tarafından söz konusu dalgacığının otomatik olarak etkin olduğu varsayılmıştır. Şekil 2'de sağlıklı ve hasta bireylerden alınan ham EEG kayıtlarından senkrosıkıştırma yöntemi uygulanarak elde edilen zaman-frekans temsilleri gösterilmektedir. Bir boyutlu sinyallerden 420x560x3 boyutunda oluşturulan görüntüler sırasıyla 224x224x3, 227x227x3 ve 299x299x3 çözünürlüğünde yeniden boyutlandırılmıştır.



Şekil 2. Ham EEG kayıtlarının SSD yöntemi uygulanarak görüntü formunda temsil edilmesi (a): Sağlıklı birey, (b): Alzheimer hastası

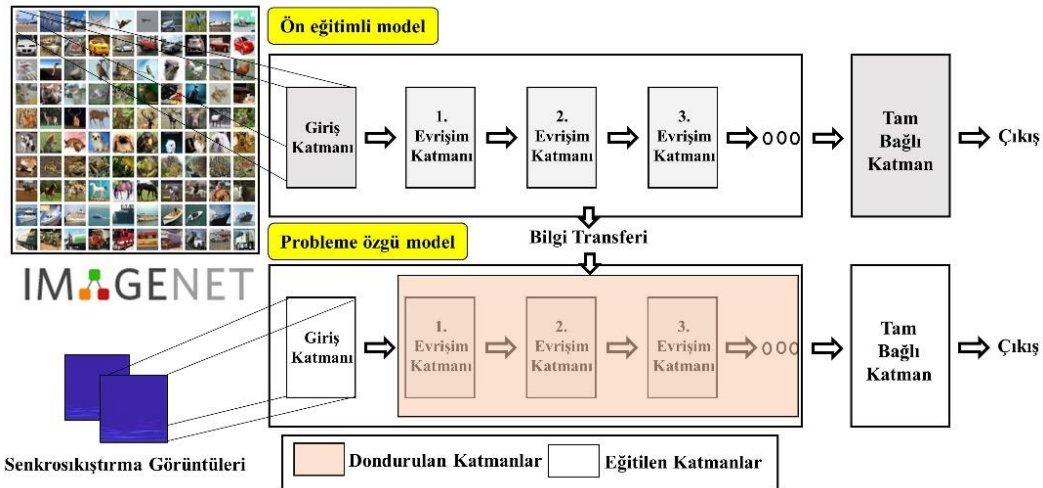
### Ön eğitilmiş modeller ve transfer öğrenimi yaklaşımı

Derin öğrenme modelleri birçok alanda etkili çözümler sunarak, önemli bir potansiyel barındırmaktadır [20]. Karmaşık problemlerde geleneksel makine öğrenme mimarilerinin gereksinim duyduğu manuel özellik çıkarımına ilişkin mevcut handikapların üstesinden gelecek büyük bir atılım sergilemişlerdir. Ancak, derin öğrenme mimarilerinin probleme özgü olarak sil baştan eğitilmeleri aşırı bir

hesaplama gücüne, zamana ve ağırlık genelleştirme yapabileceği büyük veri setlerine olan gereksinimi beraberinde getirmektedir [20], [21]. Transfer öğrenimi yaklaşımı, büyük veri seti üzerinde geliştirilmiş mimarilerin eğitilmiş ağırlıklarının yeniden kullanılması ve probleme özgü uyarlanması ile söz konusu gereksinimlere olan bağımlılığı aşarak etkili çözümlerin elde edilmesine olanak tanımaktadır [21]. Bu çalışmada, kanal bazlı sınırlı sayıda EEG görüntü kümelerinden etkin bir şekilde Alzheimer hastalığının tespiti için transfer öğrenimi yaklaşımı uygulanmıştır. Bu kapsamda, önceden çoklu sınıflandırma problemleri üzerinde eğitilmiş InceptionV3, SqueezeNet, ResNet-18 ve MobileNet mimarileri ayrı ayrı kullanılarak elde edilen sınıflandırma performansları karşılaştırılmıştır. Şekil 3'te bu çalışmada uygulanan transfer öğrenimi çerçevesi sistematik olarak tasvir edilmektedir.

### SqueezeNet

SqueezeNet, Iandola ve ark. [22] tarafından görüntü tanıma problemlerinde güçlü bir performans sağlaması amacıyla önerilen hafif bir derin öğrenme mimarisidir. Önerilen derin öğrenme mimarilerinin çoğunda genel amacın çeşitli bilgisayarlı görü uygulamalarında tanı, tespit veya segmentasyon doğruluğun artırılması yönünde olduğu görülmektedir. SqueezeNet modelinde ise diğer popüler ESA mimarilerinin sunmuş olduğu doğruluk performansından ödün vermeden çok daha az sayıda eğitebilir parametre içeren bir derin öğrenme mimarisinin tasarlanması amaçlanmıştır [23]. Bu kapsamda, sıkıştırılmış ve genişletilmiş katmanlardan oluşan ateşleme modülleri önerilmiştir. Ateşleme modülleri, 1x1 boyutunda evrişim kernellerinin kullanıldığı sıkıştırılmış katman ve 1x1 ve 3x3 boyutunda evrişim kernellerinin birlikte kullanıldığı genişletilmiş katmanların aktif bir şekilde kullanılması prensibine dayanır [24]. Ateşleme modülünde 3x3 filtreler yerine 1x1 boyutunda darboğaz filtreler kullanılarak, hesaplama maliyeti azaltılmıştır. Önerilen SqueezeNet modeli ile IMAGENET çok ölçekli görüntü tanıma yarışmasında AlexNet modelinin sunmuş olduğu doğruluk performansı, 50 kat daha az parametre kullanılarak elde edilmiştir [22].



Şekil 3. Transfer öğrenimi yaklaşımı

## MobileNet

MobileNet ve varyantları mobil ve donanımsal bilgisayarlı görü uygulamaları için önerilen verimli derin öğrenme modelleridir [25], [26]. Ağların diğer derin mimarilere kıyasla öne çıkan yönleri, çok az sayıda eğitilebilir parametrelere sahip olmalarıdır. MobileNet mimarisinde e az sayıda eğitilebilir parametre sayısı derinlemesine ayrılabilir evrişim filtrelerin kullanılması ile sağlanmaktadır. Derinlemesine ayrılabilir filtreler, evrişim filtrelerinin çarpanlarına ayrılması mantığına dayanmaktadır. Ağdaki standart evrişim filtreleri, derinlemesine ve 1x1 boyutlu noktasal evrişim filtrelerine ayrıştırılır. Derinlemesine evrişim işlemi ile her giriş kanalına tek bir filtre uygulanır. Akabinde, 1x1 boyutunda noktasal evrişim uygulayarak çıktıları derinlemesine evrişimle birleştirir. Derinlemesine ayrılabilir evrişimin aynı süreci filtreleme ve birleştirme olmak üzere iki katmanda gerçekleştirmesi, hesaplama maliyeti ve model boyutunun büyük ölçüde düşürülmesine neden olur [25]. Böylelikle, donanımsal olarak uygulanabilir ve seri çalışan bir derin mimarinin tasarımı mümkün olmaktadır.

## InceptionV3

Bir GoogleNet versiyonu olan InceptionV3 mimarisi, selefleri olan mimarilerin (InceptionV1 ve InceptionV2) başlangıç yapılarının yeniden dizayn edilmesi ile türetilmiştir [27]. InceptionV3 görüntü tanıma problemlerinde ilgilenilen bölgelere ilişkin aşırı konum değişkenlik sorunlarını ele almaktadır. Bu kapsamda, aynı düzeyde filtreler birleştirilerek ağı etkin bir şekilde genişletilmesi sağlanır [20]. InceptionV3, seleflerine kıyasladığında küçük evrişim operatörlerinin elde edilmesi için bir evrişimsel bölme yöntemi kullanır [28]. Bu yöntem ile (n×n) boyutunda evrişim filtreleri (n×1) ve (1×n) boyutlu filtrelere bölünerek, ağ içerisinde eğitilebilir parametre sayısı azaltılır. Böylelikle, ağ girişine sunulan görüntülerden daha etkin bir şekilde uzamsal özelliklerin çıkartılması ve ağı daha kısa sürede eğitilmesi mümkün kılınır [28].

## ResNet-18

Görüntü işleme üzerindeki mevcut performansın artırılması için derin mimarilere yeni katmanlar eklenerek ESA modelleri daha da derinleştirilmiştir. Ancak, artan derinlik ile birlikte performansın artmadığı gözlemlenmiştir. Derinlik artıkça ortaya çıkan kaybolan veya patlayan gradyan sorunu

eğitim performansını olumsuz etkilemiştir [29]. Daha derin mimarilerin söz konusu handikaplardan bağımsız bir şekilde dizayn edilmesi için He ve ark. [30] tarafından artık ağ çerçevesi önerilmiştir. Önerilen çerçeve, ağ yapısında artan derinlikle birlikte doğru orantılı olarak sınıflandırma doğruluğunun artırıldığını kanıtlamıştır [30]. Artık bloklara dayanan mimari, IMAGENET veri seti üzerinde diğer mimarilere kıyasla daha derin olmasına rağmen daha az kompleks olan yapısı ile üstün bir başarı sergilemiştir. Bu çalışmada, katman sayısına göre farklı varyantları bulunan artık ağlar içerisinde ResNet-18 mimarisi kullanılmıştır. Ağ içerisinde parametre sayısının diğer varyantlarına göre daha az olması, EEG senkrosıkıştırma temsillerinden Alzheimer tespitinde kullanılmasının başlıca motivasyon kaynağı olmuştur.

## Model eğitim parametreleri ve performans metrikleri

Bu çalışmada, her bir EEG kanalından alınan sınırlı sayıda görüntü olarak derin transfer öğrenimi tabanlı bir otomatik Alzheimer tanı modeli önerilmiştir. Veri setinin kısıtlılığından kaynaklı dezavantajın gelmek için çok ölçekli görüntü veri setleri üzerinde önceden eğitilmiş olan SqueezeNet, MobileNet, ResNet-18 ve InceptionV3 mimarileri kullanılmıştır. Bu kapsamda, evrişim bloklarını dondurulup ve eğitilmiş ağırlıkların transfer edilmesi ile aşırı uyumlama riskinin üstesinden gelinmesi amaçlanmıştır. Çalışmada kullanılan sınıflandırma modellerine ilişkin her bir yinelemede alınan örnek sayısı (mini-batch size), maksimum yapılan tam tur (epoch) sayısı, giriş katman boyutları, ve aktivasyon fonksiyonu gibi parametrelere ilişkin bilgiler Tablo 1’de detaylandırılmıştır.

## Bulgular

EEG işaretlerinden Alzheimer hastalığının otomatik olarak tespiti kapsamında bütün analizler Matlab programlama ortamında çalıştırılmıştır. Önerilen modelin güvenilir bir şekilde değerlendirilmesi için beş katlı çapraz doğrulama yöntemi uygulanmıştır. Her bir EEG kanalı için 96 sağlıklı ve 96 hasta olmak üzere toplamda 192 görüntü dikkate alınmıştır. Serebral lob etkinliğinin kapsamlı olarak irdelenmesinde ise senrosıkıştırma yöntemi ile elde edilen 192×19=3648 görüntü dikkate alınmıştır. Görüntü verilerinin %60’ı ağı eğitimi, %20’si doğrulama ve geriye kalan %20’si ise ağı testi için alt gruplara ayrıştırılmıştır.

Tablo 1. Ön eğitilmiş modellere ilişkin parametreler

Model Parametreleri	SqueezeNet	MobileNetV2	ResNet-18	InceptionV3
Giriş görüntü boyutu	227x227x3	224x224x3	224x224x3	299x299x3
Model Boyutu	0.723522M	2.209378 M	21.774450M	11.172738M
Mini-batch boyutu	32	32	32	32
Epoch sayısı	30	30	30	30
Başlangıç Öğrenme Oranı	0.001	0.001	0.001	0.001
İyileştirici	Adam	Adam	Adam	Adam
Aktivasyon Fonksiyonu	ReLU	Kırılmış ReLU	ReLU	ReLU
Çıkış Katmanı	Softmax	Softmax	Softmax	Softmax

EEG işaretlerinden Alzheimer tespitinde önerilen modeller tarafından sunulan performanslar sırasıyla doğruluk, özgüllük, duyarlılık, kesinlik, F-skor ve AUC başarımları

metrikleri türünden değerlendirilmiştir. Tablo 2 ve 3'te EEG kanalları için elde edilen sınıflandırma performansları gösterilmektedir

Tablo 2. Her bir EEG kanalı için uygulanan sınıflandırma modelinin doğruluk, özgüllük ve duyarlılık model başarımları türünden performans sonuçları

%	Doğruluk				Özgüllük				Duyarlılık			
	Squ.	Res.	Mob.	Inc.	Squ.	Res.	Mob.	Inc.	Squ.	Res.	Mob.	Inc.
<b>Fp1</b>	61.84	71.81	67.57	70.23	68.84	69.63	67.47	69.57	54.84	74.00	67.68	70.89
<b>Fp2</b>	56.13	66.57	62.97	60.78	59.00	63.47	66.63	60.36	53.26	69.68	59.31	61.21
<b>F7</b>	60.97	66.15	61.84	71.78	53.47	65.73	68.68	72.84	68.47	66.57	55.00	70.73
<b>F3</b>	65.52	70.23	70.21	76.97	82.21	62.47	72.84	75.89	48.84	78.00	67.57	78.05
<b>Fz</b>	64.63	70.86	71.28	74.39	69.68	70.73	71.84	73.84	59.57	71.00	70.73	74.94
<b>F4</b>	66.65	71.26	70.18	71.31	84.26	72.78	70.63	73.89	49.05	69.73	69.73	68.73
<b>F8</b>	68.05	62.34	66.52	67.00	69.73	60.26	63.31	62.26	66.36	64.42	69.73	71.73
<b>T3</b>	73.00	77.68	77.68	76.65	71.94	76.05	77.00	70.78	74.05	79.31	78.36	82.52
<b>C3</b>	69.89	76.02	74.94	79.65	70.68	70.78	72.89	70.84	69.10	81.26	77.00	88.47
<b>Cz</b>	69.21	70.81	71.36	70.78	74.78	68.68	76.94	70.73	63.63	72.94	65.78	70.84
<b>C4</b>	74.39	78.07	69.65	73.34	84.21	83.26	68.63	71.78	64.57	72.89	70.68	74.89
<b>T4</b>	69.76	68.02	75.44	80.10	60.31	54.84	76.89	68.57	79.21	81.21	74.00	91.63
<b>T5</b>	74.60	87.94	85.92	90.57	68.15	85.36	87.52	87.36	81.05	90.52	84.31	93.78
<b>P3</b>	77.68	87.92	88.50	89.50	67.63	87.42	87.42	90.52	87.73	88.42	89.57	88.47
<b>Pz</b>	81.28	77.57	76.60	80.13	90.52	77.94	84.42	75.89	72.05	77.21	68.78	84.36
<b>P4</b>	70.73	81.65	79.60	82.13	86.31	82.15	79.10	81.10	55.15	81.15	80.10	83.15
<b>T6</b>	77.07	80.15	79.10	81.31	80.00	85.36	82.26	80.31	74.15	74.94	75.94	82.31
<b>O1</b>	74.05	81.78	79.84	81.26	81.42	80.15	81.47	82.31	66.68	83.42	78.21	80.21
<b>O2</b>	69.94	82.86	85.50	86.02	66.78	86.47	89.57	86.57	73.10	79.26	81.42	85.47

Not: Squ: SqueezeNet, Res: ResNet-18, Mob: MobileNet ve Inc: InceptionV3 modellerini ifade etmektedir.

Tablo 3. Her bir EEG kanalı için uygulanan sınıflandırma modelinin kesinlik, F-skor ve AUC model başarımları türünden performans sonuçları

%	Kesinlik				F1-skor				AUC			
	Squ.	Res.	Mob.	Inc.	Squ.	Res.	Mob.	Inc.	Squ.	Res.	Mob.	Inc.
<b>Fp1</b>	65.64	71.13	68.62	71.05	50.85	70.34	67.06	69.37	70.19	80.33	77.46	74.52
<b>Fp2</b>	59.02	63.98	61.84	60.64	54.07	64.97	58.72	58.25	57.00	72.24	68.39	68.51
<b>F7</b>	62.31	66.41	62.83	73.80	61.90	65.52	56.16	71.42	71.09	72.09	68.63	80.51
<b>F3</b>	75.56	67.86	71.18	77.37	55.44	72.40	69.29	77.29	82.64	79.82	74.48	84.00
<b>Fz</b>	66.00	71.12	72.03	74.43	61.59	70.63	71.22	74.21	70.23	80.00	75.65	82.31
<b>F4</b>	83.77	72.82	73.70	72.87	56.94	70.96	70.94	70.64	80.82	79.73	80.07	78.37
<b>F8</b>	68.19	62.79	67.19	66.64	66.80	62.89	68.07	68.33	74.56	66.36	69.98	71.68
<b>T3</b>	74.08	76.90	78.06	73.98	72.79	77.94	77.49	77.60	79.37	83.08	84.12	83.60
<b>C3</b>	72.43	73.96	73.38	75.09	68.61	77.26	74.47	81.13	73.79	87.92	85.26	86.77
<b>Cz</b>	76.51	70.25	74.75	72.21	67.79	71.45	69.19	71.03	76.31	75.29	76.74	76.75
<b>C4</b>	84.01	82.90	70.46	72.81	71.00	76.63	70.04	73.79	79.75	83.77	78.82	78.16
<b>T4</b>	68.12	67.05	77.89	75.12	72.80	72.66	75.27	82.40	73.75	78.75	85.43	86.35
<b>T5</b>	75.33	86.20	87.66	88.87	76.71	88.27	85.73	91.00	86.32	92.75	90.44	95.68
<b>P3</b>	76.83	87.78	88.10	90.73	80.35	87.90	88.50	89.25	88.90	94.12	95.55	97.46
<b>Pz</b>	89.66	78.97	81.36	78.25	78.73	77.39	74.03	81.02	87.63	86.28	86.03	88.68
<b>P4</b>	81.89	81.97	79.25	82.01	64.68	81.53	79.62	82.37	77.53	89.46	87.66	87.96
<b>T6</b>	82.28	85.70	81.33	81.46	76.44	79.18	78.37	81.55	86.07	88.81	87.65	91.75
<b>O1</b>	81.33	81.43	81.70	82.90	70.58	81.91	79.63	80.81	85.09	88.75	83.40	88.29
<b>O2</b>	69.44	85.23	89.25	86.58	70.65	82.02	84.65	85.99	78.81	89.73	90.36	92.68

Not: Squ: SqueezeNet, Res: ResNet-18, Mob: MobileNetV2 ve Inc: InceptionV3 modellerini ifade etmektedir.

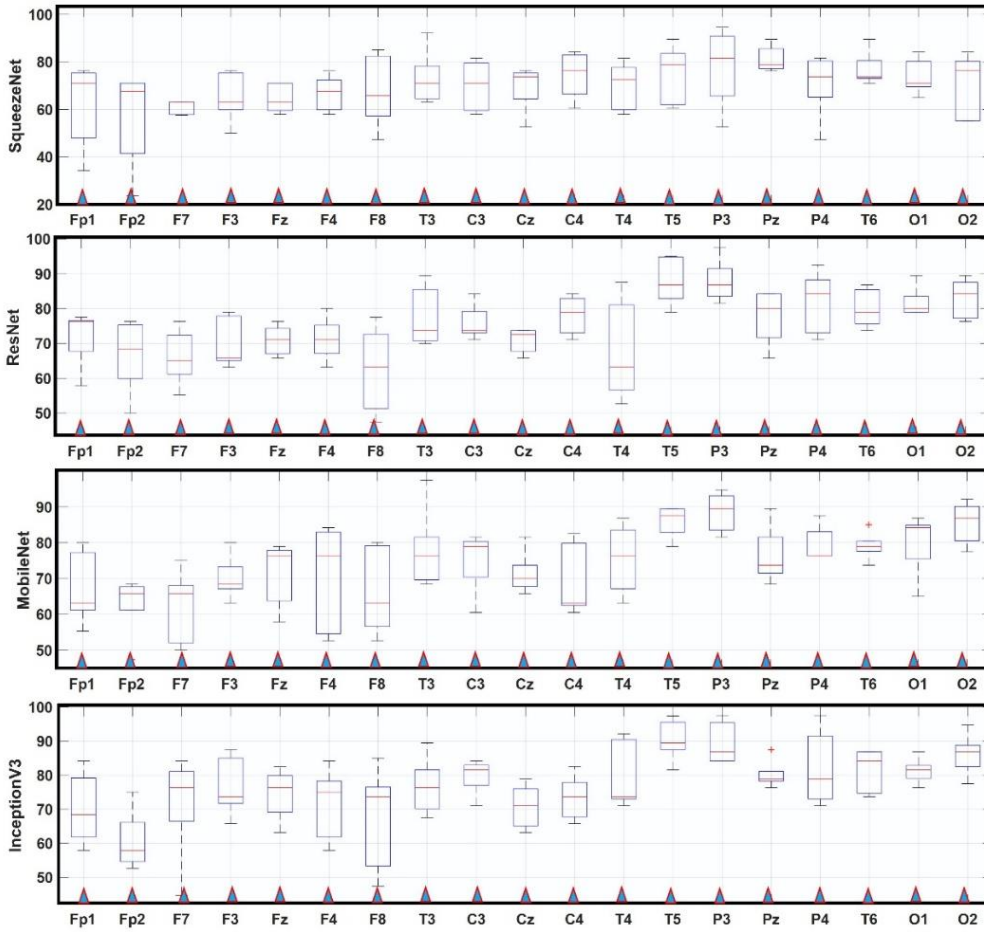
Tablo 2 ve 3'te görüldüğü üzere her bir EEG kanalı için elde edilen sınıflandırma başarımları farklılık göstermektedir. Önerilen ön eğitilmiş dört farklı model için EEG işaretlerinden Alzheimer tespitinin en verimli olarak P3 ve T5 kanallarından alınan kayıtlar ile gerçekleştiği belirlenmiştir. T5 kanalı için SqueezeNet, ResNet-18, MobileNet ve InceptionV3 mimarileri ile sınıflandırma doğrulukları sırasıyla %74.60, %87.94, %85.92 ve %90.50 olarak elde edilmiştir. P3

elektrotundan alınan kayıtlar için ise sınıflandırma doğrulukları sırasıyla %77.68, %87.92, %88.50 ve %89.50 olarak elde edilmiştir. Her iki kanala ilişkin serebral konumlarının birbirine yakın olması, ilgili bölgenin Alzheimer hastalığı için önemli dinamikleri barındırdığını göstermektedir. Her iki kanal için de InceptionV3 modelimin en etkin performansı sağladığı gözlemlenmiştir. Farklı beyin lobları kıyaslandığında ise genel olarak tempoaral ve parietal

loblara ait EEG kanalları için elde edilen performansların iyi bir seviyede oldukları rapor edilmiştir. Temporal lob için InceptionV3 tabanlı tanı sisteminin %76.65 ile %90.57 oranında değişen bir aralıkta doğruluk performansı sunduğu gözlemlenmiştir. Parietal lob üzerinde bulunana kanallar için InceptionV3 modeli tarafından %80.13 ile %82.13 aralığında değişen bir doğrulukla daha kararlı bir sınıflandırma performansı sunulmuştur. Eğitilebilir parametre sayısı açısından InceptionV3 ile kıyaslandığında neredeyse beş kat daha küçük bir mimariye sahip olan MobileNet mimarisi ise P3 ve T5 kanalları için sırasıyla %88.50 ve %85.92 oranında bir sınıflandırma doğruluğu ile rekabetçi bir performans sergilemiştir. Prefrontal lob üzerine yerleştirilen elektrotlardan alınan kayıtlar için ise genel olarak sınıflandırma performansının düşük olduğu gözlemlenmiştir. Fp1 ve Fp2 kanalları için dört derin mimari ile sırasıyla

%61.84-%71.81 ve %56.13-%66.57 aralıklarında değişen zayıf bir tanı performansı rapor edilmiştir.

Farklı ön eğitilmiş mimarilerinin kullanıldığı otomatik tanı çerçevelerinin EEG işaretlerinden Alzheimer tespitinde sunmuş oldukları performansların güvenilir bir şekilde değerlendirilmesi için eğitim aşamasında beş katlı çapraz doğrulama yöntemi uygulanmıştır. Böylelikle, veri setinde yer alan her bir örüntünün eğitim, doğrulama ve test grubunda olma ihtimallerine ilişkin bütün senaryolar denenmiştir. Önerilen modeller tarafından sergilenen performansların sınıflandırma katlarına göre dağılımları irdelenmeye çalışılmıştır. Şekil 4'te önerilen otomatik Alzheimer tespit modellerinin eğitim ve test aşamasında farklı veri senaryolarına göre sergilemiş oldukları performans dağılımları doğruluk başarı metriği türünden kutu grafikleri olarak ifade edilmiştir.



Şekil 4. Dört farklı ön eğitilmiş mimarinin her bir EEG kanalı için beş katlı çapraz doğrulama performans dağılımının doğruluk metriği türünden kutu grafikleri

Şekil 4'te temporal ve parietal lob kanallarına ilişkin dört mimari tarafından genel olarak yüksek doğruluk performansı sunulduğu ve performans dağılımlarının farklı sınıflandırma katlarında düşük varyansa sahip olduğu gözlemlenmiştir. Sonuçlar, T5 ve P3 kanallarından alınan EEG kayıtlarından Alzheimer tespitinin tüm veri seti için başarılı bir şekilde gerçekleştiğini ortaya çıkarmaktadır. Derin ağlara eğitim aşamasında gösterilmeyen test verilerinin farklı olduğu her sınıflandırma katı için önerilen modellerin söz konusu EEG kanallarında kararlı sonuçlar sunduğu gözlemlenmiştir. Diğer

serebral loblara kıyasla sınıflandırma performansının genel olarak en düşük seviyede gözlemlendiği prefrontal lob kanalları için beş katlı çapraz doğrulama sürecinde de benzer çıktılar sergilendiği belirlenmiştir. Fp1 ve Fp2 elektrotlarından alınan EEG kayıtları için beş katlı çapraz doğrulama sürecinde en yüksek varyansın sergilendiği rapor edilmiştir. Kutu grafikleri referans alınarak beş katlı çapraz doğrulama sonuçlarının genel olarak irdelenmesi ile parietal ve temporal loblardan alınan EEG kayıtlarına ilişkin performansların daha başarılı olduğu sonucuna varılmıştır.

Tablo 4. Beyin loblarına ilişkin dört model tarafından sunulan doğruluk, özgüllük, duyarlılık model başarımlarının sonuçları

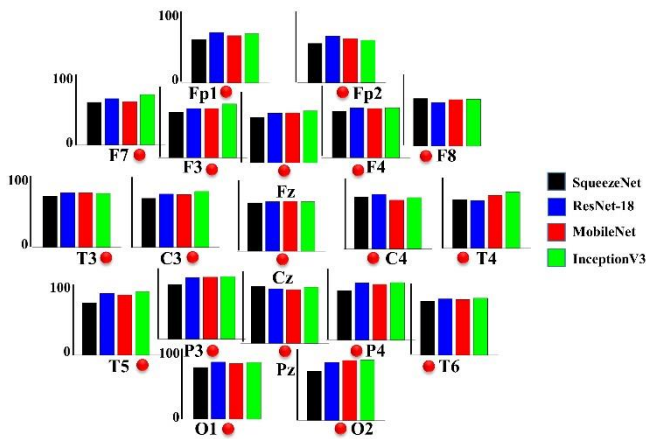
%	Doğruluk				Özgüllük				Duyarlılık			
	Squ.	Res.	Mob.	Inc.	Squ.	Res.	Mob.	Inc.	Squ.	Res.	Mob.	Inc.
<b>Frontal</b>	63.40	68.46	67.22	70.35	69.60	66.44	68.77	69.81	57.20	70.48	65.68	70.90
<b>Temporal</b>	73.61	78.45	79.53	82.16	70.10	75.40	80.92	76.76	77.11	81.50	78.15	87.56
<b>Parietal</b>	76.57	82.38	81.57	83.92	81.49	82.50	83.64	82.50	71.64	82.26	79.49	85.33
<b>Santral</b>	71.16	74.97	71.99	74.59	76.56	74.24	72.82	71.12	65.77	75.70	71.15	78.07
<b>Oksipital</b>	72.00	82.32	82.67	83.64	74.10	83.31	85.52	84.44	69.89	81.34	79.81	82.84

Not: Squ: SqueezeNet, Res: ResNet-18, Mob: MobileNet ve Inc: InceptionV3 modellerini ifade etmektedir.

### Alzheimer hastalığı tespitinde beyin loblarının etkinliği

Bu bölümde, önerilen modellerin serebral loblara göre genel olarak sergiledikleri performans dağılımları karşılaştırılmıştır. Bu kapsamda, her bir EEG kanalı, ait olduğu serebral lob sınıfına atanarak sınıf üyeleri tarafından sağlanan performansların ortalaması alınmıştır. Tablo 4'te dört ön eğitilmiş mimariye dayanan transfer öğrenimi yaklaşımı ile sırasıyla frontal, temporal, parietal, santral ve oksipital loblar için elde edilen ortalama sınıflandırma başarımları gösterilmektedir.

Tablo 4'te parietal ve oksipital loblar için genel olarak en yüksek ortalama başarımların elde edildiği tespit edilmiştir. Parietal lob için dört model tarafından sunulan genel sınıflandırma performansı doğruluk türünden sırasıyla %76.57, %82.38, %81.57 ve %83.92 olarak elde edilmiştir. Oksipital lob için ise genel sınıflandırma performansı doğruluk türünden sırasıyla %72.00, %82.32, %82.67 ve %83.64 olarak elde edilmiştir. Frontal lobun diğer beyin bölgelerine kıyasla Alzheimer tespitinde en düşük performansı sunduğu tespit edilmiştir. Frontal lob EEG kanallarından alınan kayıtlar için elde edilen ortalama sınıflandırma başarımları doğruluk metriği türünden sırasıyla %63.40, %68.46, %67.22 ve %70.35 olarak elde edilmiştir. Farklı mimari tabanlı önerilen otomatik tanı modellerinin elektrot konumlarına göre sergilemiş oldukları doğruluk performansları Şekil 5'te gösterilmektedir.



Şekil 5. Farklı mimarilerin elektrot konumlarına göre sergilemiş oldukları doğruluk performansları

Şekil 5'te beyin sol arka yarımküresinden (hemisfer) alınan EEG kayıtlarının Alzheimer hastalığına ilişkin ayırt edici özellikleri etkin bir şekilde yansıttığı görülebilmektedir. Genel olarak sol hemisfer bölgesinin Alzheimer tespitinde daha etkin bir rol oynadığı gözlemlenmiştir. Sol hemisfer parietal ve temporal lobları için sınıflandırma performansının

maksimum olduğu görsel bulgularla kanıtlanmıştır. Serebral loblar için genel değerlendirme neticesinde, parietal ve temporal bölgelerinden hastalığa ilişkin önemli dinamiklerin en verimli şekilde yakalanabileceği kanısına varılmıştır. Ayrıca, InceptionV3 tabanlı tanı çerçevesinin diğer modellere kıyasla daha etkin olduğu görsel bulgularla pekiştirilmiştir.

### Tartışma

EEG işaretlerinin zaman-frekans alanında görüntü formunda temsil edilerek, çeşitli nörolojik hastalıkların derin öğrenme yaklaşımları ile analiz edildiği çalışmalar git gide artmaktadır [7], [12], [31]–[33]. Bu kapsamda, sıklıkla KZFD ve SDD yöntemlerine başvurulmaktadır [34], [35]. KZFD tekniğinin sabit pencereler ve sinüzoidal sinyal tabanlı olması nedeniyle boyut artırımı sırasında durağan olmayan özelliklerin verimli şekilde yansıtılması sektöre uymamaktadır. Diğer bir yöntem olan dalgacık dönüşümü, analizi yapılan sinyallerin yüksek frekans bölgesinde dar, alçak frekans bölgesinde ise geniş pencereler kullanabilme kabiliyeti ile durağan olmayan bilgilerin ayıklanmasında nispeten daha avantajlıdır. Ancak, sinyallerin analizinde uygun ana dalgacık seçimi sorunu ve zaman-frekans çözünürlük handikapları alternatif yöntemlerin gerekliliğini ön plana çıkarmaktadır. Bu çalışmada, EEG işaretlerinin zaman-frekans alanında daha net gösterimleri için senkrosıkıştırma yöntemi uygulanmış ve elde edilen başarılı sınıflandırma sonuçları yöntemin etkinliğini kanıtlamıştır. Senkrosıkıştırma görüntü temsillerinden InceptionV3 mimarisinin T5 ve P3 kanalları için sırasıyla %90.57 ve %89.50 oranında bir doğruluk sunması, isabetli bir seçimin göstergesidir.

EEG tabanlı Alzheimer tespitinde karakteristik dinamikleri yansıtan beyin bölgeleri önem taşımaktadır. Hastalıkla ilişkili beyin bölgesinin tespiti ile ilgili serebral korteksin sorumlu olduğu fonksiyonlar ve Alzheimer arasındaki ilişki tespit edilebilir. Alzheimer hastalığı ile ilişkili dinamiklerin sol parietal ve temporal lobda etkin olarak gözlemlendiği geçmiş çalışmalarda rapor edilmiştir [2], [36]. Önerilen modellerin genel olarak en yüksek başarımları P3 ve T5 EEG kanalları için sunmuş olmaları, bu çalışmanın literatürü destekler niteliğinde ön plana çıkarmaktadır.

EEG işaretlerindeki ayırt edici özelliklerin ayıklanması, ilgilenilen problemlere özgü yöntemlerin uygulanmasını gerektirir. Anlamlı bilgilerin manuel olarak çıkarılması çoğunlukla deneme-yanılma yoluyla veya geçmiş çalışmalar referans alınarak gerçekleştirilir. Dolayısıyla, EEG işaretlerinin konvansiyonel yaklaşımlar ile işlenmesi araştırmacılar için aşırı iş yükünü beraberinde getirir. Bu çalışmada EEG işaretlerinden Alzheimer hastalığının tespitinde herhangi bir manuel özellik çıkarım tekniğine başvurulmadan başarılı bir düzeyde tespit sonuçları elde



edilmiştir. Sonuçlar derin öğrenmenin EEG analizindeki etkinliğini ve fizibilitesini ortaya koymaktadır. Tablo 5'te Alzheimer hastalığının EEG işaretlerinden otomatik olarak

tanısında araştırmacılar tarafından önerilen son teknoloji modeller ile bu çalışmada elde edilen sınıflandırma başarımları karşılaştırılmıştır.

Tablo 5. Önerilen model tarafından sunulan sınıflandırma performansının diğer çalışmalar ile karşılaştırılması

Yazar	Katılıcı Sayısı	Özellik Çıkarımı	Sınıflandırıcı	Doğruluk (%)
Tzimourta ve ark. [10]	10 SK, 14 AH	Spektral enerji, Shannon entropi, Permütasyon entropi.	Rastgele orman	91.80
Chen ve ark. [8]	15 SK, 15 AH	Çapraz korelasyon katsayıları, Dalgalanma analizi	LDA	90.00
Kulkarni ve ark. [37]	15 SK, 15 AH	Spektral analiz yöntemleri	DVM	96.00
Rodrigues ve ark. [7]	24 SK, 24 AH	Granger nedenselliği, Pearson ve Spearman korelasyon katsayıları	ESA	92.00
Ruiz-Gómez ve ark. [9]	37 SK, 37 OBB, 37 AH	Spektral ve lineer olmayan özellikler	Çok katmanlı sinir ağları (MLPNN)	78.43
Polat [13]	24 SK, 24 AH	Zaman-frekans karmaşıklık haritası: Complexogram	MobileNetV2	100
Ismail ve ark. [12]	20 SK, 16 AH	Frekans alt bantlarının azimut projeksiyonu tabanlı görüntü temsilleri	ESA ve Uzun kısa süreli bellek ağları (LSTM)	90.15
Bariagi [38]	20 SK, 16 AH	Spektral ve dalgacık tabanlı özelliklerin kombinasyonu	DVM KNN	94.00 92.00
Bu çalışma	24 SK, 24 AH	EEG senkrosıkıştırma temsilleri	InceptionV3	90.57

SK: Sağlıklı kontrol, AH: Alzheimer hastası, OBB: Orta dereceli bilişsel bozukluğu bulunan hasta

## Sonuç

Bu çalışmada, EEG işaretlerinden Alzheimer hastalığının otomatik olarak tespitinde senkrosıkıştırma tekniği ve transfer öğrenimine dayanan bir model önerilmiştir. EEG kanallarının ayrı ayrı değerlendirmeye alınması ile serebral korteksin hastalıkla ilişkili bölgelerinin tespiti de gerçekleştirilmiştir. Önerilen genel çerçevenin EEG tabanlı Alzheimer analizinde kapsamlı ve dikkate değer bulgular sunduğu gözlemlenmiştir. Çalışmanın bu yönüyle literatüre katkı sağlayacağı ön görülmektedir.

Çalışmanın en büyük handikabı olarak, dikkate alınan veri setinin büyüklüğü gösterilebilir. Derin mimarilerinin özellikle büyük eğitim verileri üzerinde muazzam bir performans sergilediği bilinmektedir. Ancak, söz konusu sınırlamaya rağmen transfer öğrenimi yaklaşımı ile elde edilen bulguların tatmin edici ve literatürle destekler nitelikte olması, önerilen modelin potansiyelini ortaya koymaktadır. İleriki çalışmalarda, çeşitli veri artırım yöntemleri

uygulanarak yapay görüntülerin kullanılması ile mevcut başarımın artırılması planlanmaktadır.

## Etik beyanı

Bu çalışmada, “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması gerekli tüm kurallara uyulduğunu, bahsi geçen yönergenin “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbirinin gerçekleştirilmediğini taahhüt ederiz.

## Çıkar çatışması beyanı

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

## Kaynaklar

- [1] P. A. M. Kanda, E. F. Oliveira, and F. J. Fraga, “EEG epochs with less alpha rhythm improve discrimination of mild Alzheimer’s,” *Comput. Methods Programs Biomed.*, vol. 138, pp. 13–22, 2017, doi: 10.1016/j.cmpb.2016.09.023.

- [2] A. M. Pineda, F. M. Ramos, L. E. Betting, and A. S. L. O. Campanharo, "Quantile graphs for EEG-based diagnosis of Alzheimer's disease," *PLoS One*, vol. 15, no. 6, pp. 1–15, 2020, doi: 10.1371/journal.pone.0231169.
- [3] L. Tylová, J. Kukal, V. Hubata-Vacek, and O. Vyšata, "Unbiased estimation of permutation entropy in EEG analysis for Alzheimer's disease classification," *Biomed. Signal Process. Control*, vol. 39, pp. 424–430, 2018, doi: 10.1016/j.bspc.2017.08.012.
- [4] E. Fide, H. Polat, G. Yener, and M. S. Özerdem, "Effects of Pharmacological Treatments in Alzheimer's Disease: Permutation Entropy-Based EEG Complexity Study," *Brain Topogr.*, no. 0123456789, 2022, doi: 10.1007/s10548-022-00927-8.
- [5] P. Zhao, P. Van-Eetvelt, C. Goh, N. Hudson, S. Wimalaratna, and E. Ifechor, "Characterization of EEGs in alzheimer's disease using information theoretic methods," *Annu. Int. Conf. IEEE Eng. Med. Biol. - Proc.*, pp. 5127–5131, 2007, doi: 10.1109/IEMBS.2007.4353494.
- [6] L. R. Trambaiolli, N. Spolaôr, A. C. Lorena, R. Anghinah, and J. R. Sato, "Feature selection before EEG classification supports the diagnosis of Alzheimer's disease," *Clin. Neurophysiol.*, vol. 128, no. 10, pp. 2058–2067, 2017, doi: 10.1016/j.clinph.2017.06.251.
- [7] F. A. Rodrigues, C. Alves, A. Pineda, K. Roster, and C. Thielemann, "EEG functional connectivity and deep learning for automatic diagnosis of brain disorders: Alzheimer's disease and schizophrenia," *J. Phys. Complex.*, pp. 1–10, 2022, doi: 10.1088/2632-072x/ac5f8d.
- [8] Y. Chen *et al.*, "DCCA cross-correlation coefficients reveals the change of both synchronization and oscillation in EEG of Alzheimer disease patients," *Phys. A Stat. Mech. its Appl.*, vol. 490, pp. 171–184, 2018, doi: 10.1016/j.physa.2017.08.009.
- [9] S. J. Ruiz-Gómez *et al.*, "Automated multiclass classification of spontaneous EEG activity in Alzheimer's disease and mild cognitive impairment," *Entropy*, vol. 20, no. 1, pp. 1–15, 2018, doi: 10.3390/e20010035.
- [10] K. D. Tzimourta *et al.*, "EEG window length evaluation for the detection of Alzheimer's disease over different brain regions," *Brain Sci.*, vol. 9, no. 4, 2019, doi: 10.3390/brainsci9040081.
- [11] Y. Zhang and S. Wang, "Detection of Alzheimer's disease by displacement field and machine learning," *PeerJ*, vol. 2015, no. 9, pp. 1–29, 2015, doi: 10.7717/peerj.1251.
- [12] M. Ismail, K. Hofmann, and M. A. A. El Ghany, "Early Diagnoses of Alzheimer using EEG data and Deep Neural Networks classification," *2019 IEEE Glob. Conf. Internet Things, GCIoT 2019*, 2019, doi: 10.1109/GCIoT47977.2019.9058417.
- [13] H. Polat, "Time-Frequency Complexity Maps for EEG-Based Diagnosis of Alzheimer ' s Disease Using a Lightweight Deep Neural Network" *Traitement du Signal*, vol. 39, no. 6, pp. 2102-2113, 2022, doi: 10.18280/ts.390623.
- [14] M. Raza, M. Awais, W. Ellahi, N. Aslam, H. X. Nguyen, and H. Le-Minh, "Diagnosis and monitoring of Alzheimer's patients using classical and deep learning techniques," *Expert Syst. Appl.*, vol. 136, pp. 353–364, 2019, doi: 10.1016/j.eswa.2019.06.038.
- [15] O. Russakovsky *et al.*, "ImageNet Large Scale Visual Recognition Challenge," *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, 2015, doi: 10.1007/s11263-015-0816-y.
- [16] A. S. L. O. Campanharo, F. M. Ramos, A. M. Pineda, and L. E. Betting, "Data from: Quantile Graphs for EEG-Based Diagnosis of Alzheimer's Disease," 2020, doi: 10.17605/OSF.IO/S74QF.
- [17] R. Cassani, M. Estarellas, R. San-Martin, F. J. Fraga, and T. H. Falk, "Systematic review on resting-state EEG for Alzheimer's disease diagnosis and progression assessment," *Dis. Markers*, vol. 2018, 2018, doi: 10.1155/2018/5174815.
- [18] F. Auger *et al.*, "Time-frequency reassignment and synchrosqueezing: An overview," *IEEE Signal Process. Mag.*, vol. 30, no. 6, pp. 32–41, 2013, doi: 10.1109/MSP.2013.2265316.
- [19] G. Thakur, E. Brevdo, N. S. Fučkar, and H. T. Wu, "The Synchrosqueezing algorithm for time-varying spectral analysis: Robustness properties and new paleoclimate applications," *Signal Processing*, vol. 93, no. 5, pp. 1079–1094, 2013, doi: 10.1016/j.sigpro.2012.11.029.
- [20] N. D. Kathamuthu *et al.*, "A deep transfer learning-based convolution neural network model for COVID-19 detection using Computed tomography scan images for medical applications," *Adv. Eng. Softw.*, vol. 175, no. August 2022, p. 103317, 2022, doi: 10.1016/j.advengsoft.2022.103317.
- [21] R. Naga Swetha, V. K. Shrivastava, and K. Parvathi, "Multiclass skin lesion classification using image augmentation technique and transfer learning models," *Int. J. Intell. Unmanned Syst.*, 2021, doi: 10.1108/IJIUS-02-2021-0010.
- [22] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size," pp. 1–13, 2016, [Online]. Available: <http://arxiv.org/abs/1602.07360>.
- [23] H. Polat and M. S. Özerdem, "Derin Transfer Öğrenimi Yaklaşımı ile Kamusal Alanda Medikal Maske Kullanımının Otomatik Kontrolü," *Türk Doğa ve Fen Derg.*, vol. 10, no. 2, pp. 191–198, 2021, doi: 10.46810/tdfd.948098.
- [24] A. S. Gaikwad and M. El-Sharkawy, "Pruning convolution neural network (squeezenet) using taylor

- expansion-based criterion,” *2018 IEEE Int. Symp. Signal Process. Inf. Technol. ISSPIT 2018*, vol. 2019-Janua, pp. 1–5, 2018, doi: 10.1109/ISSPIT.2018.8705095.
- [25] A. G. Howard *et al.*, “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,” 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>.
- [26] M. Sandler, A. Howard, M. Zhu, and A. Zhmoginov, “Sandler\_MobileNetV2\_Inverted\_Residuals\_CVPR\_2018\_paper.pdf,” pp. 4510–4520, 2018.
- [27] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 2818–2826, 2016, doi: 10.1109/CVPR.2016.308.
- [28] N. Dong, L. Zhao, C. H. Wu, and J. F. Chang, “Inception v3 based cervical cell classification combined with artificially extracted features,” *Appl. Soft Comput.*, vol. 93, p. 106311, 2020, doi: 10.1016/j.asoc.2020.106311.
- [29] B. Baheti, S. Gajre, and S. Talbar, “Semantic Scene Understanding in Unstructured Environment with Deep Convolutional Neural Network,” *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, vol. 2019-Octob, pp. 790–795, 2019, doi: 10.1109/TENCON.2019.8929376.
- [30] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [31] N. Mammone, C. Ieracitano, and F. C. Morabito, “A deep CNN approach to decode motor preparation of upper limbs from time–frequency maps of EEG signals at source level,” *Neural Networks*, vol. 124, pp. 357–372, 2020, doi: 10.1016/j.neunet.2020.01.027.
- [32] V. Padhmashree and A. Bhattacharyya, “Human emotion recognition based on time–frequency analysis of multivariate EEG signal,” *Knowledge-Based Syst.*, vol. 238, p. 107867, 2022, doi: 10.1016/j.knosys.2021.107867.
- [33] S. Bhattacharya *et al.*, “Deep learning and medical image processing for coronavirus (COVID-19) pandemic: A survey,” *Sustain. Cities Soc.*, vol. 65, no. November 2020, p. 102589, 2021, doi: 10.1016/j.scs.2020.102589.
- [34] H. Polat, M. U. Aluclu, and M. S. Özerdem, “Evaluation of potential auras in generalized epilepsy from EEG signals using deep convolutional neural networks and time-frequency representation,” *Biomed. Tech. (Berl.)*, vol. 65, no. 4, pp. 379–391, Aug. 2020, doi: 10.1515/BMT-2019-0098.
- [35] Ö. Türk and M. S. Özerdem, “Epilepsy detection by using scalogram based convolutional neural network from eeg signals,” *Brain Sci.*, vol. 9, no. 5, 2019, doi: 10.3390/brainsci9050115.
- [36] M. Şeker, Y. Özbek, G. Yener, and M. S. Özerdem, “Complexity of EEG Dynamics for Early Diagnosis of Alzheimer’s Disease Using Permutation Entropy Neuromarker,” *Comput. Methods Programs Biomed.*, vol. 206, 2021, doi: 10.1016/j.cmpb.2021.106116.
- [37] N. N. Kulkarni and V. K. Bairagi, “Extracting Salient Features for EEG-based Diagnosis of Alzheimer’s Disease Using Support Vector Machine Classifier,” *IETE J. Res.*, vol. 63, no. 1, pp. 11–22, 2017, doi: 10.1080/03772063.2016.1241164.
- [38] V. Bairagi, “EEG signal analysis for early diagnosis of Alzheimer disease using spectral and wavelet based features,” *Int. J. Inf. Technol.*, vol. 10, no. 3, pp. 403–412, 2018, doi: 10.1007/s41870-018-0165-5.