

Makine Öğrenme Yöntemleri ile EEG Sinyallerinden Alzheimer Hastalığı Tanısı

Yeliz ŞENKAYA^{1*}, Çetin KURNAZ²

Öz

Alzheimer bilişsel ve nörolojik işlevlerin ilerleyici kaybı olan, insan yaşamını olumsuz yönde etkileyen, geri dönüşümü mümkün olmayan bir tür nörodejeneratif hastalıktır. Hastalığın tedavisi mümkün olmadığından, erken tanı ile ilerleyişi yavaşlatmak büyük önem taşımaktadır. Tanı aşamasının uzun sürmesi tedavinin gecikmesine ve bilişsel, nörolojik kayıpların artmasına sebep olmaktadır. Bu çalışmanın amacı, kayıpların en aza indirgenmesi için Elektroensefalogram (EEG) sinyallerinden Alzheimer hastalığının (AH) tanısını makine öğrenme yöntemleri ile gerçekleştirmektir. Yapılan çalışmada AH'lı 24 kişi ve sağlıklı 24 kişinin EEG sinyalleri %50 örtüşme ile 4 saniyelik epoklara ayrılmıştır. Sinyallerin Bağımsız Bileşen Analizi (ICA) değerleri hesaplanmış ve EEG kanallarından ICA değerlerine göre otomatik gürültü temizleme işlemi yapılmıştır. Her bir sinyalin zaman alanından spektral alana geçişi Welch metodu kullanılarak gerçekleştirilmiştir. 1-30 Hz aralığında Welch Spektral analizi ile Güç Spektral Yoğunluğu (PSD) elde edilen sinyallerden 20 adet istatistiksel ve spektral özellik çıkarımı yapılmış ve öznelik vektörü oluşturulmuştur. Spearman korelasyon katsayısı ile her özelliğin etiket ile korelasyon ilişkisine bakılmış ve eşik değerine göre 9 özellik seçimi yapılarak yeni öznelik vektörü oluşturulmuştur. Elde edilen öznelik vektörlerinin %70'i eğitim, %30'u test olarak ayrılmıştır. Makine öğrenme (ML) yöntemlerinden Destek Vektör Makineleri (SVM) ve k-En Yakın Komşu (kNN) yöntemleri 10 kat çapraz doğrulama ile eğitim ve test işlemleri Temel Bileşen Analizi (PCA) uygulanmadan ve uygulanarak gerçekleştirilmiştir. Çıkan sonuçlar doğruluk, duyarlılık, özgüllük, hassasiyet ve F-Skor değerlerine göre karşılaştırılmıştır. AH tanısında en iyi doğruluk oranı 20 özellikten oluşan öznelik vektörüne PCA uygulanmasıyla %96.59 SVM ile elde edilmiştir.

Anahtar Kelimeler: EEG, Alzheimer Hastalığı, Makine Öğrenimi, SVM, kNN.

Diagnosis of Alzheimer's Disease from EEG Signals with Machine Learning Methods

Abstract

Alzheimer's is an irreversible neurodegenerative disease with progressive loss of cognitive and neurological functions that negatively affects human life. Since the disease is incurable, early diagnosis and slowing down the progression is of great importance. Prolonged diagnosis leads to delayed treatment and increased cognitive and neurological deficits. The aim of this study is to diagnose Alzheimer's disease (AD) from Electroencephalogram (EEG) signals using machine learning methods to minimize these losses. In this study, EEG signals of 24 people with AD and 24 healthy people were divided into 4-second epochs with 50% overlap. Independent Component Analysis (ICA) values of the signals were calculated and automatic noise removal was performed from the EEG channels according to the ICA values. The transition of each signal from the time domain to the spectral domain was performed using the Welch method. In the range of 1-30 Hz, 20 statistical and spectral features were extracted from the signals whose Power Spectral Density (PSD) was obtained by Welch Spectral analysis and a feature vector was created. Spearman correlation coefficient was used to correlate each feature with the label and 9 features were selected according to the threshold value and a new feature vector was created. Of the feature vectors obtained, 70% of the feature vectors were allocated as training and 30% as test. Machine learning (ML) methods Support Vector Machines (SVM) and k-Nearest Neighbor (kNN) methods were trained and tested with 10-fold cross validation without and with Principal Component Analysis (PCA). The results were compared according to accuracy, sensitivity, specificity, precision and F-Score values. The best accuracy rate for AD diagnosis was 96.59% with SVM by applying PCA to a feature vector consisting of 20 features.

Keywords: EEG, Alzheimer's Disease, Machine Learning, SVM, kNN

¹Ordu Üniversitesi, Bilgisayar Kullanımı Bölümü / Akkuş Meslek Yüksekokulu, Ordu, Türkiye, yelizsenkaya@odu.edu.tr

²Ondokuz Mayıs Üniversitesi, Elektrik-Elektronik Mühendisliği / Mühendislik Fakültesi, Samsun, Türkiye, ckurnaz@omu.edu.tr

*Sorumlu Yazar/Corresponding Author

Geliş/Received: 12.09.2023

Kabul/Accepted: 25.12.2023

Yayın/Published: 15.03.2024

1. Giriş

Sağlık alanında gelişen teknoloji ve yöntemler ile insan yaşam süresi uzamakta ve dünya yaşlı nüfusu artış göstermektedir. Bu durum beraberinde çoğunlukla yaşlılık sürecinde ortaya çıkan bunamanın artmasına sebep olmaktadır. Türk Dil Kurumu (2023) “bunama” ‘yı “yaşlanma veya bazı sinir hastalıklarına bağlı olarak başta bellekte olmak üzere zihinsel işlevlerde bozulma” şeklinde tanımlarken, tıp literatüründeki karşılığı ise “demans” ‘tır. 2018 yılında yayınlanan “Dünya Alzheimer Raporu” ‘na göre dünya çapında 50 milyon kişi demans hastalığına sahiptir. 2050 yılında ise demans hastalarının 152 milyondan fazla olması beklenmektedir (Patterson, 2018). Demans vakalarının %60-70 gibi büyük bir kısmını ise AH oluşturmaktadır (Durongbhan ve ark., 2019). AH duygu, davranış, hafıza, dil ve yargılamadaki değişiklikler de dahil olmak üzere nörolojik, zihinsel ve bilişsel işlevlerin ilerleyici kaybı olan, geri dönüşümsüz bir tür nörodejeneratif hastalıktır (Fonteijn ve ark.,2012; Ghanemi, 2015; AlSharabi ve ark., 2022). Mevcut tedavi yöntemleri AH’ni iyileştiremezken, erken tanı hastalığın ilerleme sürecini yavaşlatılabildiğinden büyük önem taşımaktadır. Üniversite hastanelerinde deneyimli profesyonellerin uzun seansları sonucunda AH tanı doğruluk oranı ise %85-93 arasında değişmektedir (Miltiadous ve ark., 2023). Bu bilgiler doğrultusunda hem AH tanı doğruluk oranını arttırmak, hem de iş yükünü azaltmak için yeni araştırmalar yapılması gerekliliği ortaya çıkmıştır.

AH’nın beyin sinyallerinden otomatik olarak tespit edilmesi için son yıllarda birçok çalışma yapılmıştır. Beyin sinyallerini elde etmenin en etkili yöntemlerinden birisi kafa derisinden alınan ve noninvaziv olan EEG yöntemidir. EEG yöntemi zaman ve maliyet açısından diğer yöntemler göre çok daha uygundur. Bu sebeple EEG sinyalinden AH tanısı üzerine sıkça araştırma yapılan bir konu olmuştur.

AlSharabi ve arkadaşları AH tanısı için EEG veri setinden gürültüleri temizledikten sonra veriye Ayrık Dalgacık Dönüşümü (DWT) tekniği uygulayarak sinyali alt frekans bantlarına ayırmışlardır. EEG öznitelik vektörünü oluşturmak için logaritmik bant gücü, standart sapma, varyans, basıklık, ortalama enerji, kök ortalama kare ve Norm sinyal özelliklerini hesaplamışlardır. Elde edilen öznitelik vektörleri 9 farklı sınıflandırma algoritması ile sınıflandırılmış ve en iyi doğruluk KNN sınıflandırıcı ile %99,98 olarak bulunmuştur (AlSharabi ve ark., 2022)

Miltiadous ve arkadaşları kendi oluşturdukları 88 denekten oluşan EEG veri seti üzerinde çalışma yapmışlardır. Elde ettikleri EEG’yi Butterworth filtresi kullanarak 1-45 Hz aralığında sınırlandırarak gürültü temizleme, özellik çıkarma işleminden sonra AH EEG sınıflandırması için yeni bir yaklaşım olarak Çift Girişli Evrişim Kodlayıcı Ağı (DICE-net) önermişlerdir. DICE-net ile %83,28’lük doğruluk oranı elde etmişlerdir (Miltiadous ve ark., 2023).

Safi ve arkadaşı erken AH tanısı için EEG'ye ön işlem yaptıktan sonra sinyali DWT ve ampirik mod ayrıştırma gibi farklı sinyal ayrıştırma yöntemleri kullanarak sinyali alt frekans bantlarına ayırarak öznitelik vektörünü oluşturmuşlardır. Oluşturdukları öznitelik vektörünü Hjorth parametreleri ile birleştirmeden ve birleştirdikten sonra sınıflandırma yapmışlardır. En iyi doğruluk oranını Hjorth parametreleri ile birleştirilen öznitelik vektörünün kNN ile sınıflandırılması ile %97,64 olarak elde etmişlerdir (Safi ve Safi, 2021).

Bairagi çalışmasında erken tanı için spektral ve Dalgacık Dönüşümlü (WT) öznitelik vektörlerini kullanarak sınıflandırma yapmıştır. En iyi doğruluk oranını spektral öznitelik vektörünün SVM sınıflandırılması ile %94 olarak bulmuştur (Bairagi, 2018).

Durongbhan ve arkadaşları AH erken tanısı için 40 kişiden oluşan 12 saniyelik EEG kayıtlarını kullanmışlardır. Kullandıkları veri setinin az olmasından dolayı 12 sn'lik kayıtları epoklara ayırarak veri setini büyütmüşler ve işlem yapmışlardır. Öznitelik vektörünü oluşturmadan önce verilere Kısa Zamanlı Fourier Dönüşümü (FFT) ve Sürekli Dalgacık Dönüşümü (CWT) uygulayarak verileri 5 alt banda ayırtmışlardır. Öznitelik vektörünü oluşturduktan sonra kNN sınıflandırıcısını uygulayarak doğruluk oranlarını elde etmişlerdir. Bazı EEG kanalları için FFT öznitelikleri için %97'ye ve CWT öznitelikleri için %99'a varan sınıflandırma doğruluğuna ulaşmışlardır (Durongbhan ve ark., 2019).

Vecchio ve arkadaşları toplam 295 denek üzerinde yaptıkları çalışmada sinyali alt frekanslarına ayırarak SVM sınıflandırıcısını kullanmış ve %95 ±%3 doğruluk oranına ve AUC 0.97±0.03 değerine ulaşmışlardır (Vecchio ve ark., 2020).

Morabito ve arkadaşları yaptıkları çalışmada EEG sinyalini 5 saniyelik epoklara ayırarak özellik çıkarımı yapmışlardır. Her kanal için 12 özellik olmak üzere toplamda 228 özellik çıkararak Evrişimsel Sinir Ağları (CNN) ile sınıflandırma yapmışlardır ve ortalama %80 doğruluk oranına ulaşmışlardır (Morabito ve ark., 2016).

Aslan, EEG sinyallerinden AH tanısı yapmak için, EEG sinyallerine ön işlem yaparak gürültüleri temizledikten sonra her bir kanaldan alınan sinyallere WT uygulamış ve istatistiksel özellikleri hesaplamıştır. kNN sınıflandırıcısı ile öznitelik vektörünü sınıflandırmış ve %91.12 doğruluk ile Alzheimer ve sağlıklı kişileri ayırt etmiştir (Aslan, 2022).

Fiscon ve arkadaşları, EEG sinyallerine ön işlem uyguladıktan sonra FFT ve DWT uygulayarak sınıflandırma başarımlarını karşılaştırmışlardır. DWT uygulanan sinyallerin FFT uygulanan sinyallere göre daha iyi sonuçlar verdiği sonucunu elde etmişlerdir (Fiscon ve ark., 2018).

Sadık, EEG sinyallerinin PSD'nu elde etmek için Welch metodunu kullanmıştır. Her kanaldan spektral ve istatistiksel 28 öznitelik çıkarmış ve bu öznitelikleri karar ağacı öznitelik önem algoritmasına göre 5'e indirgeyerek sınıflandırma yapmıştır. En iyi sınıflandırma performansını Gradyan Artırma Sınıflandırıcısı (GBC) algoritması ile %96.43 olarak elde etmiştir (Sadık, 2022).

Göker, EEG sinyallerinin 1-49 Hz arasındaki frekansların PSD'nu kullanarak 49 öznitelik çıkarmış ve topluluk öğrenme algoritmaları ile sınıflandırma yapmıştır. Kullandığı farklı topluluk öğrenme algoritmaları arasından en iyi performansı %93.04 doğruluk ile Logit Boost algoritması elde etmiştir (Göker, 2023).


Göker, EEG sinyallerinin 1-49 Hz arasındaki frekansların PSD'nu kullanarak öznitelik çıkarmış ve çıkarılan öznitelikler ML ve Derin Öğrenme (DL) yöntemleri kullanarak sınıflandırmıştır. En iyi sınıflandırma doğruluğu %98.85 ile DL yöntemlerinden çift yönlü uzun-kısa süreli bellek algoritması (BiLSTM) ile bulunmuştur (Göker, 2023).

AH insan yaşamını olumsuz yönde etkileyen bir tür nörodejeneratif hastalıktır. Bu hastalığın geri dönüşümü mümkün olmadığından erken tanı ile hastalığın ilerleyişini yavaşlatmak büyük önem arz etmektedir. Klinik testlerin çok uzun bir süreç olması erken tanı aşamasını olumsuz yönde etkilemektedir.

Bu çalışmada, Dr. Dennis Duke ve Florida Eyalet Üniversitesi araştırmacıları tarafından kaydedilmiş olan açık kaynaklı EEG veri seti kullanılmıştır. EEG sinyalleri üzerinde sinyal işleme yöntemleri ile AH erken tanısı yapılması amaçlanmıştır. Kullanılan veri seti ile ilgili daha önce birçok çalışma yapılmıştır. Bu çalışmanın diğer çalışmalardan en önemli farkı sinyalin 4 saniyelik bölütlere ayrılırken %50 örtüşme kullanılarak ayrılmasıdır. Yapılan çalışmanın, AH erken tanısı gerçekleştirilmek istenen bilimsel çalışmalara katkıda bulunacağı düşünülmektedir.

2. Materyal ve Metot

Beyinde yer alan sinir hücrelerinin elektriksel aktiviteleri sonucu oluşan sinyale EEG denir [9]. EEG sinyali beyin hakkında önemli bilgileri içinde barındırdığından sinyalin doğru şekilde yorumlanması için uygun yöntemlerle işlenmesi gerekmektedir. Sinyal işleme uygulamaları genellikle ön işleme, özellik çıkarma ve sınıflandırma olmak üzere üç aşamadan oluşmaktadır (Garcés ve Orosco, 2008).



Şekil 1. Önerilen modelin aşamaları

Bu bölümde AH otomatik tanısı için önerilen ML modelinin aşamaları Şekil 1'de sunulmuştur. Önerilen modelde ilk aşamada ham EEG verileri %50 örtüşme ile 4 sn epoklara ayrılarak gürültülerden temizlenmiştir. İkinci aşamada 1-30 Hz aralığındaki sinyalin her kanalı Welch Spektral analizi kullanılarak PSD elde edilmiştir. PSD'dan istatistiksel ve spektral özellikler çıkarılarak


öznitelik vektörü oluşturulmuştur. Son aşamada ise öznitelik vektörlerinden oluşan EEG veri setinin %70'i eğitim, %30'u test olmak üzere ikiye ayrılmış ve iki farklı ML yöntemi olan SVM ve kNN ile sınıflandırılmıştır.

2.1. Veri Seti

Bu çalışmada, Dr. Dennis Duke ve Florida Eyalet Üniversitesi araştırmacıları tarafından 48 denekten kaydedilmiş olan açık kaynaklı EEG veri seti kullanılmıştır. Bu kayıtlar Biologic Systems Brain Atlas III Plus iş istasyonu kullanılarak uluslararası 10-20 sistemine göre 19 elektrot (Fp1, Fp2, Fz, F3, F4, F7, F8, Cz, C3, C4, T3, T4, Pz, P3, P4, T5, T6, O1 ve O2) kullanılarak kaydedilmiştir. Kayıtlar 1-30 Hz aralığında bant sınırlı, 8 sn süreli ve 128 Hz örnekleme frekansına sahiptir. 48 EEG kaydı her biri 12 denek olmak üzere A, B, C ve D gruplarından oluşmaktadır. A ve B grupları nörolojik veya psikiyatrik bozukluğu bulunmayan 24 sağlıklı yaşlıdan (ortalama yaş 72, aralık 61-83) oluşurken, C ve D grupları ise “Ulusal Nörolojik ve İletişimsel Bozukluklar ve İnme Enstitüsü ve Alzheimer Hastalığı ve İlişkili Bozukluklar Derneği” (NINCDS-ADRDA) ve “Mental Bozuklukların Tanısal ve İstatistiksel El Kitabı” (DSM)-III-R kriterlerine göre tanı konmuş 24 olası Alzheimer hastasından (ortalama yaş 69, aralık 53-85) oluşmaktadır. Deneklerin EEG kayıtları alınırken A ve C setlerinde gözler açık, B ve D setlerinde ise gözler kapalıdır (Pineda ve ark, 2020).

2.2. Ön İşleme

Sinyal ön işleme, toplanan EEG sinyalindeki gürültüyü temizleyerek veya azaltarak güvenilir özellikler elde etmek için sinyalin işlemlerden geçirilmesidir (Büyüköze, 2019). Beyin sinyalleri çok düşük genliğe sahip olduğundan kaydedilirken kişi ve çevre kaynaklı sinyaller de EEG sinyaline eklenerek sinyalde bozulmaya sebep olmaktadır. Bu sebeple EEG sinyallerinden özellik çıkarmadan önce, toplanan sinyallerin bir takım ön işlemlerden geçirilerek daha temiz ve belirgin bir duruma getirilmesi gerekir. Bu çalışmada ön işlem adımı olarak öncelikle 8 sn uzunluğundaki sinyal epoklara ayrılmak istenmiştir. Literatür incelendiğinde EEG kayıtlarının 2 ile 30 sn arasında epoklara bölünebildiği ve örtüşme yapılabildiği görülmüştür (Miltiadous ve ark., 2023; Vecchio ve ark, 2020; Smith ve ark., 2017). Buradan hareketle EEG kayıtları Şekil 2’de gösterildiği gibi Matlab uygulaması EEGLAB platformu kullanılarak %50 örtüşme ile 4 saniyelik epoklara ayrılmıştır. Bu şekilde sinyal bölümlere ayrılırken sinyaldeki kayıplar en aza indirgenmeye çalışılmıştır. Ardından EEGLAB üzerinde “RunICA” algoritması çalıştırılarak EEG sinyalinin her kanalı için Bağımsız Bileşen Analizi (ICA) hesaplanmıştır. EEGLAB “Adjust” eklentisi ICA’yı kullanarak sinyal kanallarında bulunan gürültüler sinyalden otomatik olarak temizlenmiştir (Smith ve ark., 2017).



Şekil 2. 8 saniyelik EEG sinyalinin %50 örtüşme ile 4 saniyelik epoklara ayrılmasının gösterimi

2.3. Özellik Çıkarımı

Özellik çıkarmanın temel amacı, sinyallerin barındırdığı ayırt edici özelliklerin çıkarılıp öznitelik vektörünün oluşturulması işlemidir. Ancak sinyallerin barındırdığı ayırt edici özelliklerin hepsi zaman alanında ortaya çıkmayabilir. Bu sebeple sıklıkla spektral alana geçiş yapılmaktadır. Spektral alan, sinyalleri ayırt etmek ve ilgili verilerden bilgi çıkarmak için yaygın olarak kullanılan bir yöntemdir (Parhi ve Ayinala, 2013). Ön işlemden geçirilen EEG sinyalinin her bir kanalı için 1-30 Hz aralığı zaman alanından spektral alana geçiş yapmak için Welch Spektral analizi kullanılmıştır. Welch Spektral analizinde giriş sinyali örtüşen segmentlere ayrılır. Seçilen pencere fonksiyonu her segmente uygulanır. Pencerelemiş segmentlere FFT uygulanarak her pencerelemiş segmentin periyodogramı hesaplanır ve Pencerelemiş segmentlerin periyodogramının ortalaması alınarak PSD Denklem (1)'de gösterildiği gibi hesaplanır (Parhi ve Ayinala, 2013). Bu çalışmada pencere fonksiyonu olarak “Hamming” penceresi seçilmiştir ve örtüşme oranı %75 (Smith ve ark., 2017) olarak belirlenmiştir ve PSD elde edilmiştir.

$$S(w) = \frac{1}{L} \sum_{l=1}^L \phi_l(w) \quad (1)$$

L pencerelemiş bölümlerin toplam sayısı, $\phi_l(w)$ pencerelemiş bölümlerin periyodogramı, $S(w)$ ise pencerelemiş bölümlerin periyodogramının ortalamasıdır.

EEG sinyalinin her kanalı için spektral alanda istatistiksel ve spektral 20 özellik çıkarılarak öznitelik vektörü oluşturulmuştur. Öznitelik vektörü oluşturulurken belirlenen özellikler Alzheimer ve Kontrol gruplarının EEG sinyallerinin farklılıklarının ortaya çıkarılması amaçlanmıştır. Buradan hareketle sinyalin spektral alanda istatistiksel olarak Kurtosis (basıklık), Mean (ortalama), RMS (kök ortalama kare), Skewness (çarpıklık), Std (standart sapma), Variance(varyans) ve Norm değerleri hesaplanmıştır. Spektral özellikler olarak sinyalin PeakAmp1(en yüksek genlik), PeakFreq1(en yüksek frekans), BandPower (bant gücü), DeltaBandPower (delta bant gücü), ThetaBandPower (theta

band gücü), AlphaBandPower(alpha bant gücü), BetaBandPower(beta bant gücü) ve bu 4 alt bandın birbirine oranları hesaplanarak 6 özellik daha belirlenmiştir. Alt bantların frekans aralıkları; Delta 1-4 Hz, Theta 4-8 Hz, Alpha 8-13 Hz, Beta 13-25 Hz'tir.

Öznitelik vektöründeki her özelliğin etiket ile korelasyon ilişkisi Spearman korelasyon katsayısı ve Pearson korelasyon katsayısı ile hesaplanarak en iyi özelliklerin seçimi yapılmıştır. Spearman korelasyon katsayısı Denklem (2)'de (Xiao ve ark., 2016), Pearson korelasyon katsayısı Denklem (3)'te (Benesty ve ark., 2008) gösterildiği gibi hesaplanmıştır.

$$r_s = 1 - \frac{6 \sum d_i^2}{N(N^2-1)} \quad (2)$$

r_s Spearman korelasyon katsayısı, d_i sıralanan değişkenlerin her bir çifti arasındaki fark, N ise toplam örnek sayısıdır.

$$p(x, y) = \frac{\sum[xy]}{\sigma_x \sigma_y} \quad (3)$$

$p(x, y)$ x ve y değişkenlerinin Pearson korelasyon katsayısını, $\sum[xy]$ x ve y arasındaki çapraz korelasyonu, σ_x ve σ_y sırasıyla x ve y sinyallerinin varyanslarıdır. Özelliklerin Spearman ve Pearson korelasyon katsayıları Tablo1'de gösterilmiştir.

Tablo 1. Spearman ve Pearson korelasyon katsayılarına göre özelliklerin etiket ile ilişkisi

Özellik No ve Adı	Spearman Korelasyon Katsayısı	Pearson Korelasyon Katsayısı	Özellik No ve Adı	Spearman Korelasyon Katsayısı	Pearson Korelasyon Katsayısı
1- Kurtosis	0.7152	-0.6427	11- DeltaBandPower	0.6316	-0.5368
2- Mean	0.3718	-0.3229	12- ThetaBandPower	-0.1655	0.0866
3- RMS	0.4927	-0.3248	13- AlphaBandPower	0.0939	-0.2135
4- Skewness	0.7020	-0.6782	14- BetaBandPower	0.2929	-0.2476
5- Std	0.5259	-0.3245	15- Delta_theta	-0.7673	0.6451
6- Variance	0.5259	-0.1149	16- Delta_alpha	-0.3950	0.0848
7- Norm	0.4927	-0.3248	17- Delta_beta	-0.3362	0.2063
8- PeakAmp1	-0.0800	-0.1619	18- Theta_alpha	0.3177	-0.2573
9- PeakFreq1	0.2884	-0.2421	19- Theta_beta	0.4341	-0.1322
10- BandPower	0.3216	-0.2978	20- Alpha_beta	0.1249	-0.0633

Negatif değerli korelasyon katsayıları ilişkinin ters yönde olduğunu gösterdiğinden bu değerlerin mutlak değerleri alınarak etiket ile en iyi korelasyona sahip özelliklerin seçimi için Denklem (4)'te verildiği şekilde katsayıların ortalaması $R_{esik_spearman} = 0.4038$ ve $R_{esik_pearson} = 0.2954$ olarak bulunmuştur.

$$R_{esik} = \frac{1}{K} \sum_{k=1}^K r_k \quad (4)$$

R_{esik} korelasyon katsayılarının ortalamasını, K özellik sayısını, r_k ise k numaralı özelliğin korelasyon katsayısını göstermektedir. Her iki korelasyon katsayısı yönteminde $R_{esik_spearman}$ ve $R_{esik_pearson}$ değerlerine bakılmış ve korelasyon katsayısı ve eşik değeri daha yüksek olan Spearman yöntemi ile özellik seçimi yapılmıştır. $R_{esik_spearman}$ değerinin üzerinde korelasyon katsayısına sahip olan özellikler Tablo 2'de gösterilmiştir.

Tablo 2. Spearman korelasyon katsayısının eşik değerine göre belirlenen özellikler

Özellik no	Korelasyon Katsayısı
15	0.7673
1	0.7152
4	0.7020
11	0.6316
5	0.5259
6	0.5259
3	0.4927
7	0.4927
19	0.4341

Öznitelik matrislerinin %70'i ML sınıflandırıcısının eğitimi, %30'u ise testte kullanılmak için sistematik örnekleme ile belirlenmiştir.

2.4. Sınıflandırma

ML, açık talimatlar veya insan müdahalesi olmaksızın verilerden ve deneyimlerden otomatik olarak öğrenebilen ve uyarlanabilen bilgisayar modelleri ve algoritmalar olarak tanımlanabilir. Sınıflandırma, bilinmeyen bir örüntüye ait öznitelik vektörünün hangi sınıfa ait olduğunun karar mekanizması yardımıyla belirlenmesidir (Günel, 2001). Bu çalışmada denetimli ML yönteminde yer alan ve EEG AH erken tanısında sıklıkla kullanılan SVM ve kNN sınıflandırıcıları kullanılmıştır. SVM ve kNN sınıflandırıcıları, hangi sınıfa (çıktı) ait olduğu önceden bilinen öznitelik vektöründeki girdileri kullanarak öğrenme modeli oluştururlar. Oluşturulan modeller, eğitim ve deneyimlerden yola çıkarak sisteme yeni eklenen öznitelik vektörlerinin hangi sınıflara ait olabileceğine karar verirler.

SVM sınıflandırıcısı, öznitelik uzayında bulunan iki sınıfı birbirinden ayırmak için en uygun ayırıcı hiper düzlemi bulmayı amaçlayan bir öğrenme algoritmasıdır (Safi ve Safi, 2021). kNN

sınıflandırıcı ise öznitelik uzayındaki en yakın eğitim örneklerine dayanarak nesnelere sınıflandırmayı amaçlayan öğrenme algoritmasıdır (Safi ve Safi, 2021). Bu çalışmada eğitim veri setleri SVM ve kNN sınıflandırıcı algoritmaları ile eğitilirken 10 kat çapraz doğrulama kullanılmıştır. SVM algoritmasında çekirdek fonksiyon olarak Kuadratik (Quadratic) kullanılırken, kNN de ise Ağırlıklı (Weighted) yöntem kullanılmıştır. Her iki sınıflandırmada da en iyi doğruluk oranlarının elde edilmesi için öznitelik vektörlerine PCA uygulanmıştır. PCA öznitelik vektörlerinin (veri setinin) en anlamlı temelini belirleyerek yeniden ifade etmek için kullanılmaktadır (Kurita, 2019). 20 özellikten oluşan öznitelik vektöründe PCA sayısal bileşen sayısı "14", 9 özellikten oluşan öznitelik vektöründe PCA sayısal bileşen sayısı "8" olarak belirlenmiştir. Eğitilen modelin en iyi sonucu vermesi için Bayes optimizasyon yöntemi kullanılarak hiperparametreler belirlenmiştir. Bayes optimizasyon modeli ile eğitilen modelde SVM sınıflandırmasının en iyi eğitim sonucu olan %96.0 değerini veren çekirdek ölçeği "1", kutu kısıtlama seviyesi "3.9615" olan parametreler seçilmiştir. 20 özellikten oluşan eğitim veri seti üzerinde PCA uygulanmadan SVM sınıflandırma parametrelerinin analizlerinin bir bölümü Tablo 3'te ayrıntılı olarak sunulmuştur.

Tablo 3. SVM sınıflandırma parametrelerinin analizinin bir bölümü

Özellik Sayısı	PCA	Çekirdek Ölçeği	Kutu Kısıtlama Seviyesi	Eğitim %
20	Auto		1	94.5
			2	94.9
			3	95.1
			3.9615	95.1
			1	95.4
			2	95.6
	Hayır	1	3	95.9
			3.9615	96.0
			1	94.6
			2	94.9
			3	95.1
			3.9615	95.1

Bayes optimizasyon modeli ile eğitilen modelde kNN sınıflandırmasının en iyi eğitim sonucu olan %95.0 değerini mesafe metriği "Mahalanobis", komşu sayısı "1" ve mesafe ağırlığı "squared inverse" olan parametreler seçilmiştir. 20 özellikten oluşan eğitim veri seti üzerinde PCA uygulanmadan kNN sınıflandırma parametrelerinin analizlerinin bir kısmı Tablo 4'te ayrıntılı olarak sunulmuştur.

Eğitilen sınıflandırma modellerinin performanslarını değerlendirmek için %30'luk test verisi kullanılmış ve değerlendirme performansları olarak doğruluk, duyarlılık, özgüllük, hassasiyet ve F-Skor değerleri aşağıdaki Denklemler ile hesaplanmıştır:

$$Doğruluk = \frac{TP+TN}{TP+FN+TN+FP} \times 100 \quad (5)$$

$$Duyarluluk = \frac{TP}{TP+FN} \quad (6)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (7)$$

$$Hassasiyet = \frac{TP}{TP+FP} \quad (8)$$

$$F - Skor = \frac{2 * Duyarluluk * Hassasiyet}{Duyarluluk + Hassasiyet} \quad (9)$$


Burada TP , FP , TN ve FN sırasıyla doğru pozitif, yanlış pozitif, doğru negatif ve yanlış negatiftir.

Tablo 4. kNN sınıflandırma parametrelerinin analizinin bir bölümü

Özellik Sayısı	PCA	Mesafe Metriği	Komşu Sayısı	Eğitim %
20	Hayır	Euclidean	1	94.2
			2	94.2
		City Block	1	93.7
			2	93.7
		Chebyshev	1	93.4
			2	93.5
		Minkowski(cubic)	1	93.7
			2	93.7
		Mahalanobis	1	95.0
			2	95.0
		Cosine	1	93.4
			2	93.4
		Correlation	1	93.1
			2	93.1
		Spearman	1	93.0
			2	93.1
		Hamming	1	49.9
			2	49.8
		Jaccard	1	49.9
			2	49.8

3. Bulgular ve Tartışma

Toplamda 24'ü sağlıklı, 24'ü AH olan 48 denekten 8 sn olarak kaydedilen EEG verileri, veri setinin büyütülmesi için her bir kayıt %50 örtüşme ile 4 sn'lik epoklara ayrılarak ICA değerleri hesaplanmış ve otomatik gürültü temizleme işlemi yapılmıştır. Şekil 3'te 25 numaralı AH'nın ön işlemden önceki ve sonraki ilk 4 sn'nin görüntüsü verilmiştir.



Şekil 3. 25 numaralı AH'nın EEG ham verisinin gürültü temizlemeden önceki (a) ve sonraki (b) ilk 4 saniyesi

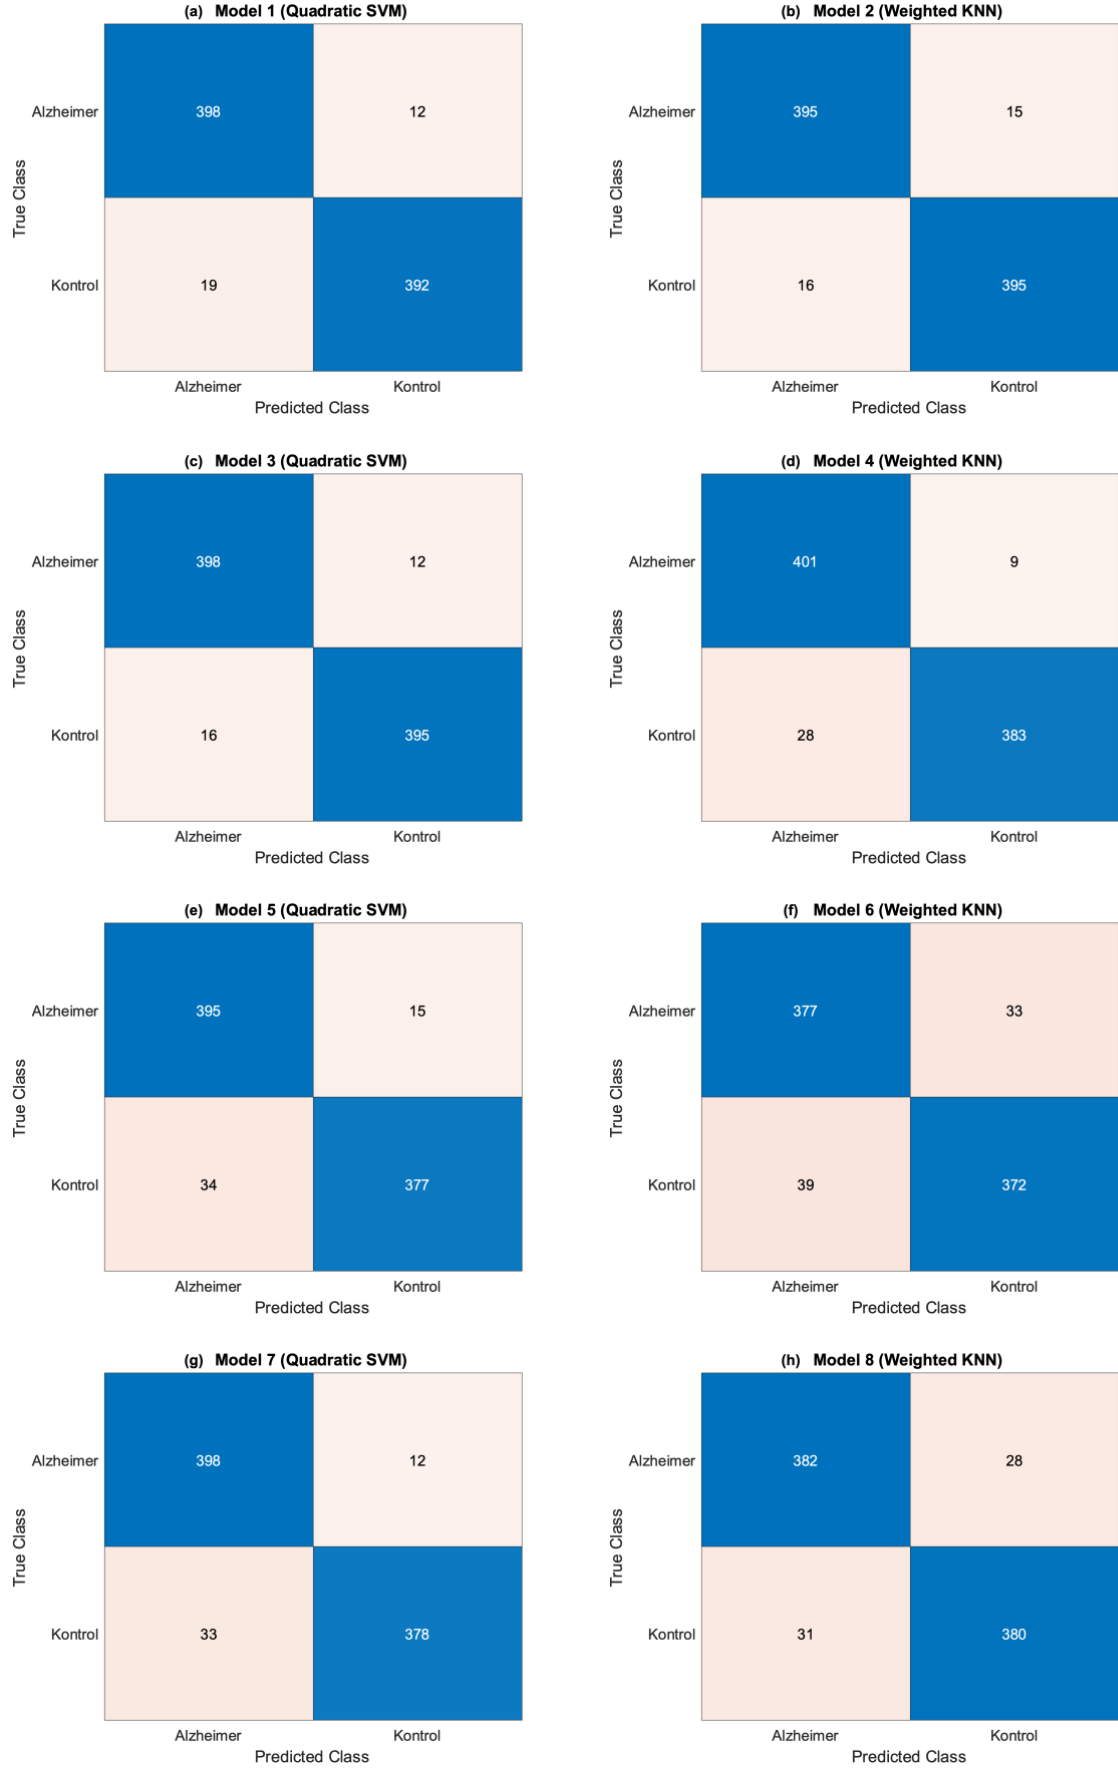
Gürültülerden temizlenen ve epoklara ayrılan EEG verilerinin 19 kanalı 19 farklı sinyal olarak ayrılmış ve toplamda $48 \times 3 \times 19$ sinyal elde edilmiştir. 1-30 Hz aralığında sinyallerin öznitelik vektörlerinin oluşturulması için Welch Spektral analizi ile PSD hesaplanan sinyallerden istatistiksel ve spektral 20 özellik çıkarımı yapılmıştır. Toplamda 2736×20 'lik öznitelik vektörü elde edilmiştir. Öznitelik vektöründe özelliklerin etiket ile olan ilişkisi Spearman korelasyon katsayısı ile hesaplanarak eşik değer üzerinde olan 9 özellikten 2736×9 'lık yeni öznitelik vektörü oluşturulmuştur. Öznitelik vektörlerinin eğitim ve test dağılımları sistematik olarak gerçekleştirilmiş ve Tablo 5'de ayrıntılı şekilde verilmiştir.

Tablo 5. Öznitelik vektörlerinin eğitim ve test dağılımları


Veri Seti	Etiket	Veri Sayısı	Yüzelik Oran	Toplam Veri Sayısı	Toplam Oran %
Eğitim	Alzheimer	958	%50.03	1915	%70
	Sağlıklı	957	%49.97		
Test	Alzheimer	410	%49.94	821	%30
	Sağlıklı	411	%50.06		

20 özellikten oluşan öznitelik vektörü ve 9 özellikten oluşan öznitelik vektörünün PCA uygulanmadan ve uygulanarak eğitilen SVM ve kNN ML modellerinin test karmaşıklık matrisleri Şekil 4'te, Eğri altında kalan alan (AUC)'ın da hesaplandığı ROC eğrileri ise Şekil 5'te verilmiştir.

Eğitilen modellerin Şekil 4'te ki test karmaşıklık matrislerine ve Şekil 5'te ki ROC eğrilerine bakıldığında en iyi sonucun 20 özellikten oluşan öznitelik vektörünün PCA uygulanarak SVM ile sınıflandırıldığında elde edildiği görülmektedir. Öznitelik vektöründeki özellik sayılarına göre eğitilen SVM ve kNN modellerinin doğruluk, duyarlılık, özgüllük, hassasiyet ve F-Skor performansları Tablo 6'da sunulmuştur. En iyi doğruluk oranı %96.59 ile 20 özellikten oluşan öznitelik vektörünün PCA uygulanarak SVM modeli ile eğitilip test edilmesinden elde edilmiştir. Bu modelin Şekil 4 c)'da verilen test karmaşık matrisi daha ayrıntılı incelendiğinde AH doğruluk tahmini %97.07 elde edilirken, kontrol grubu doğruluk tahmini %96.10'dur. Yanlış tahmin oranları ise AH grubunda %2.93 iken, kontrol grubunda %3.90 olarak bulunmuştur. Buradan hareketle AH denekleri sınıflandırması kontrol grubuna oranla daha iyi sonuç vermiştir.



Şekil 4. Karmaşıklık matrisleri; a) 20 özellik ile eğitilen SVM modeli, b)20 Özellik ile eğitilen kNN modeli, c)20 özellik ile PCA uygulanarak eğitilen SVM modeli, d)20 Özellik ile PCA uygulanarak eğitilen kNN modeli, e)9 özellik ile eğitilen SVM modeli f) 9 özellik ile eğitilen kNN modeli g)9 özellik ile PCA uygulanarak eğitilen SVM modeli ve h) 9 özellik ile PCA uygulanarak eğitilen kNN modeli



Şekil 5. ROC Eğrileri; a) 20 özellik ile eğitilen SVM modeli, b) 20 Özellik ile eğitilen kNN modeli, c) 20 özellik ile PCA uygulanarak eğitilen SVM modeli, d) 20 Özellik ile PCA uygulanarak eğitilen kNN modeli, e) 9 özellik ile eğitilen SVM modeli f) 9 özellik ile eğitilen kNN modeli g) 9 özellik ile PCA uygulanarak eğitilen SVM modeli ve h) 9 özellik ile PCA uygulanarak eğitilen kNN model

Tablo 6. Modellerin doğruluk, duyarlılık, özgüllük, hassasiyet, F-Skor performansları

Özellik Sayısı	PCA	Sınıflandırma	Doğruluk %	Duyarlılık	Özgüllük	Hassasiyet	F-Skor
20	Hayır	SVM	96.22	0.95	0.97	0.97	0.96
		kNN	96.22	0.96	0.96	0.96	0.96
	Evet	SVM	96.59	0.96	0.97	0.97	0.97
		kNN	95.49	0.93	0.98	0.98	0.96
9	Hayır	SVM	94.03	0.92	0.96	0.96	0.94
		kNN	91.23	0.91	0.92	0.92	0.91
	Evet	SVM	94.52	0.92	0.97	0.97	0.95
		kNN	92.81	0.92	0.93	0.93	0.93

Deneysel sonuçlarda iki farklı özellik sayısından oluşan (20 ve 9) öznitelik vektörlerinin sınıflandırılmasında SVM modellerinin kNN modellerinden küçük farkla da olsa daha iyi sınıflandırma yaptığı Tablo 6'da açıkça görülmektedir. SVM modellerinin ve kNN modellerinin iki farklı özellik sayısındaki (20 ve 9) doğruluk oranlarına bakıldığında daha fazla özellikle PCA uygulanarak eğitilip test edilen SVM modeli %96.59 doğruluk oranını yakalarken, kNN modelinde ise daha fazla özellikle PCA uygulanmadan en iyi doğruluk oranı %96.22 elde edilmiştir. PCA ile eğitilen modellerin bu sonuç dışındaki doğruluk oranlarına bakıldığında uygulanmamış halinden daha iyi sonuçlar verdiği açıkça görülmektedir.

Tablo 7. Önerilen çalışmanın ve diğer çalışmaların sunumu

Araştırmacı	EEG Veri seti	Özellik Çıkarımı	Sinyal Aralığı	Sınıflandırıcı	Doğruluk Oranı
(Alsharabi ve ark., 2022)	35 Sağlıklı, 31 Hafif AD, 22 Orta derece AH	DWT	0.1-60 Hz	Doğrusal Ayrım Analizi (LDA), Kuadratik Ayrım Analizi (QDA), kNN, SVM, Naïve Bayes (NB), Karar Ağacı (DT), Ekstrem Öğrenme Makinesi (ELM), Yapay Sinir Ağı (ANN), Rastgele Ağaç (RF)	%99.98
(Miltiadous ve ark., 2023)	36 AD, 23 Frontotemporal Demans, 29 Sağlıklı	Bağlı Bant Gücü (RBP), Spektral Tutarlılık Bağlantısı (SCC)	0.5-45 Hz	DICE-net	%83.28
(Bairagi, 2018)	20 AH, 25 Sağlıklı	PSD ve DWT	0.5-30 Hz	DT, kNN, SVM, Naïve Bayes, ve Sinir Ağı (NN)	%94
(Morabito ve ark. 2016)	63 AD, 56 Hafif AH, 23 Sağlıklı	CWT	0.1-30 Hz	CNN	%82
(Aslan, 2022)	24 AH, 24 Kontrol	WT ve Hjorth parametreleri	1-30 Hz	kNN	%91.12
(Sadık, 2022)	24 AH, 24 Kontrol	PSD		SVM, kNN, Torbalama Sınıflandırıcısı (BC), GBC	%96.43
(Göker, 2023)	24 AH, 24 Kontrol	PSD	1-49 Hz	Logit Boost	%93.04
(Göker, 2023)	24 AH, 24 Kontrol	PSD	1-49 Hz	RF, kNN, SVM, BİLSTM	%98.85
Önerilen Yöntem	24 AH, 24 Kontrol	PSD	1-30 Hz	SVM, kNN	%96.59

EEG sinyallerinden AH tanısı için Tablo 7’de gösterildiği gibi DWT, CWT, FFT ve PSD gibi farklı özellik çıkarımı yöntemleri ile birçok çalışma yapılmıştır. Çalışmamızda herkese açık bir veri seti kullanıldığından veri setinin kullanıldığı birçok çalışma mevcuttur. Aslan , aynı veri seti üzerinde gürültü temizleme işleminden sonra WT kullanarak frekansları alt bantlarına ayırmış ve Hjorth parametrelerini kullanarak özellik çıkarımı yapmıştır. Elde ettiği öznitelik vektörünü kNN yöntemi ile sınıflandırmış ve %91.12 doğruluk sonucuna ulaştırmıştır (Aslan, 2022). Sadık, aynı veri setinde PSD’nu kullanarak özellik çıkarımı yapmış ve en iyi doğruluk oranını %96.43 olarak GBC ile elde etmiştir (Sadık,2022). Aynı veri seti üzerinde Göker, iki farklı çalışma gerçekleştirmiştir. Her iki çalışmada da 1-49 Hz aralığında PSD ‘nu kullanarak 49 özellikten oluşan öznitelik vektörleri elde etmiştir. Göker, Logit Boost sınıflandırması ile %93.04 doğruluk oranı elde etmiştir (Göker, 2023). Diğer çalışmada ise ML ve DL yöntemlerini kullanarak sınıflandırma gerçekleştirmiş ve doğruluk oranlarını karşılaştırmıştır. ML SVM sınıflandırmasında %90.13, kNN sınıflandırmasında %92.27 sonuçlarını elde etmiştir. DL RF yönteminde %97.04, BİLSTM yönteminde ise %98.85 doğruluk oranına ulaşmıştır (Göker, 2023). Önerilen çalışmanın, diğer çalışmalardan en önemli farkı EEG sinyali 4 sn ‘lik epoklara ayrılırken %50 üst üste örtüşme uygulanmış olmasıdır. Epoklara ayrılan sinyallerde gürültü temizleme işlemi yapılmıştır. Welch metodu ile PSD’u elde edilmiş ve özellik çıkarımı yapılarak öznitelik vektörleri elde edilmiştir. Elde edilen öznitelik vektörüne Spearman korelasyon katsayısı yöntemi uygulanarak özellik seçimi yapılmış, sınıflandırma işlemleri ML yöntemlerinden SVM ve kNN ile gerçekleştirilmiştir. Elde edilen en iyi doğruluk oranı PCA uygulanan SVM ile %96.59 olarak bulunmuştur. Elde edilen sonuç aynı veri seti üzerinde AH tanısı gerçekleştiren diğer ML sınıflandırmaları ile karşılaştırıldığında en iyi doğruluk oranının elde edildiği görülmektedir. Sonuç olarak önerilen yöntem performansı AH tanısında umut verici olmuştur.

4. Sonuçlar ve Öneriler

Bu çalışmada EEG sinyallerinden Alzheimer hastalığının tanısı makine öğrenme yöntemleri ile belirlenmiştir. Çalışmada, Alzheimer hastalığı olan 24 kişi ile sağlıklı 24 kişinin EEG sinyalleri kullanılmıştır. EEG kanallarındaki veriler, Bağımsız Bileşen Analizi (ICA) değerleri kullanılarak otomatik olarak gürültüden arındırılmış ve her bir sinyalin zaman alanından spektral alana geçişi Welch yöntemi ile gerçekleştirilmiştir. Welch Spektral analizi sayesinde elde edilen Güç Spektral Yoğunluğu verilerinden, 20 farklı istatistiksel ve spektral özellik çıkarılmıştır. Her bir özelliğin hastalık durumu ile Spearman korelasyon katsayısı hesaplanarak, bu özelliklerden seçilecek olanları belirlemek üzere bir eşik değeri belirlenmiştir. Sonuç olarak, 9 önemli özellik seçilmiş ve yeni bir öznitelik vektörü oluşturulmuştur. Makine öğrenimi yöntemleri olarak Destek Vektör Makineleri (SVM) ve k-En Yakın Komşu (kNN) kullanılarak, bu yeni öznitelik vektörleri üzerinde eğitim ve test

işlemleri Temel Bileşen Analizi (PCA) uygulanmadan ve uygulanarak gerçekleştirilmiştir. Elde edilen sonuçlar, doğruluk, duyarlılık, özgüllük, hassasiyet ve F-Skor gibi metrikler kullanılarak değerlendirilmiştir. Çalışmanın sonuçları, PCA uygulanan SVM yönteminin Alzheimer hastalığının teşhisinde en yüksek doğruluğu (%96.59) sağladığını göstermektedir. Bu sonuçlar, deneyimli uzmanların hastalık teşhisinde %85-93 arasında bir doğruluk elde ettiği ve bu sürecin uzun zaman aldığı düşünüldüğünde, önerilen yöntemin hem yüksek doğruluk oranına sahip olması hem de kısa sürede sonuç üretebilmesi sayesinde deneyimli profesyonellere yardımcı olabilecek potansiyele sahip olduğunu göstermektedir.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yazarlar, makalenin tüm süreçlerinde “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması gerekli tüm kurallara uyulduğunu, karşılaşılabilecek etik ihlallerden Karadeniz Fen Bilimleri Dergisi ve yayın kurulunun herhangi bir sorumluluğunun bulunmadığını, bu çalışmanın Karadeniz Fen Bilimleri Dergisi dışında herhangi bir akademik yayın ortamında değerlendirilmediğini beyan ederler.

Kaynaklar

- AlSharabi, K., Salamah, Y. B., Abdurraqeeb, A. M., Aljalal, M., and Alturki, F. A. (2022). EEG signal processing for Alzheimer's disorders using discrete wavelet transform and machine learning approaches. *IEEE Access*, 10, 89781-89797.
- Aslan, Z. (2022). EEG sinyallerini kullanarak Alzheimer hastalığının otomatik tespiti için bilgisayar destekli tanı sistemi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 13(2), 213-220.
- Bairagi, V. (2018). EEG signal analysis for early diagnosis of Alzheimer disease using spectral and wavelet based features. *International Journal of Information Technology*, 10(3), 403-412.
- Benesty, J., Chen, J., and Huang, Y. (2008). On the importance of the Pearson correlation coefficient in noise reduction. *IEEE Transactions on Audio, Speech, and Language Processing*, 16(4), 757-765.
- Büyükgoze, S. (2019). Beyin Bilgisayar Arayüzleri ve Uygulama Alanları. Mühendislik Alanında Araştırma Makaleleri. Gece Kitaplığı. ISBN: 978-625-7958-40-0.

- Durongbhan, P., Zhao, Y., Chen, L., Zis, P., De Marco, M., Unwin, Z. C., ... and Sarrigiannis, P. G. (2019). A dementia classification framework using frequency and time-frequency features based on EEG signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(5), 826-835.
- Falk, T. H., Fraga, F. J., Trambaiolli, L., and Anghinah, R. (2012). EEG amplitude modulation analysis for semi-automated diagnosis of Alzheimer's disease. *EURASIP Journal on Advances in Signal Processing*, 2012, 1-9.
- Fiscon, G., Weitschek, E., Cialini, A., Felici, G., Bertolazzi, P., De Salvo, S., ... and De Cola, M. C. (2018). Combining EEG signal processing with supervised methods for Alzheimer's patients classification. *BMC medical informatics and decision making*, 18(1), 1-10.
- Fontejn, H. M., Modat, M., Clarkson, M. J., Barnes, J., Lehmann, M., Hobbs, N. Z., ... and Alexander, D. C. (2012). An event-based model for disease progression and its application in familial Alzheimer's disease and Huntington's disease. *NeuroImage*, 60(3), 1880-1889.
- Garcés, M. A., and Orosco, L. L. (2008). EEG signal processing in brain-computer interface. In *Smart wheelchairs and brain-computer interfaces* (pp. 95-110). Academic Press.
- Ghanemi, A. (2015). Alzheimer's disease therapies: Selected advances and future perspectives. *Alexandria Journal of Medicine*, 51(1), 1-3.
- Göker, H. (2023). Detection of alzheimer's disease from electroencephalography (EEG) signals using multitaper and ensemble learning methods. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 28(1), 141-152.
- Göker, H. (2023). Welch Spectral Analysis and Deep Learning Approach for Diagnosing Alzheimer's Disease from Resting-State EEG Recordings. *Traitement du Signal*, 40(1).
- Günel, S. (2001). *Örüntü tanıma uygulamalarında alt uzay analiziyle öznitelik seçimi ve sınıflandırma*. Doktora tezi, Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.
- Kurita, T. (2019). Principal component analysis (PCA). *Computer Vision: A Reference Guide*, 1-4.
- Miltiadous, A., Gionanidis, E., Tzamourta, K. D., Giannakeas, N., and Tzallas, A. T. (2023). DICE-net: A Novel Convolution-Transformer Architecture for Alzheimer Detection in EEG Signals. *IEEE Access*.
- Morabito, F. C., Campolo, M., Ieracitano, C., Ebadi, J. M., Bonanno, L., Bramanti, A., ... and Bramanti, P. (2016, September). Deep convolutional neural networks for classification of mild cognitive impaired and Alzheimer's disease patients from scalp EEG recordings. In *2016 IEEE 2nd International Forum on Research and Technologies for Society and Industry Leveraging a better tomorrow (RTSI)* (pp. 1-6). IEEE.
- Parhi, K. K., and Ayinala, M. (2013). Low-complexity Welch power spectral density computation. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 61(1), 172-182.
- Patterson, C. (2018). World Alzheimer report 2018: the state of the art of dementia research: new frontiers. *Alzheimer's Disease International (ADI): London, UK*, 2(4), 14-20.
- Pineda, A. M., Ramos, F. M., Betting, L. E., and Campanharo, A. S. (2020). Quantile graphs for EEG-based diagnosis of Alzheimer's disease. *Plos one*, 15(6), e0231169.
- Sadık, E. Ş. (2022). Comparison Of Machine Learning Algorithms In The Detection Of Alzheimer's Disease. *Avrupa Bilim ve Teknoloji Dergisi*, (42), 1-5.
- Safi, M. S., and Safi, S. M. M. (2021). Early detection of Alzheimer's disease from EEG signals using Hjorth parameters. *Biomedical Signal Processing and Control*, 65, 102338.
- Smith, E. E., Reznik, S. J., Stewart, J. L., and Allen, J. J. (2017). Assessing and conceptualizing frontal EEG asymmetry: An updated primer on recording, processing, analyzing, and interpreting frontal alpha asymmetry. *International Journal of Psychophysiology*, 111, 98-114.
- Vecchio, F., Miraglia, F., Alù, F., Menna, M., Judica, E., Cotelli, M., and Rossini, P. M. (2020). Classification of Alzheimer's disease with respect to physiological aging with innovative EEG biomarkers in a machine learning implementation. *Journal of Alzheimer's Disease*, 75(4), 1253-1261.
- Xiao, C., Ye, J., Esteves, R. M., and Rong, C. (2016). Using Spearman's correlation coefficients for exploratory data analysis on big dataset. *Concurrency and Computation: Practice and Experience*, 28(14), 3866-3878.