



Hafif Bilişsel Bozukluk ve Alzheimer Hastalığının Teşhisi için EEG Sinyalinin İncelenmesi

Investigation of EEG Signal for Diagnosis of Mild Cognitive Impairment and Alzheimer's Disease

Burcu OLTU ve Mehmet Feyzi AKŞAHİN
Biyomedikal Mühendisliği Bölümü
Başkent Üniversitesi
Ankara, Türkiye
boltu@baskent.edu.tr, maksahin@baskent.edu.tr

Seda KİBAROĞLU
Nöroloji Ana Bilim Dalı
Başkent Üniversitesi
Ankara, Türkiye
skibaroglu@baskent.edu.tr

Özetçe— Alzheimer hastalığı (AH), entelektüel gerileme ve nöropsikiyatrik davranışsal rahatsızlıklarla karakterize edilir, yaşamın geç dönemlerinde ortaya çıkan ve demansın en sık görülen türüdür. Hafif bilişsel bozukluk (HBB) ise normal yaşlanma ile demans arasında bir geçiş durumudur ve HBB hastalarının her yıl yaklaşık %10-15'i Alzheimer tipi demansa ilerlemektedir. Bu hastalıkların tanısı için nörolojik muayene, kan testleri, bilişsel testler, görüntüleme yöntemleri, beyin omurilik sıvısının analizi gibi ileri incelemeler yapılmaktadır. Bu tür teknikler, risk altındaki büyük popülasyon için pratik olmamakla birlikte test sonuçları yüksek doğrulukta tanı koymak için yeterli olmamaktadır. Önerilen çalışmada, objektif ve yüksek doğrulukta AH ve HBB tanısının yapılabilmesi için otomatik tanı koyabilen bir karar destek sistemi geliştirilmiştir. Geliştirilen algoritmada elektroensefalografi (EEG) sinyalleri filtrelenmiş ve filtrelenen sinyallere sürekli dalgacık dönüşümü (SDD) uygulanmıştır. Elde edilen SDD katsayıları ve skalogram değerlerinin ortalamaları ve standart sapmaları öznitelik olarak çıkartılmış, çıkartılan öznitelikler ile hastalık grupları "Altuzay K En Yakın Komşu (Altuzay KNN)" kullanılarak sınıflandırılmıştır. Altuzay KNN sınıflandırıcısı %88.9 doğruluk ile eğitilmiş ve eğitilen sistem test edilmiştir. Test sonucunda hastalık gruplarının %94.44 doğruluk oranında ayrıştığı sonucuna varılmıştır.

Anahtar Kelimeler — EEG; Alzheimer hastalığı; hafif bilişsel bozukluk; SDD.

Abstract— Alzheimer's disease (AD), is the most common form of dementia that occurs late in life and is characterized by intellectual regression and neuropsychiatric behavioral disorders. Mild cognitive impairment (MCI) is a transition between normal aging and dementia, and approximately 10-15% of MCI patients progress to Alzheimer type dementia each year. Neurological examination, blood tests, cognitive tests, imaging methods, and analysis of cerebrospinal fluid are performed for diagnosis of these diseases. Such techniques are not practical for large populations at risk, moreover test results are not sufficient to diagnose with high accuracy. In the proposed study, a decision support system that can make an automatic diagnosis is developed for objective and high accuracy diagnosis of AD and MCI. In the developed algorithm, electroencephalography (EEG) signals were filtered and continuous wavelet transform (CWT) was applied to the filtered signals. Mean and standard deviations of the SDD coefficients and scalogram values were extracted as attributes, and with the subtracted attributes disease groups were classified using

"Subspace K Nearest Neighbor (Subspace KNN)". The subspace KNN classifier was trained with an accuracy of 88.9% and the trained system tested. As a result of this test, it was concluded that the disease groups can be separated with 94.44% accuracy rate.

Keywords — EEG; Alzheimer's disease; mild cognitive impairment; CWT.

I. GİRİŞ

Demans, beyindeki nöronların hasar görmesi sonucu oluşan, bilişsel ve davranışsal işlevlerin kaybına yol açan progresif nörodejeneratif bir hastalıktır [1]. Alzheimer hastalığı ise en yaygın görülen demans türüdür, dünya çapında demans vakalarının yaklaşık %70'ini oluşturur [1, 2]. Alzheimer Hastalığı (AH), epizodik bellekte ve bilişsel işlevlerde bozulma ve nöropsikiyatrik davranışsal rahatsızlıklar ile karakterize edilen nörodejeneratif bir hastalıktır [2]. Günümüzde bu hastalığın uyarıcı ve inhibe edici sinaptik iletimi etkileyen, amiloid-beta ve hiperfosforile edilmiş tau peptidlerin patolojik birikimi sonucu oluştuğu klinik veriler tarafından desteklenmektedir [3, 4]. Hafif bilişsel bozulma (HBB), bireyin yaşından ve beklenen normal değişimlerden daha büyük bilişsel gerileme ile karakterize edilen dejeneratif bir hastalıktır [3, 5]. Demansın öncü tablosu olan HBB bir yıl içinde %10 ila 15 oranında Alzheimer hastalığına dönüşür [5-7].

Alzheimer hastalarının ortalama sağ kalım süresi klinik tanıdan sonra 5-8 yıldır ve günümüzde bu patolojiyi iyileştirmek için bilinen bir ilaç yoktur; ancak bu hastalıkların erken evrede teşhisi, hasta ve ailesine hastalık hakkında bilgi sahibi olmaları, hastaların gelecekteki bakımlarını planlamaları için zaman verir bununla birlikte hastalığın ilerlemesini geciktiren ilaçların en etkili olduğu dönemde kullanılmasını sağlamaya yardımcı olur [2, 6, 8].

Günümüzde AH'nin doğru teşhisi için fiziksel, nörolojik ve psikiyatrik muayeneler, nöropsikolojik testler, kan testleri, bilişsel testler, maliyetli nörogörüntüleme testleri ve risk altındaki popülasyona uygulanması zor olan spinal sıvı analizi dahil çeşitli teşhis testlerinin kombinasyonu kullanılmaktadır [6, 9, 10]. Bu kapsamlı ve yüksek maliyetli testlerin kullanılmasına rağmen üniversite hastanelerinde teşhisin doğruluk oranı %85-93 arasında değişmektedir [10]. Son yirmi

yılda, hastalığın erken teşhisinde hekimlere yardımcı olabilecek objektif, risk altındaki popülasyona kolay uygulanacak ve düşük maliyetli araçlar geliştirme yönünde bir baskı olmuştur [9, 10]. Elektroensefalografi (EEG), beyinde oluşan elektriksel değişimlerin kaydedilmesi için kullanılan, yüksek zamansal çözünürlüğe sahip, invaziv olmayan, nispeten ucuz bir teknoloji olduğundan potansiyel olarak AH riskine karşı büyük bir popülasyonu taramak için uygun bir araç olabilir [6, 8, 10].

Son yıllarda EEG'nin AH ve HBB teşhisi için kullanılması potansiyelini araştıran pek çok çalışma yapılmaktadır. Yapılan çalışmalarda EEG'nin spektral ve zamansal analizinin teşhis için kullanışlı sonuçlar üretebileceği gözlemlenmiştir [1, 4, 8]. Bununla birlikte yapılan çalışmaların büyük çoğunluğu yalnızca AH veya HBB üzerine yoğunlaşmıştır ve bu çalışmalarda sınıflandırma çalışmaları genellikle tek bir hastalığın teşhisine odaklanmış, AH-kontrol, HBB-kontrol veya AH-HBB arasında yapılan ikili sınıflandırma sonuçları incelenmiştir [1, 2, 9-12]. Literatürde AH, HBB ve kontrol gruplarını sınıflandıran yalnızca 3 çalışma bulunmuştur. McBride ve ark. 2014 yılında yaptıkları çalışmada EEG sinyallerinin karmaşıklığını ve spektral özelliklerini inceleyerek elde ettikleri öznelilikleri ile destek vektör makineleri kullanarak %79.2 doğrulukla üç sınıfa birbirinden ayırmışlardır [5]. 2018 yılında Gómez ve ark. EEG incelemesi için spektral ve doğrusal olmayan analiz yöntemleri ve öznelilik seçim yöntemi kullanarak optimal öznelilik seti ile üç farklı modeli eğitmiştir: doğrusal ayırıcı analiz, kuadratik ayırıcı analiz ve çok katmanlı algılayıcı yapay sinir ağı. Eğitilen modelleri test ettiklerinde en yüksek doğruluk oranını çok katmanlı algılayıcı yapay sinir ağı ile yaklaşık %63 oranında elde etmişlerdir [7]. 2016 yılında Morabita ve ark. sürekli dalgacık dönüşümü ile yaptıkları zaman-frekans analizi sonucunda elde ettikleri öznelilikler ile evrişimli sinir ağı kullanarak %82 doğrulukta üçlü sınıflandırma yapmıştır [3]. Bunun yanında Houmani ve ark. 2018 yılında epok-bazlı entropi ve bump modeli kullanarak AH, HBB ve öznel bilişsel bozukluğa sahip hastaları birbirinden ayırdığını göstermiştir [6].

Yapılan çalışmada EEG sinyalinin AH ve HBB teşhisinde kullanılabilirliğinin test edilmesi için sinyallere uygulanan sürekli dalgacık dönüşümü (SDD) sonucunda belirlenen öznelilikler ile üçlü bir sınıflandırma yapmak için "Altuzay K-En Yakın Komşu (Altuzay KNN)" sınıflandırma algoritması kullanılmıştır. Elde edilen sonuçlar değerlendirildiğinde literatürde yer alan sonuçlardan daha yüksek bir doğruluk oranına ulaşıldığı görülmüştür.

II. YÖNTEM VE ANALİZLER

A. Kullanılan Sinyaller ve Kayıt Özellikleri

Bu çalışmada 3 adet AH, 3 adet HBB ve 3 adet sağlıklı bireyden alınan toplam 9 adet EEG sinyali incelenmiştir. EEG çekimi "Başkent Üniversitesi Klinik Araştırmalar Etik Kurul" izni uyarınca 10-20 elektrot yerleşimi ile karanlık bir odada gözler kapalı dinlenme durumunda yapılmıştır. AH ve HBB teşhisi Başkent Üniversitesi Nöroloji Kliniğindeki uzman doktorlar tarafından konulmuştur. Teşhis kriteri olarak yapılan nörolojik ve fizyolojik muayenelerin yanında "Montreal Bilişsel Değerlendirme (Montreal Cognitive Assessment: MoCA)" baz alınmıştır [13]. Çalışmaya katılan hastaların bilgileri Tablo 1'de verilmiştir. Yapılan çalışmada Fp₁-Fp₃ kanalından alınan,

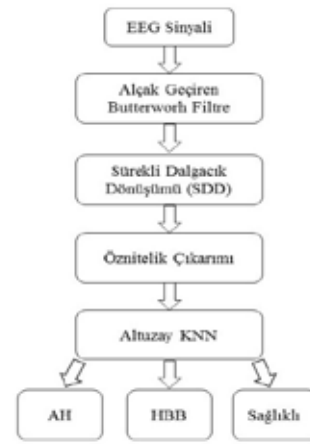
örnekleme frekansı 200 Hz olan 9 adet EEG sinyalinin 30 saniyelik bölütlere (epok) ayrıştırılarak MATLAB programı kullanılarak incelenmiştir.

TABLO I. HASTA BİLGİLERİ

Hastalık	Yaş ortalaması	MOCA Skor Ortalaması
Alzheimer Hastalığı	67	15
Hafif Bilişsel Bozukluk	71	22
Sağlıklı	67	28

B. İzlenen Algoritma

Yapılan çalışmada izlenen adımlar Şekil 1'de gösterilmiştir.



Şekil 1. Algoritma blok diyagramı

C. EEG Sinyallerinin İncelenmesi

1) *EEG Sinyallerinin Filtrelenmesi Tespiti:* EEG sinyallerindeki yüksek frekanslı gürültülerin bastırılması için sinyale kesim frekansı 55 Hz olan alçak geçiren Butterworth filtre uygulanmıştır. Böylece sinyalde yalnızca analiz için gerekli olan frekans aralığı kalmıştır [3].

2) *Sürekli Dalgacık Dönüşümü:* Sürekli dalgacık dönüşümü değişken pencere boyutları kullanılarak optimum zaman-frekans lokalizasyonu sağlamak için kullanılan yöntemdir [14, 15]. Değişken pencere boyutu, kullanılan ana dalgacığın daralıp genişlemesi ile sağlanmaktadır [16]. SDD'de küçük ölçekler yüksek frekansları, yüksek ölçekler düşük frekansları ifade eder [15]. Dalgacık dönüşümü hem zaman hem de frekans açısından sinyali temsil ettiği için durağan olmayan EEG sinyal analizi için mükemmel bir yöntemdir [17]; fakat yöntemin etkili olması için kullanılacak dalgacık analize uygun seçilmelidir [12, 16, 17]. Yapılan çalışmada EEG sinyallerinin incelenmesi için uygun olduğu tespit edilen "Morlet Dalgacığı" kullanılmıştır [12, 17].

SDD; incelenen sinyalin, kaydırılan ve ölçeklenen dalgacık fonksiyonuyla tüm zaman süresince çarpımının toplanması ile uygulanmış olur [16]. SDD uygulandıktan sonra reel ve imajiner katsayılar elde edilir [15].

Ölçeklendirilmiş ve kaydırılmış dalgacık (1)'de ifade edilmiştir. Bu ifadede a ölçeklendirme katsayısı, b ise kaydırma katsayısıdır.

$$\varphi_{ab}(t) = |a|^{1/2} \cdot \varphi\left(\frac{t-b}{a}\right) \quad (1)$$

Denklem (2) SDD'nin matematiksel ifadesidir. Bu ifadede $x(t)$ incelenecek sinyali, $\varphi_{ab}(t)$ ise kullanılacak dalgacık fonksiyonunun kompleks eşleniğini belirtmektedir.

$$W_x(a, b) = \int_{-\infty}^{\infty} x(t) \varphi_{ab}(t) dt \quad (2)$$

Skalogram ise SDD'nin genlik karesi olarak ifade edilir ve farklı gri seviyeler ya da renk haritaları ile oluşturulan görüntüler olarak temsil edilir. Bu yaklaşım kullanılarak yapılan SDD analizi, ölçek eksenini yerine frekans ekseninde görüntülenebilmektedir [14, 15].

Şekil 2'de her bir hastalık grubundan SDD uygulanmış bir epokluk sinyal örneği verilmiştir.

3) **Öznitelik Çıkarımı:** Yapılan bazı çalışmalarda AH'nin EEG sinyalini yavaşlattığı; yani delta (1-4 Hz) ve teta (4-8 Hz) dalgalarının bağıl gücünü azalttığı, alfa (8-12 Hz) ve beta (12-30 Hz) dalgalarının bağıl gücünü artırdığı gözlemlenmiştir [6, 7, 11, 12]. Bu nedenle bu çalışmada sinyallere SDD uygulandıktan sonra inceleme yapılacak frekans aralığı 2-4 Hz ve 8-50 Hz olarak seçilmiştir. Bu frekans aralıklarında elde edilen katsayıların ve skalogram değerlerinin ortalama ve standart sapma değerleri öznitelik olarak seçilmiştir.

D. Sınıflandırma Çalışmaları

Çalışmada kullanılan öznitelikler tüm hastalık gruplarındaki sinyaller için epok bazında hesaplanmış ve hesaplanan değerler kullanılarak bir öznitelik matrisi elde edilmiştir. Oluşturulan öznitelik matrisinin yarısı modelin eğitilmesi, yarısı ise eğitilmiş modelin test edilmesi için kullanılmıştır. Model eğitilirken 5 katlamalı çapraz doğrulama (5-fold cross validation) yöntemi kullanılmıştır. Yapılan deneysel sınıflandırıcı eğitimi çalışmaları sonucunda en yüksek doğruluk oranının "Altuzay KNN" algoritması ile edildiği belirlenmiştir.

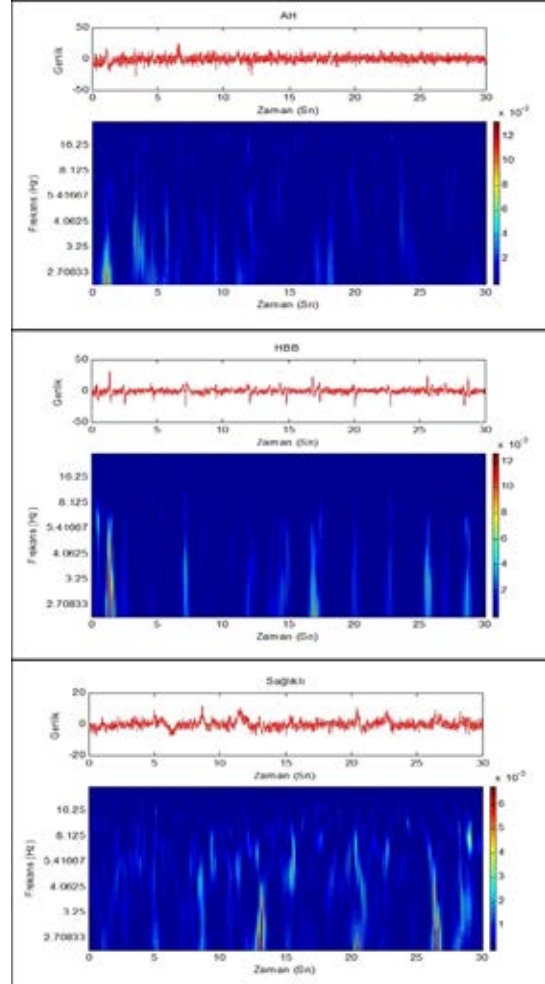
K-en yakın komşu algoritmasında ilk kez karşılaşılan örneğin eğitim setinde var olan etiketlenmiş örneklere olan uzaklığı dikkate alınarak sınıflandırma yapılır. İlk kez karşılaşılan örneğin en yakın olduğu k tane örnek belirlenir ve çoğunluk oylamasına göre bu örneğe bir etiket atanır. KNN algoritmasının performansının artırılması için topluluk yöntemlerinden alt uzay yöntemi kullanılmıştır. Bu yöntem ile sınıflandırıcılar gerçek giriş uzaylarının rastgele alt uzayında eğitilir [18].

E. Algoritma Başarısının Değerlendirilmesi

"Altuzay KNN" sınıflandırıcı algoritması kullanılarak eğitilen sistemin doğruluğu, test verilerinin kullanılmasıyla elde edilen sistem sonuçları ve hekim skorları karşılaştırılarak hesaplanmıştır. Tasarlanan algoritmanın başarısının hesaplanması için; doğru pozitif (DP), yanlış pozitif (YP), doğru negatif (DN) ve yanlış negatif (YN) değerleri tespit

edilmiş ve doğruluk (3)' te ifade edildiği gibi hesaplanmıştır [19].

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3)$$



Şekil 2. SDD uygulanmış EEG sinyalleri ve skalogram grafikleri

III. SONUÇ

Yapılan çalışmada 3 AH, 3 HBB ve 3 sağlıklı bireyden alınan 4 dakikalık EEG sinyalleri 30 saniyelik epoklar halinde incelenmiştir. Yukarıda da anlatıldığı gibi sinyaller ilk olarak alçak geçiren filtreden geçirilmiştir, daha sonra filtrelenmiş sinyallere SDD uygulanmıştır. Sinyalleri farklı hastalık sınıflarına ayırtmak için, uygulanan SDD sonucu elde edilen katsayılar ve skalogram değerlerinden öznitelikler çıkarılmıştır. Bulunan öznitelikleri sınıflandırıcıya sokulduğunda model %88.9 doğrulukla "Altuzay KNN" yöntemi ile eğitilmiştir. Yapılan eğitim sonucu eğitilen sınıflandırıcının doğru pozitif ve yanlış negatif oranları Şekil 3'te verilmiştir.

Daha sonra eğitilen sistemin verimliliği test verileri kullanılarak test edilmiş ve yapılan test sonucunda sistemin doğruluk oranı %94.44 olarak hesaplanmıştır. Test sonucunda elde edilen karışıklık matrisi Şekil 4'te verilmiştir.

IV. TARTIŞMA

Demans, dünya çapında önemli bir halk sağlığı sorunudur. Yaşlanan nüfus üzerindeki etkisi endişe verici bir oranda artmaktadır: günümüzde demans hastalığı görülen 46,8 milyon insan olduğu tahmin edilmektedir ve bu oranın 2030 yılına kadar ikiye, 2050 yılına kadar ise üçe katlanacağı beklenmektedir [6]. Alzheimer hastalığı ve hafif bilişsel bozukluk, halk sağlığı ve sağlık sistemleri için büyüyen zorluklardır ve tedavileri bulunmamaktadır. Bununla birlikte erken teşhis ile hastalığın gidişatının yavaşlatılabilmesi ve hastanın ve yakınlarının bu süreci kaliteli bir şekilde geçirebilmesi için önlemler alınması mümkün olabilir. Bu hastalığın teşhisinin yapılması için pek çok maliyetli ve subjektif yorumlanabilen testler uygulanmaktadır. Dolayısıyla daha objektif ve yüksek doğrulukta teşhis yapabilen bir karar destek sisteminin tasarlanmasının çok kullanışlı olabileceği düşünülmektedir. Bunun yanında AH ve HBB teşhisi için risk altındaki popülasyona kolayca uygulanabilecek, düşük maliyetli, invaziv olmayan bir yöntem olan EEG'nin yüksek potansiyeli olduğu sonucuna varılmıştır.

		Tahmin Edilen Skor			Doğru Pozitif Oranı	Yanlış Negatif Oranı
		AH	HBB	Sağlıklı		
Gerçek Skor	AH	%92	%8		%92	%8
	HBB		%83	%17	%83	%17
	Sağlıklı		%8	%92	%92	%8

Şekil 3. Doğru pozitif ve yanlış negatif oranları

		Tahmin Edilen Skor		
		AH	HBB	Sağlıklı
Gerçek Skor	AH	10	2	
	HBB		12	
	Sağlıklı			12

Şekil 4. Karışıklık matrisi

Yapılan çalışmada sürekli dalgacık dönüşümü kullanılarak yapılan üçlü sınıflandırma (HBB-AH-sağlıklı) sonucunda literatürde bulunan, giriş bölümünde ayrıntılı bir şekilde anlatılan, çalışmalardan daha yüksek doğruluk oranı elde edildiği görülmüştür [3, 5, 7]. Ancak çalışmalarda incelenen sinyal sayıları ve özellikleri aynı olmadığından dolayı birebir karşılaştırma yapılamaz.

Çalışmada tasarlanan algoritma, aynı hastalık türlerini içeren daha büyük bir veri setine uygulanırsa sistem doğruluğunun artacağı öngörülmektedir.

KAYNAKLAR

- [1] Cassani, R., Estarellas, M., San-Martin, R., Fraga, F. J., & Falk, T. H. (2018). Systematic review on resting-state EEG for Alzheimer's disease diagnosis and progression assessment. *Disease markers*, 2018.
- [2] Gallego-Jutglà, E., Solé-Casals, J., Vialatte, F. B., Dauwels, J., & Cichocki, A. (2015). A theta-band EEG based index for early diagnosis of Alzheimer's disease. *Journal of Alzheimer's Disease*, 43(4), 1175-1184.
- [3] Morabito, F. C., Campolo, M., Ieracitano, C., Ebadi, J. M., Bonanno, L., Bramanti, A., Desalvo, S., Mammone, N., & 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.
- [4] Alberdi, A., Aztiria, A., & Basarab, A. (2016). On the early diagnosis of Alzheimer's Disease from multimodal signals: A survey. *Artificial Intelligence in Medicine*, 71, 1-29.
- [5] McBride, J. C., Zhao, X., Munro, N. B., Smith, C. D., Jicha, G. A., Hively, L., Broster, L. S., Schmitt, F. A., Kryscio, R. J., & Jiang, Y. (2014). Spectral and complexity analysis of scalp EEG characteristics for mild cognitive impairment and early Alzheimer's disease. *Computer methods and programs in biomedicine*, 114(2), 153-163.
- [6] Houmani, N., Vialatte, F., Gallego-Jutglà, E., Dreyfus, G., Nguyen-Michel, V. H., Mariani, J., & Kinugawa, K. (2018). Diagnosis of Alzheimer's disease with Electroencephalography in a differential framework. *PLoS one*, 13(3), e0193607.
- [7] Ruiz-Gómez, S., Gómez, C., Poza, J., Gutiérrez-Tobal, G., Tola-Arribas, M., Cano, M., & Hornero, R. (2018). Automated multiclass classification of spontaneous EEG activity in Alzheimer's disease and mild cognitive impairment. *Entropy*, 20(1), 35.
- [8] Dauwels, J., Vialatte, F., & Cichocki, A. (2010). Diagnosis of Alzheimer's disease from EEG signals: where are we standing?. *Current Alzheimer Research*, 7(6), 487-505.
- [9] McBride, J., Zhao, X., Munro, N., Smith, C., Jicha, G., & Jiang, Y. (2013). Resting EEG discrimination of early stage Alzheimer's disease from normal aging using inter-channel coherence network graphs. *Annals of biomedical engineering*, 41(6), 1233-1242.
- [10] Falk, T. H., Fraga, F. J., Trambaioli, L., & Anghinah, R. (2012). EEG amplitude modulation analysis for semi-automated diagnosis of Alzheimer's disease. *EURASIP Journal on Advances in Signal Processing*, 2012(1), 192.
- [11] Kulkarni, N. N., & Bairagi, V. K. (2017). Extracting salient features for EEG-based diagnosis of Alzheimer's disease using support vector machine classifier. *IETE Journal of Research*, 63(1), 11-22.
- [12] Ghorbanian, P., Devilbiss, D. M., Hess, T., Bernstein, A., Simon, A. J., & Ashrafian, H. (2015). Exploration of EEG features of Alzheimer's disease using continuous wavelet transform. *Medical & biological engineering & computing*, 53(9), 843-855.
- [13] Nasreddine, Z. S., Phillips, N. A., Bédirian, V., Charbonneau, S., Whitehead, V., Collin, I., Cummings, J. L., & Chertkow, H. (2005). The Montreal Cognitive Assessment, MoCA: a brief screening tool for mild cognitive impairment. *Journal of the American Geriatrics Society*, 53(4), 695-699.
- [14] Uğur, T. K., & Erdamar, A. (2019). An efficient automatic arousals detection algorithm in single channel EEG. *Computer methods and programs in biomedicine*, 173, 131-138.
- [15] Karaca, B. K., Oltu, B., Kantar, T., Kiliç, E., Akşahin, M. F., & Erdamar, A. (2018, May). Classification of heart sound recordings with continuous wavelet transform based algorithm. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- [16] Kiliç, E., & Erdamar, A. (2018, May). Automatic classification of respiratory sounds during sleep. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- [17] Ghorbanian, P. (2014). Non-Stationary Time Series Analysis and Stochastic Modeling of EEG and its Application to Alzheimer's Disease. Villanova University.
- [18] Ho, T. K. (1998, August). Nearest neighbors in random subspaces. In Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition (SPR) and Structural and Syntactic Pattern Recognition (SSPR) (pp. 640-648). Springer, Berlin, Heidelberg.
- [19] Fawcett, T. (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), 861-874.