

Dalgacık Tutarlılık ve Evrşimsel Sinir Ağları Kullanarak Epilepsinin Tespiti

Detection of Epilepsy Using Wavelet Coherence and Convolutional Neural Networks

Ayşe BOZDOĞAN, Mehmet UŞTU

Biyomedikal Müh. Bölümü
Erciyes Üniversitesi
Kayseri

aysebozdogan989@gmail.com, udubey279@gmail.com

Ramis İLERİ, Fatma LATİFOĞLU

Biyomedikal Müh. Bölümü
Erciyes Üniversitesi
Kayseri

ramissileri@gmail.com, flatifoglu@erciyes.edu.tr

Özetçe— Dünya sağlık örgütüne göre epilepsi dünya çapında yaklaşık 50 milyon kişinin mustarip olduğu bir hastalıktır. Epilepsi nöbetlerinin beklenmedik bir şekilde başlayıp olmasından dolayı bedensel yaralanmalara ve ölüme yol açabilmektedir. Bu sebeple epilepsinin tahmin edilebilmesi oldukça önemlidir. Bu çalışmada Bonn Epilepsi Laboratuvarı tarafından kaydedilen Elektroensefalogram (EEG) sinyalleri kullanılarak epilepsi tespiti amaçlanmıştır. Bu amaç doğrultusunda Dalgacık Tutarlılık Analizi ve Evrşimsel Sinir Ağları (ESA) kullanılmıştır. Önerilen yöntem ile Epilepsi hastalarından kriz dışında epileptik olmayan bölgeden kaydedilen ve kriz esnasında kaydedilen EEG sinyallerinin (N-S) sınıflandırılması sonucu %96, epilepsi hastalarından kriz dışında epileptik olan bölgeden ve kriz esnasında kaydedilen EEG sinyallerinin (F-S) sınıflandırılması sonucu %96,5, sağlıklı bireylerden uyanık ve gözleri açıkken kaydedilen ve epilepsi hastalarından kriz esnasında kaydedilen EEG sinyallerinin (Z-S) sınıflandırılması sonucu %99, sağlıklı bireylerden uyanık ve gözleri kapalıyken kaydedilen ve epilepsi hastalarından kriz esnasında kaydedilen EEG sinyallerinin (O-S) sınıflandırılması sonucu %100 başarı elde edilmiştir. Elde edilen sonuçlara göre önerilen yöntemin EEG sinyallerinden epilepsi tahmininde başarılı olduğunu göstermektedir.

Anahtar Kelimeler — Epilepsi, Dalgacık Tutarlılık Analizi, Evrşimsel Sinir Ağları

Abstract— According to the World Health Organization, epilepsy is a disease that affects approximately 50 million people worldwide. Due to the unexpected onset of epileptic seizures, it can lead to bodily injury and death. For this reason, it is very important to predict epilepsy. In this study, it was aimed to detect epilepsy by using Electroencefalogram (EEG) signals recorded from Bonn Epilepsy Laboratory. Wavelet Coherence Analysis and Convolutional Neural Networks were used for this aim. Classification results show that accuracy of different clusters in the data set using the proposed method were obtained as 96% for N-S clusters, 96.5% for F-S clusters, 99% for Z-S clusters and 100% for O-S clusters. The results show that the proposed method is promising in estimating epilepsy from EEG signals.

Keywords — Epilepsy, Wavelet Coherence Analysis, Convolutional Neural Network

I. GİRİŞ

Epilepsi, beynin elektriksel aktivitesinde meydana gelen değişikliklerin neden olduğu nörolojik bir hastalıktır. Epilepsi hastaları kontrolsüz ve ani bir şekilde gelişen epileptik nöbetler geçirmektedir [1]. EEG epilepsi tanısında yaygın olarak kullanılan bir yöntemdir. EEG incelemesi belirli sürelerle tekrarlanmakta veya daha uzun süreli kayıt alınmaktadır [2]. Dünya sağlık örgütü rakamlarına göre epilepsi dünya çapında yaklaşık 50 milyon insanı etkiler ve epilepsinin ani başlangıcı bedensel zarara ve hatta ölüme neden olabilir [3]. Bu nedenle epilepsinin gerçek zamanlı tahmini hayati klinik öneme sahiptir.

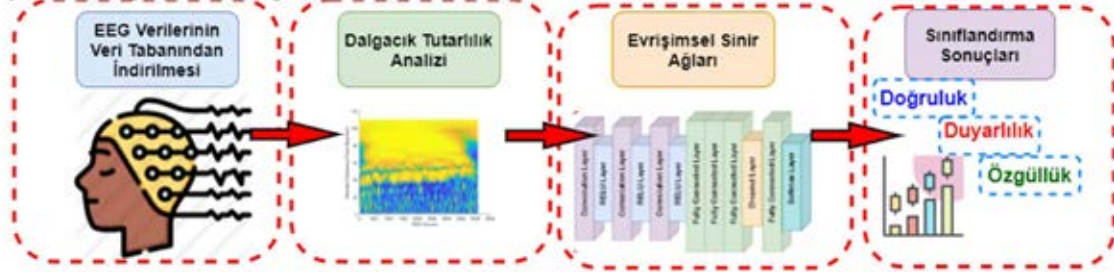
Literatürde epilepsinin tespiti için EEG sinyalleri yaygın olarak kullanılmaktadır [4, 5]. Derin öğrenme yöntemlerindeki gelişmeler ile birlikte, çeşitli derin öğrenme algoritmaları kullanılarak hastalık tespiti son yıllarda oldukça popüler hale gelmiştir [6, 7]. ESA [8] en çok kullanılan derin öğrenme yöntemlerinden biridir ve son yıllarda epilepsi teşhisi için sıklıkla tercih edilmektedir.

Gao ve arkadaşları [9] tarafından yaklaşık entropi, tekrarlanan nicel analiz ve ESA'na dayalı otomatik nöbet tespiti için bir çalışma gerçekleştirilmiştir. Bu çalışmada, nöbet sırasında kaydedilen EEG sinyallerini, sağlıklı bireylerden elde edilen EEG sinyallerinden otomatik olarak ayırt etmek için ESA kullanılmış ve farklı denemeler için %98,84, %99,35 ve %99,26'ya ulaşan sınıflandırma doğrulukları elde edilmiştir. Acharya ve arkadaşları [10] tarafından ESA kullanarak epilepsi nöbetinin otomatik tespiti için bir yöntem önerilmiştir. Bu çalışmada normal, preiktal ve epileptik sınıfları tespit etmek için 13 katmanlı derin evrşimli sinir ağı algoritması kullanılmıştır. Önerilen teknikte, sırasıyla %88,67, %90 ve %95 doğruluk, özgüllük ve duyarlılık elde edilmiştir. Guo ve arkadaşları [11] bağıl dalgacık enerjisi (RWT) ve yapay sinir ağları (YSA) kullanılarak EEG sinyallerinin sınıflandırılması üzerine bir çalışma gerçekleştirmişlerdir. Çalışma sonucunda %95,2 sınıflandırıcı doğruluğu rapor edilmiştir. Übeyli [12] EEG sinyalleri kullanarak epilepsi sınıflandırması için dalgacık katsayılarını kullanan birleşik sinir ağı (combined neural network) modeli olarak adlandırılan çok katmanlı algılayıcı

temelli bir yapay sinir ağı modelini kullanarak %94,83 doğrulukla sınıflandırma işlemini gerçekleştirmiştir.

Gerçekleştirilen bu çalışmada epilepsinin otomatik tahmini ve tespitine yönelik Dalgacık Tutarlılığı (Wavelet Coherence)

ve Evrişimsel Sinir Ağları kullanılmıştır. Önerilen bu yöntem EEG sinyallerinden epilepsi tespitine yönelik literatürde daha önce kullanılmamış olup özgün yaklaşımlar içermektedir.



Şekil 1. Çalışmanın genel akış şeması

II. YÖNTEM

A. Veri Tabanı ve EEG Sinyalleri

Bu çalışmada kullanılan EEG verileri Almanya'da Bonn Epilepsi Laboratuvarı'nın EEG veri tabanından elde edilmiştir [13]. Veri seti beş kümeden oluşmaktadır bu kümeler Z, O, N, F ve S olarak adlandırılmıştır. Tablo I her bir kümenin açıklaması verilmiştir.

TABLO I. VERİ KÜMELERİNİN TANIMI

Katılımcı Grubu	Veri	Açıklaması
Sağlıklı katılımcılar	Z	Katılımcılar uyanık ve gözleri açıkken
	O	Katılımcılar uyanık ve gözleri kapalıyken
Epilepsi hastaları	N	Epilepsi hastası kriz dışında epileptik olmayan bölgeden
	F	Epilepsi hastası kriz dışında epileptik olan bölgeden
	S	Epilepsi hastası kriz esnasında

Her veri kümesi, 173.6 Hz örnekleme frekansı ile 23.6 saniye süreli 100 klinik intrakraniyal EEG kaydı içermektedir. EEG verileri 5 sınıfa ayrılmıştır ve her sınıfta 100 adet veri dosyası, her dosyada da 4096 örnek vardır. Beş sağlıklı gönüllüden kaydedilen EEG sinyalleri sırasıyla Z ve O olarak adlandırılmıştır. N, F ve S kümeleri ise beş epileptik hastadan alınmıştır. EEG verileri ise 0.53–40 Hz frekans bandı aralığında band-geçiren filtre ile filtrelenmiştir.

B. Dalgacık Tutarlılık Analizi

Durağan bir zaman serisinde frekansla ilgili davranışı tanımlamak için Çapraz korelasyon, karşılıklı spektrum (Fourier) ve tutarlılık yaklaşımları kullanılmaktadır. Ancak, birçok zaman serisi durağan olmayıp frekans içerikleri zamanla değişmektedir. Bu zaman serilerinde, zaman-frekans düzlemindeki korelasyonu veya tutarlılığı ölçmek önemlidir. Dalgacık tutarlılığı, sinyallerin zamana bağlı salınımlarındaki düzensizlikleri tespit etmek için kullanılmamaktadır. Doğal olarak bir zaman serisi diğerini etkiliyorsa, iki zaman serisi arasındaki bağıl gecikmeyi belirlemek için kesişen dalgacık spektrumunun fazlarını kullanılmaktadır. Dalgacıkların tutarlılığı, iki dalga biçiminin zaman-frekans uzayına

uygunluğunun yararlı bir ölçüsüdür [14, 15]. Gerçekleştirilen çalışmada EEG sinyallerinin kendisi ve 10 ileri, 20 ileri örnekleri arasındaki dalgacık tutarlılığı analiz edilmiştir. Elde edilen sinyaller ESA modeline giriş olarak uygulanmıştır.

C. Evrişimsel Sinir Ağları

Bir evrişimsel sinir ağı bir girdi verisini alıp, verideki çeşitli desenleri/nesneleri birbirinden ayırabilen derin öğrenme algoritmasıdır [16]. ESA'lar, temel olarak görüntüleri sınıflandırmak, benzerlikle kümelemek ve nesne tanıma yapmak için kullanılan derin yapay sinir ağlarıdır [8]. ESA, nöronlar veya düğümler olarak adlandırılan basit uyarlanabilir işlem elemanlarından oluşan yüksek düzeyde bağlantılı bir yapı olarak tanımlanabilir. Bir ESA, birbirine bağlı birçok hesaplamalı sinirbilim biriminden oluşur. İstedığınız işlemi oluşturmak için, ESA mimarilerinin eğitilmesi gerekmektedir. Özellikle, ESA'ları, yüksek derecede düzenli paralel yapıları ve doğrusal olmayan giriş fonksiyonlarını yeniden üretme yeteneği ile örneklerden öğrenmeye dayalı örüntü tanıma problemleri için uygundur. Son yıllarda fizyolojik sinyallerin sınıflandırılması için ESA sıklıkla kullanılmaktadır [17]. Ayrıca epilepsinin tespitine yönelik ESA kullanan çalışmalar da literatürde yer almaktadır [18].

Gerçekleştirdiğimiz bu çalışmada epilepsi tespitine yönelik ortaya konulan ESA modeli; Giriş katmanı, Evrişim (Konvolüsyon) Katmanı, ReLU Katmanı, Maksimum Havuzlama Katmanı, Tam Bağlantılı Katman, Sınıflayıcı katman ve Sınıflandırma Katmanlarından oluşmaktadır. 'Adam' öğrenme algoritması kullanılmıştır. Maksimum iterasyon 8 olarak uygulanmıştır. Önerilen bu çalışmada 5 katlamalı çapraz doğrulama tekniği kullanılmıştır.

III. DENEYSEL SONUÇLAR

Bu çalışmada epilepsi tespiti için 3 farklı giriş verisi kullanılmıştır. İlk aşamada EEG sinyalleri önerilen ESA modeline herhangi bir ön işleme tabii tutulmadan uygulanmıştır. Elde edilen performans sonuçları Tablo II'de görülmektedir. Tablo II'den görüldüğü gibi Hassasiyet, Özgüllük ve Doğruluk değerleri O-S sınıflandırması için %64 civarındadır. Z-S sınıflandırması için %74 doğruluk oranı mevcuttur. F-S için %85, N-S için %89 doğruluk oranları elde edilmiştir.

$$\text{Doğruluk} = \frac{DN + DP}{(DP+DN+YP+YN)} \quad (1)$$

$$\text{Duyarlılık} = \text{DP} / (\text{DP} + \text{DN}) \quad (2)$$

$$\text{Özgüllük} = \text{DN} / (\text{DN} + \text{YP}) \quad (3)$$

TABLE II. SADECE EEG VERİLERİ İLE YAPILAN SINIFLANDIRMA SONUÇLARI

N-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	90	90	95	87.5	82.5	89±4,54
Duyarlılık	100	89.5	89.5	90.9	89.5	91.88±4,57
Özgüllük	84	90.5	100	83.3	76.2	86.8±8,94
F-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	95	80	77.5	92.5	80	85±8,10
Duyarlılık	94,10	82.6	100	100	75	90.34±11,13
Özgüllük	95.7	76.5	70	86.4	87.5	83.22±10,05
Z-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	67.5	70	72.5	72.5	87.5	74±7,82
Duyarlılık	100	71.5	83.3	92.3	81.5	85.72±10,87
Özgüllük	61.8	69.2	67.9	63.0	100	72,38±15,75
O-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	67,50	45	70	62,50	70	63±10,51
Duyarlılık	59,30	36,40	75	69,20	84,60	64,90±18,38
Özgüllük	84,60	48,30	65	59,30	63	64,04±13,18

2. aşamada EEG sinyallerinin kendisi ve 10 ileri örnekleri kullanılarak Dalgacık Tutarlılığı uygulanmış ve ESA modeline uygulanmıştır. Elde edilen performans sonuçları Tablo III'te görülmektedir. Dalgacık Tutarlılık Analizi kullanıldığında O-S kümelerinin sınıflandırması %63'ten %98,50 doğruluk seviyesine ulaşmıştır. Z-S %98,50, F-S %97,50, N-S ise %96,50 doğrulukla sınıflandırılmıştır.

TABLE III. WAVELET COHERENCE 10 İLERİ VERİLERİ KULLANILARAK YAPILAN SINIFLANDIRMA SONUÇLARI

N-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	100	100	95	92,50	95	96,50±3,35
Duyarlılık	100	100	94,70	90,90	90,90	95,30±4,56
Özgüllük	100	100	95,20	94,40	100	97,92±2,86
F-S	1.Fold	2.Fold	3.Fold	4.Fold	5.Fold	Ortalama(±SD)
Doğruluk	97,50	100	95	97,50	97,50	97,50±1,76
Duyarlılık	100	100	94,70	95,50	95,20	97,08±2,86
Özgüllük	95,80	100	95,20	100	100	98,20±2,47
Z-S	1.Fold	2.Fold	3.Fold	4.Fold	5.Fold	Ortalama(±SD)
Doğruluk	100	97,50	97,50	100	97,50	98,50±1,36
Duyarlılık	100	100	95	100	95,20	98,04±2,68
Özgüllük	100	85	100	100	100	97±6,70
O-S	1.Fold	2.Fold	3.Fold	4.Fold	5.Fold	Ortalama(±SD)
Doğruluk	97,50	97,50	100	100	97,50	98,50±1,36
Duyarlılık	94,40	100	100	100	100	98,80±2,50
Özgüllük	100	94,40	100	100	95,20	97,92±2,86

Son aşamada ise 3. aşamada EEG sinyallerinin kendisi ve 20 ileri örnekleri kullanılarak Dalgacık Tutarlılığı uygulanmış ve ESA modeline uygulanmıştır. Elde edilen performans sonuçları Tablo IV 'de görülmektedir. Tablo 4 'den edindiğimiz en iyi sonuçları göstermektedir. EEG sinyallerine ait tüm kümelerinde

yüksek doğru tahmin oranı vermiş ve ilk defa bu uygulamada %100 doğruluğa ulaşılmıştır.

TABLE IV. WAVELET COHERENCE 20 İLERİ VERİLERİ KULLANILARAK YAPILAN SINIFLANDIRMA SONUÇLARI

N-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	90	97,50	97,50	97,50	97,50	96±3,35
Duyarlılık	86,40	95,50	96	93,80	95,20	93,88±3,98
Özgüllük	94,40	100	100	100	100	98,88±2,50
F-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	97,50	92,50	97,50	95	100	96,50±2,85
Duyarlılık	100	95,50	95	100	100	98,10±2,60
Özgüllük	95,80	88,90	100	90,50	100	95,04±5,19
Z-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	100	97,50	100	100	97,50	99±1,36
Duyarlılık	100	100	100	100	100	100±0,00
Özgüllük	100	94,40	100	100	95,20	97,92±2,86
O-S	1.fold	2.fold	3.fold	4.fold	5.fold	Ortalama(±SD)
Doğruluk	100	100	100	100	100	100±0,00
Duyarlılık	100	100	100	100	100	100±0,00
Özgüllük	100	100	100	100	100	100±0,00

IV. SONUÇLAR VE TARTIŞMA

Bu çalışmada epilepsinin tespiti için dalgacık tutarlılık analizi ve evrimsel sinir ağları temelli yeni bir yaklaşım önerilmiştir. Önerilen yaklaşımda açık erişimli bir veri tabanından elde edilen EEG verilerine dalgacık tutarlılık analizi yapılmış ve elde edilen veriler önerilen ESA mimarisine giriş olarak uygulanmıştır. Çalışmada epilepsi krizi anında kaydedilen veriler ile Tablo I'de tanımlanan diğer kayıtlar arasında ikili sınıflandırma yapılmıştır. Ayrıca önerilen yöntemin performansını tespit etmek amacıyla veri tabanından elde edilen EEG verileri doğrudan önerilen ESA modeline uygulanmıştır.

N-S kümeleri arasındaki sınıflandırma sonuçlarına bakıldığında, sınıflandırıcı doğruluk değeri yalnızca EEG verileri uygulandığında %89 iken, 10 ileri-dalgacık tutarlılığı uygulandığında %96,50 seviyesine, 20 ileri uygulandığında ise %96 sınıflandırıcı doğruluğuna ulaşmıştır. F-S kümelerinin sınıflandırması sonucunda ise yalnızca EEG sinyalleri kullanıldığında %85 sınıflandırıcı doğruluğuna ulaşılmıştır. Ancak dalgacık tutarlılığı uygulandığında doğruluk değeri 10 ileri analizde %97,50, 20 ileri analizde ise %96,50 olarak elde edilmiştir. Aynı işlemler Z-S kümeleri için yapılan analizde ise sadece EEG verileri ile yapılan sınıflandırma sonucunda veriler %74 doğrulukla sınıflandırılmıştır. Dalgacık tutarlılığı uygulandığında 10 ileri ve 20 ileri analizler için sırasıyla %98,50 ve %99 sınıflandırıcı doğruluğuna ulaşılmıştır. Son olarak O-S kümeleri arasında gerçekleştirilen ikili sınıflandırmada ise EEG sinyalleri tek başına uygulandığında %63 doğruluğuna ulaşılmıştır. Dalgacık tutarlılığında 10 ileri durumda %98,50, 20 ileri durumda ise %100 doğrulukla sınıflandırılmıştır.

Tablo II-IV'den de görüldüğü gibi dalgacık tutarlılığının tüm kümelerde sınıflandırma sonuçlarını iyileştirdiği görülmektedir. Ancak sinyalleri 10 ileri ve 20 ileri durumları ile dalgacık tutarlılık analizleri karşılaştırıldığında 10 ileri durum 20 ileri duruma göre N-S ve F-S sınıflandırmalarında daha yüksek

doğrulukta Z-S ve O-S için daha düşük doğruluk sonucu vermiştir. EEG sinyallerinin kendisinin ve EEG sinyallerinden dalgacık tutarlılığı ile elde edilen sinyallerin ESA'na uygulanması durumundaki en önemli değişim O-S kümelerinin sınıflandırmalarında görülmüştür. EEG sinyallerinin kendisi uygulandığında O-S sınıflandırması en düşük doğrulukta iken EEG sinyallerine dalgacık tutarlılığı uygulandığında en yüksek performans sonucu yine O-S sınıflandırmasında elde edilmiştir.

Tablo V'de literatürde gerçekleştirilen çalışmalardan birkaçı verilmiştir. Bu çalışmalarda olduğu gibi dalgacık analizi EEG sinyallerinden epilepsi tespiti için kullanılan popüler bir yöntemdir.

TABLO V. SINIFLANDIRMA SONUÇLARININ ÖNCEKİ ÇALIŞMALAR İLE KARŞILAŞTIRILMASI

Çalışma	Yöntem	Doğruluk
Gao ve arkadaşları[9]	Yaklaşıklık Entropisi ve ESA	%99,26
Ocak[19]	Yaklaşıklık Entropisi ve Dalgacık Dönüşümü	%96
Acharya ve arkadaşları[10]	ESA	%88,67
Guo ve arkadaşları[11]	Dalgacık Dönüşümü ve ANN	%95,2
Übeyli[12]	Dalgacık dönüşümü, ANN	%94,83
Önerilen çalışma	Dalgacık tutarlılık analizi ve ESA	%100

Önerilen yöntemde dalgacık tutarlılık analizi kullanarak EEG sinyallerinden epilepsinin sınıflandırılmasında %100 başarıya ulaşılmıştır. Gelecek çalışmalarda önerilen bu yöntemin farklı veri setlerine uygulanarak çeşitli hastalıkların tespitinde kullanılması planlanmaktadır.

KAYNAKLAR

- [1] G. Akdağ , D. Algin ve O. Erdinç , "EPİLEPSİ / EPILEPSY", Osmangazi Tıp Dergisi, c. 38, sayı. 1, (Mar. 2016), doi:10.20515/otd.88853
- [2] Blinowska, Katarzyna, and Piotr Durka. "Electroencephalography (eeg)." Wiley encyclopedia of biomedical engineering (2006).
- [3] Dünya Sağlık Örgütü, Available: <https://www.who.int/news-room/fact-sheets/detail/epilepsy>
- [4] Smith, Shelagh JM. "EEG in the diagnosis, classification, and management of patients with epilepsy." Journal of Neurology, Neurosurgery & Psychiatry 76.suppl 2 (2005): ii2-ii7.
- [5] Acharya, U. Rajendra, et al. "Automated EEG analysis of epilepsy: a review." Knowledge-Based Systems 45 (2013): 147-165.
- [6] Ullah, Ihsan, Muhammad Hussain, and Hatim Aboalsamh. "An automated system for epilepsy detection using EEG brain signals based on deep learning approach." Expert Systems with Applications 107 (2018): 61-71.

- [7] Latifoğlu, Fatma, Ramis İleri, and Esra Demirci. "Assessment of dyslexic children with EOG signals: Determining retrieving words/re-reading and skipping lines using convolutional neural networks." Chaos, Solitons & Fractals 145 (2021): 110721. doi:10.1016/j.chaos.2021.110721
- [8] Kalchbrenner, Nal, Edward Grefenstette, and Phil Blunsom. "A convolutional neural network for modelling sentences." arXiv preprint arXiv:1404.2188 (2014).
- [9] Gao, X., Yan, X., Gao, P., Gao, X., & Zhang, S. Automatic detection of epileptic seizure based on approximate entropy, recurrence quantification analysis and convolutional neural networks. Artificial intelligence in medicine, 102, 101711.(2020)
- [10] Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adeli, H. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. Computers in biology and medicine, 100, 270-278(2018).
- [11] L. Guo, D. Rivero, J. A. Seoane, and A. Pazos, "Classification of EEG signals using relative wavelet energy and artificial neural networks," in *Proceedings of the first ACM/SIGEVO Summit on Genetic and Evolutionary Computation*, 2009, pp. 177-184.
- [12] Übeyli, Elif Derya. "Combined neural network model employing wavelet coefficients for EEG signals classification." Digital Signal Processing 19.2 (2009): 297-308.
- [13] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., & Elger, C. E. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. Physical Review E, 64(6), 061907.(2001).
- [14] Klein, A., Sauer, T., Jedynak, A., & Skrandies, W. Conventional and wavelet coherence applied to sensory-evoked electrical brain activity. IEEE transactions on biomedical engineering, 53(2),(2006)., 266-272.
- [15] Sankari, Ziad, and Hojjat Adeli. "Probabilistic neural networks for diagnosis of Alzheimer's disease using conventional and wavelet coherence." Journal of neuroscience methods 197.1 (2011): 165-170.
- [16] Albawi, Saad, Tareq Abed Mohammed, and Saad Al-Zawi. "Understanding of a convolutional neural network." 2017 International Conference on Engineering and Technology (ICET). IEEE, 2017.
- [17] Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. Fundamental concepts of convolutional neural network. In Recent Trends and Advances in Artificial Intelligence and Internet of Things (pp. 519-567) (2020). Springer, Cham.
- [18] M. H. Cilasun and H. Yalçın, "A deep learning approach to EEG based epilepsy seizure determination," in *2016 24th Signal Processing and Communication Application Conference (SIU)*, 2016, pp. 1573-1576: IEEE.
- [19] Ocak, Hasan. "Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy." Expert Systems with Applications 36.2 (2009): 2027-2036.