



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



EEG sinyallerini kullanarak 2D konvolüsyonel sinir ağları ile epilepsi hastalığının çok sınıflı tespiti

Multi-class detection of epilepsy disease with 2D convolutional neural networks using EEG signals

Yazarlar (Authors): Yiğithan GENİŞ¹, Eda AKMAN AYDIN²

ORCID¹: 0009-0009-5346-4574

ORCID²: 0000-0002-9887-3808

To cite to this article: Genis Y. ve Aydın E. A., “EEG Sinyallerini Kullanarak 2D Konvolüsyonel Sinir Ağları ile Epilepsi Hastalığının Çok Sınıflı Tespiti”, *Journal of Polytechnic*, *(*) : *, (*).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Genis Y. ve Aydın E. A., “EEG Sinyallerini Kullanarak 2D Konvolüsyonel Sinir Ağları ile Epilepsi Hastalığının Çok Sınıflı Tespiti”, *Politeknik Dergisi*, *(*) : *, (*).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1589819

EEG Sinyallerini Kullanarak 2D Konvolüsyonel Sinir Ağları ile Epilepsi Hastalığının Çok Sınıflı Tespiti


EEG Sinyallerini Kullanarak 2D Konvolüsyonel Sinir Ağları ile Epilepsi Hastalığının Çok Sınıflı Tespiti

Önemli noktalar (Highlights)

- ❖ EEG sinyallerinin 2D CNN ağlarda kullanımı için CWT ile zaman-frekans dönüşümü yapılmıştır./ Time-frequency representation of EEG signals is made with CWT for use in 2D CNN networks.
- ❖ Beş sınıfa ait EEG sinyalleri %95.33 doğrulukla ayırt edilebilmiştir./ Five-class EEG signals are classified with 95.33% accuracy.
- ❖ En yüksek sınıflandırma doğruluğu GoogleNet transfer öğrenme modeli ile elde edilmiştir./ The highest classification accuracy was obtained with the GoogleNet transfer learning model.

Grafik Özet (Graphical Abstract)

Bu çalışmada sağlıklı ve epilepsi hastalığına sahip kişilerden toplanan EEG sinyallerinin 2D CNN modelinde kullanılmak üzere zaman-frekans gösterimini elde edebilmek amacıyla Sürekli Dalgacık Dönüşümü ile skalogram görüntüleri elde edilerek transfer öğrenme modelleriyle çok sınıflı sınıflandırılması amaçlanmıştır.



Şekil. EEG sinyallerine dayalı epilepsi teşhisi için CWT ve 2D CNN modeli akış diyagramı/
Figure. Flowchart of CWT and 2D CNN model for epilepsy diagnosis based on EEG signals

Amaç (Aim)

EEG sinyallerine dayalı çok sınıflı epilepsi teşhisi için CNN modellerin performansının değerlendirilmesi. /Evaluating the performance of CNN models for multi-class epilepsy diagnosis based on EEG signals.

Tasarım ve Yöntem (Design & Methodology)

EEG sinyallerinin 2D CNN modelinde kullanılmak üzere CWT ile skalogram görüntüleri elde edilerek transfer öğrenme modelleriyle sınıflandırılmıştır./ Scalogram images were obtained with CWT to be used in the 2D CNN model of EEG signals and classified with transfer learning models.

Özgünlük (Originality)

EEG sinyallerinin 2D CNN modeller ile sınıflandırılması beş-sınıf sınıflandırma performansını arttırmıştır. / Classification of EEG signals with 2D CNN models increased the performance in five-class classification.

Bulgular (Findings)

GoogleNet transfer öğrenme modelleri arasında en yüksek performansı gösteren model olmuştur ve beş-sınıf EEG sinyallerinin skalogram görüntülerini %95.33 doğrulukla sınıflandırmıştır./ GoogleNet was the highest performing model among transfer learning models and classified scalogram images of five-class EEG signals with 95.33% accuracy.

Sonuç (Conclusion)

EEG sinyallerinin 2D gösterimlerinin derin öğrenme modelleri ile çok sınıflı sınıflandırılması, sınıflandırma başarısını arttırmaktadır./ Multi-class classification of 2D representations of EEG signals with deep learning models increases the classification success.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

EEG Sinyallerini Kullanarak 2D Konvolüsyonel Sinir Ağları ile Epilepsi Hastalığının Çok Sınıflı Tespiti

Araştırma Makalesi / Research Article

Yiğithan GENİŞ, Eda AKMAN AYDIN*

Elektrik-Elektronik Mühendisliği Bölümü, Teknoloji Fakültesi, Gazi Üniversitesi Ankara, Türkiye
(Geliş/Received : 22.11.2024 ; Kabul/Accepted : 19.03.2025 ; Erken Görünüm/Early View : 12.04.2025)

ÖZ

Elektroensefalogram (EEG) epilepsi hastalığının teşhisi için önemli bir sinyaldir. Transfer öğrenme, veri boyutlarının model eğitimi için yeterli olmadığı durumlarda, önceden eğitilmiş model ağırlıklarının yeni problemlerde kullanılmasını sağlayan bir tekniktir. Bu çalışmada, transfer öğrenme modelleri sağlıklı gözü açık, sağlıklı gözü kapalı, nöbet anında olmayan hastadan epileptojenik bölgenin karşısından kaydedilmiş, nöbet anında olmayan hastadan epileptojenik bölgeden kaydedilmiş ve nöbet anındaki hastadan epileptojenik bölgeden kaydedilmiş EEG sinyal örneklerinin sınıflandırılması amacıyla kullanılmıştır. Sinyallerin, 2D CNN modelinde kullanılmak üzere zaman-frekans gösterimini elde edebilmek amacıyla Sürekli Dalgacık Dönüşümü (CWT) ile skalogram görüntüleri elde edilerek konvolüsyonel sinir ağı (CNN) için giriş görüntüleri olarak kullanılmıştır. Çalışmanın sonuçları GoogleNet transfer öğrenme modelinin CWT zaman-frekans gösterimi kullanılarak epilepsi teşhisinde en başarılı model olduğunu, önerilen yöntemin beş duruma ait EEG sinyallerini %95.33 doğrulukla ayırt edebildiğini göstermektedir.

Anahtar Kelimeler: EEG, epilepsi, sürekli dalgacık dönüşümü, transfer öğrenme, derin öğrenme, konvolüsyonel sinir ağları

Multi-Class Detection of Epilepsy Disease with 2D Convolutional Neural Networks Using EEG Signals

ABSTRACT

Electroencephalogram (EEG) is an important signal for the diagnosis of epilepsy. Transfer learning is a technique that allows the use of previously trained model weights in new problems when the data size is not sufficient for model training. In this study, transfer learning models were used to classify EEG signal samples recorded from volunteers relaxed in an awake state with eyes open and eyes closed; recorded from within the epileptogenic zone, and from the opposite of epileptogenic zone during seizure free intervals; and recorded from within the epileptogenic zone during seizure activity. In order to obtain the time-frequency representation of the signals, scalogram images were obtained with Continuous Wavelet Transform (CWT) and used as input images for the convolutional neural network (CNN). The results of the study show that the GoogleNet transfer learning model is the most successful model in the diagnosis of epilepsy with CWT images, and the proposed method can distinguish EEG signals belonging to five conditions with 95.33% accuracy.

Keywords: EEG, epilepsy, continuous wavelet transform, transfer learning, deep learning, convolutional neural network.

1. GİRİŞ (INTRODUCTION)

Epilepsi, dünya çapında 65 milyon insanı etkileyen, beyindeki kortikal nöronlardaki aşırı elektrik boşalmasının nedeni olduğu kronik bir hastalıktır [1]. Epileptik nöbetlerin tekrarlanması hastaların sosyal aktivitelerini ve psikolojisini ciddi şekilde etkilemektedir [2]. Bu nedenle epilepsili hastaların doğru teşhis edilmesi ve doğru tedavinin uygulanması önemlidir. Epilepsi tanısı için yaygın olarak kullanılan yöntemler, elektroensefalogram (EEG) [3], pozitron emisyon tomografisi (PET) [4] ve manyetik rezonans görüntüleme (MRI)'dir [5]. Bu yöntemler arasında EEG sinyalleri, düşük maliyetli olmaları ve kolay elde edilmeleri sebebiyle yaygın olarak kullanılmaktadır [6]. Epileptik nöbetleri daha doğru ve hızlı bir şekilde tespit etmek, nöbetler için tedavi sağlamaya yardımcı olabilmektedir. Epilepsi tedavisi genellikle ilaçlı veya cerrahi yöntemler olmak üzere iki şekilde gerçekleştirilmektedir. İlaçlara dirençli hastalarda cerrahi yöntemler uygulanmaktadır [7]. Ancak bu yöntem fokal epileptik nöbetleri olan

hastalarda uygulanmaktadır. EEG, sinir sistemi hastalıklarına dair beyinin elektriksel aktivitedeki değişimlerin açıklanmasında ve epileptik sinyallerin tanımlanmasında kullanılmaktadır.

Literatürde, EEG sinyalleri kullanılarak epilepsi hastalığının teşhisi ve nöbet anlarının belirlenmesine yönelik birçok öznelitik çıkarma ve sınıflandırma modelleri önerilmiştir [6]-[23]. Birçok entropi ölçümü türü [8], [9] çeşitli dalgacık dönüşümleri [6], [10], [11], ampirik mod ayrıştırma [6], [12], doğrusal olmayan ölçümler [13], [14], hibrit yaklaşımlar [15] çoğunlukla özellik çıkarma işlemlerinde kullanılmıştır. Destek vektör makineleri (SVM), sinir ağları, k-en yakın komşular (KNN), adaptif ağ tabanlı bulanık mantık çıkarım sistemi (ANFIS), Naive Bayes gibi epileptik nöbetlerin performansını belirlemek için birçok sınıflandırma ve kümeleme algoritması kullanılmıştır [9], [15]-[22]. El yapımı özellik çıkarma olarak bilinen tüm bu yöntemler, hem zaman alıcı hem de hesaplama karmaşıklığı sunmaktadır. Bu nedenle, bu karmaşık

*Sorumlu Yazar (Corresponding Author)

e-posta : edaakman@gazi.edu.tr

süreçleri gerçek zamanlı uygulamalarda uygulamak çok zordur [23].

Derin öğrenme teknikleri, günümüzde tıbbi karar destek sistemlerinde çeşitli problemleri çözmek için kullanılmaktadır. Öznelik çıkarma ve sınıflandırma aşamalarındaki karmaşıklığın üstesinden gelebilmek için derin öğrenme teknikleri, ham verileri kullanarak doğrudan özellik çıkarma ve sınıflandırma süreçlerini uçtan uca bir yapı ile gerçekleştirmektedir. Bununla birlikte, büyük miktarda veri ve bu veriyi işleyebilecek güçlü hesaplama kabiliyetlerine sahip donanımsal özellikler gerektirmektedir [24]. Derin öğrenme modelleri, biyomedikal tek boyutlu (1D) sinyallerde, elektrokardiyogram (EKG) [25], [26], EEG [27], [28], elektromiyografi (EMG) [29] gibi sinyallerden üretilen iki veya üç boyutlu (2D veya 3D) görüntülerde başarıyla uygulanmaktadır. Son yıllarda ise sınıflandırma için transfer öğrenme tekniğini kullanan önceden eğitilmiş derin evrişimli sinir ağları (CNN) modelleri kullanılmıştır [30], [31].


Kumar ve arkadaşları [32] iğnecikli ve iğnecikli olmayan derin evrişimli sinir ağları (SNSDeepNet) adını verdikleri bir derin öğrenme modeli ile epilepsi hastalarını atak anında ve atak anı dışında olmak üzere iki sınıflı sınıflandırması için %94.1 doğruluk oranı elde etmiştir. Reddy ve arkadaşları [33], Bonferroni ortalama tabanlı bulanık örüntü ağacı yöntemini kullanarak sağlıklı, nöbet anında olmayan epilepsi hastası ve nöbet anı olmak üzere üç grubu sınıflandırarak %97.8 doğruluk oranı elde etmiştir. Zhao ve arkadaşları [34] artık ağlar (ResNet) ve çift yönlü uzun kısa süreli bellek (BiLSTM) modellerini kullanarak üç sınıflı sınıflandırma için %99.23, beş sınıflı sınıflandırmada ise %91.27 doğruluk oranı elde etmişlerdir. Shanmugam ve Dharmar [35] 1D-CNN-LSTM hibrit model geliştirmişler ve bu modeli kullanarak beş grubu %92.5 doğrulukla sınıflandırmışlardır. Qui ve arkadaşları [36] ise CNN ve RNN modelleri birleştirerek bir hibrit model önermişler, ve beş sınıf için %90.17 doğruluk oranına erişmişlerdir. Geniş ve arkadaşları [37] ise önerdikleri CNN modeli ile epilepsi hastaları ve sağlıklı katılımcıları %100 doğrulukla; sağlıklı, hasta ve kriz anına ait üç grubu %99 doğrulukla; son olarak beş grubu %94.17 doğrulukla sınıflandırmışlardır. Epilepsi ve sağlıklı kişilere ait EEG

incelenen problemler olmasına rağmen, beş sınıflı sınıflandırma problemini ele alan çalışmaların sınırlı olduğu ve doğruluk oranlarında iyileştirmelere gerekliliği olduğu görülmektedir.

Bu çalışmada, sağlıklı ve epilepsi hastası katılımcılardan kaydedilen EEG sinyallerinin sürekli dalgacık dönüşümü (CWT) tabanlı zaman frekans dönüşümü yapılarak elde edilen skalogram görüntülerinin 2D CNN modelleri ile sınıflandırılması amaçlanmıştır. Bu kapsamda, önerilen modelin üç ve beş sınıflı verileri sınıflandırma performansları değerlendirilmiştir. Üç sınıflı problemde, sağlıklı katılımcılara ait EEG kayıtları, nöbet anında olmayan epilepsi hastaları ve atak anındaki epilepsi hastalarına ait EEG sinyallerini sınıflandırma başarıları ele alınmıştır. Sınıf sayısının beşe artırılması durumunda ise önerilen modelin, sağlıklı katılımcıların gözlerinin açık olması durumu, sağlıklı deneklerin gözlerinin kapalı olması durumu, nöbet anında olmayan hastalardan epileptojenik bölgeden kaydedilen, nöbet anında olmayan hastalardan epileptojenik bölge karşısından kaydedilen ve epilepsi hastalarından atak anı sırasında kaydedilen beş farklı durumu temsil eden sinyallerin sınıflandırılma performansı değerlendirilmiştir. Bu amaçla, EEG sinyallerine CWT tabanlı zaman-frekans dönüşümü yapılarak elde edilen skalogram görüntüleri kullanılmıştır. Elde edilen görüntülerin transfer öğrenme modelleri kullanılarak beş sınıflı epilepsi sinyallerinin beş sınıflı sınıflandırma başarıları değerlendirilmiştir. Bu çalışmanın ikinci bölümünde EEG veri seti, elde edilen skalogram tabanlı CWT, önceden eğitilmiş transfer öğrenme modelleri, deneysel çalışmalar ve performans metrikleri dahil olmak üzere sınıflandırma için kullanılan metodolojileri sağlamaktadır. Üçüncü bölümde, deney sonuçları paylaşılmaktadır. Son bölümde ise çalışma sonuçları değerlendirilmektedir.

2. MATERYAL VE METOD (MATERIAL AND METHOD)

Sunulan çalışmanın tüm iş akışı Şekil 1'de gösterilmektedir. Çalışmada, sağlıklı ve hasta gruplardan toplanan beş farklı durum için EEG sinyallerine ait görüntülerin elde edilmesi amacıyla zaman-frekans gösterimlerinden faydalanılmıştır. Bu kapsamda, ilk



Şekil 1. Önerilen yöntemin iş akışı (The complete workflow of the proposed method)

sinyallerini ayırt etme ve nöbet anını belirleme gibi iki sınıflı problemler literatürde yaygın olarak başarıyla

olarak tek boyutlu EEG sinyallerine sürekli dalgacık dönüşümü uygulanarak skalogram görüntüleri elde

edilmiştir. Skalogram görüntüleri, farklı transfer öğrenme modellerinde kullanılabilirler üzere farklı görüntü boyutlarında kaydedilmiştir. Sunulan çalışmanın temel amaçlarından biri de AlexNet, GoogLeNet, EfficientNet-B0, ResNet50 ve VGG16 olan önceden eğitilmiş modellerin sınıflandırma performansını karşılaştırmaktır. Ayrıca bu modellerde diğer geleneksel makine öğrenmesi yöntemlerinden farklı olarak ön işleme ve özellik çıkarma işlemi yapılmamaktadır. Böylece elde edilen 2 boyutlu skalogram görüntüleri başka bir işleme gerek kalmadan doğrudan önceden eğitilmiş modellere girdi olarak verilmektedir. Skalogram görüntüleri transfer öğrenme modellerinin girişine uygulanarak, model performansları işlem süresi, konfüzyon matrisleri ve istatistiksel performans ölçütleri üzerinden karşılaştırılmıştır

2.1. Veri Kümesi (Dataset)

Bu çalışmada Bonn veri kümesi kullanılmıştır [38]. Veri kümesi, sağlıklı ve epilepsi hastası katılımcılara ait beş farklı durumda kaydedilen EEG sinyallerini içermektedir. Beş farklı duruma ait sınıflar A ile E arasında isimlendirilmiştir. Sağlıklı katılımcılara ait EEG sinyalleri, katılımcıların gözlerinin açık olması ve gözlerinin kapalı olması durumlarında, saçlı deriden 10-20 uluslararası elektrot konumlandırma sistemine göre yerleştirilen yüzey elektrotlar kullanılarak kaydedilmiştir. Gözlerin açık olması durumunda kaydedilen veriler Sınıf A ve gözlerin kapalı olması durumunda kaydedilen veriler Sınıf B olarak isimlendirilmiştir. C, D ve E sınıflarına ait veriler ise epilepsi hastalarına ait EEG kayıtlarını içermektedir. C sınıfı, epilepsi hastası katılımcıdan kafatası içine yerleştirilen elektrod ile epileptojenik bölgenin karşısından nöbet anı dışında toplanan EEG sinyalini; D sınıfı epilepsi hastası katılımcıdan kafatası içine yerleştirilen elektrod ile epileptojenik bölgeden nöbet anı dışında toplanan EEG sinyalini, ve E sınıfı ise epilepsi nöbeti sırasında epileptojenik bölgeden kaydedilen EEG sinyal kayıtlarını içermektedir. Her veri sınıfı için 23.6 saniye süresince kayıt alınmıştır. Veriler, 173.61 Hz örnekleme frekansında kaydedilmiştir. Veri kaydı sırasında 12-bit analog dijital dönüştürücü ve band genişliği 0.53-40 Hz bant geçiren filtreler kullanılmıştır. Tek kanaldan kaydedilen veriler 100 bölüme ayrılmıştır. Veri kümesine ait sınıflar ve özellikleri

Çizelge 1’de açıklanmıştır. Tüm EEG sinyallerinin kaydı sırasında 128 kanallı EEG yükselteç kullanılarak ve ortak bir referans noktası kullanılmıştır.

2.2. Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)

EEG sinyalleri, beyin aktivitesindeki elektriksel değişimlere dair önemli bilgiler içermektedir. Bu sinyallerdeki bilgilerin bazıları zaman ekseninde ayırt edilmeyebilirler. Spektral analiz yöntemleri, bu bilgilerin bulunmasında sinyallerin frekans bileşenlerinden faydalanılmasına olanak sağlamaktadır. EEG işaretleri durağan olmayan sinyallerdir ve bu sinyallerde zaman zaman ortaya çıkan kısa süreli anlık değişimler ve karmaşık dalgalar tespit için önemli bilgiler taşımaktadır. Dalgacık dönüşümü, durağan olmayan sinyallerin zaman-frekans analizi için etkili bir analiz yöntemidir. Dalgacık dönüşümünün en önemli avantajı, yüksek frekanslar için dar, düşük frekanslar için geniş olacak şekilde değişen pencere boyutlarıyla sinyalin analiz edilmesine imkan sağlamasıdır. Böylece tüm frekans aralıklarında optimum zaman-frekans çözünürlüğü sağlanabilmektedir.

Frekans zamana göre değişen sinyallerin sürekli dalgacık dönüşümü (CWT) ile analizinde zaman-frekans diyagramı elde edilmektedir. Tespit yöntemlerinde zaman-frekans alanına dönüşüm için seçilen yöntem çok önemlidir. Dalgacık dönüşümü bu dönüşüm için çok uygundur. Çünkü bu dönüşüm EEG, EKG ve EMG gibi durağan olmayan sinyaller için oldukça etkili bir yöntemidir [39], [40], [41]. Dalgacık dönüşümünde sinyal Daubechies, Morlet, Symlets ve Gaussian gibi dalgacık fonksiyonları yardımıyla dönüştürülür. Morlet dalgacık, EEG sinyal dönüşümünde kullanılan diğer dalgacık fonksiyonlarına kıyasla dönüştürme uygulamalarında yaygın olarak kullanılmaktadır [42], [43]. Bu nedenle bu çalışmada Morlet dalgacığı kullanılmıştır. Sürekli zaman dalgacık dönüşümüne sahip 1D-EEG sinyalinin katsayıları Denklem 1 ile hesaplanmaktadır.

$$X_{cwt}(\tau, a) = \frac{1}{\sqrt{a}} \int x(t) \psi^* \left(\frac{t-\tau}{a} \right) dt \quad (1)$$

Burada $x(t)$, dönüştürülecek 1D sinyalini gösterir. τ öteleme parametresidir, a dalgacık fonksiyonunun ölçek parametresidir, ψ ana dalgacık olarak adlandırılır.

Çizelge 1. Bonn Veri Kümesi (Bonn Dataset)


Denek	5 Sağlıklı Denek		5 Hasta Denek		
Sınıf	Sınıf A	Sınıf B	Sınıf C	Sınıf D	Sınıf E
Kişinin Durumu	Sağlıklı ve uyanık Gözler açık	Sağlıklı ve uyanık Gözler kapalı	Epilepsi hastası Nöbet durumunda değil	Epilepsi hastası Nöbet durumunda değil	Epilepsi hastası Nöbet durumunda
Elektrot Tipi	Yüzey	Yüzey	Kafatası İçi	Kafatası İçi	Kafatası İçi
Elektrot Yerleşimi	10-20 sistem	10-20 sistem	Epileptojenik bölgenin karşısı	Epileptojenik bölge	Epileptojenik bölge

Ölçek parametresi (a) büyük olduğunda dalgacık sinyali genişler ve düşük frekanslarda kullanılır; küçük ölçekli parametre (a) dalgacık sinyalini sıkıştırır ve yüksek frekanslarda kullanılır. CWT sadece ana dalgacığın ölçeğine etki etmez, aynı zamanda genliğe de etki eder. a büyükse dalgacığın genliği düşüktür ve a küçükse dalgacığın genliği yüksektir. Başka bir deyişle, dalgacık işlevi, belirli bir ölçek parametresi a değeri için τ öteleme parametresine dayalı olarak x giriş sinyalini konvolüsyona tabi tutar ve bu işlem her a değeri için tekrarlanır.

Çalışmada kullanılan skalogram görüntüleri aslında sinyalin zaman kaymasındaki (τ) ve ölçekleme faktöründeki (a) enerji dağılımının bir ölçüsüdür. Enerji formülü Denklem 2’de tanımlanmıştır.

$$\text{Energy}_{\text{cwt}}(\tau, a) = \sum_{\tau} \sum_a (X_{\text{cwt}}(\tau, a))^2 \quad (2)$$

Şekil 2’de sağlıklı gözü açık, sağlıklı gözü kapalı, nöbet anında olmayan hastadan epileptojenik bölgenin karşısından kaydedilmiş, nöbet anında olmayan hastadan epileptojenik bölgeden kaydedilmiş ve nöbet anındaki hastadan epileptojenik bölgeden kaydedilmiş EEG sinyal



Şekil 2. Beş sınıfa ait EEG sinyalleri için CWT dönüşümündeki 2D-skalogram görüntüleri (2D-scalogram images of CWT transform of EEG signals for five classes)


örnekleri ve her bir örnek için çizdirilen CWT zaman-frekans gösterimleri görülmektedir. Şekil 2'deki görüntüler üzerinde herhangi bir normalizasyon işlemi yapılmamıştır. Görüntülerin her boyutu varsayılan olarak 512x512 boyutlu olarak kaydedilmiştir. Tüm giriş verileri renklendirilmiştir. Kaydedilen görüntüler transfer öğrenme modellerinin girişlerine uygulanmıştır.

2.3. Evrişimsel Sinir Ağları ve Transfer Öğrenme (Convolutional Neural Networks and Transfer Learning)

Evrişimsel sinir ağları (CNN), derin sinir ağlarının bir alt algoritmasıdır. CNN, doğrudan verinin kendisinden öğrenmeye dayalı bir yöntemdir [44]. Genel olarak, CNN, bir evrişim katmanı, bir havuzlama katmanı ve bir tam bağlantılı katman olmak üzere üç farklı katmandan oluşur. Özellik çıkarma işlemi, evrişim ve havuzlama katmanlarında gerçekleşir. Sınıflandırma işlemi tam bağlantılı katmanda gerçekleşir. Evrişim katmanı, CNN'nin temel katmanıdır. Girdi verisinden çeşitli özellikleri tespit etmekten sorumludur. Bu katman, desendeki düşük ve yüksek seviyeli özellikleri çıkarmak için desen boyunca kayan bazı filtreler uygulamaktadır. Havuzlama katmanı, gerekli matematiksel hesaplamayı uygulayarak özellik haritalarının ve ağ parametrelerinin sayısını azaltmak için kullanılır. Tam bağlantılı katman, çok katmanlı bir algılayıcı gibi çalışır. Aktivasyon

yalnızca tamamen bağlı katmanları eğitebileceği gibi, var olan ağırlıklar ile beraber tüm modeli baştan eğitebilir. Bu çalışmada, sınıflara ait skalogram görüntülerini tespit etmek için kullanılan transfer öğrenme tekniğinin yapısı Şekil 3'te verilmiştir. Öncelikle 1 boyutlu EEG verilerinden skalogram görüntüleri elde edilmektedir. Bu orijinal görüntüler, önceden eğitilmiş model için uygun olmayabilir. Farklı önceden eğitilmiş CNN modelleri için farklı giriş görüntüsü boyutları uygulanmaktadır. Örneğin, ResNet50 için 224x224 görüntü boyutu kullanılırken InceptionV3 için 229x229 görüntü boyutu kullanılmaktadır. Bu nedenle tüm görüntülerin önceden eğitilmiş modele göre değişebilecek görüntü boyutlarına dönüştürülmesi gerekmektedir. Dönüştürülen bu görüntüler kullanılarak önceden eğitilmiş modelin ağırlıkları ve hiperparametreleri aktarılmaktadır. Modelin sonuna eklenen tam bağlantılı ağ katmanları ile de model eğitilir. Tüm modelin eğitimi bu işlemlerden sonra elde edilmektedir.

Bu çalışmada AlexNet, GoogLeNet, EfficientNet-B0, ResNet50 ve VGG16 gibi mevcut performansları bilinen derin öğrenme modelleri kullanılmıştır. Tüm bu modeller 1000 sınıflı çok büyük bir ImageNet veri tabanında eğitilmiş ve bu çalışmada kullanılmıştır. Bu CNN modelleri şu şekilde ifade edilmektedir:



Şekil 3. Transfer Öğrenme Akış Diyagramı (Transfer Learning Flowchart)

fonksiyonları ve dropout işlemleri de bu katmanda kullanılmaktadır [45].

CNN algoritmasındaki katmanlar çeşitli şekillerde birbirine bağlanarak birçok farklı derin öğrenme modelini oluşturmaktadır. Bir CNN modelini eğitmek için büyük miktarda veriye ihtiyaç vardır. Bu nedenle, çok sayıda veriye erişmek zor bir iştir. Bu problemin çözümü için transfer öğrenme modelleri olarak adlandırılan önceden eğitilmiş derin sinir ağları kullanılmaktadır [46], [47]. Herhangi bir önceden eğitilmiş derin CNN modelinden alınan ağırlıklar, transfer öğreniminde kullanılır. Transfer öğreniminde,

AlexNet: Bu mimari, 2012'deki ImageNet yarışmasında tanımlanmıştır [48]. Bu yarışmanın galibi AlexNet olmuştur. Bu model kullanılarak nesne tanımlama hata oranının %26,2'den %15,4'e düştüğü görülmüştür. AlexNet mimarisi 5 evrişim katmanı, havuzlama katmanı ve 3 tam bağlantılı katmandan oluşmaktadır. Mimarisi, ImageNet veritabanındaki 1000 nesneyi sınıflandırmak için tasarlanmıştır. Filtre boyutu 11x11 olup, adım kayma sayısı (stride) 4 olarak belirlenmiştir.

GoogLeNet: ILSVRC 2014 yarışmasının galibi Google'dan GoogLeNet (a.k.a. Inception V1) olmuştur. %6.67'lik top 5 hata oranına ulaşmıştır [49]. Ağ,

LeNet'ten ilham alan bir CNN kullanmıştır ve başlangıç modülü olarak adlandırılan yeni bir öge uygulamıştır. Toplu normalleştirme, görüntü distorsiyonları ve RMSprop kullanılmıştır. Bu modül, birkaç küçük konvolüsyona dayandığından parametre sayısını azaltmaktadır. Mimarisi 22 katmanlı bir CNN'den oluşmaktadır ancak parametre sayısını 60 milyondan (AlexNet) 4 milyona indirmiştir.

EfficientNet-B0: EfficientNet, tüm derinlik/genişlik/çözünürlük boyutlarını ölçeklemek için bileşik bir katsayı kullanan bir evrişimli sinir ağı mimarisi ve ölçekleme yöntemidir [50]. ImageNet'te yaklaşık %84,4 top-1 ve %97,3 top-5 doğruluk elde etmiştir. Ayrıca model boyutu, önceki state-of-the-art modellerinden 8,4 kat daha küçük ve 6,1 kat daha hızlı hale gelmiştir. CIFAR-100 veri setinde %91,7 ve Flowers veri setinde %98,8 doğruluk elde etmiştir.

ResNet50: Deep Residual Network Architectures (ResNet), He, Zhang, Ren ve Sun (2016) [51] tarafından ortaya çıkarılmıştır. ResNet modeli, VGG ağlarına dayanmaktadır. ResNet50, AlexNet gibi geleneksel sıralı ağ mimarisinden farklı bir yapıya sahiptir. ImageNet yarışmasında ResNet50 mimarisi, AlexNet ve VGGNet gibi yaygın olarak kullanılan modellerden daha başarılı sonuçlar vermiştir.

VGG16: VGG16 mimarisi, Oxford University Visual Geometry Group tarafından ILSVRC2014 yarışmasında daha iyi sonuçlar elde etmek için kullanılan 13 evrişim ve 3 tam bağlantılı katmandan oluşan bir ağıdır. Evrişim katmanı, maksimum havuzlama katmanı ve dropout katmanları ile toplam 41 katman bulundurmaktadır. ImageNet yarışmasında %89 doğruluk elde ettiği bildirilmiştir [52].

2.4. Deneysel Çalışmalar (Experimental Studies)

Bu çalışmada, epilepsi hastaları ve sağlıklı katılımcılardan kaydedilen EEG sinyallerinin beş sınıflı sınıflandırılması amacıyla CWT'ye dayalı bir zaman-frekans dönüşümü ve CNN modellerinin kullanımı önerilmiştir. Önceden eğitilmiş modelin hiperparametreleri için öğrenme oranı 0.0001 olarak ayarlanmıştır. Yüksek performans elde edebilmek adına 10-15-20-25-30 batch size'lar denenmiştir. Tüm modeller için 50 epoch kullanılmıştır. Adam optimizer ve kayıp fonksiyonu olarak kategorik çapraz entropi seçilmiştir. Adam optimizer parametreleri $B_1=0.9$, $B_2=0.9$ ve decay rate = 0,001 olarak kullanılmıştır. Kullanılan tüm hiperparametreler, maksimum eğitim doğruluğunu elde eden eğitim veri kümesine dayalı olarak ince ayarlanmıştır. Daha sonra beşli sınıflandırmada eğitim için toplam %70 görüntü, test için %30 görüntü kullanılmıştır. Modeller beş kez eğitildikten sonra her eğitim için test doğruluğu hesaplanmaktadır. MATLAB'de Deep Network Designer Toolbox'ını kullanarak önceden eğitilmiş modeller tasarlanmıştır. Deneyler NVIDIA GeForce GTX1650 GPU, 16 GB RAM ve 2,50 GHz hızında Intel Core i5-10300H işlemciye sahip bir bilgisayar kullanılarak yapılmıştır.

2.5. Performans Metrikleri (Performance Metrics)

Önceden eğitilmiş beş modelin performansları genel doğruluk, duyarlılık, özgüllük, kesinlik ve F1-Skoru metrikleri kullanılarak değerlendirilmektedir [53], [54]. Bu metrikler eşitlik (3)-(7) ile tanımlanmıştır. Denklemlerde, True Positive (TP): tahmin sağlıklı ve gerçek değer sağlıklı, False Positive (FP): tahmin sağlıklı ve gerçek değer hasta, False Negative (FN): tahmin hasta ve gerçek değer sağlıklı, True Negative (TN): tahmin hasta ve gerçek değer hasta olarak değerlendirilmektedir

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4)$$

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (5)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (6)$$


$$\text{F1 Skoru} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (7)$$

3. DENEYSEL SONUÇLAR VE TARTIŞMA (EXPERIMENTAL RESULTS AND DISCUSSION)

Bu çalışmada, epileptik nöbetlerin tespiti için 1D-EEG sinyallerinden elde edilen iki boyutlu (2D) skalogram görüntüleri kullanılmıştır. 2D skalogram görüntülerinin her biri 224x224 veya 227x227 boyutundadır. Bu görüntüler kullanılarak önceden eğitilmiş derin öğrenme modellerinin performansları karşılaştırılmıştır. Önceden eğitilmiş modellerin parametreleri ImageNet veri setinden ve deney sonuçlarından elde edilmiştir. Bu parametreler doğrudan önerilen modellerimize (fine tuning) aktarılmaktadır. Modellerin eğitim aşaması, önceden eğitilmiş modellerin tüm katmanlarının eğitilmesiyle yapılmıştır.

Tüm modeller için batch size değerleri deneysel olarak belirlenmiş ve her biri için en iyi başarımlar ve kayıp değerini veren batch size'lar esas alınmıştır. GoogleNet için 15 batch size, Resnet için 20 batch size, EfficientNet-B0 için 25 batch size, VGG-16 için 10 batch size ve Alexnet için 15 batch size değeri kullanılmıştır.

Transfer öğrenme modellerine ait karmaşıklık matrisleri Şekil 4'te sunulmuştur. Tüm transfer öğrenme modellerinde nöbet anına ait sinyallerin (E) %100 doğrulukla belirlendiği görülmektedir. GoogleNet modelinin karmaşıklık matrisi incelendiğinde en yüksek sınıflandırma performansına sahip olduğu görülmektedir. Bu model, sağlıklı ve gözler açık (A) durumu ile nöbet anını (E) %100 doğrulukla ayırt etmesinin yanında özellikle hasta ve sağlıklı katılımcılara ait EEG sinyal



Şekil 4. Transfer öğrenme modellerinin karmaşıklık matrisleri (Confusion matrices of transfer learning models.)

örneklerini de çok yüksek doğruluklarla ayırt edebildiği görülmektedir.

Mimari derinlik açısından bazı modellere göre daha sığ olmasına rağmen GoogleNet, diğer modellere göre daha iyi sonuçlar vermektedir. Resnet ve EfficientNet modellerinin sağlıklı ve gözler açık (A) durumu ile nöbet anını (E) %100 doğrulukla ayırt edebildiği görülmektedir. Ancak bununla birlikte, bu modellerin hasta ve sağlıklı sınıfları ayırmada başarılı olmalarına rağmen, sağlıklı (A ve B) ve epilepsi hastalığı olan (C ve D) örneklerin sınıflandırılmasında hata oranlarının daha yüksek olduğu söylenebilir.

Beş sınıflı sınıflandırma (A-B-C-D-E sınıfları) için tüm modellerin daha ayrıntılı performans ölçütleri aşağıdaki

Çizelge 2’de verilmiştir. Transfer öğrenme modellerinin doğruluk oranlarının GoogleNet için %95.33, Resnet-50 için %93.33, EfficientNet-B0 için %87.33, VGG-16 için %90.6 ve Alexnet için %85.33 olduğu görülmektedir. Modellerin F1 skor oranlarının doğruluklarıyla paralel olduğu ve sınıflar arası dengenin uyumlu olduğu değerlendirilmektedir. Modeller eğitim süreleri açısından karşılaştırıldığında ise eğitim süresinin en kısa GoogleNet (668sn) modeli ile en uzun EfficientNet-B0 (2184) modeli ile sürdüğü görülmektedir. Genel performans açısından GoogleNet modeli en iyi performans değerini verirken, en düşük doğruluk sırasıyla Alexnet modelinde görülmektedir. Daha sığ mimariye sahip modellerin daha düşük performans sonuçlarına sahip olduğu anlaşılmaktadır. Ancak

Çizelge 2. Beşli sınıflandırma için performans metrikleri (Performance metrics for the five-class classification)

CNN Modelleri	Toplam Eğitim Süresi	Doğruluk (%)	Özgüllük (%)	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
GoogLeNet	668 sn	95.33	93	96.66	97	96.83
Resnet-50	1460 sn	93.33	90	90	87	88.47
EfficientNet-B0	2184 sn	87.33	85	89	80	84.26
VGG-16	1982 sn	90.6	89	92	90	90.99
Alexnet	1500 sn	85.33	83	82	85	83.47

modelde derinliğin artırılması performansı çok fazla artırmamaktadır.

Çizelge 3'te transfer öğrenme modellerinin üç sınıflı sınıflandırma (AB-CD-E) için performans metrikleri görülmektedir. Buna göre, transfer öğrenme modellerinin doğruluk oranları GoogleNet için %97.6, Resnet-50 için %96.66, EfficientNet-B0 için %92.33, VGG-16 için

B), nöbet anında olmayan epilepsi hastaları (C ve D) ve atak anındaki epilepsi hastasına (E) ait EEG sinyallerinin sınıflandırma sonuçlarını göstermektedir. Tuncer vd. [55] çalışmasında, dalgacık dönüşümü ve destek vektör makinelerine dayalı bir yöntem kullanarak epilepsi hastası ve sağlıklı katılımcılara ait sinyalleri farklı gruplara sınıflandırmış ve %95 doğruluk oranı elde

Çizelge 3. Üçlü sınıflandırma için performans metrikleri. (Performance metrics for the three-class classification)

CNN Modelleri	Toplam Eğitim Süresi	Doğruluk (%)	Özgüllük (%)	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)
GoogLeNet	468 sn	97.6	95	98.66	98	98.33
Resnet-50	1278 sn	96.66	92	91	88	89.47
EfficientNet-B0	1942 sn	92.33	87	91	83	86.81
VGG-16	1599 sn	90.2	91	94	91	92.47
Alexnet	965 sn	87.75	85	84	88	85.95

%90.2 ve Alexnet için %87.75'tir. Sınıf sayısının azalmasıyla birlikte VGG-16 dışında tüm modellerin doğruluk oranlarının arttığı, özgüllük, kesinlik, duyarlılık ve F1 skoru ise tüm modeller için arttığı görülmektedir. Doğruluk oranında en yüksek artış EfficientNet-B0 modelinde gerçekleşmiştir. En yüksek sınıflandırma başarısının elde edildiği model, beş sınıflı sınıflandırmada olduğu gibi GoogLeNet modeli olmuştur. Bonn veri kümesi epilepsi hastalığının varlığını, nöbet anını ve sağlıklı kişilerin ayırt edilebilirliğinin değerlendirilmesi amacıyla yapay zeka araştırmalarında sıklıkla kullanılan bir veri kümesidir. Bonn veri kümesinin kullanıldığı diğer bazı çalışmalar Çizelge 4'te özetlenmiştir. Çizelgede, üç sınıflı sınıflandırma sonuçları sağlıklı katılımcılara ait EEG kayıtları (A ve

etmiştir. Varlı vd. [56] CNN ve RNN modelleri birlikte kullanarak %97.30 doğruluk oranı elde etmiştir. Geniş vd.[37]'nin ise, 1D CNN modeli önererek EEG sinyallerini doğrudan sınıflandırdıkları çalışmalarında %99.48 doğruluk oranına eriştiği görülmektedir. Çizelge 4'te ayrıca, sağlıklı göz açık (A), sağlıklı göz kapalı (B), nöbet anı dışında hasta epileptojenik bölge (C), nöbet anı dışında hasta epileptojenik bölge karşısı (D) ve hasta atak anı (E) olmak üzere beş sınıf sınıflandırma problemini ele alan çalışmaların performansları açısından karşılaştırılmıştır. Xu vd [57] vd. CNN ve LSTM modelleri birlikte kullandıkları çalışmalarında %82 doğruluk oranı elde ederken, Tunçer vd [55]'nin, Dalgacık dönüşümü ve DVM ile %88 doğruluk oranı elde ettiği görülmektedir. Geniş vd [37]'nin ise EEG sinyallerini 1D CNN ile beş sınıflı sınıflandırdıkları

Çizelge 4. Bonn veri kümesini kullanan literatürdeki çalışmaların karşılaştırılması (Comparison of studies in the literature using the Bonn dataset)

Sınıflar	Çalışma	Yöntem	Doğruluk Oranı (%)
AB-CD-E	Tuncer vd. [55]	Dalgacık +DVM	95
	Varlı vd. [56]	CWT-CNN+RNN	97.30
	Geniş vd. [32]	1D CNN	99.48
	Bu çalışma	CWT-2D CNN	97.60
A-B-C-D-E	Xu vd [57]	CNN+LSTM	82
	Tuncer vd.[55]	Dalgacık +DVM	88
	Geniş vd. [32]	1D CNN	94.17
	Bu çalışma	CWT-2D CNN	95.33

çalışmalarında %94.17 doğruluk oranına eriştiği görülmektedir. Çalışma sonuçları incelendiğinde, ele alınan sınıf sayısının arttığı durumlarda doğruluk oranlarının azaldığını, ancak derin öğrenme modellerinin özellikle ele alınan sınıf sayısının arttığı durumlarda daha başarılı sonuçlar sağladığı görülmektedir. Bununla birlikte, EEG sinyallerinin zaman-frekans dönüşümü ile skalogram görüntülere dönüştürülerek 2D CNN ile sınıflandırılmasının beş sınıflı sınıflandırmada doğruluk oranını iyileştirdiği görülmektedir.

4. SONUÇ (CONCLUSION)

Derin öğrenme, veriyi doğrudan işleyerek öznelitik çıkarma, boyut indirgeme ve sınıflandırma aşamalarının algoritma tarafından yapıldığı ve günümüzde birçok alanda başarılı bir şekilde kullanılan bir yapay zeka tekniğidir. Transfer öğrenme, bir modelin daha önceden öğrendiği bilgi ve özellikleri, başka bir göreve aktararak yeniden kullanılmasıdır ve özellikle veri kümesinin modelin eğitimi için sınırlı kaldığı uygulamalar için önemli bir yaklaşımdır. Bu çalışmada, transfer öğrenme modelleri epilepsi hastası ve sağlıklı kişilerden sağlıklı gözü açık, sağlıklı gözü kapalı, nöbet anında olmayan hastadan epileptojenik bölgenin karşısından kaydedilmiş, nöbet anında olmayan hastadan epileptojenik bölgeden kaydedilmiş ve nöbet anındaki hastadan epileptojenik bölgeden kaydedilmek üzere beş farklı durumda kaydedilen EEG sinyallerinin sınıflandırılması amacıyla kullanılmıştır. Bu kapsamda GoogleNet, Resnet, EfficientNet-B0, VGG-16 ve Alexnet modelleri olmak üzere beş farklı transfer öğrenme modelinin performansı beş sınıf ve üç sınıflı problemlerin değerlendirilmesinde kullanılmıştır. Sinyallerin, 2D CNN modellerinin girişine uygulanabilmesi için gerekli görüntülerin elde edilebilmesi için zaman-frekans gösterimini elde edebilmek amacıyla CWT ile skalogram görüntüleri elde edilmiştir. Çalışmanın sonuçları CWT görüntüleri ile transfer öğrenme modellerinin kullanıldığı CNN modeli ile sağlıklı, epilepsi hastası ve kriz anındaki hastaya ait 3 gruptan alınan EEG sinyallerinin %97.6 doğrulukla; 5 gruptan alınan sinyallerin ise %95.33 doğrulukla tespit edildiğini ortaya koymuştur. Bununla birlikte, GoogleNet modelinin transfer öğrenme modelleri arasında hem üç hem de beş sınıflı durumlarda en başarılı model olduğunu görülmüştür. Çalışma sonuçları, EEG sinyallerinin 2D gösterimlerinin derin öğrenme modelleri ile çok sınıflı sınıflandırma performansını iyileştireceğini ortaya koymaktadır. İlerleyen çalışmalarda, sinyallerin 2D gösterimlerini elde etmek için farklı sinyal-görüntü dönüşüm yöntemleri kullanılarak, sınıflandırma başarısı üzerindeki etkisi incelenebilir.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı tarafından yürütülen 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı tarafından 1919B012102339 kodlu proje ile desteklenmiştir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Yiğithan GENİŞ: Deneyleri yapmış, deney sonuçlarını analiz etmiş ve makalenin yazım işlemini gerçekleştirmiştir.

Eda AKMAN AYDIN: Çalışmanın kavramsal tasarımı, sonuç analizi ve makalenin yazım işlemini gerçekleştirmiştir.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] Bromfield E.B., Cavazos J.E., Sirven J.I., (editors) "An introduction to epilepsy: Basic mechanisms underlying seizures and epilepsy", *American Epilepsy Society*, West Hartford, (2006).
- [2] Wiegartz P., Seidenberg M., Woodard A., Gidal B., Hermann B., "Comorbid psychiatric disorder in chronic epilepsy: recognition and etiology of depression" *Neurology*, 53: 3-8, (1999).
- [3] Arunkumar N., Kumar K.R., Venkataraman V., "Entropy features for focal EEG and non-focal EEG", *Journal of Computational Science*, 27: 440-444, (2018).
- [4] Mendes V.C., Morita M.E., Amorim B.J., Ramos C.D., Yasuda C.L., Tedeschi H., et al. "Automated online quantification method for 18F-FDG positron emission tomography/CT improves detection of the epileptogenic zone in patients with pharma coexistent epilepsy" *Frontiers in Neurology*, 8: 453, (2017).
- [5] Ponnatur J., Vemanna S., Ballal S., Singla A., "Utility of magnetic resonance imaging brain epilepsy protocol in new-onset seizures: how is it different in developing countries?" *Journal of Clinical Imaging Sciences*, 8: 43 (2018).
- [6] Deivasigamani S., Senthilpari C., Yong W.H., "Classification of focal and non-focal EEG signals using ANFIS classifier for epilepsy detection", *International Journal of Imaging Systems and Technology*, 26: 277-283, (2016).
- [7] Jobst B.C., Cascino G.D., "Resective epilepsy surgery for drug-resistant focal epilepsy: a review", *JAMA*, 313 (3): 285-293, (2015).
- [8] Zhu G., Li Y., Wen P.P., Wang S., Xi M., "Epileptogenic focus detection in intracranial EEG based on delay permutation entropy" *AIP Conference Proceedings*, 1559: 31-36, (2013).
- [9] Sharma R., Pachori R.B., Acharya U.R., "Application of entropy measures on intrinsic mode functions for the automated identification of focal electroencephalogram signals", *Entropy*, 17: 669-691, (2015).
- [10] Bhattacharyya A., Pachori R.B., Acharya U.R., "Tunable-Q wavelet transform based multivariate sub-band fuzzy entropy with application to focal EEG signal analysis" *Entropy*, 19(3): 99, (2017).

- [11] Sharma R., Kumar M., Pachori R.B., Acharya U.R., "Decision support system for focal EEG signals using tunable-Q wavelet transform" *Journal of Computational Science*, 20:52-60, (2017).
- [12] Das A.B., Bhuiyan M.I.H., "Discrimination and classification of focal and non-focal EEG signals using entropy-based features in the EMD-DWT domain", *Biomedical Signal Processing and Control*, 29:11-21 (2016).
- [13] Chatterjee S., Pratiher S., Bose R., "Multifractal detrended fluctuation analysis based novel feature extraction technique for automated detection of focal and non-focal electroencephalogram signals", *IET Science, Measurement & Technology*, 11(8): 1014-1021, (2017).
- [14] Acharya U.R., Hagiwara Y., Deshpande S.N., Suren S., Koh J.E.W., Oh S.L., et al., "Characterization of focal EEG signals: a review", *Future Generation Computer Systems*, 91:290-299, (2018).
- [15] Siddharth T., Gajbiye P., Tripathy, R.K., Pachori R.B., "EEG based detection of focal seizure area using FBSE-EWT rhythm and SAE-SVM network", *IEEE Sensors Journal*, 20(19):11421-11428, (2020).
- [16] Rai K., Bajaj V., Kumar A., "Novel feature for identification of focal EEG signals with K-means and fuzzy C-means algorithms", *2015 IEEE International Conference on Digital Signal Processing*, Singapore, 412-416, (2015).
- [17] Bajaj V., Rai K., Kumar A., Sharma D., Singh G.K., "Rhythm-based features for classification of focal and non-focal EEG signals", *IET Signal Processing*, 11(6):743-748, (2017).
- [18] Arunkumar N., Ramkumar K., Venkatraman V., Abdulhay E., Fernandes S.L., Kadry S., et al., "Classification of focal and non-focal EEG using entropies", *Pattern Recognition Letters*, 94: 112-117, (2017).
- [19] Arunkumar N., Ramkumar K., Venkatraman V., Abdulhay E., Fernandes S.L., Kadry S., et al., "Classification of focal and non-focal EEG using entropies", *Pattern Recognition Letters*, 94:112-117, (2017).
- [20] Siddharth T., Tripathy R.K., Pachori R.B., "Discrimination of focal and non-focal seizures from EEG signals using sliding mode singular spectrum analysis", *IEEE Sensors Journal*, 19(24): 12286-12296, (2019).
- [21] Sharma R., Sircar P., Pachori R.B., "Automated focal EEG signal detection based on third order cumulant function", *Biomedical Signal Processing and Control*, 58:101856, (2020).
- [22] Acharya U.R., Hagiwara Y., Deshpande S.N., Suren S., Koh J.E.W., Oh S.L., et al., "Characterization of focal EEG signals: a review", *Future Generation Computer Systems*, 91: 290-299, (2018).
- [23] Kiranyaz S., Zabihi M., Rad A.B., Tahir A., Ince T., Hamila R., et al., "Real-time PCG anomaly detection by adaptive 1D convolutional neural networks", *Neurocomputing*, 411:291-301, (2020).
- [24] Kaya U., Yılmaz A., Dikmen Y., "Sağlık alanında kullanılan derin öğrenme yöntemleri", *Avrupa Bilim ve Teknoloji Dergisi*, 16:792-808, (2019).
- [25] Acharya U.R., Fujita H., Oh S.L., Hagiwara Y., Tan, J.H., Adam M., "Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals" *Information Sciences*, 415:190-198, (2017).
- [26] Huang J., Chen B., Yao B., He W., "ECG arrhythmia classification using STFT-based scalogram and convolutional neural network", *IEEE Access*, 7: 92871-92880, (2019).
- [27] Xu B., et al., "Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification", *IEEE Access*, 7: 6084-6093, (2018).
- [28] Sharma R., Sircar P., Pachori R.B., "Automated seizure classification using deep neural network based on autoencoder" *Handbook of research on advancements of artificial intelligence in healthcare engineering, Advancement of Artificial Intelligence in Healthcare Engineering, IGI Global*, 1-19, (2020).
- [29] Xia P., Hu J., Peng Y., "EMG-Based Estimation of Limb Movement Using Deep Learning With Recurrent Convolutional Neural Networks", *Artif Organs*, 42(5):67-77, (2018).
- [30] Talo M., "Automated classification of histopathology images using transfer learning", *Artificial Intelligence in Medicine*, 101:101743, (2019).
- [31] Talo M., Baloglu U.B., Yildirim Ö., Acharya U.R., "Application of deep transfer learning for automated brain abnormality classification using MR images", *Cognitive Systems Research*, 54:176-188, (2019).
- [32] Kumar P., Upadhyay P.K., Panda M.K., "SNSDeepNet: spike and non-spike detection in epilepsy", *Engineering Research Express*, 6(3):035365, (2024).
- [33] Reddy G. N., Hait S.R., Guha D., Mahadevappa M., "Classification of epileptic EEG signals with the utilization of Bonferroni mean based fuzzy pattern tree", *Expert Systems with Applications*, 239: 122424, (2024).
- [34] Zhao W., Wang W.F., Patnaik L. M., Zhang B.C., Weng S.J., Xiao S.X., Wei D.-Z., Zhou H.F., "Residual and bidirectional LSTM for epileptic seizure detection", *Frontiers in Computational Neuroscience*, 18:1415967, (2024).
- [35] Shanmugam, S., Dharmar, S. A., "CNN-LSTM hybrid network for automatic seizure detection in EEG signals", *Neural Computing and Applications*, 35:20605-20617, (2023).
- [36] Qiu X., Yan F., Liu H., "A difference attention ResNet-LSTM network for epileptic seizure detection using EEG signal", *Biomedical Signal Processing and Control*, 82: 104652, (2023).
- [37] Geniş Y., Aydın E.A., "Diagnosis of Epilepsy Disease with Deep Learning Methods Using EEG Signals," *30th Signal Processing and Communications Applications Conference*, 1-4, (2022).
- [38] Andrzejak R.G., Lehnertz K., Normann 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: 1-8, (2001).
- [39] Faust O., Acharya U.R. , Adeli H., Adeli A., "Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis", *Seizure*, 26: 56-64, (2015).
- [40] Yochum M., Renaud C., Jacquir S., "Automatic detection of P, QRS and T patterns in 12 leads ECG signal based on CWT" *Biomedical Signal Processing and Control*, 25: 46-52, (2016).
- [41] Yochum M., Bakir T., Lepers R., Binczak S., "Estimation of muscular fatigue under electromyostimulation using CWT", *IEEE Transactions on Biomedical Engineering*, 59(12): 3372-3378, (2012).

- [42] Darvishi S., Al-Ani A., "Brain-computer interface analysis using continuous wavelet transform and adaptive neuro-fuzzy classifier", *International Conference of the IEEE Engineering in Medicine And Biology Society*, Lyon, France, 3220-3223,(2007).
- [43] Samar V., Bopardikar A., Rao R., Swartz K. "Wavelet analysis of neuroelectric waveforms: a conceptual tutorial", *Brain and Language*, 66 (1): 7-60, (1999).
- [44] LeCun Y., Bengio Y., Hinton G., "Deep learning", *Nature*, 521(7553):436, (2015).
- [45] Goodfellow I., Bengio Y., Courville A., "Deep learning" **Cambridge: MIT Press**, 1(2): 20-120, (2016).
- [46] Yildirim O., Talo M., Ay B., Baloglu U.B., Aydin G., Acharya U.R., "Automated detection of diabetic subject using pre-trained 2D-CNN models with frequency spectrum images extracted from heart rate signals", *Computers in Biology and Medicine*, 113: 103387, (2019).
- [47] Krizhevsky A., Sutskever I., Hinton G.E., "Imagenet classification with deep convolutional neural networks", *Advances in Neural Information Processing Systems*, Pereira F., BurgesC.J., Bottou L., Weinberger K.Q., **Curran Associates, Inc.**, 25, (2012).
- [48] Szegedy C., Ioffe S., Vanhoucke V., Alemi A., "Inception-v4, inception-ResNet and the impact of residual connections on learning" **31. AAAI Conference on Artificial Intelligence**, California, USA, 4278-4284, (2017).
- [49] Szegedy C., Reed S., Erhan D., Anguelov, D., Ioffe, S. "Scalable, high-quality object detection". arXiv:1412.1441, (2014).
- [50] Tan, M., Le, Q., "Efficientnet: Rethinking model scaling for convolutional neural networks", **36th International Conference on Machine Learning, PMLR**, California, USA, 97: 6105-6114, (2019).
- [51] Simonyan K., Zisserman A., "Very deep convolutional networks for large-scale image recognition", arXiv:1409.1556, (2014).
- [52] Kingma D.P., Ba J.L., "Adam: a method for stochastic optimization", **3rd International Conference for Learning Representations**, San Diego, 1-41, (2015).
- [53] Narin A., Isler Y., Ozer M., Perc M., "Early prediction of paroxysmal atrial fibrillation based on short-term heart rate variability" *Physica A*, 509: 56-65, (2018).
- [54] Isler Y., Narin A., Ozer M., Perc M., "Multi-stage classification of congestive heart failure based on short-term heart rate variability" *Chaos Solitons Fractals*, 118:145-151, (2019).
- [55] Tuncer E., Bolat E. D., "Destek vektör makineleri ile EEG sinyallerinden epileptik nöbet sınıflandırması", *Politeknik Dergisi*, 25(1): 239249, (2022).
- [56] Varlı M., Yılmaz H., "Multiple classification of EEG signals and epileptic seizure diagnosis with combined deep learning", *Journal of Computational Science*, 67:101943, (2023).
- [57] Xu, G., Ren, T., Chen, Y., Che, W., "A One-Dimensional CNN-LSTM Model for Epileptic Seizure Recognition Using EEG Signal Analysis", *Frontiers in Neuroscience*, 14:1253, (2020).

ERKEN GÖRÜŞ