



Şizofreni Tanısında Beyin Dalgalarının Derin Öğrenme Yöntemleri ile İncelenmesi Analysis of the Brainwaves for the Diagnosis of Schizophrenia with Deep Learning Methods

¹Berkay SERİN , ²Sevcan EMEK 

^{1,2}Manisa Celal Bayar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, 45140 Manisa, Türkiye

¹berkayserin@cbu.edu.tr, ²sevcan.emek@cbu.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 25 July 2023

Accepted : 20 September 2023

Keywords:

Brainwaves, Classification,
Deep Learning, CNN, RNN

ABSTRACT

This study offers an alternative approach to diagnosing schizophrenia. In this study, data obtained from 14 schizophrenic patients and 14 healthy individuals, using standard 10-20 EEG montages with 19 EEG channels are used. These data are classified in different ways and the findings obtained from the experimental studies are compared in terms of accuracy and time spent. Although the first approach is to conduct the brainwaves with Convolutional Neural Networks (CNN) without processing, it is observed that it does not yield an efficient result, because CNN forgets the wave data associated with each other between each neuron layer. As an alternative approach to the developed models, Recurrent Neural Network (RNN) is used to maintain the integrity of the data. While the maximum accuracy is 0.94 with the improved RNN, it reaches 0.93 accuracy with the proposed CNN model. It is observed that the learning time increases in the CNN model compared to the RNN model. Throughout the study, brainwaves are classified with suggested deep learning methods and it is tried to reach the most efficient one.

© 2023 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 25 Temmuz 2023

Kabul : 20 Eylül 2023

Anahtar Kelimeler:

Beyin Dalgası, Sınıflama,
Derin Öğrenme, CNN, RNN

ÖZET

Bu çalışmada şizofreni hastalığının teşhis edilmesine yönelik alternatif bir yaklaşım sunulmaktadır. Çalışmada, 14 şizofreni hastası ve 14 sağlıklı bireyden alınmış, 19 EEG kanalıyla standart 10-20 EEG montajı kullanılarak 250 Hz örnekleme frekansı ile elde edilen veriler kullanılmaktadır. Çalışma boyunca, bu veriler farklı şekillerde sınıflandırılmakta ve deneysel çalışmalarla elde edilen bulgular doğruluk ve harcanan süre açısından karşılaştırılmaktadır. İlk yaklaşım olarak, beyin dalgalarının işlenmeden evrişimli sinir ağları (Convolutional Neural Network -CNN) ile yürütmek olsa da CNN her nöron katmanı arasında birbiriyle ilişkili dalga verilerini unuttuğu için verimli bir sonuç vermediği gözlemlenmektedir. Geliştirilen modellere alternatif bir yaklaşım olarak, verilerin bütünlüğünü koruyacak tekrarlayan sinir ağları (Recurrent Neural Network -RNN) önerilmektedir. Elde edilen maksimum doğruluk değeri geliştirilen RNN ile 0.94 olurken, yapılandırılmış CNN modeli ile 0.93 doğruluk seviyesine erişmektedir. Başarıyı artırılmada CNN modelinde, RNN modeline kıyasla öğrenme süresinin arttığı gözlemlenmektedir. Çalışma boyunca, önerilen derin öğrenme yöntemleriyle beyin dalgaları sınıflandırılarak en verimli olanına ulaşılmaya çalışılmaktadır.

© 2023 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Şizofreni tanısı psikiyatristler tarafından bazı gözlemler sonucunda ortaya konmaktadır. Tek bir test şizofreniyi teşhis edemez. Bir hastanın yaşayabileceği farklı semptomlar nedeniyle, bir psikiyatrist kapsamlı bir klinik muayeneden sonra tanı koyabilmektedir. Muayenenin bir parçası olarak, bir psikiyatrist hastanın davranışlarında ve biyolojik işleyişinde (uykusuzluk, yemeğe veya sosyalleşmeye ilgi eksikliği) değişiklikler olup olmadığını kontrol etmektedir veya hasta davranışındaki sapmalar hakkında aile üyelerinden bilgi alabilmektedir [1-6]. Bu hastalığın pratikte daha kolay teşhisini sağlayabilecek teknik ve teknolojilerin gelişimi son yıllarda hız kazanmıştır. İnsan beyninin matematiksel modellenmesi ve derin öğrenme yöntemlerinin özellik tabanlı yöntemlere alternatif olarak kullanılmasına yönelik artan bir ilgi vardır. Derin öğrenme algoritmaları, önemli özellikleri otomatik olarak çıkarabilir ve bunları doğrudan verilerden sınıflandırabilir [7-11]. Bu yöntemler, veri işleme ve karar-verme kullanım modellerini oluşturmada insan beyninin işleyişini taklit ederek geliştirilmektedir. Sinir ağı mimarisi tasarımı ve eğitimindeki son gelişmeler, araştırmacıların daha önce zor olan derin öğrenme yöntemlerinin öğrenme görevlerini çözmelerini sağlamıştır. Birçok araştırma, derin öğrenmenin makine öğreniminde uygulanmasına, özellikle tıbbi uygulamalarda elektroensefalografi (EEG) sinyallerini başarılı bir şekilde işlemek için bilgisayarlı görü çalışmalarına odaklanmıştır [12-17]. Hastalıkların tanısında veya bir problemin çözüm sürecinde bir karar-verme mekanizması sunan yapay zeka yöntemleri yazılım geliştirme sürecinde önemli bir potansiyel güç oluşturmaktadır. Yapay zeka yöntemlerinde derin öğrenme alanında yapılan çalışmalar incelendiğinde, verilerin analizi ve işleyişi için kullanılan yöntemlerin ve algoritmaların karar-verme mekanizmasında verdiği sonuçlar hayati öneme sahip olabilmektedir. Geleneksel sınıflandırmada örneğin özellik çıkarma, özellik seçimi gerçekleştirme gibi yöntemlerin yanı sıra derin öğrenme algoritmaları ile önemli özellikler otomatik çıkarılmakta ve bunları doğrudan verilerden sınıflandırabilmektedir. Buradaki en önemli güç insan beyninin işleyiş modelini ortaya koymaktır [7, 18]. Birçok araştırma makalesi, derin öğrenmenin makine öğreniminde önemli bir teknoloji (state-of-the-art technology) olarak uygulanmasına, özellikle CNN'nin geniş yer bulduğu tıbbi uygulamalara yönelmiştir [19-24]. Benzer çalışmalar daha detaylı incelendiğinde mevcut sinir ağı modelleri ile geliştirilen ve başarıyı önemli derecede arttıran yöntem ve yaklaşımlar dikkat çekmektedir.

Literatürde bir durum çalışması olarak geniş yer bulan şizofreni karmaşık ve ciddi bir ruhsal bozukluktur. Dünya Sağlık Örgütü'ne göre şizofreni yüksek sağlık harcamalarına yol açan ciddi sakatlıklarla bağlantılıdır, uzun süreli ilaçlar kullanılarak tedavi edilebilir ve yönetilebilir [25, 26]. Dünya nüfusunun yaklaşık 24 milyon fazla insanı etkileyen bu hastalığın erken tanısında geliştirilen yöntemlere alternatif çözüm arayışları sürmektedir [26-30]. Şizofreni hastalığının derin öğrenme ile teşhisinde, son 3 yılda yapılan çalışmalara ait güncel literatür incelendiğinde; Shalhaf ve ekibi [16] çalışmalarında şizofreni tanısında CNN ve EEG sinyallerinin önerilen metotlarla kullanıldığı çalışmalara atıf yapmışlardır. Bu çalışmalarda ne tür yöntemler geliştirildiği örnek verilerle sunulmaktadır. Çalışmalarında, Sürekli Dalgacık Dönüşümü (SDD) (Continuous Wavelet Transform – CWT), önceden eğitilmiş dört popüler derin CNN (AlexNet, ResNet-18, VGG-19 ve Inception-v3) ile transfer öğrenme ve destek vektör makinesi kombinasyonu ile beyin işlev bozukluğunu modellemek için daha geliştirilmiş bir yaklaşım ortaya koymuşlardır. Siuly ve ekibi [26], EEG sinyal verilerini kullanarak şizofreninin tespiti için derin artık ağı (deep residual network -ResNet) modelini kullanan derin öğrenmeye dayalı bir özellik çıkarma yöntemini önermektedir. Aslan ve Akın [31] çalışmalarında, EEG kayıtlarından şizofreniyi otomatik olarak tespit etmeyi amaçlayan bir yöntem önermektedir. İki farklı veri setinde farklı CNN algoritmaları yürüterek deneysel bulgular ortaya koymaktadır. Ko ve Yang [28], zaman serisi görüntü dönüştürme algoritmaları, Recurrence Plot (RP) ve Gramian Angular Field (GAF) kullanarak görüntüye dönüştürülen EEG verilerini VGGNet temel alınarak oluşturulan Evrimsel Sinir Ağı (CNN) modelleri ile öğrenmesini çalışmalarında göstermektedir. Sobahi ve ekibi [32], EEG kayıtlarının her kanalını EEG ritimlerine ayırtan bir yöntem ortaya koymaktadır. Yeni bir haritalama prosedürü ile çalışmanın etkinliği deneysel olarak incelenmektedir. Şeker ve Özerdem [33] çalışmalarında şizofreni tanısında kullanılan yöntemleri inceleyen güncel çalışmaları ve bu çalışmalardaki bulguları paylaşmışlardır. Emre ve ekibi [6], psikiyatride makine öğrenmesi yöntemlerinin kullanıldığı çalışmalara dikkat çekmektedir. Bu alanda makine öğrenmesi ve EEG verisi ile yapılan çalışmalarda kullanılan yöntemler karşılaştırmalı olarak anlatılmaktadır. Khare ve ekibi [29], EEG sinyallerini SDD, kısa zamanlı Fourier dönüşümü ve Wigner-Ville dağılımı (SPWVD) ile işleyerek, dört evrimsel katmana sahip CNN modeli önermektedir. 11 katmanlı CNN modeli geliştiren Oh ve ekibi, subjektif olmayan (non subjective) ve subjektif (subjective) tabanlı testler ortaya koymaktadır. Sharma ve Acharya [34] tek kanallı EEG'den elde edilen optimal dalgacık tabanlı 11-norm özelliklerini kullanarak şizofreniyi tespit eden yöntem önermektedir.

Belirtilen çalışmalarda da görüleceği üzere, hastalıklı ve sağlıklı bireylerin görüntü ve sinyal işleme metotları ile beyin dalgalarının bilgisayar tabanlı hesaplamalı yöntemlerle sınıflandırılması sonucunda önemli bulgular tespit edilmektedir. Bu tür çalışmalarda EEG önemli bir görüntüleme aracı olmaktadır ve klinik uygulamalarda yaygın olarak kullanılmaktadır [12-17, 35-39]. Ancak mevcut literatürde, geliştirilen yöntemlerin şizofreni tespitinin etkinliğini ve doğruluğunu dengeleme ölçütlerinin hala sınırlı olduğu çalışmalarda vurgulanmaktadır [26, 28]. Çalışmalarda bazı derin öğrenme modellerin nasıl tahmin yaptığını ve tahminleri etkileyen faktörlerin veya varsayımların nasıl tanımladığını anlamak zor olabilmektedir. Çalışmalarda çok fazla vurgulanmayan diğer faktör, modelin eğitim sırasında harcadığı zaman ve maliyettir, bu durum güçlü GPU'lar ve büyük miktarda

bellek dahil olmak üzere önemli hesaplama kaynakları gerektirmektedir. Açık erişimli benzer veri kümelerinin birçok çalışmada sıklıkla kullanıldığı görülmektedir. Aynı veri kümesi üzerinden eğitilen modellerin sonuçlarının karşılaştırmalı olarak gösterildiği çalışmalar mevcut literatürde az sayıdadır. Çalışmaların sonuçlarında gözlemlenen yüksek başarı oranları gerçek yaşam/dünya uygulamalarında gözlemlenme imkanı bulmalıdır, çünkü analiz, doğrulama ve ölçeklendirmeye yönelik test teknikleri büyük ölçüde farklılık gösterebilmektedir. Çalışmalarda bir modelin işlevselliği tek bir durum çalışmasına bağlı olarak gözlemlenmektedir, ancak farklı problemlere adapte olabilecek karmaşık yapıdan uzak bir modelin geliştirmeye açık olan yönlerinin vurgulanması gerekmektedir. Optimizasyon tekniklerinin daha fazla kullanılması veya mevcut yöntemler üzerinden yapılandırılmış yeni çalışmaların sunulması daha iyi sonuçların elde edilmesinde mevcut literatüre daha fazla katkı sunmalıdır.

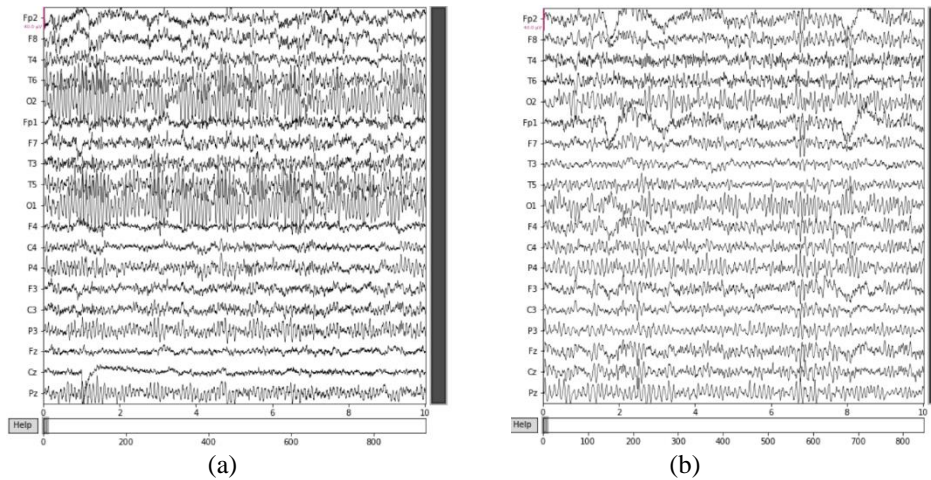
Bu çalışmanın mevcut duruma katkısı olarak; 1) EEG verileri kullanılarak yeniden yapılandırılmış karşılaştırmalı modeller üzerinden şifozreni tanısına yönelik literatürde mevcut çalışmalara alternatif çözüm sunulmaktadır, 2) Yapılan deneysel çalışmaların yazılımı Pyhton kütüphanesi kullanılarak oluşturulmuş, kütüphane ve fonksiyonları net olarak sunulmaktadır, 3) Modellerin eğitim ve test sürecinde, Intel Coffee Lake Core i7-9750H CPU ve 6GB GDDR6 Nvidia GTX1660Ti 192-Bit GPU kullanılarak zaman karşılaştırması yapılmaktadır, 4) Literatürde aynı veri kümesi ile işlenen benzer çalışmaların sonuçları bu çalışma sonunda değerlendirilmektedir, 5) Önerilen modeller, sadece şifozreni tanısında değil, diğer nörolojik ve psikiyatrik hastalıkların teşhisine de taşınabilir bir modül olma potansiyeline sahiptir. Bu çalışmada literatürde yer alan çalışmalar referans alınarak, diğer çalışmalarda da kullanılan açık erişimli veri kümelerinden örnekler işlenerek, beyin dalgalarının derin öğrenme yöntemleri ile karşılaştırmalı ve önerilen modeller üzerinde incelenmesi ele alınmaktadır. EEG verileri üzerinden RNN yöntemi ile çeşitli bulguların saptandığı çeşitli durum çalışmaları ve çözümler literatürde görülmektedir. Bu çalışmada sunulan RNN modeli, geliştirilen çözümlere paralel bir alternatif yaklaşım getirmektedir. Bu önerilen modelde, mevcut RNN mimarisinde bulunan birleştirme öncesinde paralel bir şekilde gerçekleştirilen evrişim katmanlarına, filtre boyutu 16 olan ve 32 filtre içeren bir katman daha eklenmiş ve bu birleştirme işlemi Kapı Özyinelemeli Geçitler (Gated Recurrent Unit -GRU) katmanlarına gelmeden önce bir kez daha gerçekleştirilmiştir. Bunların dışında mevcut RNN mimarisinde bulunan GRU katmanlarının çıktı uzayının boyutluluğu 64 olarak değiştirilmiş ve çıktı katmanının aktivasyon fonksiyonu sınıflandırılacak iki sınıf bulunduğundan sigmoid olarak değiştirilmiştir. Verilerin işleme süreçleri, mimaride kullanılan parametre ve kütüphaneler, deneysel çalışmalar ve sonuçların analizi çalışma boyunca ayrıntıları ile sunulmaktadır.

Çalışmanın içeriği 5 bölümden oluşmaktadır; çalışma kapsamında verilerin nasıl işlendiği ve analizi Bölüm 2’de anlatılmaktadır. Bölüm 3’de, kullanılan yöntemler ile elde edilen bulguların doğrulanması ve geçerliliği gösterilmektedir. Çalışmanın karşılaştırmalı sonuçları Bölüm 4’de değerlendirilmektedir. Son bölümde ise bu çalışmanın genel bir değerlendirilmesi ile geliştirilmeye açık olan kısımları tartışılmaktadır.

2. VERİLERİN İŞLENMESİ

Bu çalışmada, 14 şifozreni hastası ve 14 sağlıklı bireyden, 19 EEG kanalıyla standart 10-20 EEG montajı kullanılarak 250 Hz örnekleme frekansı ile elde edilen veriler kullanılmaktadır. Bu veriler IBIB PAN - Beyin Görüntüleme Yöntemleri ve Sinir Sisteminin İşlevsel Araştırma Departmanı’ndan alınmaktadır [40]. Katılımcılardan elde edilen beyin dalgası verileri dışında başka bir veri kullanılmamaktadır.

.edf dosyası halinde tutulan veriler (Şekil 1), çalışma boyunca ham .edf dosyaları içindeki dalga verileri halinde, mevcut .edf verilerinin kanal-saniye bazında .csv dosyalarına ve zaman-frekans bazında SDD kullanılarak temsili görsellere dönüştürülmektedir.




Şekil 1. Beyin sinyallerinin .edf verileri; a) Sağlıklı birey, b) Hastalıklı birey.


SDD, değişken sinyallerin varyasyonunun özelliklerini haritalamak için kullanılan bir yöntemdir, spektral

analizlerde Fourier analizler yerine kullanılabilir. Bu çalışmada CNN kullanımında veri çeşidi olarak dalga verisini haritalamak için kullanılmaktadır. EEG sinyalleri SDD yöntemiyle skalogram görüntülerine dönüştürülmektedir. Parametre olarak 19 elektrottan alınmış EEG kayıtları (Fp2, F8, T4, T6, O2, Fp1, F7, T3, T5, O1, F4, C4, P4, F3, C3, P3, Fz, Cz, Pz) kullanılmaktadır.

Her katılımcıya ait .edf dosyalarının içindeki dalga verileri kanal-saniye bazında .csv belgesine dönüştürülmektedir. Bu dönüşümler veri çerçevelerine (frame) aktararak çeyrekler arası aralık yöntemiyle temizlenip ölçeklendirilmektedir. Katılımcıların sinyalleri 12 – 15 dakika aralıklarında kaydedilmekte ve bu verileri pencereleme işlemi uygulanırken öncelikle her bir katılımcının her bir kanalından her saniye elde edilen verileri dikey bir şekilde sıralanarak katılımcının durumu için 0 veya 1 olacak şekilde ek bir sütunda gösterilmektedir. Tüm katılımcılar için bu işlem gerçekleştirildikten sonra bütün veriler dikey düzlemle birleştirilerek tek bir pencere haline getirilmektedir. Hasta ile sağlıklı bireylere ait veri çerçevelerinin yanına temsili 0 ve 1'lerden oluşan durum değişkenleri eklendikten sonra eğitim ve test kümeleri olarak ayrılarak çeşitli sınıflandırma metodlarıyla öğrenme sağlanmaktadır. Sıralı verilerin sınıflandırılmasında ve öğrenilmesinde kullanılan GRU katmanlarına sahip tekrarlı bir yapay sinir ağı (Recurrent Neural Network –RNN) kullanılmaktadır. Eldeki .edf dosyalarının içindeki dalga verileri okunarak, hasta ve sağlıklı bireyler bir önceki yöntemdeki gibi belirtildikten sonra veriler eğitim ve test kümeleri olarak ayrılmakta ve oluşturulan yapay sinir ağı ile eğitilmektedir. Python kullanılarak oluşturulan sağlıklı ve hasta bireylere ait spektrogramlar Şekil 2'de sunulmaktadır.



Şekil 2. Spektrogram görüntü; a) Sağlıklı birey, b) Hastalıklı birey

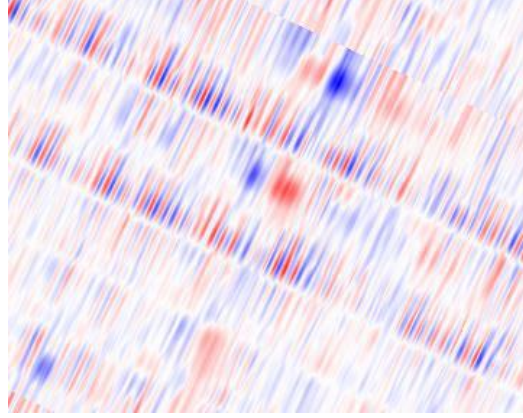


Şekil 3. Beyin sinyallerinin SDD uygulanarak elde edilmiş temsili görsel verileri; a) Sağlıklı birey, b) Hastalıklı birey.

Elde edilen görsel verileri (Şekil 3) CNN üzerinde denemek için eğitim, test ve validasyon kümelerine %10 test, %10 validasyon ve %80 eğitim kümesi olacak şekilde rastgele dağıtılmıştır. Bu dağılımdan sonra hastalıklı katılımcıların verilerinin eğitim kümesinde sağlıklı katılımcıların verilerinden daha fazla olduğu gözlemlenmiştir. Eğitim setinde sağlıklı bireylerde 2606 kare (frame) ve hasta bireylerde 3165 kare elde edilmiştir. Bu gözlem sonucunda veri kümesi kopyalanarak aynı veri kümesi üzerinde sağlıklı katılımcıların eğitim kümesindeki görsel verilerini rastgele seçip, rastgele bir derecede döndürülüp, döndürme işlemi sonucunda kenarda oluşan boşlukları da döndürülmüş ana görsel ile kaplayarak eğitim kümeleri arasındaki dengesizliğin olmadığı yeni bir veri kümesi elde edilmiştir (Şekil 4). İlk veri kümesi tekrar kopyalanarak fazla olan hastalıklı katılımcı verileri rastgele olacak şekilde silinerek dengesizliğin eksi yönde giderildiği başka bir veri kümesi oluşturulmuştur.


Eldeki veri kümesi, oluşturulan CNN ile sınıflandırılmıştır. Oluşturulan sinir ağı optimize edilip, katman sayıları, aktivasyon fonksiyonları, filtre boyutları, filtre işlemleri ve öğrenme oranı gibi parametrelerin değerleri belirlenmiştir. Yapılan işlemlerden sonra elde edilen CNN üzerinde, oluşturulan veri kümeleri denenmiştir. Test

kümesi kullanılarak elde edilen en yüksek doğruluk değeri, artı yönde yapılan veri eşitleme sonucu elde edilen veri kümesi ile sağlandığı gözlemlenmiştir.




Şekil 4. Veri artırımı (data augmentation) sonucu elde edilen görüntü örneği.

Görsele dönüştürülen verileri içeren veri kümeleri ile CNN üzerinde çalışırken bu görsel verilerinin yatay ekseninde tekrar eden bir örüntüye sahip olduğu fark edilmiştir. Üzerinde belirli bir düzlemde ve frekans şeklinde olan renk geçişlerine sahip görsellere Fourier Dönüşümü uygulanmıştır. Frekans alanının görsel ile ifade edilmiş halinde belirli noktalarda çıkacak parlaklıklar varsayılacağından, elde edilen görsel verilerden yeni bir veri kümesi oluşturulmuştur. Ancak elde edilen verilerin birbirlerinden ayırt edilmesinin zor olması, beklenildiği gibi parlak noktaların çeşitli frekans değişimlerinden dolayı elde edilememesi ve asıl verilere göre renk bazında ayırt edilmek için sadece siyah ve beyaz renkleri içerdikleri için hedeflenen doğruluk değerlerine ulaşamamış, %60-%70 doğruluk değerlerinin üzerinde bir başarı elde edilememiştir. Bunun sebebi olarak, görüntü alanındaki görüntülerin üzerindeki tekrarlayarak aynı düzlemde gerçekleşen renk geçişleri, görüntüye Fourier dönüşümü uygulanarak elde edilecek olan frekans alanındaki görüntünün merkezinde ana görüntüdeki renk geçişleriyle aynı doğrultuda bir parlaklık olarak temsil edileceği bilinmektedir. SDD uygulanarak elde edilmiş görüntüler üzerinde de Şekil 5'deki gibi düzlemsel geçişler fark edildiği için SDD uygulanarak elde edilen görüntüler önce filtrelenecek gri tonlarına dönüştürülmüş sonrasında bu dönüşüme laplace filtresi uygulanarak geçişler daha kalın hale getirilerek uygun bir dolgulama (padding) belirlendikten sonra Fourier dönüşümü uygulanmıştır. Fourier dönüşümü sonrası elde edilen görüntüler Şekil 6'da gösterilmektedir. SDD uygulanarak elde edilen görüntüler daha önceden test, eğitim ve validasyon gruplarına ayrıldığından Fourier dönüşümü işlemi de bu gruplar üzerinden doğrudan gerçekleştirilmiştir. Ancak elde edilen görüntülerde beklenildiği gibi bir parlaklık ifadesi ile karşılaşmamıştır.

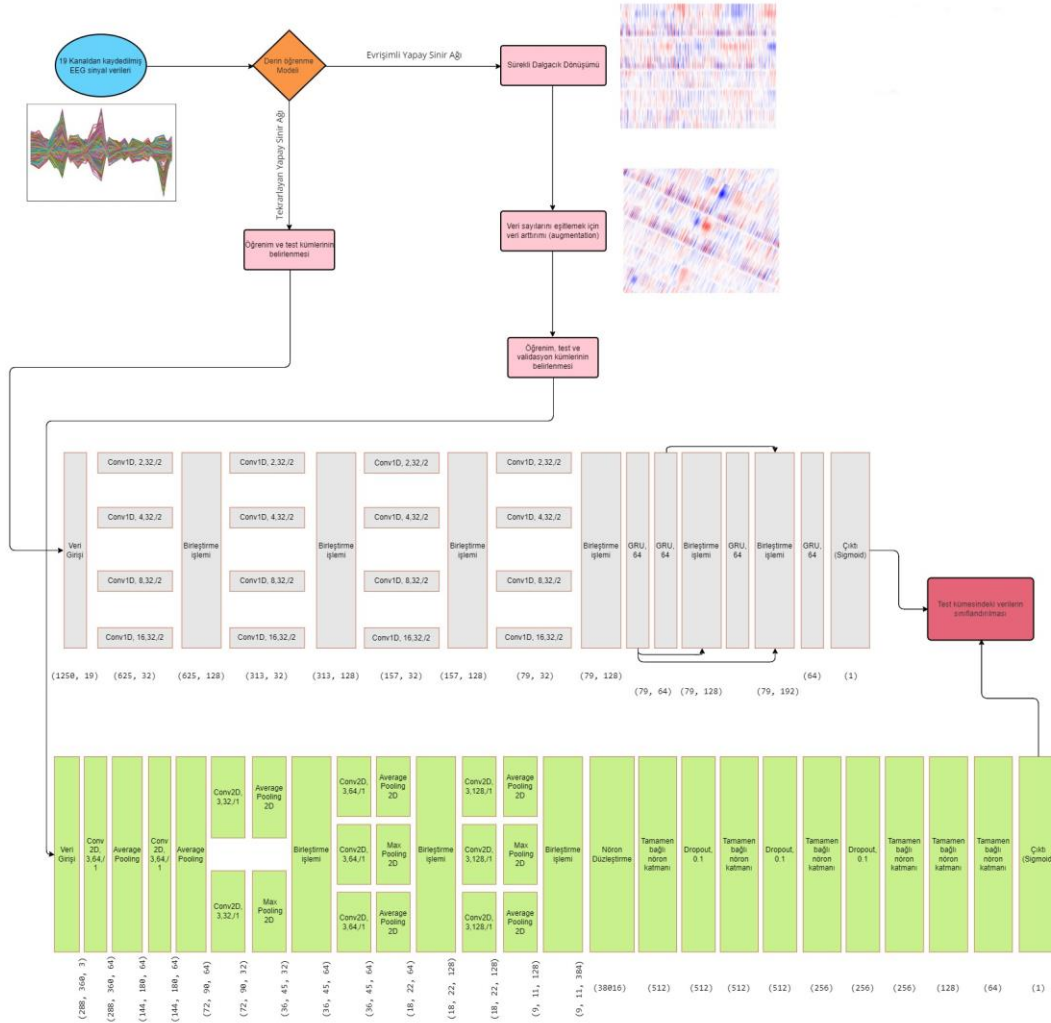


Şekil 5. Farkedilen sürekli geçişler.



Şekil 6. Fourier Dönüşümü sonucunda elde edilen görüntüler; a) Sağlıklı birey, b) Hastalıklı birey

Son olarak görsel verilerinin sınıflandırılması için yeniden bir CNN oluşturulmuştur. Bu aşta ortaklama (pooling) yapılırken sadece ortalama (average pooling) yerine paralel olarak hem ortalama hem de maksimum ortaklama (max pooling) yapılmış sonrasında bu işlemlerin çıktıları birleştirilip tekrar paralel olacak şekilde ortaklama işlemleri yapılmıştır. Üç adet birleştirilme katmanı oluşturulmuş ve ilk katmanda paralel olarak bir ortalama, bir maksimum ortaklama yapıлып birleştirilmiş, diğer ikisinde ise iki ortalama bir maksimum ortaklama işlemi gerçekleştirilmiştir. Bir önceki CNN’de olduğu gibi, yeniden oluşturulan CNN’de eldeki veri kümesinin eğitim ve validasyon kümeleri ile model eğitilip test kümesi ile test edilmiştir. Katman sayıları, parametre değerleri, aktivasyon fonksiyonları gibi bütün değerleri optimum seviyeye getirdikten sonra devamlı verilerin sınıflandırılmasında kullanılan ve kullanılması istenilen RNN’nin doğruluk değerine yakın bir değer elde edilmiştir. Önerilen modellere ait akış diyagramı Şekil 7’de sunulmaktadır. Verilerin işlenmesinde kullanılan kütüphaneler ve çalışmadaki fonksiyonları Tablo 1’de sunulmaktadır.



Şekil 7. Önerilen metotlara ait akış diyagramı.


Tablo 1. Kütüphaneler

Kütüphaneler	Açıklama
pandas	.csv dosyasına dönüştürülen .edf dosyalarının işlenmesi
numpy	Diziler üzerinde matematiksel işlemlerin gerçekleştirilmesi
seaborn	.csv dosyasına çevirilmiş verilerin ısı haritalarının elde edilmesi
sklearn	Veri artırımı (data augmentation)
keras	Derin öğrenme modellerinin oluşturulması
visualker	Oluşturulan derin öğrenme modellerinin üç boyutlu olarak görselleştirilmesi
matplotlib	Derin öğrenme modellerinin öğrenme süreçlerindeki doğruluk oranlarının ve elde edilen sonuç verilerinin grafikleştirilmesi
mne	.edf dosyalarının program tarafından okunması, görselleştirilmesi ve analiz edilmesi
glob	.edf dosyalarına bilgisayar üzerinde kaydedildiği yerden ulaşılması
ssqueezepy	Sinyal alanında bulunan verileri zaman-frekans ilişkisi kullanarak görsele dönüştürerek görsel alanına getirilmesi
splitfolders	Görsele dönüştürülen sinyal verilerini eğitime, test, doğrulama verileri olarak ayrılması
os	İşletim sistemi ile etkileşim kurulması
PIL	Visualker kütüphanesinin font parametresinin ayarlanması
Paddedsiz	Görsele dönüştürülmüş sinyal verilerine Fourier Dönüşümü uygulanması

3. DOĞRULAMA VE GEÇERLİLİK

3.1. Yapay Sinir Ağı

.csv dosyalarından elde edilen veri çerçevelerini eğitim ve test kümelerine ayırdıktan sonra eğitim kümesiyle eğitmek için basit bir sinir ağı oluşturulmuştur. Ancak elde edilen doğruluk değerleri veri çerçevelerindeki frekans değerlerinin aralarında herhangi bir ilişkisel bağlantı bulunmadığından istenilen değerlere ulaşamamıştır. Ulaşılan maksimum doğruluk değeri 0.71 olmuştur, doğruluk ve kayıp oranları Şekil 8'de belirtilmektedir.




Şekil 8. Yapay sinir ağına ait validasyon ve eğitim işlemindeki doğruluk ve kayıp grafikleri.

3.2. Lojistik Regresyon

Mevcut veri kümesinde bulunan şizofreni hastası ve sağlıklı bireyler olmak üzere iki adet sınıf bulunduğundan .csv dosyalarından elde edilen veri çerçeveleri yapay sinir ağlarının yanında, sınıflandırma işlemlerinde kullanılan lojistik regresyon eğitim kümesi verileri ile eğitilmiştir. Ancak test verilerini tahmin etmekte başarılı olamamış, elde edilen maksimum doğruluk değeri 0.52 olmuştur.

3.3. Tekrarlayan Sinir Ağı (Recurrent Neural Network -RNN)


Sinyal verileri gibi sürekli verilerin öğrenilmesinde/sınıflandırılmasında kullanılan tekrarlayan sinir ağı yapısı, tekrarlayan birimler kullanılarak oluşturulmuş, gizlenmiş durumlar (veriler) oluşturularak uzun süreli hafıza elde edilmiştir. Bu uzun süreli hafıza kullanılarak dalga verilerinin saniyeler arasındaki frekanslarının bağlantıları öğrenme aşamasında unutulmadığından test kümesi tahmininde 0.94 doğruluk değerlerine ulaşılmıştır. Chrononet [17] mimarisinin parametreleri (nöron sayıları, filtre boyutları) ayarlanarak, birleştirilme işlemine uygulanacak evrişim katmanları sayısı dörde çıkarılıp birleştirilme işleminin sayısı artırılmıştır. Modelin doğruluk ve kayıp değerleri Şekil 9'da gösterilmektedir.



Şekil 9. RNN modeline ait validasyon ve eğitim işlemindeki doğruluk ve kayıp grafikleri.

3.4. Evrişimli Sinir Ağı, LeNet-5


LeNet-5 baz alınarak oluşturulmuştur. Sinyal verilerinin ilişkisel bağlantıları bu tarz kısa süreli hafızaya sahip derin öğrenme ağlarında unutulduğu için sinyal verileri ile bu ağı eğitmenin mümkün olmadığı gözlemlenmiştir. Test kümesi için ayrılan görsellerin hastalıklı veya sağlıklı şeklinde tahmin edilmesinde 0.89 doğruluk oranı elde edilmiştir, doğruluk ve kayıp değerleri Şekil 10'da gösterilmektedir.



Şekil 10. İlk evrişimsel sinir ağına ait validasyon ve eğitim işlemindeki doğruluk ve kayıp grafikleri.

3.5. Evrişimli Sinir Ağı, LeNet-5 ve Fourier Dönüşümü

LeNet-5 baz alınarak oluşturulmuştur. Beyin dalgalarını SDD kullanarak görüntü halinde ifade ettikten sonra bu görüntülere Fourier Dönüşümü uygulanmaktadır. Ancak dönüşüm sonucu oluşan görsellerin önceden bulundukları çeşitli renk geçişlerindeki verileri siyah ve beyaz olacak şekilde kaybettiğinden, aynı zamanda elde edilen çıktılar birbirlerinden farkları ayırt edilemeyeceği için test kümesini tahmin etme işleminde en çok 0.60 doğruluk oranına yaklaşmıştır, doğruluk ve kayıp değerleri Şekil 11'de gösterilmektedir.




Şekil 11. İlk evrişimsel sinir ağının Fourier Dönüşümü uygulanmış veriler ile yapılan validasyon ve eğitim işlemindeki doğruluk ve kayıp grafikleri.

Fourier dönüşümü SDD yönteminde olduğu gibi beyin dalgalarına doğrudan uygulandığında, elde edilecek spektrogramlar evrişimli sinir ağlarını kullanarak sınıflandırıldığında başarı oranının artması beklenmektedir.

3.6. Önerilen Yapılandırılmış Evrişimli Sinir Ağı

Görsel alana çekilen verilerin daha önce geliştirilen evrişimli sinir ağının test kümesindeki verilerin sınıflarını tahmin etmede elde ettiği doğruluk oranından daha fazla bir doğruluk oranına erişmek için, daha karmaşık ve daha kapsamlı yeni bir CNN oluşturulmuştur. Elde edilen bu sinir ağının karmaşık yapısı çalışma zamanında dezavantaj getirirse de, test kümesindeki verilerin tahmininde diğer geliştirilen CNN'den fazla ve asıl verileri sınıflandırmak için kullanılması gereken RNN doğruluk oranına yakın olmaktadır. Bu model için gözlemlenen doğruluk oranı 0.93 olmaktadır, doğruluk ve kayıp değerleri Şekil 12'de gösterilmektedir.



Şekil 12. Yapılandırılmış evrişimsel sinir ağına ait validasyon ve eğitim işlemindeki doğruluk ve kayıp grafikleri.

4. SONUÇ

Bu çalışmada kullanılan tüm modeller için model ve eğitim parametreleri Tablo 2’de karşılaştırmalı olarak sunulmaktadır.

Tablo 2. Modellerin eğitim parametreleri.

Derin Öğrenme Modeli	Parametreler
Yapay Sinir Ağı	Dense(64,input_shape=(19,),activation = 'sigmoid') Dense(128,activation = 'sigmoid') Dense(256,activation = 'sigmoid') Dense(512,activation = 'sigmoid') Dense(512,activation = 'sigmoid') Dense(1,activation = 'sigmoid') optimizer='adam',loss='binary_crossentropy',metrics=['accuracy'] validation_split = 0.1, epochs=10,batch_size=10025
Lojistik Regresyon	penalty='l2', dual=False, tol=0.0001, C=1.0, fit_intercept=True, intercept_scaling=1, class_weight=None, random_state=None, solver='lbfgs', max_iter=100, multi_class='auto', verbose=0, warm_start=False, n_jobs=None, l1_ratio=None
Tekrarlayan Sinir Ağı	Conv1D(filters=32, kernel_size=2, strides=2, activation = 'relu', padding = 'causal') Conv1D(filters=32, kernel_size=4, strides=2, activation = 'relu', padding = 'causal') Conv1D(filters=32, kernel_size=8, strides=2, activation = 'relu', padding = 'causal') Conv1D(filters=32, kernel_size=12, strides=2, activation = 'relu', padding = 'causal') Dropout(0.5) GRU(units = 64,return_sequences = True) x4 w/Concat Dense(1,activation='sigmoid') optimizer=keras.optimizers.Adam(learning_rate = 0.0001),loss='binary_crossentropy',metrics = ['accuracy'] validation_split = 0.1,shuffle=True, epochs = 32, batch_size = 32, callbacks =[keras.callbacks.EarlyStopping(monitor='val_loss',patience=8,restore_best_weights=True)]
Evrişimli Sinir Ağı (LeNet-5)	layers.Conv2D(filters=6, kernel_size=(3, 3), activation='relu', padding = 'same') layers.AveragePooling2D() layers.Conv2D(filters=16, kernel_size=(3, 3), activation='relu', padding = 'same', strides =1) layers.AveragePooling2D() layers.Conv2D(filters=32, kernel_size=(3, 3), activation='relu', padding = 'same', strides =1) layers.AveragePooling2D() layers.Conv2D(filters=32, kernel_size=(3, 3), activation='relu', padding = 'same', strides =1) layers.AveragePooling2D() layers.Flatten() layers.Dense(units=512, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.10) layers.Dense(units=512, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.10) layers.Dense(units=256, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.10) layers.Dense(units=128, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.10) layers.Dense(units=64, activation=keras.layers.LeakyReLU(alpha=0.5)) layers.Dense(units=1, activation = 'sigmoid') loss='binary_crossentropy', optimizer=keras.optimizers.Adam(learning_rate = 0.0001), metrics=['accuracy'] epochs=64,batch_size=6, callbacks =[keras.callbacks.EarlyStopping(monitor='val_loss',patience=5,restore_best_weights=True)]
Önerilen Evrişimli Sinir Ağı	Conv2D(filters=64, kernel_size=(3, 3), activation='relu', padding = 'same') AveragePooling2D() Conv2D(filters=64, kernel_size=(3, 3), activation='relu', padding = 'same') AveragePooling2D() Conv2D(filters=32, kernel_size=(3, 3), activation='relu', padding = 'same') MaxPooling2D() Conv2D(filters=32, kernel_size=(3, 3), activation='relu', padding = 'same') AveragePooling2D() Concatenate() Conv2D(filters=64, kernel_size=(3, 3), activation='relu', padding = 'same') MaxPooling2D() Conv2D(filters=64, kernel_size=(3, 3), activation='relu', padding = 'same') AveragePooling2D() Concatenate() Conv2D(filters=128, kernel_size=(3, 3), activation='relu', padding = 'same') MaxPooling2D() Conv2D(filters=128, kernel_size=(3, 3), activation='relu', padding = 'same') AveragePooling2D() Conv2D(filters=128, kernel_size=(3, 3), activation='relu', padding = 'same') AveragePooling2D() Concatenate() Flatten() Dense(units=512, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.25) Dense(units=512, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.25) Dense(units=256, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.25) Dense(units=256, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.50) Dense(units=128, activation=keras.layers.LeakyReLU(alpha=0.5)) Dropout(0.50) Dense(units=64, activation=keras.layers.LeakyReLU(alpha=0.5)) Dense(units = 1, activation = 'sigmoid')

Yapay sinir ağı modeli, lojistik regresyon, tekrarlayan sinir ağı, LeNet-5 baz alınarak oluşturulmuş CNN, LeNet-5 baz alınarak ve Fourier Dönüşüm sonucu elde edilen görseller kullanılarak oluşturulmuş evrişimli sinir ağı ve önerilen yapılandırılmış yeni bir CNN modeli ile yapılan deneysel çalışmaların başarı oranları Tablo 3’de sunulmaktadır.

Tablo 3. Deneysel çalışmalar sonucu derin öğrenme modellerinin doğruluk oranları.

Derin Öğrenme Modeli	Test İşleminin Doğruluk Oranı
Yapay Sinir Ağı	0.71
Lojistik Regresyon	0.52
Tekrarlayan Sinir Ağı	0.94
Evrişimli Sinir Ağı (LeNet-5)	0.89
Evrişimli Sinir Ağı (LeNet-5, Fourier Dönüşüm)	0.60
Önerilen Evrişimli Sinir Ağı	0.93

Başarının yüksek olduğu önerilen CNN ve RNN modellerde yapılandırılmış bir ağ yapısı görülmektedir. Doğrulama oranında artış gösteren CNN, karmaşık bir ağ yapısı gibi görünse de test kümesindeki verilerin tahmininde RNN doğruluk oranına yaklaşmıştır. Yapılandırılmış RNN modelinde, mevcut RNN mimarisinde bulunan birleştirme öncesinde paralel bir şekilde gerçekleştirilen evrişim katmanlarına, filtre boyutu 16 olan ve 32 filtre içeren bir katman daha eklenmiş ve bu birleştirme işlemi GRU katmanlarına gelmeden önce bir kez daha gerçekleştirilmiştir. Bunların dışında mevcut RNN mimarisinde bulunan GRU katmanlarının çıktı uzayının boyutluluğu 64 olarak değiştirilmiş ve çıktı katmanının aktivasyon fonksiyonu sınıflandırılacak iki sınıf bulunduğundan sigmoid olarak değiştirilmiştir. RNN’in bu yapısı ile başarı oranında artış sağladığı gözlemlenmiştir.

Referans olarak verilen aynı veri kümesi (14 sağlıklı birey, 14 hasta birey) ile yürütülen çalışmalardaki yöntem ve başarı oranları Tablo 4’de sunulmaktadır.

Tablo 4. Derin öğrenme ile şizofreni tanısı yapılan çalışmaların başarı oranı karşılaştırması.

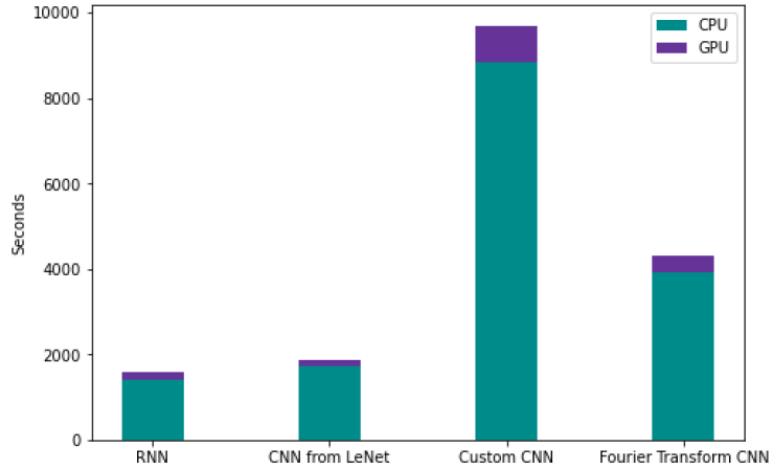
Referans	Metod	Başarı oranı
Oh ve ekibi (2019) [30]	CNN -subjektif olmayan test (non subject base testing)	%98,07
	CNN - subjektif test (subject base testing)	%81,26
Jahmunah ve ekibi (2019) [41]	Doğrusal olmayan özellik çıkarım (nonlinear feature extraction)	%92,91
Shalbf ve ekibi (2020) [16]	CNN	%98.60%±2.29
Phang ve ekibi (2020) [42]	CNN	%91,69
Sharma ve Acharya 2020 [34]	Optimal dalgacık tabanlı L1-norm (optimal wavelet-based L1-norm)	%99,2
Aslan ve Akın 2020 [43]	CNN	%97
Chandran ve ekibi (2021) [44]	LSTM (long short-term memory)	%99
Aslan ve Akın 2022 [31]	CNN	%99,5

Tablo 4’de belirtilen çalışmalar incelendiğinde, başarı oranlarının karşılaştırılması yapılırken kullanılan yöntemlere ait birçok özellik ve parametrenin dikkate alınması gerekir. 11 katmanlı CNN modeli geliştiren Oh ve ekibi [30], subjektif olmayan (non subjective) ve subjektif (subjective) tabanlı testler ortaya koymaktadır. CNN modelini doğrudan EEG kanallarından gelen verilerle işledikleri görülmektedir. Jahmunah ve ekibi [41] doğrusal olmayan özellik çıkarma ve sınıflandırma tekniklerini kullanmaktadır. Bu çalışmaları 12 özellik ve Destek Vektör Makineleri (Support-Vector-Machine –SVM) sınıflandırıcıyla %92,91 oranında doğruluk sağladığı belirtilmektedir. Shalbf ve ekibi [16], hastaların otomatik tespiti için CNN ile SDD ve SVM yöntemleriyle transfer öğrenmeyi kullanmaktadır. EEG sinyallerinin frontal, santral, parietal ve oksipital bölgelerinin birleşiminden oluşan skalogram görüntülerinde ResNet-18-SVM mimarisi için %98,60±2,29 doğruluk değerine ulaştıklarını belirtmektedir. Phang ve ekibi [42], EEG’den türetilen beyin konektomunun sınıflandırılması için bir CNN modeli önermektedir, ancak beyin bağlantı grafik yapısı özellikleri gibi bir takım sınırlamaların olduğu çalışma sonunda ifade edilmektedir. Sharma ve Acharya [34], tek kanallı EEG’den elde edilen optimal dalgacık tabanlı L1-norm özelliklerini %99’un üzerinde bir doğrulukla hastalığı tespit etmektedir. Optimal dalgacık tabanlı özellik, k-en yakın komşu (kNN) sınıflandırıcısı ile sınıflandırıldığı görülmektedir. Aslan ve Akın [43] çalışmalarında iki ayrı veri kümesi kullanmaktadır, elde ettikleri spektrogram görüntülerini CNN derin öğrenme ağı ile eğiterek %97 doğrulukla sınıflandırma işlemi gerçekleştirdikleri belirtilmektedir. Diğer çalışmalarında [31] ise boyut artırma yöntemlerini kullanarak, her kanaldan alınan EEG kayıtlarını 5’er saniyelik segmentlere bölüp skalogram görüntüleri elde etmişlerdir. Farklı CNN algoritmaları ile deneysel çalışmalar yaparak en iyi başarı oranını %99,5 ile VGG-16’da sağladıklarını çalışmalarında belirtmişlerdir.

Chandran ve ekibi [44], uzun kısa süreli hafıza (LSTM) yöntemi ile EEG sinyalinden özellikler çıkarılarak şizofreninin tespit edilmesine yönelik çalışmalarını sunmaktadır. Katz fraktal boyutu (KFD) ve yaklaşık entropi (ApEn) gibi doğrusal olmayan özellikler ve varyans değerlerinin zaman alanı ölçümlerini EEG sinyalinden hesaplamaktadır, yüksek başarı oranı gözlemlenmiştir belirtilmektedir.

Tablo 4’de karşılaştırılan çalışmalar her ne kadar aynı veri kümesini işlese de kullanılan sınıflandırıcılar ve genelinde gözlemlenen hibrit yaklaşımlar ile farklı yöntemleri ortaya çıkarmaktadır. Bu yöntemlerden elde edilen bulgulara ve başarı oranlarına bakıldığında, şizofreni tanısında her ne kadar yüksek başarı oranları görülse de bir takım varsayımlar ve sınırlamaların mutlaka bu oranda etkili olduğu vurgulanmaktadır. Bu çalışmada elde edilen başarı sonuçlarının bu hastalığın tanısına alternatif bir çözüm sunması amaçlanmaktadır. Diğer çalışmalarla kıyaslandığında başarı oranlarında her ne kadar hata payı farklılıkları olsa da, önerilen modellerin yapısal özellikleri, işleyiş süreçleri, verilerin doğru yöntemlerle işlenmesi, sonuçların yorumlanabilir bulgular içermesi gibi birçok faktörün birlikte değerlendirilmesi çalışmanın başarısının artmasına ve geliştirilmesine imkan sağlamaktadır.

Derin öğrenme modelleri çok fazla sinir ağı katmanına sahip olduğu için CPU’nun ilişkili tüm görevleri yönetmesi zor olabilir. Derin öğrenme ağlarını büyük veri kümeleri ile eğitmek doğruluk oranlarını arttırdığı gibi çalışma süresini uzatabilir. Derin öğrenme, çok fazla hız ve yüksek performans gerektirmektedir, tüm işlemler aynı anda işlendiğinde daha hızlı öğrenme gerçekleşmektedir. GPU’lar derin öğrenme modellerini eğitmek için optimize edilmiştir ve birden çok paralel görevi bir CPU’dan üç kate kadar daha hızlı işleyebilmektedir [45, 46]. Modellerin eğitim ve test sürecinde CPU ve GPU karşılaştırması Şekil 13’deki grafikte gösterilmektedir.



Şekil 13. Modellerin eğitim ve test süresinin CPU ve GPU ile karşılaştırılması.

5. TARTIŞMA VE ÖNERİLER

Bu çalışmada ele alınan yöntemlerle, şizofreni hastalığının tanısının uzman kişilere karar-verme mekanizması oluşturacak bir yaklaşımı sunulmaktadır. Bireylerin EEG sinyallerinin işlenmesi ve derin öğrenme yöntemleri ile verilerin sınıflandırılması üzerine birtakım bulgular ortaya konmaktadır. Beyin dalgalarında olduğu gibi sürekli verilerin sınıflandırılmasında, aralarındaki zamansal bağlantıyı unutmayacak uzun zamanlı bir hafızaya sahip olan derin öğrenme yöntemlerinin yanında, daha çok görsel verileri sınıflandırmak için kullanılan evrişimli sinir ağları oluşturulmaktadır. Yapılan deneysel analizlerle derin öğrenme yöntemleri sonucunda elde edilen benzer doğruluk seviyesine erişilmekte ve var olan çözüm yöntemine alternatif bir yaklaşım sunulmaktadır. Bu çalışma sonucunda gözlemlenen değerlere göre, derin öğrenme yöntemlerini farklı yönlerden deneyerek doğruluk değerlerini onaylamak mümkün olmaktadır. Geliştirilen evrişimli sinir ağı ve tekrarlayan sinir ağı sadece şizofreni hastalığının tanısında değil, bu modellerin sınıflandırmayı öğrendiği veriler; insanların aynı durumlar altında üreteceği beyin dalgaları ve farklı frekansta beynin herhangi bir yerinde üretilen beyin dalgaları olduğundan, bu sınıflara ait verilerin oluşmasını sağlayacak durumlarda da kullanılabilir. Örneğin dinlenme durumunda beyin dalgalarında bozulmaya yol açan herhangi bir hastalık, yeterli verinin toplanması sonucunda bu derin öğrenme modelleri ile ayırt edilebilecektir. Model üzerindeki geliştirmeler ile çıktı katmanı olarak sigmoid fonksiyonu yerine softmax fonksiyonu kullanılarak birden çok sınıf içerisinde beyin dalgalarının hangi sınıftan olduğunu ayırt etmesi sağlanabilir. Bu durumda sınıflandırılacak beyin dalga çeşidi sayısı artacağı için, ilgili süreçler için yapılabilecek işlemler de artarak modellerin kullanım alanlarının esnek hale dönüşebileceği tahmin edilmektedir. Çok sınıflı durumlara insan beyninin kaslarını hareketlendirmek için üreteceği dalgalar örnek olarak verilebilir. Bu modellerin geliştirilmesi durumunda bu dalgaları birbirinden ayırt etmenin mümkün olabileceği varsayılabilir. Bunların yanında parametrelerin öğrenim süresinin kısaltması güçlü ekran kartı ve uzun zamanda daha iyi optimize edilmiş model parametreleri ile mümkün olacaktır. Derin öğrenme yöntemlerine uygulanacak yaklaşımların, bu çalışmada da görüldüğü üzere Fourier Dönüşümünün SDD ile oluşturulan görsel veriler yerine, doğrudan beyin dalga verilerine uygulanması daha başarılı doğruluk değerlerine ulaşılmasını sağlamaktadır.

Not

Bu çalışma, 12. Genç Beyinler Yeni Fikirler (GBYF'12) proje yarışmasında Akademik ve Diğer Bilişim Uygulamaları kategorisinde birinci olarak seçilmiştir. Erişim linki: gbyf.org.tr

Yazar Katkıları

Sevcan Emek, bu çalışmanın konusunun ve kapsamının detaylarını inceleyerek, deneysel analiz sürecinin gözlemlenmesine ve sonuçların yorumlanmasına katkı sağlamıştır. Berkay Serin, bu çalışmada sunulan ilgili yöntemlerin yürütülmesine ve çalışmanın anlatılmasına katkıda bulunmuştur.

Veri Kullanılabilirliği

Kullanılan veri kümesi [40] erişim linki:

<https://reprod.icm.edu.pl/dataset.xhtml?persistentId=doi:10.18150/repod.0107441>

Çıkar Çatışması

Makale yazarları, aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKÇA

- [1] P. Fusar-Poli, G. Salazar de Pablo, R.P. Rajkumar, A. López-Díaz, S. Malhotra, S. Heckers, S.M. Lawrie, and F. Pillmann “Diagnosis, prognosis, and treatment of brief psychotic episodes: a review and research agenda”, *Lancet. Psychiatry*, vol. 9, no. 1, pp. 72–83 2022.
- [2] R.L. Spitzer, and J.L. Fleiss “A re-analysis of the reliability of psychiatric diagnosis”, *The British journal of psychiatry : the journal of mental science*, vol. 125, no. 0, pp. 341–347, 1974.
- [3] W. Gaebel, A. Kerst, and J. Stricker “Classification and Diagnosis of Schizophrenia or Other Primary Psychotic Disorders: Changes from ICD-10 to ICD-11 and Implementation in Clinical Practice”, *Psychiatria Danubina*, vol. 32, no. 3-4, pp. 320–324, 2020.
- [4] S.B. Guze “Diagnostic and statistical manual of mental disorders: DSM-IV”, American Psychiatric Association, Washinton D.C., 4th Ed., 1994.
- [5] W. Fenton, L. Mosher, and S. Matthews “Diagnosis of Schizophrenia: A Critical Review of Current Diagnostic Systems Schizophrenia Bulletin”, vol. 7, pp.452–476, 1981.
- [6] İ.E. Emre, C. Taş, and Ç. Erol, “Psikiyatride Makine Öğrenmesi Yöntemlerinin Kullanımı”, *Psikiyatride Güncel Yaklaşımlar-Current Approaches in Psychiatry*, vol. 13, no. 2, pp. 332-353, 2021.
- [7] Y. Bengio, I. Goodfellow, and A. Courville “Deep learning”, MIT press, Cambridge, 2017.
- [8] G. Litjens, T. Kooi, B.E. Bejnordi, A.A.A. Setio, F. Ciompi, M. Ghafoorian, and et al. “A survey on deep learning in medical image analysis”, *Med Image Anal*, vol. 42, pp. 60–88, 2017.
- [9] Ö. İnik, and E. Ülker “Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri”, *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, vol. 6, no. 3, pp. 85-104, 2017.
- [10] S. Dong, P. Wang, and K. Abbas “A survey on deep learning and its applications”, *Computer Science Review*, vol. 40, p. 100379, 2021.
- [11] L. Deng “A tutorial survey of architectures, algorithms, and applications for deep learning”, *APSIPA Transactions on Signal and Information Processing*, vol. 3, 2014.
- [12] M.A. Jatoui, F.A. Dharejo, and S.H. Teevino “Comparison of machine learning techniques based brain source localization using eeg signals”, *Curr Med Imaging*, 2020.
- [13] R. Buettner, D. Beil, S. Scholtz, and A. Djemai “Development of a machine learning based algorithm to accurately detect schizophrenia based on one-minute EEG recordings”, In: *Proceedings: 53rd Hawaii International Conference on System Sciences, Maui, Hawaii*, pp 7–10, 2020.
- [14] U.R. Acharya, S.L. Oh, Y. Hagiwara, J.H. Tan, and H. Adeli “Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals”, *Comput Biol Med*, vol. 100, pp. 270–278, 2018.
- [15] Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T.H. Falk, and J. Faubert “Deep learning-based electroencephalography analysis: a systematic review”, *J Neural Eng* vol. 16, no. 5, 2019.
- [16] A. Shalhaf, S. Bagherzadeh, and A. Maghsoudi “Transfer learning with deep convolutional neural network for automated detection of schizophrenia from EEG signals”, *Physical and Engineering Sciences in Medicine*, vol. 43, pp. 1229–1239, 2020.
- [17] S. Roy, I. Kiral-Kornek, and S. Harrer “ChronoNet: A Deep Recurrent Neural Network for Abnormal EEG Identification”, arXiv:1802.00308, 2018.
- [18] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, and M.S. Lew “Deep learning for visual understanding: a review”, *Neurocomputing*, vol. 187, pp. 27–48, 2016.
- [19] G. Litjens, F. Ciompi, J.M. Wolterink, B.D. de Vos, T. Leiner, J. Teuwen, and I. Išgum “State-of-the-art deep learning in cardiovascular image analysis”, *JACC Cardiovasc Imaging*, vol. 12, no. 8, pp. 1549–1565, 2019.
- [20] J. Chai, H. Zeng, A. Li, and E.W.T. Ngai “Deep learning in computer vision: A critical review of emerging techniques and application scenarios”, *Machine Learning with Applications*, vol. 6, 2021.

- [21] H. Greenspan, B. van Ginneken, and R.M. Summers "Guest editorial deep learning in medical imaging: overview and future promise of an exciting new technique", *IEEE Trans Med Imaging*, vol. 35, no. 5, pp. 1153–1159, 2016.
- [22] X. Zhang, L. Yao, X. Wang, J. Monaghan, and D. Mcalpine "A survey on deep learning based brain computer interface: recent advances and new frontiers", *arXiv:1905.04149* 2019.
- [23] K. Simonyan, and A. Zisserman "Very deep convolutional networks for large-scale image recognition", *arXiv preprint arXiv:1409.1556*, 2014.
- [24] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna "Rethinking the inception architecture for computer vision", In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2818–2826, 2016.
- [25] T.H. McGlashan "Early detection and intervention of schizophrenia: rationale and research", *The British journal of psychiatry. Supplement*, vol. 172, no. 33, pp. 3–6, 1998.
- [26] S. Siuly, Y. Guo, O. F. Alcin, Y. Li, P. Wen, and H. Wang "Exploring deep residual network based features for automatic schizophrenia detection from EEG", *Physical and Engineering Sciences in Medicine*, vol. 46, pp. 561–574, 2023.
- [27] World Health Organization (WHO), "Schizophrenia", 2022, <https://www.who.int/news-room/fact-sheets/detail/schizophrenia>. Accessed 6 Sep 2023
- [28] D-W. Ko, and J-J. Yang "EEG-Based Schizophrenia Diagnosis through Time Series Image Conversion and Deep Learning", *Electronics*, vol. 11, no. 14, 2265, 2022,
- [29] S.K. Khare, V. Bajaj, and U.R. Acharya "SPWVD-CNN for Automated Detection of Schizophrenia Patients Using EEG Signals," in *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1-9, 2021.
- [30] S.L. Oh, J. Vicnesh, E.J. Ciaccio, R. Yuvaraj, and U.R. Acharya "Deep Convolutional Neural Network Model for Automated Diagnosis of Schizophrenia Using EEG Signals", *Applied Sciences*, vol. 9, no. 14, p. 2870, 2019.
- [31] Z. Aslan, and M. Akin "A deep learning approach in automated detection of schizophrenia using scalogram images of EEG signals", *Physical and Engineering Sciences in Medicine*, vol. 45, pp. 83–96, 2022.
- [32] N. Sobahi, B. Ari, H. Cakar, O.F. Alcin, and A. Sengur "A New Signal to Image Mapping Procedure and Convolutional Neural Networks for Efficient Schizophrenia Detection in EEG Recordings," in *IEEE Sensors Journal*, vol. 22, no. 8, pp. 7913-7919, 2022.
- [33] M. Şeker, and M.S. Özerdem "EEG based Schizophrenia Detection using SPWVD-ViT Model", *European Journal of Technique (EJT)*, vol. 12, no. 2, pp. 137-144, 2022.
- [34] M. Sharma, and U.R. Acharya "Automated detection of schizophrenia using optimal wavelet-based 11 norm features extracted from singlechannel EEG," *Cognit. Neurodynamics*, pp. 1–4, Dec. 2020.
- [35] A. Savio, J. Charpentier, M. Termenón, A.K. Shinn, and M. Grana "Neural classifiers for schizophrenia diagnostic support on diffusion imaging data", *Neural Netw World*, vol. 20, no. 7, p. 935, 2010.
- [36] F. Afshani, A. Shalhaf, R. Shalhaf, and J. Sleight "Frontal-temporal functional connectivity of EEG signal by standardized permutation mutual information during anesthesia", *Cognitive Neurodyn*, vol. 13, no. 6, pp. 531–540, 2019.
- [37] A. Saeedi, M. Saeedi, A. Maghsoudi, and A. Shalhaf "Major depressive disorder diagnosis based on effective connectivity in EEG signals: a convolutional neural network and long short-term memory approach", *Cognitive Neurodyn*, vol. 15, pp. 239-252, 2021.
- [38] Z. Dvey-Aharon, N. Fogelson, A. Peled, and N. Intrator "Schizophrenia detection and classification by advanced analysis of EEG recordings using a single electrode approach", *PLoS ONE* 10:e0123033, 2015.
- [39] J.W. Kim, Y.S. Lee, D.H. Han, K.J. Min, J. Lee, and K. Lee "Diagnostic utility of quantitative EEG in un-medicated schizophrenia", *Neurosci Lett*, vol. 589, pp. 126–131, 2015.
- [40] E. Olejarczyk, and W. Jernajczyk "EEG in schizophrenia", 2017.
- [41] V. Jahmunah, S.L. Oh, V. Rajnikanth, E.J. Ciaccio, K. H. Cheong, N. Arunkumar, and U.R. Acharya "Automated detection of schizophrenia using nonlinear signal processing methods", *Artificial Intelligence in Medicine*, vol. 100, 2019,
- [42] C.R. Phang, F. Noman, H. Hussain, C.M. Ting, and H. Ombao "A Multi-Domain Connectome Convolutional Neural Network for Identifying Schizophrenia From EEG Connectivity Patterns," in *IEEE Journal of Biomedical and Health Informatics*, vol. 24, no. 5, pp. 1333-1343, May 2020,
- [43] Z. Aslan, and M. Akin "Automatic detection of schizophrenia by applying deep learning over spectrogram images of EEG signals", *Traitement du Signal*, vol. 37, no. 2, pp. 235-244, 2020.
- [44] A.N. Chandran, K. Sreekumar, and D.P. Subha "EEG-Based Automated Detection of Schizophrenia Using Long Short-Term Memory (LSTM) Network", In: Patnaik, S., Yang, X.S., Sethi, I. (eds) *Advances in Machine Learning and Computational Intelligence. Algorithms for Intelligent Systems*. Springer, Singapore, 2021.
- [45] T. Çetinkaya Saray, and A. Sertbaş "Derin Öğrenme Algoritmalarının GPU ve CPU Donanım Mimarileri Üzerinde Uygulanması ve Performans Analizi: Deneysel Araştırma", *Avrupa Bilim ve Teknoloji Dergisi*, vol. 33, pp. 10-19, 2022.
- [46] M. Pandey, M. Fernandez, F. Gentile, and et al. "The transformational role of GPU computing and deep learning in drug discovery", *Nat Mach Intell* 4, pp. 211–221, 2022.