



## ADHD ve Sağlıklı Bireylerin Tanısında Boyut Azaltan Zamansal Karakteristik Özellik Çıkarma Yaklaşımı ve 1D-CNN

### Low Dimensionality Temporal Characteristic Feature Extraction Approach and 1D-CNN for Diagnosing ADHD and Healthy Individuals

<sup>1</sup>Kutlucan GÖRÜR 

<sup>1</sup>Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik Elektronik Mühendisliği, 10200 Bandırma, Balıkesir, Türkiye

[kgorur@bandirma.edu.tr](mailto:kgorur@bandirma.edu.tr)

Araştırma Makalesi/Research Article

#### ARTICLE INFO

##### Article history

Received : 2 August 2023

Accepted : 21 September 2023

##### Keywords:

ADHD, t-SNE Feature Extraction, Deep Learning, Diagnostic

#### ABSTRACT

Electroencephalography (EEG) signals can be reliably used to obtain critical information about ADHD/Attention Deficit Hyperactivity Disorder, a childhood neurodevelopmental disorder. Early detection of ADHD is important to reduce the development of this disorder and reduce its long-term impact. This study aims to achieve an approach with high prediction success that distinguishes between ADHD and healthy individuals with 1D-CNN (Convolutional Neural Network) after extracting time domain features with t-SNE (t-distributed Stochastic Neighbor Embedding). This study aims to define a high-performance temporal characteristic approach (1D-CNN and t-SNE) involving 61 ADHD patients and 60 healthy control individuals. These features are then used in 1D-CNN models to classify ADHD patients and healthy individuals. 1D-CNN deep model-2 (ACC: 81.82% and AUC: 0.834) showed more successful outcomes than 1D-CNN deep model-1 (ACC: 73.51% and AUC: 0.820). The study presents a novel supportive diagnostic approach using EEGs and 1D-CNN with a low-dimensional temporal characteristic feature extraction approach (t-SNE).

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

#### MAKALE BİLGİSİ

##### Makale Tarihleri

Gönderim : 2 Ağustos 2023

Kabul : 21 Eylül 2023

##### Anahtar Kelimeler:

ADHD, t-SNE Özellik Çıkarma, Derin Öğrenme, Hastalık Teşhisi

#### ÖZET

Elektroensefalografi (EEG) sinyalleri, çocukluk çağı nörogelişimsel bir bozukluk olan ADHD/Dikkat Eksikliği Hiperaktivite Bozukluğu hakkında kritik bilgilerin elde edilmesi için güvenilir bir şekilde kullanılabilir. ADHD'nin erken tespiti, bu bozukluğun gelişimini azaltmak ve uzun vadeli etkisini azaltmak için önemlidir. Bu çalışma, t-SNE (t-dağılımlı Stokastik Komşu Gömme) ile zaman alanı özelliklerini çıkardıktan sonra 1D-CNN (Evrışimli Sinir Ağı) ile ADHD ve sağlıklı bireyleri birbirinden ayıran yüksek tahmin başarısına sahip bir yaklaşıma ulaşmayı amaçlamaktadır. Bu çalışma, 61 ADHD hastasını ve 60 sağlıklı kontrol bireyini içeren yüksek başarımlı bir zamansal karakteristik yaklaşım (1D-CNN ve t-SNE) tanımlamayı amaçlamaktadır. Bu özellikler daha sonra ADHD hastalarını ve sağlıklı bireyleri sınıflandırmak için 1D-CNN modellerinde kullanılır. 1D-CNN derin model-2 (ACC: 81.82% ve AUC: 0.834), 1D-CNN derin model-1'e (ACC: 73.51% ve AUC: 0.820) göre daha başarılı sonuçlar göstermiştir. Çalışma, düşük boyutlu zamansal karakteristik özellik çıkarma yaklaşımı (t-SNE) ile EEG'leri ve 1D-CNN'yi kullanan yeni bir destekleyici teşhis yaklaşımı sunmaktadır.

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

## 1. GİRİŞ

Dikkat eksikliği hiperaktivite bozukluğu (Attention Deficit Hyperactivity Disorder/ADHD), dünya çapında başlıca psikiyatrik ve nörogelişimsel bozukluklardan biridir. Dikkat eksikliği hiperaktivite bozukluğu (ADHD), dünya çapındaki çocukların %5'ini etkileyen, dünya çapındaki başlıca psikiyatrik ve nörogelişimsel bozukluklardan biridir. 4-17 yaş arası ABD'li çocukların yaklaşık %11'i ADHD'den etkilenmektedir [1]–[9]. Diğer bir çalışmada ADHD'nin çocuk ve ergenlerde küresel yaygınlığı yaklaşık %2.2, yetişkinlerde ise %2.8 olarak rapor edilmiştir. ADHD olan çocukların dikkatsizlik, dürtüsellik ve hiperaktivite gibi çeşitli sorunları vardır. ADHD genellikle 6 ila 12 yaşları arasındaki çocuklarda teşhis edilir ve yetişkinliğe kadar, intihar da dahil olmak üzere ciddi etkileri sürmektedir. ADHD'den mustarip çocukların ve daha küçük bireylerin %40'ından fazlası, yetişkin olma sürecine kadar ciddi sorunlara yol açan davranış sorunları geliştirir. ADHD aynı zamanda astım, depresyon, anksiyete ve öğrenme güçlükleri gibi sorunlarla da önemli ölçüde ilişkilidir. Erkeklerin kadınlara göre ADHD'ye sahip olma olasılığı daha yüksektir ve davranışları farklıdır [1], [2].

Günümüzde, ADHD'li çocukların etkili bir şekilde teşhis edilmesi hala önemli bir sorundur. ADHD'li çocukların erken teşhisi için otomatik bir sistem önermek için çeşitli araştırmalar yapılmıştır. ADHD'li çocukların erken tespiti ve sınıflandırılması için otomatik bir sistem önermek için hala bir kapsam vardır. ADHD'nin erken saptanması, hastaların uygun sağlık hizmetlerine ulaşmalarına, etkili tedavi görmelerine ve yaşamlarını sürdürme konusunda daha bilinçli olmalarına yardımcı olacaktır [1]–[9]. ADHD'nin beyin sinyalleri üzerindeki etkisini araştırmak için yaygın olarak kullanılan elektromiyografi (EMG), olayla ilgili potansiyeller (ERP) ve elektroensefalografi (EEG) gibi çeşitli nörogörüntüleme ve nörofizyolojik yöntemler vardır. Bunun dışında fMRI (Functional Magnetic Resonance Imaging) da ADHD'li bireyleri ayırmada kullanılmaktadır. Fonksiyonel manyetik rezonans görüntüleme (fMRI), insan beyni haritalaması üzerine araştırma yapmak için önde gelen yöntemlerden biri haline geldi. fMRI edinimleri, biliş veya görev performansının arkasındaki beyin süreçlerini anlamaya yardımcı olan beyin aktivasyon modellerinin keşfedilmesine olanak tanır. Bu paradigmada, beyindeki içsel işlevsel bağlantı, herhangi bir özel görev gerçekleştirme veya dinlenme esnasında incelenebilir [1]–[9].

Bu çalışmada, daha popüler, düşük maliyetli, non-invaziv ve taşınabilir bir teknik olduğu için ağırlıklı olarak EEG analizine odaklandık. EEG sinyalleri doğrudan insan beyninden alındığından, beynin iç fizyolojik koşullarını göstermede daha doğru ve geçerli bir tekniktir. Çeşitli çalışma türleri, farklı alanlarda farklı türde sonuçlar çıkarmak için EEG sinyallerini kullanmıştır. Örneğin, EEG kullanılarak nöbetin saptanması veya sınıflandırılması, EEG kullanılarak uyku skorlamasının otomatik aşaması, EEG kullanılarak taşınabilir bir kablosuz kapalı döngü nöbet denetleyicisi geliştirme [1]–[3]. Ayrıca, EEG tabanlı analiz, ADHD, Parkinson hastalığı vb. gibi çeşitli nörolojik bozuklukların tespiti için yaygın olarak kullanılmaktadır. EEG verileri, çok değişkenli ve çok kanaldan toplanan bir zaman serisi veri türüdür. Zamana bağlı özelliklerle bağlantılı ve zamana göre düzenlenmiş veri noktalarının bir koleksiyonundan oluşmaktadır. Yerel örüntüler, veri setinin ayırt edici özelliklerini tanımlarken, global örüntüler, veri setinin genel eğilimini gösterir. Günümüzde, EEG sinyallerinden etkili özellik çıkarımı ve özellik seçimi hala büyük bir zorluktur. Bu zorlukların üstesinden gelmek için, istatistiksel özellikler, frekans alanı özellik çıkarma, zaman-frekans alanı özellik çıkarma ve derin öğrenmeye dayalı özellikler çıkarma gibi çeşitli yöntemler mevcuttur [1]–[5]. Günümüzde, ADHD'li çocukların tanısında yaygın olarak kullanılan çeşitli doğrusal ve doğrusal olmayan özellikler vardır. Örneğin, Khaleghi ve ark., ADHD'li çocukları teşhis etmek için EEG sinyallerinden çeşitli morfolojik, zaman alanı, frekans ve doğrusal olmayan özellikleri çıkardı [10]. Altınkaynak ve ark. ayrıca ADHD'li çocukları teşhis etmek için morfolojik, doğrusal olmayan ve dalgacık özelliklerini çıkardı [11].

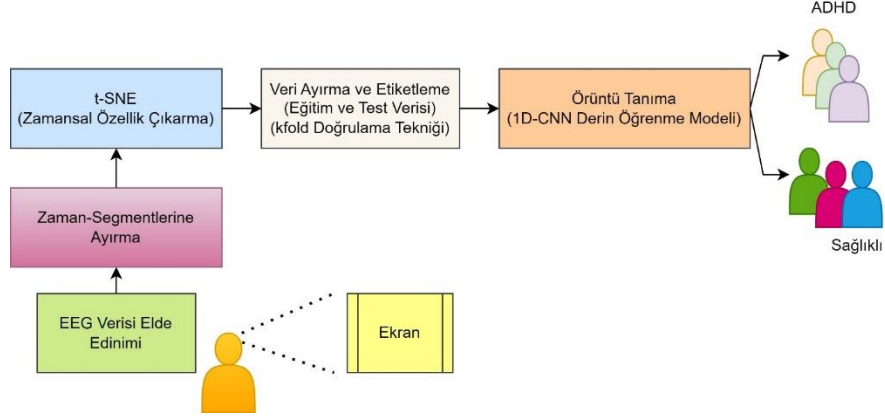
Mevcut çalışmamızda, önceki çalışmalara dayanarak zaman alanı ve doğrusal olmayan özellikleri t-SNE metodu ile gerçekleştirdik. t-dağılımlı stokastik komşu yerleştirme (t-SNE), yüksek boyutlu verileri düşük boyutlu bir temsile indirmek için bir yöntemdir ve çoğunlukla verileri görselleştirmek için kullanılır [12]–[18]. t-SNE, yüksek boyutlu uzaydaki bir veri noktasını 2 boyutlu veya 3 boyutlu öklid uzayındaki bir noktaya eşleyen, doğrusal olmayan bir boyutluluk azaltma tekniğidir. Diğer doğrusal olmayan boyut indirgeme yaklaşımlarından farklı olarak, t-SNE olasılıksal bir yapıya sahiptir. İlgili çalışmamızda t-SNE yöntemi EEG analizi ile beraber bu sinyallerden zaman alanında özellik çıkarılması için kullanılmıştır. Literatürde istatistiksel ve diğer frekans alanı özellik çıkarma yöntemlerinden hangisinin optimal olduğu bilinmemektedir [12]–[18]. Buna göre veriler genellikle önce bir dizi özelliğe dönüştürülür daha sonra 1D-CNN derin öğrenme yöntemleri kullanılarak ADHD ve sağlıklı bireyler arasında sınıflandırma işlemi yapılmıştır. Bununla beraber t-SNE yöntemi bu bireyler arasındaki ayrımı EEG verileri üzerinden grafiksel olarak ayırmanın ne kadar başarılı olduğunu göstermek için kullanılmıştır. Beyin haritalama ve fonksiyonel bağlantı grafikleri de çalışmaya eklenmiştir.

## 2. VERİ TOPLANMASI VE METOTLAR

ADHD'si olan bireylerin ve sağlıklı bireylerin EEG sinyalleri üzerinden tahmin edilmesi için önerilen makine öğrenimine dayalı yaklaşımın genel görünümü, Şekil 1'de gösterilmektedir. Çalışmanın ilk adımında, ADHD'li bireyler ve sağlıklı bireyleri içeren EEG verileri toplanmıştır. İkinci adımda toplanan bu verilerden t-SNE yöntemi ile zaman alanında özellik çıkarılmıştır. En son adımda örüntünün tanınması için ilgili bu özelliği çıkarılmış veriler derin öğrenme modellerine verilmiştir ve bireylerin ADHD/sağlıklı bireyler olup olmadığı sınıflandırılmıştır.


## 2.1. Veri Elde Edinimi

Deney için açık bir veri tabanı olan IEEE veri portundan ADHD ve sağlıklı bireylerden toplanan veri seti kullanılmıştır. Bu veri setinde toplanan EEG sinyalleri için örnekleme frekansı 128 Hz olarak belirtilmiştir. Veri seti içinde EEG sinyalleri, altmış sağlıklı çocuktan (erkek: 50 ve kız: 10) ve altmış bir ADHD'li çocuktan (erkek: 48 ve kız: 13) toplanmıştır. Bu bireylerin yaş ortalaması 7-12 arasındadır [19].



Şekil 1. ADHD ve sağlıklı bireyleri ayırmak için t-SNE ve derin öğrenme tabanlı sistem.

Her çocuk çizgi film karakterlerinin resimlerini izlemiş ve karakterleri sayması istenmiştir. Her resimde 5'ten 16'ya kadar farklı sayılar çizilmiştir ve resimlerin boyutu çocukların kolayca görüp sayılabileceği kadar büyüktür. Veri setinde elde edilen EEG sinyalleri şu kanallardan toplanmıştır; Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T7, T8, P7, P8, Fz, Cz, Pz. Bu çalışmada kullanılan elektrot dağılımı Şekil-2'de gösterilmektedir. Her çocuğun bilişsel etkinliklerdeki performansı farklıdır bu da EEG kayıtlarının toplam süresini ve veri kümesi boyunca değişiklik göstermesini sağlamıştır [19]. İlgili EEG sinyallerinin genlik ( $\mu V$ ) Recurrence Plot [20] ve güç spektrumu gösterimleri Şekil 3'de verilmiştir. Dikkat eksikliği hiperaktivite bozukluğu (ADHD), dikkat eksikliği ve hiperaktivite ile karakterize edilebilen yaygın bir nörogelişimsel mental bir hastalıktır [1]-[9]. ADHD bireylerin, sağlıklı bireylere göre nörolojik ve davranışsal farkları Tablo 1'de gösterilmiştir.




Şekil 2. EEG kanallarının yerleşimi.

Tablo 1. ADHD bireylerde nörolojik ve davranışsal farklar.

Nörolojik ve Davranışsal Farklar
Konsantrasyonda belirgin zorluk
Kısa dikkat süresi
Aceleci hareketler
Bireyin bilişsel, sosyal ve duygusal gelişimde önemli zorluklar yaşaması

## 2.2. 1D-CNN Derin Öğrenme Modeli


CNN modeli, görüntüleri sınıflandırma yeteneği ile iyi bilinmektedir ve bunun sonucunda yüz ve nesne tanımlama, uydur tahmini ve MRI, CT, X-RAY ve PET gibi tıbbi görüntülerin analizi gibi uygulamalarda kullanılmaktadır. İlgili verisetlerinde farklı sınıflara ait görüntüleri tanımlamak için 2 boyutlu (2D) görüntülerin yanı sıra CNN modelleri EEG ve ECG gibi 1 boyutlu (1D) biyosinyallere de uygulanabilmektedir [21][22]. Bu nedenle çalışmamızda EEG zaman segmentlerine, t-SNE ile zamansal özellik çıkarma işlemi uyguladıktan sonra, ADHD ve sağlıklı bireylere ait sınıfları ayırmak için 1D-CNN derin öğrenme modelleri kullanılmıştır (bakınız; Şekil 4.). CNN modeli üç ana bileşenden oluşur; evrişimsel katman (convolutional layer), havuzlama katmanı (pooling layer) ve tam bağlantılı katman (fully-connected layer). Evrişim katmanı, çekirdek (kernel) ile ilgili veriyi evrişim



Şekil 3. ADHD ve sağlıklı bireylere (ADHD/ Healthy Person) ait EEG sinyalleri gösterimi, Recurrence grafiği (Recurrence Plot) gösterimleri ve güç spektrumları.

işlemine tabi tutuktan sonra ReLU aktivasyon fonksiyonu ile oluşan negatif değerleri 0 değerine dönüştürmektedir. Ayrıca, evrişim katmanı ve havuzlama katmanı, girdinin karmaşıklığını azaltırken önemli özelliklerin belirginliğini artırır ve modelin aşırı öğrenmesini önler. Evrişim katmanının çalışma mekanizması denklemde (Denk. 1) gösterilmektedir. Sırasıyla bu denklemde;  $S$  sinyal girdisidir,  $*$  ayrık evrişim işlemidir,  $W$  evrişim çekirdeğidir,  $i$  giriş sinyalinin uzunluğudur. Düzleştirici katman (flatten layer), çok boyutlu veri yapısını tek boyutlu bir vektöre dönüştürmektedir. Bununla beraber, sınıflandırma katmanı (softmax/classification layer) ise ilgili sınıflara ait olasılık değerlerini bulmaktadır [21], [22][23][24].

$$S * W = \sum_{i=1}^{|W|} WiSi \quad (1)$$



Şekil 4. 1D-CNN şematik gösterimi.

Bu çalışmada ilgili 1D-CNN derin öğrenme modelleri için oluşturulan hiper-parametreler ve mimari Şekil-5'te görülmektedir. Buna ek olarak ilk derin modelinde eğitim için gerekli olan epoch sayısı 220, ikinci derin öğrenme modeli için 250 belirlenmiştir. Bununla beraber ReLU aktivasyon fonksiyonu gerçekleştirilmiş ve eğitim algoritması olarak Adam kullanılmıştır.

1D-CNN Model-1			1D-CNN Model-2		
Name	Type		Name	Type	
1 sequenceinput Sequence input with 12 dimensions	Sequence Input		1 sequenceinput Sequence input with 12 dimensions	Sequence Input	
2 conv1d_1 120 10x12 convolutions with stride 1 and padding 'causal'	Convolution		2 conv1d_1 150 8x12 convolutions with stride 1 and padding 'causal'	Convolution	
3 relu_1 ReLU	ReLU		3 relu_1 ReLU	ReLU	
4 layernorm_1 Layer normalization with 120 channels	Layer Normalization		4 layernorm_1 Layer normalization with 150 channels	Layer Normalization	
5 conv1d_2 240 10x120 convolutions with stride 1 and padding 'causal'	Convolution		5 conv1d_2 300 8x150 convolutions with stride 1 and padding 'causal'	Convolution	
6 relu_2 ReLU	ReLU		6 relu_2 ReLU	ReLU	
7 layernorm_2 Layer normalization with 240 channels	Layer Normalization		7 layernorm_2 Layer normalization with 300 channels	Layer Normalization	
8 globalavgpool1d 1-D global average pooling	1-D Global Average ...		8 globalavgpool1d 1-D global average pooling	1-D Global Average...	
9 fc 2 fully connected layer	Fully Connected		9 fc 2 fully connected layer	Fully Connected	
10 softmax softmax	Softmax		10 softmax softmax	Softmax	
11 classoutput crossentropyx with classes '1' and '2'	Classification Output		11 classoutput crossentropyx with classes '1' and '2'	Classification Output	

Şekil 5. Çalışmada ADHD/sağlıklı bireyleri ayırmada kullanılan 1D-CNN modelleri.

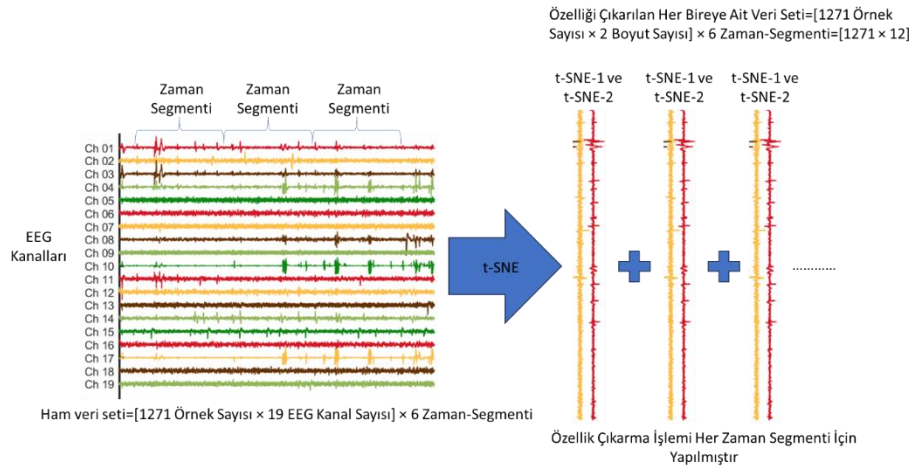
### 2.3. Performans Metrikleri

Örüntü tanıma için seçilen değerlendirme metrikleri, derin öğrenme modellerinin performanslarını ortaya çıkarmak için çok önemlidir. Bu çalışma için uygun metrikler; sınıflandırma doğruluğu (ACC), duyarlılık (SENS), özgüllük (SPEC), kesinlik (PREC), F-score, ve eğrinin altındaki alan (AUC). Bununla beraber alıcı çalışma özellikleri (ROC) de performans analizi için elde edilmiştir [25], [26]. Eğitim ve test veri setleri, kfold tekniği ile 3 parçaya ayrılmış ve doğrulama yöntemi bu teknik üzerinden uygulanmıştır.

## 2.4. t-SNE Özellik Çıkarma Yöntemi

t-SNE yöntemi, verilerin yüksek ve düşük boyutlu temsilde komşu olma olasılıklarının eşleşmesine dayanır. Önerilen yaklaşım, EEG verilerinin yüksek boyutlu bir temsili daha düşük bir temsile dönüştürerek özellik çıkarma işlemine dayanır. t-SNE, bir dizi yüksek boyutlu veriyi 2 boyutlu veya 3 boyutlu vektöre dönüştürmek için son derece uygun olan doğrusal olmayan bir boyut indirgeme tekniğidir [12]–[18]. Bu işlem özellik çıkarmanın yanında, birçok farklı ölçekte yapıyı ortaya çıkarmak için tek bir harita oluşturur ve önceki tekniklerle üretilenlerden çok daha iyi görselleştirmeler üretebilir. Bu çalışmada ADHD ve sağlıklı bireyleri ayırmada derin öğrenme modellerini eğitmek ve test etmek için zaman alanında özellik çıkarmak için kullanılmıştır. ADHD ve sağlıklı her bireye ait ham verisetinde [1271 Örnek Sayısı×19 EEG Kanal Sayısı] × 6 zaman-segmenti alınmıştır. Bunun ardından, ilgili her bir birey için alınan verisetleri alt alta konularak, t-SNE ile zamansal örüntüyü bozmadan boyut azaltılarak özellik çıkarılmıştır. Yeni oluşan her bir kişiye ait veri seti [1271 Örnek Sayısı×2 Boyut Sayısı] × 6 zaman-segmenti olarak oluşturulmuştur. 1271 örnek sayısı, 128 örnekleme frekansında yaklaşık 10 saniyelik bir veri kaydına denk gelmektedir.

Zaman alanında, zamansal örüntüyü koruyarak özellik çıkaran t-SNE boyut azaltma tekniğinin, frekans düzlemine göre başlıca sağlayabileceği avantajlarından birisi de zamana bağlı bilgileri korumasıdır. Zaman alanı analizi, geçici davranış (transient response), zamanlama ve nedensellik gibi zamanla ilgili bilgileri koruyarak sinyallerin zaman boyutunda ayrıntılı bir temsili sağlayabilir. Ancak frekans alanında durağan olmayan sinyaller için sınırlıdır: Frekans alanı analizi özellik çıkarma yöntemleri ise durağan olmayan sinyaller (non-stationary) için sınırlıdır çünkü sinyalin analiz süresi boyunca sabit kaldığını varsayar. Durağan olmayan sinyaller için, kısa zamanlı Fourier dönüşümü (Short-Time Fourier Transform/STFT) veya dalgacık dönüşümü (Wavelet Transform/WT) gibi zaman-frekans analiz teknikleri daha uygun olabilir [27].



Şekil 6. t-SNE tekniği ile özellik çıkarma işlemi.


## 3. BULGULAR VE TARTIŞMA

ADHD ve sağlıklı bireyleri ayırmada (bakınız; Tablo 2) sınıflandırma performansının deneysel sonuçları önerilen 1D-CNN derin öğrenme modelinde (model-1) 3-fold için, doğruluk: 73.51%, duyarlılık: 77.30%, özgüllük: 70.00%, kesinlik: 73.51%, F-score: 74.69%'lik bir ortalama performans elde ettiğini göstermiştir. AUC değeri, ADHD ve sağlıklı bireyleri ayırmada 0.820 olarak hesaplanmıştır. Bu modeldeki bütün performans değerleri her fold için farklı çıkmakla beraber en iyi doğruluk değeri 80.00% ile fold-1'de elde edilmiştir. Hassasiyet değeri 95.00% ve F-score değeri  $\geq 86\%$  olarak hesaplanmıştır. AUC değeri de yine  $\geq 0.8$  olarak bulunmuştur. Bununla beraber fold-2 ayırmada verisetindeki test sonuçlarında en iyi ikinci sınıflandırma başarısı görülmektedir. Buna göre iki sınıfı (ADHD/Sağlıklı) ayırma başarısı doğruluk için 78.04%, duyarlılık için 61.90%, özgüllük için 95.00%, kesinlik için 62.50% ve F-score değeri için 68.18% hesaplanmıştır. AUC değeri ise 0.840 olarak bulunmuştur. Aynı derin öğrenme modelinde en düşük tahmin etme sonuçları ise fold-3 ayırmada hesaplanmıştır (ACC:  $\geq 62.00$ ).

Tablo 2. Sınıflandırma performans sonuçları (ADHD ve Sağlıklı Bireyler).

Perf.Metrik/1D-CNN Model	Model-1				Average
	fold-1	fold-2	fold-3		
(%)					
ACC	80.00	78.04	62.50		73.51
SENS	95.00	61.90	75.00		77.30
SPEC	65.00	95.00	50.00		70.00
PRES	80.00	78.04	62.50		73.51
F-score	86.85	69.04	68.18		74.69
AUC	0.852	0.840	0.770		0.820

Perf.Metrik: Performans Metriği, Average: Ortalama



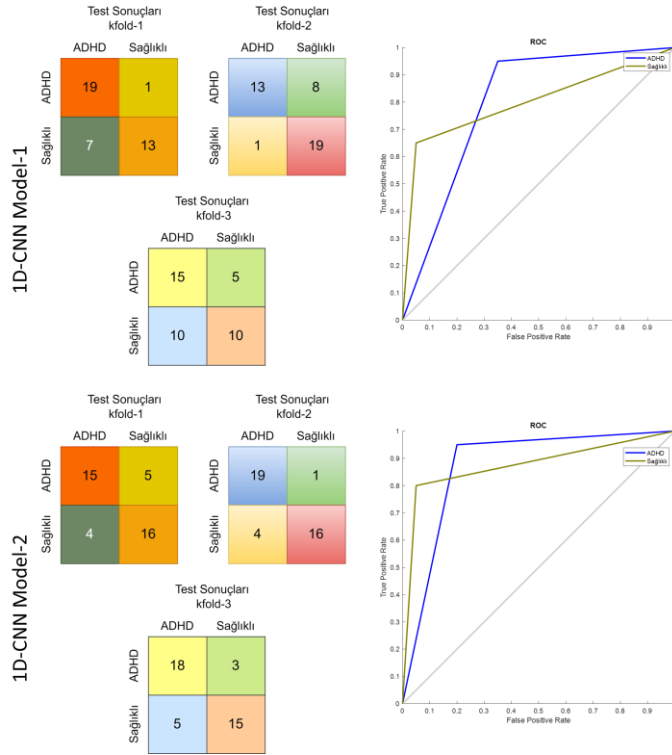
Şekil 7. ADHD ve sağlıklı bireyleri sınıflandırma performans değişimlerinin boxplot gösterimi. a. 1D-CNN Model-1, b. 1D-CNN Model-2 (Üst Sıra), 1D-CNN eğitim süreci gösterimi (Alt Sıra).

Tablo 3. Sınıflandırma performans sonuçları (ADHD ve Sağlıklı Bireyler)

Perf.Metrik/1D-CNN Model	Model-2			Average
	fold-1	fold-2	fold-3	
(%)				
ACC	77.50	87.50	80.48	81.82
SENS	85.00	95.00	85.71	88.57
SPEC	70.00	80.00	75.00	75.00
PRES	77.50	87.50	80.48	81.82
F-score	81.07	91.09	83.01	85.05
AUC	0.787	0.912	0.804	0.834

Perf.Metrik: Performans Metriği, Average: Ortalama

Çalışmanın bir sonraki adımında, 1D-CNN derin öğrenme model-2 ile ADHD ve sağlıklı bireyleri tahmin etmek için örüntü tanıma sonuçları elde edilmiştir. Tablo 3' de elde edilen sınıflandırma sonuçlarına göre, en düşük sınıflandırma doğruluğu 77.50% ile fold-1'de aynı veri setinde (61 ADHD ve 60 sağlıklı birey) elde edilmiştir. Yine aynı fold-1/ayırma için 1D-CNN model-2 sırasıyla 85.00% hassasiyet ve 70.00% özgüllük oranlarına sahip sınıflandırma sonuçlarına ulaşmıştır. Duyarlılık, özgüllük, kesinlik ve F-score değerleri fold-3 için sırasıyla 80.48%, 85.71%, 75.00%, 80.48% ve 83.01% aralığında değerlere sahiptir. AUC sonucu ise aynı fold için 0.804 olarak hesaplanmıştır. En iyi performans metrikleri fold-2 için ACC:  $\geq 87.00\%$  üzerinde elde edilmiştir. Hassasiyet ve AUC değeri ise sırasıyla 95.00% ve 0.912'dir. Ortalama sınıflandırma doğruluğu ise 81.82% ve AUC değeri 0.834 olarak başarı elde etmiştir. Elde edilen bu bulgulara göre, ADHD ve sağlıklı bireyler farklı hiper parametrelere sahip 1D-CNN modellerinde (bakınız; Şekil-7), farklı tahmin performans değerlerine ulaştığı görülmektedir. Bununla beraber, model-1 ve model-2 derin öğrenme modellerinin, bütün fold ayırmalarında ve 121 katılımcı için AUC:  $\geq 0.770$  performans gösterdiği gözlenmiştir (bakınız; Tablo 2, Tablo 3 ve Şekil 8). ADHD ve sağlıklı bireylerin, t-SNE ile özellik çıkarıldıktan sonra yine aynı yöntemle 2D saçılım grafiği gösterimlerinde (bakınız; Şekil-9) bu sınıflara ait kümelerin yüksek bir başarı ile ayırt edilebildiği gözlenmiştir.



**Şekil 8.** ADHD ve Sağlıklı Bireyleri Sınıflandırma Performans Değerlerinin Confusion Matrisi Gösterimi (solda) ve ROC eğrisi grafiği (sağda) (ROC grafikleri her iki derin öğrenme modelinde en iyi kfold test sonucuna göre oluşturulmuştur).


Beynin ADHD'den etkilenen bölgesini ve ADHD'si olan bireyleri sağlıklı kontrol bireylerinden ayırmada önemli EEG kanallarını ve beyin kortikal bölgelerini incelemek için beyin haritalama (bakınız; Şekil-10) ve fonksiyonel bağlantı (bakınız; Şekil-11) grafikleri elde edilmiştir [28], [29]. Buna göre ADHD bireylerde, frontal lobe (frontal lobe) ve ön-frontal lobe (prefrontal lobe) üzerinde daha düzensiz bir güç yoğunluğu artışı sağlıklı bireylere kıyasla görülmektedir [30]–[32]. Bununla beraber ADHD bireylerde, anterior cingulate korteksinde (prefrontal korteks bölgesi) pozitif fonksiyonel bağlantı (positive functional connectivity) gözlenirken, posterior cingulate korteksinde (parietal bölgesi) negatif fonksiyonel bağlantı (negative functional connectivity) olduğu gözlenmiştir [1], [2] [30]–[32]. Bu açıdan literatürde belirtilen ADHD hastalığına sahip bireyler ve ilgili beyin korteksleri, elde edilen beyin haritalama ve fonksiyonel bağlantı grafiklerinde tutarlı sonuçlar üretildiği gözlenmiştir. Yine de bu bağlantısal grafikler üzerinden daha iyi yorumlamak için daha fazla katılımcının grafiksel sonuçlarını elde etmek gerektiği söylenebilir. Literatürdeki diğer çalışmalarla olan karşılaştırma Tablo 4'de verilmiştir.

**Tablo 4.** Literatürdeki diğer çalışmalar ve karşılaştırmalı özet


Çalışma/Yıl	Katılımcı Sayısı	Sinyal	Özellik Çıkarma/Özellik Seçme/Sınıflandırıcı	Performans Değerleri
[11]/2020	46	EEG/ERP	Morfolojik/Nonlineer/ Wavelet Özellikleri ve SVM k-NN RF Adaboost MLP, NB, LR	ACC: 91.3% AUC: 0.910
[33]/2020	40	EEG	Spektrum/CNN	ACC: 88%
[34]/2021	120	EEG	AB, RF, SVM	ACC: 84.0%
[35]/2021	121	EEG	GA ve MLP	ACC: 89.7%
[36]/2022	121	EEG	Morfolojik/Zaman Alan Özellikleri ve t-test/LASSO Özellik Seçme ve MLP/SVM	ACC: 94.2% AUC: 0.964
[1]/2023	121	EEG	LASSO Özellik Seçme ve GPC, DT, RF, k-NN, MLP, and LR	ACC: 97.5% AUC: 0.999
[37]/2023	219	Functional Magnetic Resonance Imaging (fMRI)	ICA/CNN/CorrAE/Deep Forest/SVM/Logistic Regression	ACC: 69%
[7]/2023	33	EEG	ITD ve Bağlantı Tabanlı Özellik/ DT, NB, SVM, kNN, Bagged Tree	ACC: 92.90-100%
<b>Bu Çalışmada</b>	30	EEG	t-SNE Özellik Çıkarma ve 1D-CNN Derin Öğrenme Modelleri	ACC: 81.82% SENS: 88.57% AUC: 0.834

ERP: Event Related Potential, RF: Random Forest, MLP: Multilayer Perceptron, NB: Naive Bayes, LR: Logistic Regression, AB: Adaboost, SVM: Support Vector Machine, GA: Genetic Algorithm, GPC: Gaussian Process Classification, DT: Decision Tree, ITD: Intrinsic Time-Scale Decomposition, kNN: k-Nearest Neighbors

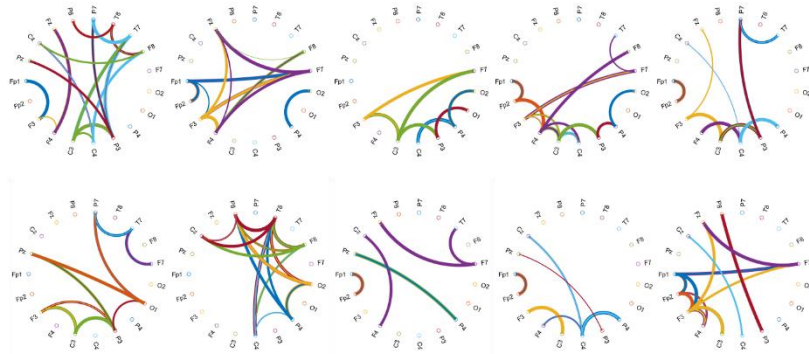




**Şekil 9.** t-SNE tekniği ile ADHD ve sağlıklı bireyleri ayırmada saçılım grafiği sonuçları (Sınıf 1: ADHD, Sınıf 2: Sağlıklı) (İlgili gösterimler her zaman segmenti için t-SNE ile özelliği çıkarılan ADHD ve sağlıklı birer bireye ait veri setleri için oluşturulmuştur. Veri setleri: 2 katılımcı  $\times$  [1271 örnek sayısı  $\times$  2 boyut]).



**Şekil 10.** Farklı kişilere ait beyin haritalama (brain mapping) grafikleri **üst sıra:** ADHD bireyler, **alt sıra:** sağlıklı bireyler (İlgili beyin haritalama sonuçları 15 Hz'de elde edilmiştir ve güç yoğunluğu ifadeleri  $\mu V^2$  aralığındadır.)



**Şekil 11.** Farklı kişilere ait fonksiyonel bağlantı (functional connectivity) grafikleri **üst sıra:** ADHD bireyler, **alt sıra:** sağlıklı bireyler (Oluşan grafiklerin daha anlaşılır olması için korelasyon matrisinde her birey için farklı eşik seviyeleri uygulanmıştır. İlgili fonksiyonel bağlantı grafiklerinde, beyin haritalama sonuçlarındaki bireylere ait veri setleri kullanılmıştır.)

#### 4. SONUÇ

Dikkat eksikliği/hiperaktivite bozukluğu (ADHD), gelişimsel olarak uygun olmayan dikkatsizlik düzeyleri, hiperaktivite/dürtüsellik ve işlevsel bozulma ile karakterize edilen, erken yaşta ortaya çıkan, yaşam boyu süren, maliyetli ve yaygın bir hastalık olarak tanımlanmaktadır. Bu çalışma, çocukluk çağı nörogelişimsel bozukluğunda sıklıkla karşılaşılan ADHD'nin erken ve objektif tanısını desteklemek için zaman-serisi sinyalleri üzerinde zamansal örüntüyü bozmadan boyut azaltarak ve makine öğrenmesi modeli ile farklı bir teknik sunmaktadır. Bulgularımız, EEG veri setlerinden elde edilen zaman alanı ve boyut azaltma özellik çıkarma özelliği olan t-SNE ile ilgili özellik çıkarılmış ve 1D-CNN derin öğrenme modelleri ile eğitim/test performansları 3-fold için ve ortalama sonuçları dahil edilerek elde edilmiştir. Yüksek tahmin performansına (ACC:  $\leq 87.50\%$ , SENS:  $95.00\%$  ve AUC:  $\leq 0.912$ ) sahip 1D-CNN ve t-SNE yaklaşımı, ADHD'nin tanılma amaçları için yararlı ve ayırt edici bir araç olabileceğini ortaya koymaktadır. Araştırma çalışmamızın, literatürdeki önceki yaklaşım ve performanslara göre daha iyi sonuç üretmemesi not edilmesi gerekmektedir. Ancak var olan literatürdeki tüm bu çalışmalar, frekans veya zaman alanında kapsamlı bir araştırma sonrasında EEG'den hastalığı karakterize eden özelliklerin manuel olarak seçilmesini gerektirmiştir. İlgili çalışmamız, t-SNE tekniği ile zaman alanı içinde kalıp, zamansal örüntüyü bozmadan boyut azaltarak özellik çıkarmanın yanında, 1D-CNN derin öğrenme modelleri üzerinde kıyas edilerek, ADHD ve sağlıklı bireyleri ayırmada ne kadar başarılı olduğuna dair literatürdeki ilk çalışma olarak görülmektedir. Ayrıca bu yaklaşım ADHD tanısına EEG sinyalleri üzerinden kullanımı kolay, düşük maliyetli yeni bir bakış açısı getirebilir ve bulgular tedavinin düzenlenmesinde yardımcı olabilir.

#### Yazar Katkıları

Kutlucan GÖRÜR, bu çalışmanın konusunun ve kapsamının detaylarını inceleyerek, deneysel analiz sürecinin gözlemlenmesine ve sonuçların yorumlanmasına katkı sağlamıştır. Ve yayının yazılması süreci yine kendisi tarafından yapılmıştır.

#### Veri Kullanılabilirliği

Kullanılan veri kümesi erişim linki: <https://iee-dataport.org/open-access/eeg-data-adhd-control-children>

#### Çıkar Çatışması

Makale yazarı, herhangi bir çıkar çatışması olmadığını beyan eder.

#### KAYNAKÇA

- [1] M. Maniruzzaman, M.A.M. Hasan, N. Asai, and J. Shin "Optimal Channels and Features Selection Based ADHD Detection From EEG Signal Using Statistical and Machine Learning Techniques," IEEE Access, vol. 11, pp. 33570–33583, 2023.
- [2] G. Hámori et al. "Adolescent ADHD and electrophysiological reward responsiveness: A machine learning approach to evaluate classification accuracy and prognosis," Psychiatry Res., vol. 323, p. 115139, 2023.
- [3] A. Alim and M.H. Imtiaz "Automatic Identification of Children with ADHD from EEG Brain Waves," Signals, vol. 4, no. 1, pp. 193–205, Feb. 2023
- [4] S.K. Khare and U.R. Acharya "An explainable and interpretable model for attention deficit hyperactivity disorder in children using EEG signals," Comput. Biol. Med., vol. 155, p. 106676, Mar. 2023
- [5] Y.S. Liu, B. Cao, and P.R. Chokka "Screening for Adulthood ADHD and Comorbidities in a Tertiary Mental Health Center Using EarlyDetect: A Machine Learning-Based Pilot Study," J. Atten. Disord., vol. 27, no. 3, pp. 324–331, Feb. 2023
- [6] C.-C. Chen, E.H.-K. Wu, Y.-Q. Chen, H.-J. Tsai, C.-R. Chung, and S.-C. Yeh "Neuronal Correlates of Task Irrelevant Distractions Enhance the Detection of Attention Deficit/Hyperactivity Disorder," IEEE Trans. Neural Syst. Rehabil. Eng., vol. 31, pp. 1302–1310, 2023
- [7] O. Karabiber Cura, S. Kocaaslan Atli, and A. Akan "Attention deficit hyperactivity disorder recognition based on intrinsic time-scale decomposition of EEG signals," Biomed. Signal Process. Control, vol. 81, p. 104512, Mar. 2023
- [8] R.C. Joy et al. "Detection and Classification of ADHD from EEG Signals Using Tunable Q-Factor Wavelet Transform," J. Sensors, vol. 2022, pp. 1–17, 2022.
- [9] H. Deng et al. "Systematic bibliometric and visualized analysis of research hotspots and trends in attention-deficit hyperactivity disorder neuroimaging," Front. Neurosci., vol. 17, 2023.
- [10] A. Khaleghi, P.M. Birgani, M.F. Fooladi, and M.R. Mohammadi "Applicable features of electroencephalogram for ADHD diagnosis," Res. Biomed. Eng., vol. 36, no. 1, pp. 1–11, 2020.
- [11] M. Altunkaynak et al., "Diagnosis of Attention Deficit Hyperactivity Disorder with combined time and frequency features," Biocybern. Biomed. Eng., vol. 40, no. 3, pp. 927–937, Jul. 2020.
- [12] M. Svantesson, H. Olausson, A. Eklund, and M. Thordstein "Get a New Perspective on EEG: Convolutional Neural Network Encoders for Parametric t-SNE," Brain Sci., vol. 13, no. 3, p. 453, 2023.
- [13] S. Hwang, K. Hong, G. Son, and H. Byun "Learning CNN features from DE features for EEG-based

- emotion recognition,” *Pattern Anal. Appl.*, vol. 23, no. 3, pp. 1323–1335, 2020.
- [14] O.P. Idowu, A.E. Ilesanmi, X. Li, O W. Samuel, P. Fang, and G. Li “An integrated deep learning model for motor intention recognition of multi-class EEG Signals in upper limb amputees,” *Comput. Methods Programs Biomed.*, vol. 206, p. 106121, 2021.
- [15] J. Xu, H. Zheng, J. Wang, D. Li, and X. Fang “Recognition of EEG Signal Motor Imagery Intention Based on Deep Multi-View Feature Learning,” *Sensors*, vol. 20, no. 12, p. 3496, 2020.
- [16] T. Nishimoto, H. Higashi, H. Morioka, and S. Ishii “EEG-based personal identification method using unsupervised feature extraction and its robustness against intra-subject variability,” *J. Neural Eng.*, vol. 17, no. 2, p. 026007, 2020.
- [17] Z. Wang, Y. Wang, J. Zhang, C. Hu, Z. Yin, and Y. Song “Spatial-Temporal Feature Fusion Neural Network for EEG-Based Emotion Recognition,” *IEEE Trans. Instrum. Meas.*, vol. 71, pp. 1–12, 2022.
- [18] M. Sun, W. Cui, S. Yu, H. Han, B. Hu, and Y. Li “A Dual-Branch Dynamic Graph Convolution Based Adaptive TransFormer Feature Fusion Network for EEG Emotion Recognition,” *IEEE Trans. Affect. Comput.*, vol. 13, no. 4, pp. 2218–2228, 2022.
- [19] “EEG DATA FOR ADHD / CONTROL CHILDREN.” <https://ieec-dataport.org/open-access/eeg-data-adhd-control-children>.
- [20] “Recurrence Plot.” <https://www.mathworks.com/matlabcentral/fileexchange/58246-tool-box-of-recurrence-plot-and-recurrence-quantification-analysis>.
- [21] H. W. Loh et al. “Deep neural network technique for automated detection of ADHD and CD using ECG signal,” *Comput. Methods Programs Biomed.*, vol. 241, p. 107775, 2023.
- [22] Ö. Kasim and M. Tosun “Biometric Authentication from Photic Stimulated EEG Records,” *Appl. Artif. Intell.*, vol. 35, no. 15, pp. 1407–1419, 2021
- [23] R. Du, S. Zhu, H. Ni, T. Mao, J. Li, and R. Wei “Valence-arousal classification of emotion evoked by Chinese ancient-style music using 1D-CNN-BiLSTM model on EEG signals for college students,” *Multimed. Tools Appl.*, vol. 82, no. 10, pp. 15439–15456, 2023.
- [24] S. Shanmugam and S. Dharmar “A CNN-LSTM hybrid network for automatic seizure detection in EEG signals,” *Neural Comput. Appl.*, vol. 35, no. 28, pp. 20605–20617, 2023.
- [25] K. Gorur and B. Eraslan “The single-channel dry electrode SSVEP-based biometric approach: data augmentation techniques against overfitting for RNN-based deep models,” *Phys. Eng. Sci. Med.*, vol. 45, no. 4, pp. 1219–1240, 2022.
- [26] I. Ozer, C.K. Ozer, A.C. Karaca, K. Gorur, I. Kocak, and O. Cetin “Species-level microfossil identification for globotruncana genus using hybrid deep learning algorithms from the scratch via a low-cost light microscope imaging,” *Multimed. Tools Appl.*, vol. 82, no. 9, pp. 13689–13718, 2023.
- [27] “Time Domain Analysis.” <https://www.quora.com/What-are-the-advantages-and-disadvantages-of-frequency-domain-analysis-compared-to-time-domain-analysis>.
- [28] “Functional Connectivity.” <https://www.mathworks.com/matlabcentral/fileexchange/48576-circulargraph>.
- [29] “Brain Mapping.” <https://www.mathworks.com/matlabcentral/fileexchange/72729-topographic-eeg-meg-plot>.
- [30] K. Rubia et al. “Functional connectivity changes associated with fMRI neurofeedback of right inferior frontal cortex in adolescents with ADHD,” *Neuroimage*, vol. 188, pp. 43–58, 2019.
- [31] G. Leisman and R. Melillo “Front and center: Maturational dysregulation of frontal lobe functional neuroanatomic connections in attention deficit hyperactivity disorder,” *Front. Neuroanat.*, vol. 16, 2022.
- [32] A.F.T. Arnsten “The Emerging Neurobiology of Attention Deficit Hyperactivity Disorder: The Key Role of the Prefrontal Association Cortex,” *J. Pediatr.*, vol. 154, no. 5, pp. I-S43, 2009.
- [33] L. Dubreuil-Vall, G. Ruffini, and J. A. Camprodon “Deep Learning Convolutional Neural Networks Discriminate Adult ADHD From Healthy Individuals on the Basis of Event-Related Spectral EEG,” *Front. Neurosci.*, vol. 14, Apr. 2020
- [34] A. Parashar, N. Kalra, J. Singh, and R. Kumar Goyal, “Machine Learning Based Framework for Classification of Children with ADHD and Healthy Controls,” *Intell. Autom. Soft Comput.*, vol. 28, no. 3, pp. 669–682, 2021.
- [35] A. Ekhlesi, A. Motie Nasrabadi, and M. Mohammadi, “Classification of the Children with ADHD and Healthy Children Based on the Directed Phase Transfer Entropy of EEG Signals,” *Front. Biomed. Technol.*, 2021.
- [36] M. Maniruzzaman, J. Shin, M. Al Mehedi Hasan, and A. Yasumura “Efficient Feature Selection and Machine Learning Based ADHD Detection Using EEG Signal,” *Comput. Mater. Contin.*, vol. 72, no. 3, pp. 5179–5195, 2022.
- [37] D. Wang, D. Hong, and Q. Wu “Attention Deficit Hyperactivity Disorder Classification Based on Deep Learning,” *IEEE/ACM Trans. Comput. Biol. Bioinforma.*, vol. 20, no. 2, pp. 1581–1586, 2023.