

Evrişimli Sinir Ağları Kullanılarak Epileptik Nöbet Tespiti: CHB-MIT Scalp EEG Veri Kümesi Üzerinde Çoklu Sınıflandırma

Epileptic Seizure Detection Using Convolutional Neural Networks: Multi-class Classification on the CHB-MIT Scalp EEG Dataset

Meltem KURT PEHLİVANOĞLU
Kocaeli Üniversitesi
Bilgisayar Mühendisliği Bölümü
Kocaeli, Türkiye
meltem.kurt@kocaeli.edu.tr
ORCID:0000-0002-7581-9390

Ömer Emircan AYVAZ
Kocaeli Üniversitesi
Bilgisayar Mühendisliği Bölümü
Kocaeli, Türkiye
omereayvaz@gmail.com
ORCID:0009-0000-8254-7330

Eren ÇALBAY
Kocaeli Üniversitesi
Bilgisayar Mühendisliği Bölümü
Kocaeli, Türkiye
calbayeren@gmail.com
ORCID:0009-0008-1034-7223

Yunus Emre KIRCI
Kocaeli Üniversitesi
Bilgisayar Mühendisliği Bölümü
Kocaeli, Türkiye
yunusemrekirci@gmail.com
ORCID:0009-0003-1546-1264

Öz

Epileptik nöbet tespiti, epilepsinin yönetimi ve tedavisinde kritik bir görevdir ve doğru ve etkili tanı araçlarının geliştirilmesini gerektirir. Bu çalışma, CHB-MIT Scalp EEG veri kümesinden yararlanarak, kafa derisi EEG kayıtlarından epileptik nöbetleri tespit etmek için Evrişimli Sinir Ağları (CNN) kullanan modeller sunar. Analiz sağlamlığını artırmak için, epilepsi teşhisi konmuş farklı sayıda denekle bu veri kümesinin birden fazla versiyonu oluşturulmuştur. Ek olarak, model performansı üzerindeki etkilerini değerlendirmek için temel ve gelişmiş olarak adlandırılan iki tür etiketleme tekniği kullanılmıştır. Nöbet tespitindeki etkinlikleri belirlemek için özellikle ResNet50, ResNet101, VGG16, InceptionV3, Xception ve DenseNet121 olmak üzere CNN tabanlı modeller kullanılmıştır. Bu çalışma, CHB-MIT Scalp EEG veri kümesi özelinde üç-sınıf sınıflandırma problemini ele alan ilk çalışmadır. DenseNet121 modeli, %85,52'lik bir F1 skoru ile en yüksek performansı elde etmiştir.

Anahtar sözcükler: EEG, Epilepsi, Atak Tespiti, CNN, Derin Öğrenme

Abstract

The detection of epileptic seizures is a critical task in the management and treatment of epilepsy, requiring the development of accurate and effective diagnostic tools. This study presents models using Convolutional Neural Networks (CNN) to detect epileptic seizures from scalp EEG recordings, leveraging the CHB-MIT Scalp EEG dataset. To enhance the robustness of the analysis, multiple versions of this dataset were created with a different number of subjects diagnosed with epilepsy. Additionally, two types of labeling techniques, referred to as basic and advanced, were employed to evaluate their impact on model performance. CNN-based models, particularly ResNet50, ResNet101, VGG16, InceptionV3, Xception, and DenseNet121, were used to assess their effectiveness in seizure detection. This study is the first to address the three-class classification problem specifically with the CHB-MIT Scalp EEG dataset. The DenseNet121 model achieved the highest performance with an F1 score of 85.52%.

Keywords: EEG, Epilepsy, Seizure Detection, CNN, Deep learning

1. Giriş

Epilepsi, dünya genelinde milyonlarca insanın yaşam kalitesini önemli ölçüde etkileyen, tekrarlayan, kendiliğinden ortaya çıkan nöbetlerle karakterize kronik bir nörolojik bozukluktur. Epilepsi dünya çapında yaklaşık 50 milyon insanı etkileyerek en yaygın nörolojik hastalıklardan biri haline gelmiştir [1]. Epilepside nöbetler, beyindeki anormal elektriksel boşalmalardan kaynaklanarak çeşitli fiziksel ve davranışsal semptomlara yol açar. Nöbetlerin zamanında ve doğru bir şekilde tespiti, etkili yönetim ve tedavi için kritik olup, yaralanma riskini azaltmakta ve hasta sonuçlarını iyileştirmektedir [2].

Nöbet tespiti için geleneksel yöntemler genellikle tıbbi uzmanlar tarafından elektroensefalogram (EEG) kayıtları elle analiz edilir. Bu yöntemler etkili olsa da zaman alıcıdır, insan hatasına açıktır ve uzun süreli izleme için uygun olmayabilir. Son yıllarda, makine öğrenimi ve derin öğrenme tekniklerindeki ilerlemeler, epileptik nöbetlerin tespiti ve sınıflandırılmasının otomatikleştirilmesi için yeni yollar açmıştır.

Bu çalışmada, epileptik nöbet sınıflandırması için CHB-MIT Scalp EEG veri kümesi [3] kullanılmıştır. CHB-MIT veri kümesi, pediatrik hastalardan alınan ve inatçı nöbetler yaşayan bireylerin EEG kayıtlarını içerir. Bu çalışmada kaynaklardaki diğer çalışmalardan farklı olarak; CHB-MIT veri kümesinde yer alan farklı sayıdaki (8/12/20) hasta verileriyle çalışılmış olup, oluşturulan veri kümeleri üzerinde bu çalışmada önerilen “gelişmiş” ve “temel etiketlendirme” yöntemleri kullanılarak üç-sınıf sınıflandırma (nöbet öncesi/nöbet sırası/nöbet olmayan) gerçekleştirilmiştir. Sınıflandırma problemi için ResNet50, ResNet101, VGG16, InceptionV3, Xception ve DenseNet121 modelleri kullanılmıştır. CHB-MIT veri kümesi üzerinde gerçekleştirilen çoklu sınıflandırma (üç-sınıf sınıflandırma) ve etiketleme yaklaşımları kaynaklarda yer almayıp, bu çalışma ile ilk kez kazandırılmıştır. Çalışma kapsamında gerçekleştirilen deneysel çalışmaları içeren kaynak kodları GitHub üzerinde [4] erişime açık olarak sunulmuştur.

1.2 Organizasyon

Çalışmanın ikinci bölümünde kaynaklarda yer alan ve CHB-MIT veri kümesi üzerinde epilepsi tespiti yapan çalışmalar verilmiştir. Üçüncü bölümde ise bu çalışmada önerilen tespit modeli kapsamlı olarak sunulmuştur. Dördüncü bölümde çalışmada gerçekleştirilen deneysel sonuçlar verilmiş olup, son bölümde ise elde edilen sonuçlar değerlendirilerek ileriki çalışmalardan bahsedilmiştir.

2. İlgili Çalışmalar

Kaynaklarda makine öğrenmesi ve derin öğrenme temelli, EEG sinyalleri üzerinden epileptik nöbet tespiti amaçlı birçok çalışma yer almaktadır. Bu çalışmalar arasında özellikle CHB-MIT veri kümesini kullanan çalışmalar ele alınmış olup ayrıntılı biçimde incelenmiştir.

Esmailpour ve ark. 2024 yılındaki çalışmalarında [5], çok katmanlı CNN (Convolutional Neural Network-Konvolüsyonel Nöron Ağı) tabanlı ikili sınıflandırma modeli ile nöbet

olmayan/nöbet öncesi dönem tespitini amaçlamışlardır. Çalışmada, CHB-MIT veri kümesinde yer alan 20 hasta kullanılmıştır. Veriler üzerinde bazı ön işleme adımları uygulanmıştır, bunlar; 30 saniyelik örtüşmeyen bölütleme (segmentleme), frekans-zaman analizi için Fourier dönüşümü ve sinyallerin gürültüden arınması için 50-60 Hz bant geçiren filtrelemedir. Çalışmada en yüksek duyarlık oranı %90,76 olarak elde edilmiştir.

Georgis-Yap ve ark. 2024 yılındaki çalışmalarında [6], denetimli nöbet tahmin yöntemlerinin nöbet öncesi dönemi tespit etmekte zorlanmasına değinerek denetimsiz nöbet tahmin yöntemleri önermişlerdir. CNN, CNN-LSTM ve TCN olmak üzere üç farklı model üzerinde eğitim gerçekleştirerek nöbet olmayan/nöbet öncesi dönemi tespit etmeyi amaçlamışlardır. STFT (Short Time Fourier Transform - Kısa Süreli Fourier Dönüşümü) ile EEG sinyal verilerini zaman-frekans alanına dönüştürmüşlerdir. Veriler üzerinde değişken segment boyutları (5-10-15-30-60 sn) ve nöbet öncesi dönem aralıkları (30-60-120 dk) olarak belirlemişlerdir. Modeller CHB-MIT veri kümesinde bulunan 23 hasta özelinde uygulanmış ve keskinlik-duyarlılık eğrisi (0.104 ile 1.000) arasında elde edilmiştir.

Xia ve ark. 2024 yılındaki çalışmalarında [7], nöbetinin tahminini gerçekleştirmek amacıyla nöbet olmayan/nöbet öncesi dönem ayrımını yapabilen melez bir LSTM-Transformer modeli önermişlerdir. Çalışmalarında CHB-MIT veri kümesinde bulunan 15 hastayı ve verilerde ortak olan 18 kanalı kullanmışlardır. Ham veriyi 30 saniyelik örtüşmeyen bölütlere bölmüşlerdir. Hat gürültüsünü kaldırmak amacıyla 57-63 Hz ve 117-123 Hz aralığındaki değerleri filtrelemişlerdir. STFT kullanarak EEG sinyallerinden zaman-frekans özelliklerini çıkarmışlardır. Geliştirilen en iyi modelde her bir hasta özelinde %99,75 duyarlık oranı elde edilmiştir.

Singh ve Malhotra 2022 yılındaki çalışmalarında [8], çok kanallı EEG sinyallerini kullanarak LSTM tabanlı model kullanarak epilepsi nöbet tahmin modeli geliştirmişlerdir. Tahmin modeli, CHB-MIT veri kümesinde nöbet olmayan/nöbet öncesi dönemleri ikili sınıflandırmayı hedefler. Ön işlemede filtreleme olarak Butterworth ile düşük ve yüksek kesme frekansı uygulanmış sinyaller gürültüden arındırılmıştır. EEG segmentasyon yöntem ile sinyal verilerini 5 ile 50 saniye arasında değişen çerçevelere bölmüşlerdir. Hızlı Fourier Dönüşümü kullanarak kanalların daha iyi yorumlanabilmesi için 5 frekans bandına ayrılmasını sağlamışlardır. Bir ve iki katmanlı LSTM (1L-LSTM, 2L-LSTM) modeli kullanılmıştır. Geliştirdikleri iki farklı LSTM modelini veri kümesinde bulunan 23 farklı hasta için uygulayarak elde ettikleri doğruluk ve F1-skorları 1L-LSTM modeli için sırasıyla; %97,34 ve %97,20, 2L-LSTM modeli için; %98,14 ve %98,23'tür.

Aslam ve ark. 2022 yılındaki çalışmalarında [9], EEG verilerini kullanarak nöbet öncesi dönemi dikkate alan ve hastaya özel nöbet tahmini yapmayı amaçlamışlardır. Özellik çıkarımı için CNN modeli, sınıflandırma için LSTM modelleri kullanılmıştır. Ön işleme adımı sinyal verilerine hat gürültüsü ve yüksek geçiş filtresi uygulamışlardır. CHB-MIT veri kümesinde yer alan verileri 30 saniyelik bölütlere bölmüşlerdir. Nöbet öncesi

verileri artırmak amacıyla bölütlerin yarısı örtüşecek şekilde ayrılmıştır. STFT kullanılarak zaman-frekans alanına dönüşüm yapılarak spektrogramlar elde edilmiştir. Spektrogramlar CNN modeline girdi olarak verilerek özellik çıkartımı gerçekleştirmişlerdir. LSTM modelini elde edilen özelliklerle besleyerek nöbet olmayan ve nöbet öncesi dönemleri sınıflandırmışlardır. Önerdikleri yöntem ile elde edilen en iyi doğruluk ve duyarlık oranları sırasıyla %94 ve %93,8'dir.

Jemal ve ark. 2022 yılındaki çalışmalarında [10], EEG verilerini FBCSP (Filter Bank Common Spatial Pattern- Filtre Bankası Ortak Uzamsal Desen) değerler dizisine [11] dayandırarak ilgili sinyal özelliklerini çözmek ve görselleştirmek için kullanılan bant geçiş ve uzamsal filtrelerle benzer konvolüsyonel katmanlara sahip çok katmanlı CNN önermişlerdir. Nöbet olmayan ve nöbet öncesi dönem ayrımı sağlayarak erken nöbet teşhisi sağlayabilen CNN tabanlı ikili sınıflandırma modeli önermişlerdir. Modelde hasta özeli ve çapraz hasta (cross subject) tahminleri gerçekleştirilmiştir. Önerilen en başarılı nöron ağı modeli ile CHB-MIT veri kümesindeki 23 hasta özelinde ortalama F1-sonucu ve duyarlık ölçüleri için sırasıyla; %91,9 ve %96,1, çapraz hasta için ise aynı ölçülerle sırasıyla; %65,84 ve %67,17 başarımları elde edilmiştir.

Xu ve ark. 2022 yılındaki çalışmalarında [12], EEG verileri üzerinde tek ve çoklu kanallarla çalışarak epilepsi nöbeti öncesi tahmini amaçlamışlardır. CHB-MIT veri kümesinde bulunan hastaların hepsinde ortak elektrot yerleştirmeleri bulunmadığı için sadece ortak olanlardan 7 hastayı kullanmışlardır. Veri manipülasyonu için DCWGAN'ı kullanarak çok kanallı EEG sinyallerini sentezleyip yapay veri örnekleri oluşturmuşlardır. Elde edilen verilerle nöbet öncesi ve nöbet olmayan durum arasındaki ikili sınıflandırmayı sağlayacak olan çok katmanlı CNN modeli oluşturmuşlardır. Önerilen en iyi CNN modelini her bir hasta özelinde uygulamışlardır. Ortalama olarak en iyi doğruluk oranını veri manipülasyonu yapılan ve yapılmayan denemeler olmak üzere 4 farklı doğruluk sonucunu sırasıyla; %73,0, %76,8, %77,8 ve %78,0 olarak elde etmişlerdir.

Yukarıda verilen güncel kaynak çalışmaları değerlendirildiğinde; bazı çalışmaların CHB-MIT veri kümesindeki tüm hastaları kullanmadığı, bazılarının ise hasta özeline ait çalışmalar yaptığı görülmüştür. Ayrıca kaynak yayınlarda yer alan bu çalışmaların tamamı sadece ikili sınıflandırma gerçekleştiren modellerin tasarımı üzerinedir. Bu çalışmada literatürdeki diğer çalışmalardan farklı olarak; CHB-MIT veri kümesinde yer alan farklı sayıdaki (8/12/20) hasta verileriyle çalışılmış olup, veri kümeleri üzerinde yine bu çalışmada önerilen "gelişmiş" ve "temel etiketlendirme" yöntemleri ile üçlü sınıflandırma gerçekleştirilmiştir. CHB-MIT veri kümesi üzerinde gerçekleştirilen üçlü sınıflandırma ve yeni etiketleme yaklaşımları literatürde yer almayıp, bu çalışma ile ilk kez literatüre kazandırılmıştır.

3. Önerilen Epilepsi Tespit Modelleri

Bu çalışma kapsamında CHB-MIT veri kümesinde yer alan hastalar kullanılarak farklı epilepsi tespit modelleri önerilmiştir. Modellere ait ayrıntılı bilgiler aşağıdaki alt bölümlerde sunulmuştur.

3.1 Veri Kümesi

Bu çalışmada, CHB-MIT veri kümesi kullanılmıştır. Bu veri kümesine ait kapsamlı bilgiler Çizelge 1'de sunulmuştur.

Boston Çocuk Hastanesi'nde toplanan veriler, zorlu nöbetleri olan pediatrik hastaların EEG kayıtlarından oluşmaktadır. Nöbetlerini karakterize etmek ve cerrahi müdahaleye adaylıklarını değerlendirmek amacıyla, nöbet önleyici ilacın kesilmesinden sonra hastalar birkaç güne kadar izlenmiştir. Kayıtlar 23 vaka halinde gruplandırılmış ve 22 denekten toplanmıştır (5 erkek, yaşları 3-22; 17 kadın, yaşları 1,5-19). Her vaka (chb01, chb02, vb.) tek bir hastadan 9 ila 42 arasında sürekli .edf dosyası içermektedir. Tüm sinyaller 16 bit çözünürlükte saniyede 256 örnekle örneklenmiştir. Dosyaların büyük bir kısmı 23 EEG sinyali içerir (birkaç durumda 24 veya 26). Bu kayıtlar için Uluslararası 10-20 EEG elektrot konumları ve isimlendirme sistemi kullanılmıştır.

Çizelge 1'de CHB-MIT veri kümesinde yer alan hastalara ait ayrıntılı bilgiler verilmiştir.

Çizelge-1: CHB-MIT Veri Kümesi [13]

Hasta ID	Cinsiyet	Yaş	Toplam Nöbet Sayısı	Kanal Sayısı (Min-Max)	Toplam Kayıt Süresi (saat:dk:sn)
chb01	K	11	7	(23)	40:33:08
chb02	E	11	3	(23)	35:15:59
chb03	K	14	7	(23)	38:00:06
chb04	E	22	4	(23)	156:03:54
chb05	K	7	5	(23)	39:00:10
chb06	K	1.5	10	(23)	66:44:06
chb07	K	14.5	3	(23)	67:03:08
chb08	E	3.5	5	(23)	20:00:23
chb09	K	10	4	(23-24)	67:52:18
chb10	E	3	7	(23)	50:01:24
chb11	K	12	3	(23)	34:47:37
chb12	K	2	27	(23-24)	20:41:40
chb13	K	3	12	(18-23)	33:00:00
chb14	K	9	8	(23)	26:00:00
chb15	E	16	20	(26-33)	40:00:36
chb16	K	17	10	(18-23)	19:00:00
chb17	K	12	3	(18-23)	21:00:24
chb18	K	18	6	(18-23)	35:38:05
chb19	K	19	3	(18-23)	29:55:46
chb20	K	6	8	(23)	27:36:06
chb21	K	13	4	(23)	32:49:49
chb22	K	9	3	(23)	31:00:11
chb23	K	6	7	(23)	26:33:30
chb24	-	-	16	(23)	21:17:47

Bu çalışma kapsamında orijinal veri kümesi üç farklı şekilde ele alınmıştır: İlk versiyonda 8, ikinci versiyonda 12, üçüncü versiyonda ise 20 hasta ile çalışılmıştır. Bu veri kümesi versiyonlarına ait bilgiler Çizelge 2'de sunulmuştur.

Çizelge-2: Çalışma Kapsamında Oluşturulan Alt Veri Kümesi Çeşitleri

Veri Kümesi Versiyon	Hasta ID	Toplam Nöbet Sayısı	Kanal Sayısı	Toplam Nöbet Süresi (sn)
Versiyon1 (8 hasta)	chb01	7	23	442
	chb03	6	23	502
	chb05	1	23	557
	chb08	4	23	729
	chb18	6	23	317
	chb19	3	23	236
	chb21	3	23	143
	chb22	3	23	207
Versiyon2 (12 hasta)	chb01	7	23	442
	chb03	6	23	502
	chb05	1	23	557
	chb08	4	23	729
	chb10	7	23	437
	chb11	3	23	816
	chb17	3	23	293
	chb18	6	23	317
	chb19	3	23	236
	chb21	3	23	143
	chb22	3	23	207
	chb24	9	23	339
Versiyon3 (20 hasta)	chb01	7	23	442
	chb02	3	23	171
	chb03	6	23	502
	chb05	5	23	592
	chb07	3	23	325
	chb08	4	23	729
	chb09	2	23	126
	chb10	7	23	437
	chb11	3	23	816
	chb13	5	23	215
	chb14	6	23	127
	chb15	8	23	1309

	chb17	3	23	293
	chb18	6	23	317
	chb19	3	23	236
	chb20	4	23	141
	chb21	3	23	143
	chb22	3	23	207
	chb23	1	23	113
	chb24	9	23	339

3.2 Veri Önileme


Çalışma kapsamında kullanılan veri önileme adımları aşağıdaki alt başlıklarda ayrıntılı olarak sunulmuştur.

3.2.1 Spektrogram Görüntülerinin Elde Edilmesi

Bu çalışma kapsamında kullanılan model girdileri için EEG sinyallerinin dönüştürülmüş spektrogram görüntüleri kullanılmıştır. Bu görüntüler oluşturulurken sırasıyla aşağıdaki alt adımlar uygulanmıştır:

- Adım 1: EEG sinyallerinde yer alan gürültülerin Butterworth filtresi [14] ile temizlenmesi,
- Adım 2: Veri kümesinde hasta kayıtlarında yer alan 23 kanalın her biri için ayrı ayrı FFT (Fast Fourier transform-Hızlı Fourier Dönüşümü) [15] uygulanması ve sonrasında her kanal için ayrı ayrı spektrogram görüntülerinin oluşturulması,
- Adım 3: Oluşturulan spektrogramların üst üste eklenerek tek bir görüntü haline getirilmesi.

Adım 1’de EEG sinyallerinde yer alan gürültüler temizlenirken, Butterworth filtresinde yüksek frekans 50 Hz, düşük frekans ise 1 Hz seçilmiştir. Şekil-1’de veri kümesinde yer alan chb12 isimli hastanın 11. kaydındaki sinyalin Butterworth filtresinden (yüksek 50 Hz, düşük 1 Hz) geçirilmiş hali verilmiştir.



Şekil-1: Butterworth filtresi uygulanmış örnek sinyal görüntüsü (chb12 hastası 11. kayıt)

Temizlenmiş sinyalleri içeren kayıtların model girdileri 23 kanal içermektedir. Bu 23 kanalın her biri beynin farklı bir bölgesinden gelen 23 sinyalin zamana göre yerleştirilmesinden oluşmaktadır. Adım 2’de bu kayıtlardan görüntü elde edilmesi için her görüntünün kapsayacağı alan 4 saniyelik pencere olarak belirlenmiştir. Bu 4 saniyelik pencereler birer saniye kaydırılarak ardışık pencere görüntüleri oluşturulmuştur. Her bir kayıt parçasına ait bu görüntülere ait spektrogramlar FFT dönüşümü kullanılarak oluşturulmuştur.


FFT dönüşümü, sinyalleri zaman alanından frekans alanına dönüştürmek için sisteme uygulanır. FFT dönüşüm formülü Denklem (1)’de verilmiştir:

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j(\frac{2\pi}{N})kn} \quad (1)$$

Burada $X[k]$ frekans alanındaki ayırık sinyali, $x[n]$ ise zaman alanındaki ayırık sinyali temsil etmektedir.

Tek bir FFT işlemi, 1 boyutlu bir frekans spektrumu ortaya çıkarırken, art arda gerçekleştirilen FFT uygulamaları sinyalin zaman-frekans çözümlemesini yaparak 2 boyutlu bir spektrogram görüntüsü oluşturur. Bu sayede sinyalin frekans içeriği zamanla nasıl değiştiği görselleştirilebilir.

Adım 3’de ise; Adım 2’de oluşturulan bu spektrogram görüntüleri veri kümesindeki kayıtlarda bulunan kanalların sırasına göre alt alta ekleme yapılarak birleştirilmiştir. Bu işlemle, model eğitiminde 23 spektrogram görüntüsünün tamamının tek bir görüntü olarak modele verilmesi sağlanmıştır. Şekil-2’de chb06 numaralı hastanın 4. saat kaydına ait örnek spektrogram görüntüsü görülmektedir.



Şekil-2: Sinyallerden elde edilen spektrogram görüntülerinin birleştirilmesi (chb06 hastasının 4. saat kaydına ait bir spektrogram)

3.2.2 Spektrogram Görüntülerinin Etiketlendirilmesi

Çalışma kapsamında elde edilen spektrogram görüntüleri etiketlenirken, literatürdeki diğer çalışmalardan farklı olarak, iki farklı etiketleme yöntemi ele alınmıştır:

- Temel etiketleme,
- Gelişmiş etiketleme

Temel etiketleme yönteminde; nöbetten önceki 20 dakika “nöbet öncesi”, nöbetin geçirildiği dakikalar “nöbet sırası”,

diğer kalan dakikalar ise “nöbet olmayan” durum olarak etiketlenmiştir.

Gelişmiş etiketlemede ise; nöbetten önceki 20 dakikayı içeren ve temel etiketlemede kaba olarak “nöbet öncesi” dönemi temsil eden her bir spektrogram görüntüsü “Doğrusallık, Ortalama, Tepe Noktaları, Nöbetten Önceki 5 Dakika” özelliklerine göre detaylı olarak değerlendirilir. Böylece nöbetten önceki 20 dakika içinde yer alan tüm spektrogram görüntülerini “nöbet öncesi” durum olarak etiketlemek yerine; daha incelikli hesaplamalarla gerçekten nöbet geçirilmeden önceki dönemin hesaplanıp etiketlenmesine odaklanılmıştır. İnce hesaplamalar sonucunda bulunan ilgili dönemler “nöbet öncesi” olarak etiketlenirken bu 20 dakikalık alanın içinde kalan diğer alanlar “nöbet olmayan” durum olarak etiketlenmiştir. Sonrasında; temel etiketlemedeki gibi nöbetin geçirildiği dakikalar “nöbet sırası”, nöbet sırasından sonra kalan dakikalar ise “nöbet olmayan” durum olarak etiketlenmiştir.

Gelişmiş etiketleme için ele alınan özelliklere ait detaylı bilgiler aşağıdaki alt başlıklar verilmiştir.

3.2.2.1 Doğrusallık

EEG sinyal verilerinde “nöbet sırasını” temsil eden bölümlerde doğrusallık diğer bölümlere göre daha azdır. Epilepsi nöbeti sırasında elektrik deşarj sayısı olağandan fazla olması sinyal hareketliliğini arttırarak doğrusallığın azalmasına yol açmaktadır. “nöbet öncesi” dönemde ise doğrusallık azalmaktadır. Çalışma kapsamında ilgili spektrogram bölümü etiketlenirken aynı bölümün sinyal verileri üzerinde doğrusallık oranı çıkarılmıştır.

Doğrusallık hesaplamasında ilk adımda Welch [16] yöntemi ile sinyallerin güç spektral yoğunluğu hesaplanır. Güç spektral yoğunluğu hesaplaması formülü Denklem (2)’de verilmiştir.

$$PSD_i(f) = \frac{1}{\Delta f \cdot M} |FFT\{x_i(t) \cdot w_i(t)\}|^2 \quad (2)$$

İkinci adımda elde edilen güç spektral yoğunlukları için Shannon Entropisi [17] hesaplaması yapılır. Hesaplama sonucunda ilgili verinin rastgeleliği ve belirsizliği ölçülerek oran elde edilir. Shannon Entropisi hesaplamasının formülü Denklem (3)’de verilmiştir.

$$H(X) = - \sum_{i=1}^n p(x_i) \cdot \log p(x_i) \quad (3)$$

Her bir spektrogram görüntüsü için elde edilen bu oranlara 0 ila 1 arasında normalizasyon uygulanmıştır. Normalizasyon sonucunda elde edilen doğrusallık oranı %80 (0,8)’den az olan bölümler “nöbet öncesi” dönem olarak etiketlenmiştir.

3.2.2.2 Ortalama

Çalışma kapsamında kullanılan veri kümesinde EEG sinyal verileri gerilim (volt) cinsinden verilmiştir. Her bir spektrogramın elde edildiği bölümün sinyal aralıkları 4 saniyede toplam 512 Hz örnekleme (nokta sinyal verisi) sahiptir. Her bir nokta sinyal verisinin de artı/eksi gerilim değeri bulunmaktadır. Bu çalışmada önerilen ortalama yönteminde nöbet durumundan önceki 20 dakikada bulunan gerilim değerlerinin mutlak değer cinsinden ortalaması alınarak elde edilen bu değer genel ortalama değer olarak

belirlenmektedir. Her bir spektrogram bölümünün sinyal aralıklarında bulunan 512 gerilim değerinin ortalaması alınıp genel ortalama değeri ile karşılaştırılmaktadır. Eğer ilgili sinyal aralığından elde edilen ortalama gerilim değeri; genel ortalama değerden yüksek bir değere sahipse “nöbet öncesi” durumunu temsil etmesine karar verilmektedir.

3.2.2.3 Tepe Noktaları

Tepe noktaları bir sinyalin olağandan mutlak yükseklikte gerilim değerine ulaşması durumunda adlandırılan noktalar. EEG sinyallerinde anormal aktiviteleri sinyallerin ani tepe noktalarını görmesiyle bağdaştırılabilir. Tepe noktalarının arka arkaya olan sıklığı hem doğrusallıktan uzak olduğunu hem de anormal aktivitenin olduğunu göstermektedir. Nöbet döneminde anormal aktiviteler fazla iken, nöbet öncesi dönemlerde de anormal aktiviteler sonucunda ani yükselişler ile tepe noktaları elde edilebilmektedir. Nöbetten önceki dakikalarda tepe noktalarının sıklığı nöbetin geleceğini ifade edebilir. Bu çalışmada önerilen tepe noktaları yönteminde; her bir spektrogramın ilgili sinyal aralıklarında arka arkaya tekrarlayan (10 değer) tepe noktaları var ise “nöbet öncesi” dönem olarak değerlendirilir.

3.2.2.4 Nöbetten Önceki 5 Dakika

Çalışma kapsamında kaynak yayınlarda bulunan bazı çalışmalar [18, 19] SPH (Seizure Prediction Horizon - Atak Tahmin Dönem) “nöbet öncesi” dönem ile “nöbet sırası” arasında bulunan bir ara dönem olarak tanımlamışlardır. Bu çalışmada; SPH ara dönemi kat sayısı (ağırlığı) artırılarak nöbet döneminin tahmininin artırılması hedeflenmiştir. Önerilen son 5 dakika yönteminde, nöbet döneminden önceki 5 dakikanın “nöbet öncesi” dönem olarak etiketlenmesi için ağırlık değeri verilmiştir. Verilen ağırlık değeri, diğer 3 özellik (doğrusallık, ortalama, tepe noktaları) ile ilişkilendirilerek ilgili spektrogram bölümünün “nöbet öncesi” veya “nöbet olmayan” durum olarak etiketlenmesi sağlanır. İlişkilendirme ile ilgili diğer özelliklerin etiketleme için gereken eşik değerleri bu özellikte belirlenen sabit bir ağırlık değerine göre güncellenir. Çalışma süresince sabit ağırlık değeri (0,2-%20) olarak belirlenmiş olup ilgili veri kümesine dayanarak verilmiştir.

4. Deneysel Sonuçlar

Bu çalışma kapsamında CHB-MIT veri kümesi üzerinde üçlü sınıflandırma modelleri kurulmuş olup sınıflandırma etiketleri “nöbet öncesi/nöbet sırası/nöbet olmayan” olarak belirlenmiştir. Çalışma kapsamında önerilen temel ve gelişmiş etiketleme yöntemleri kullanılarak bu etiketleme yöntemlerinin başarımları gözlemlenmiştir.

Spektrogram görüntüleri ve etiketlerinden oluşturulan farklı versiyonlardaki veri kümeleri (Bknz. Çizelge-2) için ResNet50, ResNet101, VGG16, InceptionV3, Xception ve DenseNet121 ana modelleri kullanılmıştır. Modeller kurulurken aynı zamanda ezberleme probleminin yaşanmaması için ana model mimarilerine basit ek model CNN mimarileri (Conv2D-64, Conv2D-128, Conv2D-256) eklenerek farklı boyutlarda,

farklı epoch ve batch büyüklüğü verilerek model eğitimleri gerçekleştirilmiştir. Çalışma kapsamında her bir modele ait elde edilen deneysel sonuçlar Çizelge-3’de verilmiştir. Temel etiketleme modeli kaba kaldığından Çizelge-3’den de görüleceği gibi, Versiyon2 ve Versiyon3 veri kümelerinde sadece gelişmiş etiketleme yöntemi kullanılmıştır. Ayrıca çalışma kapsamında Çizelge-3’de verilen her bir model için kullanılan hiper parametre özellikleri Çizelge-4’de kapsamlı olarak sunulmuştur.

Çizelge-3’den de görüleceği gibi; F1-sonuç, kesinlik, duyarlık ve doğruluk ölçüleri için sırasıyla %85,52, %85,88, %85,33, %84,87 değerleri ile en başarılı model, Versiyon3 veri kümesi üzerinde gelişmiş etiketleme yöntemi kullanılarak oluşturulan DenseNet121 (+Conv2D-64, Conv2D-128, Conv2D-256) modeli olmuştur. DenseNet daha az parametre ve hesaplama gerektirirken nesne tanıma görevlerinde geliştirilen son modellere göre daha verimli çalışır [20]. Bu nedenle, bu çalışma kapsamında kullanılan diğer modeller arasında; ek model yapısı ile desteklenmesi ve gelişmiş etiketleme yönteminin de katkısı ile DenseNet121 modelinin en iyi başarımları üretmesi beklenen bir durumdur.

Kaynak yayınlarda CHB-MIT veri kümesi üzerinde ikili sınıflandırma problemine odaklanan model başarımları; bu çalışmada önerilen üçlü sınıflandırma model başarımlarına oranla daha yüksek olduğu açıktır. Ancak üçlü sınıflandırma problemi ikili sınıflandırma problemine göre çok daha zorlu bir problemdir. Üçlü sınıflandırma probleminde ikili sınıflandırmadan farklı olarak; özellikle “nöbet olmayan” ve “nöbet öncesi” dönemlere ait spektrogram görüntüleri birbirine çok benzerdir. Bu benzerliğin temel nedeni; “nöbet öncesi” dönemde “nöbet sırası” döneme göre sinyallerdeki pik sayısı ve şiddeti daha azdır. Bu da “nöbet öncesi” dönem ile “nöbet olmayan” dönem sinyallerinin birbirine benzemesine/karışmasına yol açar. Bu da ikili sınıflandırma problemine oranla üçlü sınıflandırma probleminin çok daha zorlu bir problem olduğunu kanıtlar. Bu nedenle bu çalışma kapsamında ilk kez önerilen üçlü sınıflandırma sonuçları değerlidir.

5. Sonuç ve İleriki Çalışmalar

Bu çalışmada CHB-MIT veri kümesi üzerinde daha önce kaynaklarda çalışılmamış bir problem olan üç sınıflandırma (nöbet öncesi/nöbet sırası/nöbet olmayan) problemi üzerine çalışılmıştır. Çalışma kapsamında ana veri kümesi üzerinden oluşturulan versiyon veri kümeleri ve iki farklı etiketleme yöntemiyle farklı sınıflandırma modelleri kullanılarak model başarımları karşılaştırılmıştır. Deneysel sonuçlar incelendiğinde en başarılı model olan DenseNet121 (+Conv2D-64, Conv2D-128, Conv2D-256) modeli F1-skor, kesinlik, hassasiyet ve doğruluk skorları sırasıyla %85,52, %85,88, %85,33, %84,87 elde edilmiştir.

İleriki çalışmalarda çoklu sınıflandırmalar için sadece etikete bağlı olmamakla beraber farklı derin öğrenme modellerinin kullanımıyla beraber daha yüksek başarımlarına sahip modellerin geliştirilmesi hedeflenmektedir.

Çizelge-3: CHB-MIT Veri Kümesi Üzerinde Ön İşleme Sonrası Elde Edilen Görüntüler Üzerinde Üç-Sınıf Sınıflandırma (Nöbet Öncesi/Nöbet Sırası/Nöbet Olmayan) Model Başarımları

Ana Model	Ek Model Yapısı	Etiket	Veri Kümesi Versiyon	Başarım Metrikleri			
				F-Skor (F1)	Kesinlik (Precision)	Hassasiyet (Recall)	Doğruluk (Accuracy)
ResNet50	Conv2D-64 Conv2D-64	Temel	Versiyon1	%79.83	%80.30	%79.55	%78.97
ResNet101	Conv2D-64 Conv2D-128	Temel	Versiyon1	%81.32	%81.91	%80.95	%80.74
ResNet101	Conv2D-128 Conv2D-64	Gelişmiş	Versiyon2	%82.90	%83.24	%82.67	%81.88
VGG16	Conv2D-64 Conv2D-128	Gelişmiş	Versiyon2	%76.27	%77.20	%75.70	%75.16
ResNet101	Conv2D-64 Conv2D-256	Gelişmiş	Versiyon3	%82.98	%83.18	%82.89	%83.03
InceptionV3	Conv2D-64 Conv2D-128 Conv2D-256	Gelişmiş	Versiyon3	%84.63	%84.88	%84.70	%84.55
Xception	Conv2D-64 Conv2D-128 Conv2D-256	Gelişmiş	Versiyon3	%81.47	%81.73	%81.45	%80.52
DenseNet121	Conv2D-64 Conv2D-128 Conv2D-256	Gelişmiş	Versiyon3	%85.52	%85.88	%85.33	%84.87

Çizelge-4: Her Bir Model İçin Kullanılan Hiper Parametreler

Ana Model	Ek Model Yapısı	Hiper Parametreler
ResNet50	Conv2D-64 Conv2D-64	Epoch = 25, Batch Büyüklüğü = 8, Öğrenme Oranı = 0.001, Optimizasyon Fonksiyonu = Adam, Aktivasyon Fonksiyonu = Relu/Softmax
ResNet101	Conv2D-128 Conv2D-64	Epoch = 20, Batch Büyüklüğü = 8, Öğrenme Oranı = 0.001, Optimizasyon Fonksiyonu = Adam, Aktivasyon Fonksiyonu = Relu/Softmax
ResNet101	Conv2D-128 Conv2D-64	Epoch = 50, Batch Büyüklüğü = 16, Öğrenme Oranı = 0.005, Optimizasyon Fonksiyonu = Adam, Aktivasyon Fonksiyonu = Relu/Softmax
VGG16	Conv2D-64 Conv2D-128	Epoch = 40, Batch Büyüklüğü = 16, Öğrenme Oranı = 0.001, Optimizasyon Fonksiyonu = Adam, Aktivasyon Fonksiyonu = Relu/Softmax
ResNet101	Conv2D-64 Conv2d-256	Epoch = 25, Batch Büyüklüğü = 8, Öğrenme Oranı = 0.001, Optimizasyon Fonksiyonu = Adam, Aktivasyon Fonksiyonu = Relu/Softmax
InceptionV3	Conv2D-64 Conv2D-128	Epoch = 40, Batch Büyüklüğü = 16,

	Conv2D-256	Öğrenme Oranı = 0.001, Optimizasyon Fonksiyonu = Adam, Aktivasyon Fonksiyonu = Relu/Softmax
Xception	Conv2D-64 Conv2D-128 Conv2D-256	Epoch = 40, Batch Büyüklüğü = 16, Öğrenme Oranı = 0,001, Optimizasyon Fonksiyonu = Adam, Aktivasyon Fonksiyonu = Relu/Softmax
DenseNet121	Conv2D-64 Conv2D-128 Conv2D-256	Epoch = 40, Batch Büyüklüğü = 8 , Öğrenme Oranı = 0,001, Optimizasyon Fonksiyonu = Adam, Aktivasyon Fonksiyonu = Relu/Softmax

Teşekkür

Bu çalışma TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında 1919B012327866 numaralı proje kapsamında desteklenmiştir.

Kaynakça

- [1] WHO. World Health Organization: epilepsy: epidemiology, aetiology and prognosis, WHO factsheet, 2001.
- [2] Fisher, R. S., Boas, W. V. E., Blume, W., Elger, C., Genton, P., Lee, P., & Engel Jr, J. Epileptic seizures and epilepsy: definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE), *Epilepsia*, 2015, 46.4, pp. 470-472.
- [3] Shueb, A. H. Application of machine learning to epileptic seizure onset detection and treatment (Doctoral dissertation, Massachusetts Institute of Technology), 2009.
- [4] CHB-MIT-Scalp-EEG-Seizure-Classification, <https://github.com/erencalbay/CHB-MIT-Scalp-EEG-Seizure-Classification>, Erişim Tarihi: 31.07.2024.
- [5] Esmaeilpour, A., Tabarestani, S. S., & Niazi, A. Deep learning-based seizure prediction using EEG signals: A comparative analysis of classification methods on the CHB-MIT dataset, *Engineering Reports*, 2024, e12918.
- [6] Georgis-Yap, Z., Popovic, M. R., & Khan, S. S. Supervised and Unsupervised Deep Learning Approaches for EEG Seizure Prediction. *Journal of Healthcare Informatics Research*, 2024, pp. 1-27.
- [7] Xia, L., Wang, R., Ye, H., Jiang, B., Li, G., Ma, C., & Gao, Z. Hybrid LSTM-Transformer model for the prediction of epileptic seizure using scalp EEG. *IEEE Sensors Journal*. 2024.
- [8] Singh, K., & Malhotra, J. Two-layer LSTM network-based prediction of epileptic seizures using EEG spectral features. *Complex & Intelligent Systems*, 2022, pp. 2405-2418
- [9] Aslam, M. H., Usman, S. M., Khalid, S., Anwar, A., Alroobaea, R., Hussain, S., ... & Yasin, A. Classification of EEG signals for prediction of epileptic seizures. *Applied Sciences*, 12(14), 2022, pp. 7251.
- [10] Jemal, Imene, et al. An interpretable deep learning classifier for epileptic seizure prediction using EEG data, *IEEE Access* 10, 2022, pp. 60141-60150.
- [11] Ang, Kai Keng, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface, 2008 IEEE international joint conference on neural networks (IEEE world congress on computational intelligence) IEEE, 2008.
- [12] Xu, Yankun, Jie Yang, and Mohamad Sawan. Multichannel synthetic preictal EEG signals to enhance the prediction of epileptic seizures. *IEEE Transactions on Biomedical Engineering* 69.11, 2022, pp. 3516-3525.
- [13] Jumaah, Mahmood A., Ammar Ibrahim Shihab, and Akeel Abdulkareem Farhan. Epileptic Seizures Detection Using DCT-II and KNN Classifier in Long-Term EEG Signals. *Iraqi Journal of Science*, 2020, pp. 2687-2694.
- [14] Butterworth, S. On the theory of filter amplifiers. *Wireless Engineer*, 7(6), 1930, pp. 536-541.
- [15] Duhamel, P., & Vetterli, M. Fast Fourier transforms: a tutorial review and a state of the art. *Signal processing*, 19(4), 1990, 259-299.
- [16] Barbe, K., Pintelon, R., & Schoukens, J. Welch method revisited: nonparametric power spectrum estimation via circular overlap. *IEEE Transactions on signal processing*, 58(2), 2009, pp. 553-565.
- [17] Lin, J. Divergence measures based on the Shannon entropy. *IEEE Transactions on Information theory*, 37(1), 1991, pp. 145-151.
- [18] Jiang, X., Liu, X., Liu, Y., Wang, Q., Li, B., & Zhang, L. Epileptic seizures detection and the analysis of optimal seizure prediction horizon based on frequency and phase analysis. *Frontiers in Neuroscience*, 17, 2023, 1191683.
- [19] Shokouh Alaei, H., Khalilzadeh, M. A., & Gorji, A. Optimal selection of SOP and SPH using fuzzy inference system for on-line epileptic seizure prediction based on EEG phase synchronization. *Australasian physical & engineering sciences in medicine*, 42, 2019, pp. 1049-1068.
- [20] Huang, G., Liu, Z., Pleiss, G., Van Der Maaten, L., & Weinberger, K. Q. Convolutional networks with dense connectivity. *IEEE transactions on pattern analysis and machine intelligence*, 44(12), 2019, pp. 8704-8716.