

A Convolutional Neural Network Using Raw EEG Signal Obtained from Single Channel for Automatic Sleep Staging

 Gökse Zekiye ÖZEN¹,  Rayimbek SULTANOV²,  Yunus ÖZEN³,  Zahide YILMAZ GÜNEŞ⁴

¹Corresponding Author; Computer Engineering Department, Kyrgyz–Turkish Manas University, Bishkek, Kyrgyzstan; goksu@goksu.info; <https://orcid.org/0000-0001-7033-0126>; +902623433393

²Computer Engineering Department, Kyrgyz–Turkish Manas University, Bishkek, Kyrgyzstan; rayimbek.sultanov@manas.edu.kg; <https://orcid.org/0000-0001-8802-8021>

³Vocational School Department of Computer Technologies, Yalova University, Yalova; yunus.ozen@yalova.edu.tr; <https://orcid.org/0000-0003-3225-8797>

⁴Derince Education and Research Hospital, Clinic of Neurology, Kocaeli; yilmazzahide@hotmail.com; <https://orcid.org/0000-0001-6948-9324>

Received 4 May 2020; Revised 07 August 2020; Accepted 12 August 2020; Published online 28 August 2020

Abstract

Sleep stages are determined firstly for the evaluation of sleep quality and the diagnosis of sleep diseases. The signals, recorded from sensors connected to various parts of the body, such as electroencephalogram (EEG), electrocardiogram (ECG), electrooculogram (EOG) and electromyogram (EMG) are used for this purpose. After the production of affordable wearable EEG devices for individual use, studies have begun to detect sleep stages from a single channel EEG signal. This paper presents an automated system that can perform sleep staging using a single-channel raw EEG signal. A Convolutional Neural Network (CNN) model was trained with the raw EEG signal for sleep stage detection. The use of CNN does not require any feature extraction. The developed CNN model classifies the sleep data sampled at 250 Hz, divided into 30-second segments according to the 5-class sleep staging system. According to the test results, the performance of the proposed system was found to be 93% macro F1 score and 92% accuracy.

Keywords: Convolutional Neural Network, EEG, Sleep Scoring

Tek Kanallı Ham EEG Sinyali Temelli Otomatik Uyku Evrelemesi Yapan Evrişimsel Sinir Ağı

Öz

Uyku kalitesinin değerlendirilmesi ve uyku hastalıklarının teşhisi için öncelikle uyku evreleri tespit edilmektedir. Bunun için vücudun çeşitli bölgelerine bağlı sensörlerden kaydedilen elektroensefalogram (EEG), elektrokardiyogram (ECG), elektrookülogram (EOG), elektromiyogram (EMG) gibi sinyaller kullanılmaktadır. Bireysel kullanım için uygun fiyatlı giyilebilir EEG cihazlarının üretilmesi ile tek kanallı EEG sinyalinden uyku evreleri tespiti yapılabilmesi için çalışmalar başlamıştır. Bu makalede tek kanallı ham EEG sinyali kullanarak uyku evreleri tespiti yapabilen otomatik bir sistem sunulmaktadır. Bu amaçla ham EEG sinyalleri ile bir Evrişimsel Sinir Ağı (ESA) modeli eğitilmiştir. ESA kullanımı sayesinde herhangi bir özellik çıkarımı yapılmasına ihtiyaç bulunmamaktadır. Geliştirilen ESA modeli 250 Hz’de örneklenmiş, 30 sn’lik segmentlere bölünmüş uyku verisini 5 sınıflı uyku evrelemesi sistemine göre sınıflandırmaktadır. Yapılan testlerin sonuçlarına göre önerilen sistemin başarımları %93 makro F1-skoru ve %92 doğruluk olarak bulunmuştur.

Anahtar Kelimeler: EEG, Evrişimsel Sinir Ağı, Uyku Evrelemesi

1. Giriş

Uyku insan sağlığı için gerekli bir eylemdir. Uyku kalitesinin ölçülmesi ve uyku hastalıklarının tespiti için denekler uyku kliniklerinde belirli bir süre için çeşitli ölçüm aletleri bağlanarak gözetim altında uyutulurlar. Uyku uzmanları vücudun farklı bölgelerine bağlı sensörlerden kaydedilen elektriksel


aktiviteyi kullanarak uyku kalitesini değerlendirirler. Bu sensörler yardımıyla ölçülen çoklu fizyolojik sinyallere polisomnogram (PSG) denilmektedir. Bu sinyaller genellikle elektroensefalogram (EEG), elektrokardiyogram (ECG), elektrookülogram (EOG), elektromiyogram (EMG), hava akımı ve oksijen saturasyonundan (SaO₂) oluşmaktadır. PSG, uyku ile ilgili analizlerde en sık kullanılan tanı aracıdır [1]. Bununla birlikte PSG cihazları hastane ve uyku laboratuvarlarında kullanılan pahalı ve özel cihazlardır. Bu cihazlar evde kişisel kullanım için uygun değildir.

PSG ile kaydedilen sinyaller, 30 sn'lik epok adı verilen dilimlere ayrılır ve daha sonra Rechtschaffen ve Kales (R&K) [2] veya Amerikan Uyku Tıbbı Akademisi (AUTA) gibi uyku kılavuzlarına göre uzmanlar tarafından farklı uyku aşamalarına göre sınıflandırılır. AUTA tarafından yayınlanan güncel standart, dört farklı uyku evresi tanımlamaktadır. Bu evreler S1 (uyku hali), S2 (hafif uyku), S3 / SWS (yavaş dalga uyku), REM (hızlı göz hareketi uykusu) ve buna ilave olarak Uyanıklık (W) şeklinde adlandırılmaktadır. AUTA standardı, eski R&K standardının güncellenmiş sürümüdür [3]. AUTA ve R&K arasındaki dönüşüm işlemi Tablo 1'de sunulmaktadır. R&K'da yer alan S3 ve S4 evreleri AUTA'da SWS olarak birleştirilmiştir.

Tablo 1 R&K Standardının AUTA Standardına Dönüşüm Tablosu

Standart	Uyku Evreleri				
R&K	S1	S2	S3 ve S4	REM	W
AUTA	S1	S2	SWS	REM	W

Gece uykusu genellikle birbirini takip eden döngüler halinde gerçekleşmektedir. Bir uyku döngüsü yaklaşık 90 dakika sürmekte ve bu döngü S2, SWS, REM uykusunu ve ardından uyku esnasında ve gece boyunca uyarılmalardan sonra gelen S1'i içermektedir. Bir gece uykusunda bu döngü 3-5 defa tekrarlanmaktadır. Uyku evrelerinin seyri hipnogram adı verilen grafiklerle gösterilir [4]. Şekil 1'de örnek bir hipnogram görülmektedir.



Şekil 1 Örnek Bir Hipnogram Görüntüsü

PSG ölçümü esnasında deneklerin vücudunda farklı bölgelere kablolar yardımıyla çeşitli ölçüm uçları bağlanmaktadır. PSG düzeneği ölçümlerde gürültülere neden olabilmekte ve deneklerin uyku kalitesini etkilemektedir [5]. Bu nedenle, daha az fizyolojik sinyal kullanarak yapılacak bir uyku evreleme sistemine ihtiyaç duyulmaktadır. Böylece ev tabanlı uyku izleme sistemlerinin geliştirilmesi de mümkün olacaktır.

PSG kayıtlarının uzmanlar tarafından elle uyku evrelerine ayrılması işlemi hem zaman alıcı hem de yorucu bir işlemdir [6]. Bu işlemin otomatik olarak bir yazılım tarafından yapılabilmesi, daha az insan gücü kullanmayı ve daha doğru sonuçlar üretmeyi de olanaklı kılacaktır.

Uyku evreleme işleminde evrelerin tespiti için çeşitli özellikler belirlenmektedir. Doğrusal olmayan süreçlerden türetilen bu elle çıkarılan özellikler, zaman domeni [7] özelliklerinden frekans domeni [8] özelliklerine kadar çeşitlilik göstermektedir. Bu özellikleri sınıflandırmak için genellikle geleneksel makine öğrenmesi yöntemleri kullanılmaktadır [9].

Literatürde son yıllarda derin öğrenme yöntemlerinin çeşitli sınıflandırma problemlerine uygulandığı çalışmalar yer almaktadır. Uyku evrelemesi işleminde de derin öğrenme modellerinin kullanılması yaygınlaşmıştır. Derin öğrenmenin gücü verilerden otomatik özellik öğrenme yeteneğine dayanmaktadır. Bir derin öğrenme çeşidi olan Evrişimsel Sinir Ağları (ESA), sınıflandırma problemlerinde başarılı sonuçlar üretmektedir [10].

ESA modelleri bir giriş sinyaline uygulanan aynı ya da farklı boyutta, birden fazla filtre içerir. Evrişim katmanı, havuzlama katmanı, aktivasyon katmanı ve tam bağlı katman olmak üzere dört temel katmandan oluşur. Genellikle katmanlar ardışık olarak bağlanır ve her katman bir önceki katmanın çıkışını alarak bunlardan daha soyut özellik çıkarımları yapabilir. Her bir evrişim katmanındaki yüksek boyutlu özellikler havuzlama katmanı yardımıyla düşük boyutlu özelliklere dönüştürülürler. ESA'da evrişim katmanlarının sonunda sınıflandırma yapmak için tam bağlı katman olarak adlandırılan çok katmanlı bir yapay sinir ağı yer alır. Tam bağlı katmanda düşük boyutlu özellikler ile sınıflar eşleştirilerek sınıflandırma yapılır. Bu adımların gerçekleştirilmesi ile ham veriden soyut özelliklerin otomatik olarak çıkarılması mümkün olmaktadır [11].

Literatürde uyku evrelerini EEG, EOG ve EMG gibi çoklu sinyaller kullanarak otomatik olarak sınıflandıran çeşitli çalışmalar yer almaktadır. Sokolovsky vd. EEG ve EOG sinyallerini kullanarak bir ESA modeli ile otomatik uyku evrelemesi yapan bir sistem geliştirmişlerdir. Modelin makro F1-skoru %77 ve doğruluğu %81 olarak bulunmuştur [12]. Bununla birlikte tek kanallı EEG sinyalleri kullanarak da benzer bir doğruluk başarımına sahip çalışmalar bulunmaktadır. Bu çalışmaların bazılarında geleneksel makine öğrenmesi yöntemleri tercih edilmiştir ve başarımı çok kanallı çalışmalardan düşük değildir. Ghimatgar vd. tarafından yapılan çalışmada tek kanallı EEG sinyali kullanarak bir özellik seçici yöntemiyle uyku epoklarından elle özellik çıkarımı yapılmış, bir makine öğrenmesi yöntemi olan rassal orman sınıflandırıcı ile veri sınıflandırılmıştır. 6 aşamalı R&K ve 5 aşamalı AUTA'ya göre modelin uyku evreleme başarımı sırasıyla en yüksek %87,4 ve %80,4 doğruluk olarak bulunmuştur [13].

Elle özellik çıkarımı yapmak yerine otomatik özellik çıkaran derin öğrenme yöntemleri kullanıldığında da önerilen modellerin başarımı düşmemiştir. Tsinalis vd. tarafından önerilen otomatik uyku evrelemesi yapan tek kanallı ham EEG sinyallerini işleyebilen ESA modeli, genel bir veriseti üzerinde %74 F1-skoru ve %81 doğrulukla evreleme yapmıştır [14]. Zhang vd. iki genel verisetinden alınan tek kanallı EEG sinyallerine Hilbert–Huang dönüşümü uygulamışlar ve 2 boyutlu zaman-frekanslı görüntüler elde etmişlerdir. Çalışmada önerilen Ortogonal ESA ile eğitilen model uyku evrelemesinde sırasıyla %88.4 ve %87.6 toplam sınıflandırma doğruluğu elde etmiştir [15]. Sors vd. tarafından yapılan çalışmada 12 evrişim katmanı ve 2 tam bağlı katmana sahip bir ESA kullanılmıştır. Etiketli ve tek kanallı ham EEG sinyalleri herhangi bir ön işleme ya da özellik seçimine gerek kalmadan sisteme verilmiştir. 5 sınıflı uyku evrelemesi yapan sistemin doğruluğu %0.81 kapa katsayısıyla, %87 olarak bulunmuştur [16]. Supratak vd. MASS ve Sleep-EDF adlı iki ayrı veriseti üzerinde sınıflandırma yapan iki aşamalı bir model geliştirmiştir. Tek kanallı EEG kullanarak EEG epoklarından özellik çıkarımı için ESA ve uyku evreleri arasındaki geçiş kurallarını öğrenmek için çift yönlü uzun-kısa dönem bellek kullanmışlardır. Modelin doğruluk ve makro F1-skoru sırasıyla MASS için %86.2 ve %81.7 olarak, Sleep-EDF için ise %82 ve %76.9 olarak bulunmuştur [6]. Karmaşık bir yöntem tercih edilmesine rağmen sunulan çalışmanın başarımı literatürdeki tek kanallı EEG kullanan çalışmalardan daha yüksek değildir.

Bu makalede sunulan çalışmada ise yine tek kanallı EEG sinyalleri kullanılarak benzer çalışmalardan daha yüksek başarımlar sağlayacak bir ESA modeli geliştirilmiştir. Aktivasyon fonksiyonu olarak ELU (Üstel Doğrultulmuş Birim) tercih edilmiştir. Evrişimsel katmanlara sistemin başarımını artırmak için normalizasyon katmanı ilave edilmiştir. Sistemin ezberlemesinin engellenmesi için de uygun bir dropout değeri belirlenmiştir.

Makalenin 2. bölümünde, kullanılan veriseti, geliştirilen ESA mimarisi ve değerlendirme ölçekleri sunulmaktadır. 3. bölümde ESA'nın eğitilmesi sonucunda ortaya çıkan sonuçlar literatürde yer alan

diğer çalışmalarla karşılaştırmalı olarak tartışılmaktadır. Son bölümde ise değerlendirmeler ve öneriler yer almaktadır.

2. Materyal ve Metot

Bu bölümde çalışmada kullanılan veriseti ve özellikleri yer almaktadır. Verisetinde yer alan dosyalar ve özellikleri ile ESA modeline verilmeden önce sinyallere uygulanan ön işleme adımları sunulmaktadır. Geliştirilen ESA modeli ve bu modelin başarımını ölçmek için kullanılan değerlendirme ölçekleri de detaylı bir şekilde açıklanmaktadır.

2.1 Veriseti

Bu makalede kullanılan EEG sinyalleri PhysioNet'te yer alan polisomnografik veritabanı MIT-BIH'den alınmıştır. Denekler, Boston'daki Beth Israel Hospital Uyku Laboratuvarı'nda kronik obstrüktif uyku apne sendromunun değerlendirilmesi için izlenmiştir. Veritabanında yer alan çok kanallı PSG kayıtlarındaki her bir kayıt uzmanlar tarafından evrelerine ayrılmış ve çeşitli uyku rahatsızlıkları ile birlikte etiketlenmiştir. Verisetinde toplam 80 saatlik kayıt bulunmaktadır. Her biri farklı derecelerde apneye sahip 32-56 yaşları arasındaki 16 erkek denekten alınan 18 tüm gece PSG kaydı içermektedir. Her kayıta 250 Hz frekansında örneklenmiş EKG sinyali, invazif kan basıncı sinyali, solunum sinyali ve EEG sinyali bulunmaktadır. Her bir kayıt için veritabanında 4 farklı türde dosya bulunmaktadır [17]. Tablo 2'de MIT-BIH uyku verisetinde yer alan dosyaların uzantıları ve açıklamaları sunulmaktadır.

Tablo 2 MIT-BIH Uyku Veriseti Dosya Uzantıları ve Açıklamaları

Dosya Uzantısı	Açıklama
st	Uyku evreleri ile beraber uyku apnesi açıklamaları
ecg	Kalp ritmi açıklamaları
dat	Sinyaller
hea	Başlık dosyaları

MIT-BIH verisetinde yer alan her bir st uzantılı dosyanın içindeki uyku evresi ve uyku apnesi için olan açıklamaların tamamı dosyadaki aux alanında yer almaktadır. Bu dosyada yer alan her bir açıklama notu, açıklama notuna karşılık gelen bir epok veriye aittir. Aux alanındaki uyku evrelerine dair kodlar ve açıklama bilgileri Tablo 3'te yer almaktadır.

Tablo 3 Aux Alanında Yer Alan Uyku Evrelerine Dair Açıklamalara Karşılık Gelen Kodlar

Aux alanında yer alan kodlama kısaltmaları	Açıklaması
W	Uyanıklık
1	Uyku evresi 1 (S1)
2	Uyku evresi 2 (S2)
3	Uyku evresi 3 (S3)
4	Uyku evresi 4 (S4)
R	REM evresi

16 denegin EEG sinyallerinin tamamı kafa derisi üzerinde aynı bölgelerden alınmamıştır. Verisetinde yer alan slp02 kaydı O2-A1 elektrot çiftinden, slp01, slp32, slp37 ve slp41 kayıtları C4-A1 elektrot çiftinden ve diğer kayıtlar C3-O1 elektrot çiftinden kaydedilmiştir [18]. Tüm EEG kayıtları, birbiri ile çakışmayan 30 saniyelik epoklara ayrılmış ve daha sonra bu epokların her biri taşıdıkları özelliklere göre uzmanlar tarafından elle etiketlenmiştir.

Bu makalede sunulan çalışmada MIT-BIH uyku verisetinden alınan toplam 4640 epok'luk EEG sinyali kullanılmıştır. Bu epokların REM, S1, S2, SWS ve W evrelerine göre dağılımı sırasıyla 1198, 1177, 1072, 1193 şeklindedir. Sinyaller 250 Hz ile örneklediği için 30 sn'lik epokların her biri 7500 adet örnek içermektedir.

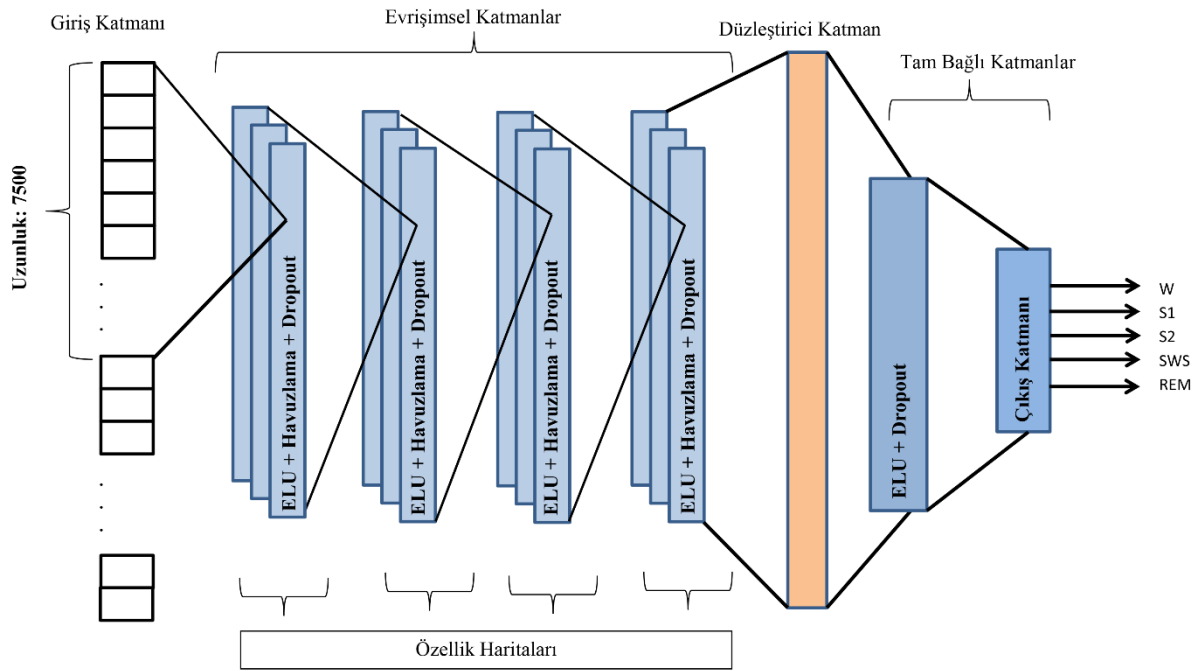
2.2 Önışleme

Deneklerin PSG kayıtlarında etiketlenmemiş olarak yer alan epoklar ESA'ya gönderilmeden önce sinyalden çıkarılmıştır. Verisetini dengeli hale getirebilmek ve gereksiz kaynak kullanımını engellemek için uykuya geçilmeden önceki ve uykudan uyandıktan sonraki uyanıklık evreleri sinyalden çıkarılmıştır. AUTA tarafından tavsiye edilen şekilde uyku evreleri W, S1, S2, SWS (S3 ve S4), REM şeklinde etiketlenmiştir, yani S3 ve S4 evreleri SWS olarak birleştirilmiştir.

2.3 Önerilen ESA Mimarisi

Bu çalışmada giriş olarak tek kanallı ham EEG sinyali alan ve özellikleri kendisi öğrenen bir ESA modeli kullanılmıştır. Önerilen ESA modeli blok diyagramı Şekil 2'de gösterilmektedir. Aktivasyon fonksiyonu olarak tüm katmanlarda ELU (Üstel Doğrultulmuş Birim) [19] kullanılmıştır.

Oluşturulan ESA modelinde 1 epokluk giriş dizisi, farklı sayılarda filtre ve çekirdeklere sahip 4 evrişimsel katman ve her bir evrişim katmanının sonunda aynı boyutta oluşturulan maksimum havuzlama katmanı bulunmaktadır. Evrişim katmanlarının sonunda bir düzeltirici katman ve 25 nörona sahip bir tam bağı katman ile de sınıflandırma işlemi yapılmaktadır. Tüm evrişimsel katmanlara normalizasyon eklenmiştir. Sistemin ezberlemesinin engellenmesi için tüm katmanlara deneyler sonucu bulunan en uygun dropout değeri eklenmiştir.



Şekil 2 Önerilen ESA Modelinin Blok Diyagramı

Tablo 4'te model mimarisi, çıktı boyutları ve parametre sayıları detaylı olarak sunulmaktadır. Sıralı yapıda bir model kullanıldığı için bir önceki katmanın çıkışı bir sonraki katmanın girişi olacak şekilde çalışmaktadır.

Tablo 4 Kullanılan Modelin Özellikleri

Katman Tipi	Çıktı Biçimi	Parametre Sayısı
Conv1D_1 (Conv1D)	(7500, 40)	3240
Batch_Normalization_1	(7500, 40)	160
Activation_1	(7500, 40)	0
Max_Pooling1d_1	(7500, 40)	0
Dropout_1	(750,40)	0
Conv1D_2(Conv1D)	(750, 60)	48060

Tablo 4 Kullanılan Modelin Özellikleri (Devamı)

Katman Tipi	Çıktı Biçimi	Parametre Sayısı
Batch_Normalization_2	(750, 60)	240
Activation_2	(750, 60)	0
Max_Pooling1d_2	(150,60)	0
Dropout_2	(150,60)	0
Conv1D_3(Conv1D)	(150,80)	48080
Batch_Normalization_3	(150,80)	320
Activation_3	(150,80)	0
Max_Pooling1d_3	(30,80)	0
Dropout_3	(30, 80)	0
Conv1D_4(Conv1D)	(30,100)	32100
Batch_Normalization_4	(30, 100)	400
Activation_4	(30,100)	0
Max_Pooling1d_4	(6,100)	0
Dropout_4	(6, 100)	0
Flatten_1	(600)	0
Dense_1 (Dense)	(50)	30050
Dropout_5	(50)	0
Dense_2(Dense)	(5)	255

ESA modeli 5 katlamalı çapraz doğrulama kullanılarak verinin %80'i eğitim, %20'si test olacak şekilde ayrılmıştır. Çapraz doğrulama kullanıldığı için test setinde yer alan epoklar her bir katlamada rastgele seçilmiş ve böylece her katlamada farklı verilerle doğrulama işlemi yapılmıştır.

Sistemin ezberlemesini engellemek için kullanılan dropout değerleri tüm katmanlarda 0.3 olarak kullanılmıştır. 5 epok boyunca doğrulama setinde hiç iyileşme olmazsa eğitim durdurulmuştur. Eğitim tamamlandıktan sonra çıkışlar 5'li olarak sınıflandırılmıştır. Bu sınıflar REM, S1, S2, SWS ve W şeklindedir.

Deneyler Python dili 3.7 sürümü ile Keras Kütüphanesi ve Tensorflow Kütüphanesi kullanılarak gerçekleştirilmiştir. Eğitimler için Google bulut sunucusu ortamında 15GB disk, 32GB bellek ve 16 çekirdek işlemcili sanal makineler kullanılmıştır. Geliştirme ortamı Ubuntu 18.0.4 LTS işletim sistemi üzerinde kurulmuştur.

2.4 Değerlendirme Ölçekleri

Önerilen yöntemin başarımı Denklem 1-4'te verilen doğruluk, hassaslık, kesinlik, karışıklık matrisi ve F1-skoru değerlendirme ölçekleri kullanılarak ölçülmüştür.

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

$$\text{Hassasiyet} = \frac{DP}{DP+YN} \quad (2)$$

$$\text{Kesinlik} = \% \frac{DP}{DP+YP} \quad (3)$$

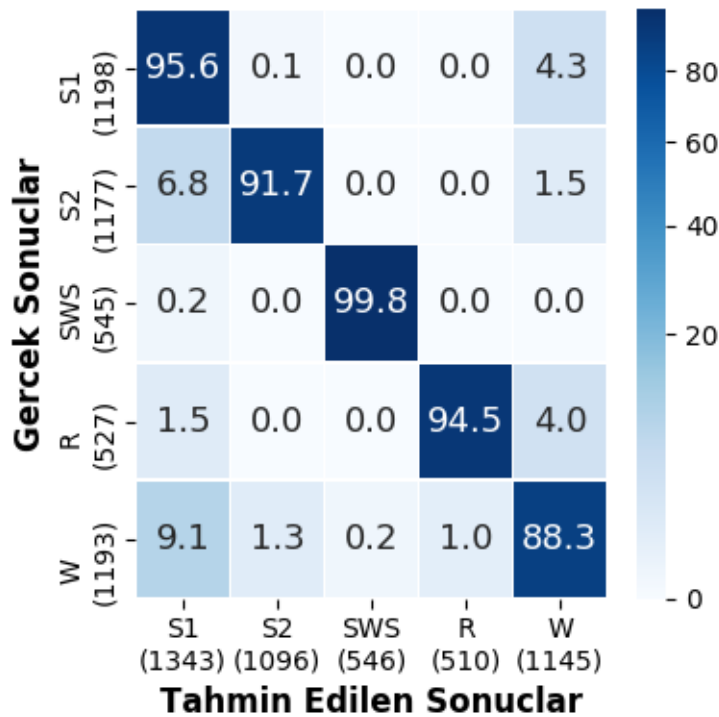
$$\text{F1} = 2 \times \frac{(\text{Hassasiyet} \times \text{Kesinlik})}{\text{Hassasiyet} + \text{Kesinlik}} \quad (4)$$

Denklemlerde yer alan Doğru Pozitif (DP), belirtilen uyku evresinin doğru olarak tahmin edildiği epokların sayısını belirtmektedir. Doğru Negatif (DN), belirtilen uyku evresine ait olmayan ve bu şekilde işaretlenmiş epokların sayıdır. Yanlış Pozitif (YP), belirtilen uyku evresine ait olmasına rağmen

o şekilde işaretlenmeyen epokların sayısıdır. Yanlış Negatif (YN) ise belirtilen uyku evresine ait olmadığı halde, o evreye aitmiş gibi işaretlenen epokların sayısıdır [15].


3. Bulgular ve Tartışma

Çalışmada sunulan sisteme ait test sonuçları Şekil 3’de karışıklık matrisi olarak gösterilmektedir. En yüksek doğruluk değeri %99.8 ile SWS evresinde, en düşük doğruluk değeri ise %88.3 ile W evresinde hesaplanmıştır. S1 evresi uyanıklıktan uyku durumuna geçiş evresi olduğu için W ve S2 evresi ile karışabilmektedir. Bunun nedeni S1 evresindeki dalga yapısının kendisinden önce gelen W ve kendisinden sonra gelen S2 evresindeki dalga yapısına olan benzerlikleridir [15]. Önerilen ESA modeli bu karışıklığı yüksek oranda önlemekle birlikte W evresini diğer evrelere göre daha düşük doğrulukla sınıflandırmış ve bu evre %9.1 oranında S1 evresi ile karışmıştır. S2 evresi de aynı şekilde %6.8 oranında S1 evresi ile karışmıştır.



Şekil 3 Uyku Evreleme İşlemine Ait Karışıklık Matrisi

Verisetinden örnek olarak seçilen slp59 kaydı için makalede sunulan ESA modeli tarafından uyku evrelemesi yapılarak elde edilen evreler ile elle skorlanmış evrelerin birlikte gösterildiği hipnogram görüntüsü Şekil 4’te gösterilmektedir. Turuncu renk ile gösterilen uyku evreleri ESA modeli tarafından, mavi renk ile gösterilen uyku evreleri ise uzmanlar tarafından elle etiketlenmiştir. Evreler yüksek bir oranda birbiri ile örtüşmüştür. Önerilen sistem deneğin tüm gece uyku verisinden otomatik olarak uyku evrelerini işaretleyebilmektedir.



Şekil 4 Slp59 için Elle Etiketlenmiş ve ESA ile Otomatik Etiketlenmiş Evrelerin Hipnogramı

Modeli test etmede kullanılan değerlendirme ölçeklerine göre başarımlarını Tablo 5'te sunulmaktadır.

Tablo 5 Başarımların Sonuçları

Uyku Evreleri	Keskinlik	Hassasiyet	F1-Skorlama
REM	0.85	0.95	0.90
S1	0.96	0.91	0.93
S2	0.99	1.00	0.99
SWS	0.93	0.97	0.95
W	0.93	0.85	0.89
Makro F1 Skorlama	0.93	0.94	0.93
Doğruluk			0.92

Sunulan modelin literatürde yapılan diğer tek kanallı EEG sinyali kullanılarak yapılan çalışmalarla karşılaştırması Tablo 6'da gösterilmiştir. Her bir çalışma için kullanılan veriseti, bu verisetinde kullanılan kanal sayısı ve denek sayıları, evreleme çeşidi, çalışmalar için kullanılan yöntemler ve çalışmaların başarımlarını tablodaki yer almaktadır.

Tablo 6 Yapılan Çalışmanın Sonuçlarının Literatürde Yapılan Diğer Çalışmaların Sonuçlarıyla Karşılaştırılması

Çalışma	Veriseti	Kanal Seçimi	Denek Sayısı	Evreleme Tipi	Kullanılan Yöntem	Doğruluk	F1-skoru
Sors	SHHS-1	Tek Kanal EEG	5728	R&K	ESA	%87	%87
Tsinalis	Sleep-EDF	Tek Kanal EEG	20	R&K	ESA	%74	%81
Zhang	MIT-BIH	Tek Kanal EEG	16	R&K	Hilbert Huang Dönüşümü, OESA	%88.4	%85.8
Supratak	MASS	Tek Kanal EEG	32	AUTA	ESA - UKDB	%86	%86
Bu çalışma	MIT-BIH	Tek Kanal EEG	16	AUTA	ESA	%92	%93

Makalede sunulan tek kanallı EEG kullanan ESA modelinin hem doğruluk hem de F1-skoru değeri literatürdeki rakiplerine göre yüksek çıkmıştır. Zhang vd. tarafından sunulan çalışmada da MIT-BIH veriseti kullanılmış, sinyaller Hilbert Huang Dönüşümü ile resim işleme aşamasından geçirilmiş olmasına rağmen modelin doğruluk başarımlarını %88.4'te kalmıştır. Ham EEG sinyalinde dönüştürme işlemleri yapmadan da uygun bir ESA modeli ile daha yüksek başarımlarını alınabilmektedir.

4. Sonuçlar

Bu makalede sunulan çalışmada tek kanallı ham EEG sinyal örnekleri kullanılarak otomatik uyku evrelemesi yapan bir sistem sunulmaktadır. Bu sistem için tek kanallı ham EEG sinyalleri alan bir Evrişimsel Sinir Ağı modeli geliştirilmiştir. Geliştirilen model PhysioNet'te yer alan MIT-BIH

polisomnografik veritabanında yer alan 16 erkek denekten alınan 18 tüm gece PSG kaydı ile eğitilmiştir. Gerçekleştirilen deneylerin sonuçlarına göre elle özellik çıkarımı yapmadan bir derin öğrenme ağının yüksek başarımla eğitilebildiği görülmektedir. Önerilen sistemin test başarımları %93 makro F1-skoru ve %92 doğruluk olarak bulunmuştur. Yapılan çalışma diğer çalışmalarla karşılaştırıldığında, önerilen modelin başarımları daha yüksektir. Tek kanallı EEG sinyali ile uyku evrelemesi yapılabilmesi sonucunda kişisel kullanıma uygun ve giyilebilir uyku izleme sistemlerinin geliştirilmesinin mümkün olacağı değerlendirilmektedir.

Referanslar

- [1] R. Sharma, R.B. Pachori, and A. Upadhyay, “Automatic Sleep Stages Classification Based on Iterative Filtering of Electroencephalogram Signals,” *Neural Computing and Applications*, vol. 28, no. 10, pp. 2959-2978, 2017.
- [2] J. A. Hobson, “Sleep: Biochemical Aspects,” *New England Journal of Medicine*, vol. 281, no. 26, pp. 1468-1470, 1969.
- [3] C. Iber, “Development of A New Manual for Characterizing Sleep,” *Journal of Sleep and Sleep Disorder Research*, vol. 27, no. 2, pp. 190-192, 2004.
- [4] B. J. Swihart, B. Caffo and K. Bandeen, “Characterizing Sleep Structure Using the Hypnogram,” *Journal of Clinical Sleep Medicine*, vol. 4, no.04, pp. 349-355, 2008.
- [5] H. Phan, F. Andreotti, N. Cooray and O. Y. Chen, “Joint Classification and Prediction CNN Framework for Automatic Sleep Stage Classification,” *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 5, pp.1285 – 1296, 2019.
- [6] A. Supratak, H. Dong, C. Wu and Y. Guo, “DeepSleepNet: A Model for Automatic Sleep Stage Scoring Based on Raw Single-Channel EEG,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 25, no. 11, pp. 1998-2008, 2017.
- [7] S. J. Redmond and C. Heneghan, “Cardiorespiratory-based Sleep Staging in Subjects with Obstructive Sleep Apnea,” *IEEE Transactions on Bio-Medical Engineering*, vol. 53, no. 3, pp. 485-496, 2006.
- [8] B. Koley and D. Dey, “An Ensemble System for Automatic Sleep Stage Classification Using Single Channel EEG Signal,” *Computers in Biology and Medicine*, vol. 42, no.12, pp.1186-1195, 2012.
- [9] E. Alickovic, J. Kevric and A. Subasi, “Performance Evaluation of Empirical Mode Decomposition, Discrete Wavelet Transform, and Wavelet Packed Decomposition for Automated Epileptic Seizure Detection and Prediction,” *Biomedical Signal Processing and Control*, vol. 39, pp. 94-102, 2018.
- [10] N. Stephansen, E. Shane, C. Jessica, R. Jason. and R. David, “Survey of Machine Learning Techniques in Drug Discovery,” *Current Drug Metabolism*, vol. 20, no. 3, pp.185-193, 2019.
- [11] K. O. Shea and R. Nash, 2015. “An Introduction to Convolutional Neural Networks,” *Arxiv:1511.08458v2*, 2015.

- [12] M. Sokolovsky, F. Guerrero, S. Paisarnsrisomsuk and S. A. Alvarez, "Deep Learning for Automated Feature Discovery and Classification of Sleep Stages," *Transactions of the Institute of Measurement and Control*, vol. 38, pp. 435-451, 2018.
- [13] H. Ghimatgar, K. Kazemi, M. S. Helfroush. and A. Aarabi, "An Automatic Single-Channel EEG-Based Sleep Stage Scoring Method Based on Hidden Markov Model," *Journal of Neuroscience Methods*," vol. 324, pp. 270-285, 2019.
- [14] O. Tsinalis, P. M. Matthews and Y. Guo, "Automatic Sleep Stage Scoring Using Time-Frequency Analysis and Stacked Sparse Autoencoders," *Annals of Biomedical Engineering*, vol. 44, pp. 1587-1597, 2016.
- [15] J. Zhang, R. Yao, W. Ge and J. Gao, "Orthogonal Convolutional Neural Networks for Automatic Sleep Stage Classification Based on Single-Channel EEG," *Transactions of the Institute of Measurement and Control*, vol. 38, pp. 435-451, 2019.
- [16] A. Sors, S. Bonnet, S. Mirek, L. Vercueil and J. Payen, "A Convolutional Neural Network for Sleep Stage Scoring from Raw Single-Channel EEG," *Biomed. Signal Proc. Control*, vol. 42, pp. 107-114, 2018.
- [17] physionet, "MIT-BIH Polysomnographic Database Files," 1999. [Online]. Available: <https://physionet.org/content/slpdb/1.0.0/>. [Accessed: 19-Oct-2019].
- [18] physionet, "MIT-BIH Polysomnographic Database Information," 1999. [Online]. Available: <https://physionet.org/content/slpdb/1.0.0/slpdb.shtml>. [Accessed: 21-Oct-2019].
- [19] D. Pedamonti, "Comparison of Non-Linear Activation Functions for Deep Neural Networks on Mnist Classification Task," *Arxiv:1804.02763v1*, 2018.