

## Transformer Kodlayıcı ve Zaman-Frekans Görüntüleri Kullanarak Otomatik Uyku Evreleri Sınıflandırması

### Automated Sleep Stage Classification Using Transformer Encoders and Time-Frequency Images

Göksu Zekiye ÖZEN<sup>1</sup> , Yunus ÖZEN<sup>2</sup> 

<sup>1</sup>Bilgisayar Mühendisliği Bölümü, Kütahya Dumlupınar Üniversitesi, Kütahya, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği Bölümü, Yalova Üniversitesi, Yalova, Türkiye

(goksu.ozen@dpu.edu.tr, yunus.ozen@yalova.edu.tr)

Received: Oct.3,2023

Accepted: Oct.17,2023

Published: Oct.18,2023

**Özetçe**— Bu çalışmada Polisomnografi (PSG) kayıtlarından alınan tek kanallı EEG verileri kullanarak otomatik uyku evreleri sınıflandırması yapan bir derin öğrenme modeli önerilmektedir. Önerilen model, EEG sinyallerinin kısa süreli Fourier dönüşümü (STFT) ile elde edilen zaman-frekans görüntülerinden öznelik çıkarmak için Transformer kodlayıcı kullanmaktadır. Transformer kodlayıcının çok başlı dikkat mekanizması, zaman-frekans görüntülerindeki zaman bağımlılıklarını yakalayarak modelin uykunun sıralı doğasını anlama performansını artırmaktadır. Önerilen modelin performansı, SleepEDF Expanded adlı açık erişim veri seti üzerinde değerlendirilmiştir ve 0.84 F1 skoru ile yüksek doğruluk değerine sahip sonuç elde edilmiştir. Modelin zaman-frekans görüntüleri kullanması, EEG sinyallerinin temel zaman alanı ve frekans alanı özelliklerini yakalayarak doğru uyku evreleri sınıflandırmasına katkı sağlamaktadır. Gelecek çalışmalarda, diğer PSG kanalları da dâhil edilerek uygulamada kullanımı mümkün olabilecek bir model geliştirilebileceği değerlendirilmektedir.

**Anahtar Kelimeler** : Uyku evreleri sınıflandırması, Derin öğrenme, Transformer kodlayıcılar, EEG sinyalleri, Polisomnografi, Zaman-frekans görüntüleri.

**Abstract**— This study proposes a deep-learning model for automatic sleep stage classification using single-channel EEG data from polysomnography (PSG) recordings. The model employs transformer encoders to extract features from time-frequency images obtained through short-time Fourier transform (STFT) of the EEG signals. The transformer encoder's multi-head attention mechanism captures temporal dependencies within the time-frequency images, improving the model's ability to understand the sequential nature of sleep. We evaluated the model's performance on the publicly available SleepEDF Expanded dataset, and a high accuracy of 0.84 F1 score was obtained. The model's use of time-frequency images enables it to capture essential time-domain and frequency-domain features of EEG signals, contributing to accurate sleep stage classification. In conclusion, our deep learning model based on transformer encoders provides an efficient and reliable solution for sleep stage classification from single-channel EEG data. Future research may explore extending the model to incorporate additional PSG channels and expanding its utility to broader sleep studies.

**Keywords** : Sleep stage classification, Deep learning, Transformer encoders, EEG signals, Polysomnography, Time-frequency images.

## 1. Giriş

Uyku; duyguların, davranışların ve hafıza ve biliş gibi fizyolojik işlevlerin çeşitli yönlerini etkilediği için insan sağlığı için hayati öneme sahiptir. Uyku bozuklukları ciddi fiziksel ve zihinsel sağlık sorunlarına neden olabilmektedir. Yetersiz uyku, ölüm riski, kardiyovasküler ve serebrovasküler bozukluklar gibi hastalıkları artırmaktadır (Chen, 2022). Uyku, gece boyunca her biri farklı aktiviteler içeren çeşitli döngülerden oluşur. Bu aktiviteler uyku evreleri olarak adlandırılmaktadır. Beyin aktivitesini ve değişikliklerini gösteren elektroensefalogram (EEG) sinyalleri, tek başına veya diğer sinyallerle birlikte uyku evrelerini belirlemek için yaygın olarak tercih edilmektedir (Figueiro, 2023).

Uyku evrelemesi, uykunun değerlendirilmesinde anahtar bir süreçtir. Uyku evrelerinin doğru sınıflandırılması, uykuyla ilgili olayların analizine katkıda bulunmaktadır. Klinik ortamda alınan polisomnografi (PSG) kayıtları, uyku evrelerini analiz etmek ve uyku bozukluklarını teşhis etmek için sık kullanılan bir tekniktir. PSG kayıtları; (EEG), elektrookülogram (EOG), elektrokardiyogram (EKG) ve elektromiyogram (EMG) gibi çeşitli sinyallerden oluşmaktadır (Rundo, 2019).

1968'de oluşturulan Rechtschaffen ve Kales (R&K) yönergeleri, PSG sinyallerine dayalı uyku evrelemesi için ilk oluşturulan standarttır (Wolpert, 1969). Bu yönergelere göre, PSG sinyalleri 30 saniyelik dilimlere ayrılmakta ve altı farklı uyku evresine kategorize edilmektedir. Bu evreler uyanıklık evresi, dört farklı hızlı olmayan göz hareketi (NREM) evresi (N1, N2, N3 ve N4) ve hızlı göz hareketi evresinden (REM) oluşmaktadır. Bununla birlikte, 2007'de Amerikan Uyku Tıbbı Akademisi (AUTA), aralarında belirgin farklar olmadığı gerekçesi ile uyku evresi sınıflandırmasını revize etmiş ve N3 ile N4 evrelerini tek bir NREM evresinde (N3) birleştirmiştir. AUTA ayrıca en son araştırmalara dayanarak evreleme kurallarında da bazı başka değişiklikler ve eklemeler yapmıştır (Iber, 2007).

Geleneksel uyku evresi sınıflandırma yöntemi, eğitimli uzmanlar tarafından uyku evrelerini belirlemek için EEG, EOG ve EMG sinyallerinin belirli özelliklerinden faydalanarak PSG sinyallerinin görsel olarak incelenmesini içermektedir (Chriskos, 2021). Bu yöntem zaman alıcı, karmaşık ve hata üretmeye yatkındır. Bu nedenle, uzmanların iş yükünü azaltabilecek ve uyku analizinin doğruluğunu ve tutarlılığını artırabilecek otomatik ve güvenilir uyku evresi sınıflandırma yöntemlerine ihtiyaç bulunmaktadır.

Uyku evreleme sürecini otomatikleştirmek amacıyla literatürde ham sinyallerden öznitelik çıkarmak için sinyal işleme teknikleri içeren çeşitli makine öğrenimi yöntemleri önerilmiştir. Bu çıkarılan öznitelikler ile Naive Bayes, k-en yakın komşu, destek vektör makinesi ve rastgele orman gibi geleneksel makine öğrenimi algoritmaları eğitilmektedir (Fiorillo, 2019). Bununla birlikte, bu yöntemlerin alan bilgisine ve uygun özelliklerin seçimine bağlı olması, gürültüye karşı duyarlılık gibi bazı dezavantajları bulunmaktadır. Ayrıca öznitelik belirleme sırasında sinyallerin kritik bilgileri kaybolabilmektedir (Malekzadeh, 2022).

Derin öğrenme yöntemleri, özellikle evrışımsel sinir ağları (CNN'ler), insan müdahalesi olmadan ham verilerden öznitelikleri öğrenebildikleri için otomatik uyku evrelemede daha iyi sonuçlar ortaya koymaktadır. Literatürde uyku evrelemesi için pek çok CNN mimarisi önerilmiştir. Bu yöntemler, CNN'lerin uzmanlar tarafından görsel incelemede tespit edilen belirli sinyal özelliklerini yakalayabildiğini göstermektedir. Bununla birlikte, CNN'ler yapısı gereği uzamsal özelliklere odaklanmakta ve uykunun sıralı doğasını modellemek için gerekli olan PSG sinyallerinin zamansal bağımlılığını göz ardı etmektedir (Sekkal, 2022).

Tekrarlayan sinir ağları (RNN), tekrarlayan yapısı nedeniyle dizi modellemede yaygın olarak kullanılmaktadır (Özen, 2020). Ancak, RNN'ler yüksek model karmaşıklığına sahiptirler ve paralel olarak eğitilmeleri zor olmaktadır. Son zamanlarda RNN'lerin yerine bazı çalışmalarda modellere bir dikkat mekanizması da dâhil edilmektedir. Ancak bu çalışmalar dikkat mekanizmasını kullanmadan önce öznitelik çıkarımı için yine de diğer ağ yapılarını kullanmaktadır ve ağ daha karmaşık hale gelmektedir (Sri, 2022).

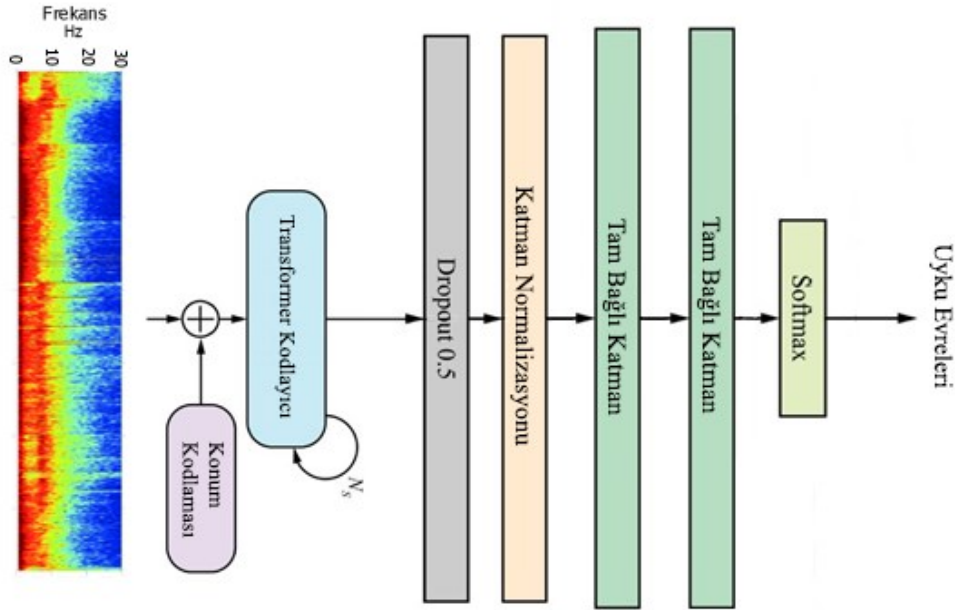
Mevcut uyku evreleme yöntemleri incelendiğinde sinyallerin tek boyutlu ham sinyaller ve zaman-frekans görüntüleri olmak üzere iki farklı şekilde temsilinin oluşturulduğu görülmektedir. Zaman-frekans görüntüleri, kısa süreli Fourier dönüşümü (STFT), Choi-Williams dağılımı (CWD) ve sürekli dalgacık dönüşümü (CWT) gibi zaman-frekans analizi teknikleriyle ham sinyallerin işlenmesiyle elde edilmektedir. Hem ham sinyaller hem de zaman-frekans görüntüleri benzersiz özelliklere sahipken; zaman-frekans görüntüleri, sinyallerin hem zaman-alanı hem de frekans-alanı özelliklerini içermesi bakımından ham sinyallere göre birtakım avantajlara sahiptir. Bu özellikler uyku evrelemesinde kullanılmaktadır (Haghayegh, 2023).

Bu bildiride sunulan çalışmada uyku evrelerini sınıflandırmak için evrışımsel ve tekrarlayan yapılar olmadan EEG verilerini kullanan bir derin öğrenme modeli önerilmektedir. Model, öz-dikkat mekanizması ve bire bir mimari ile tek kanal özellik çıkarımı için Transformer kodlayıcıya (Vaswani, 2017) dayanmaktadır. Önerilen model, derin öğrenme ağının boyutunu ve karmaşıklığını azaltmakta ve paralel eğitimi olanaklı hale getirmektedir. Zaman-frekans görüntüleri modele girdi olarak verilmektedir. Açık erişim bir veri seti üzerinde gerçekleştirilen deneylerde, önerilen model yüksek performans değerlerine sahip sonuçlar ortaya koymaktadır. Bu bildirinin literatüre temel katkısı, tek kanallı EEG verilerinden öznitelikleri çıkarmak için Transformer kodlayıcıların kullanılmasıdır.

## 2. Yöntem

Önerilen tek kanallı öznitelik çıkarma ve sınıflandırma aşamalarından oluşan model mimarisi Şekil 1 üzerinde gösterilmektedir. EEG kanalının verileri için, Transformer kodlayıcılar öznitelik haritasını zaman-frekans

görüntüsünden çıkarmaktadır. Ağın son kısmında iki tam bağlı katman ve bir softmax aktivasyon işlevi ile de sınıflandırma gerçekleştirilmektedir.



Şekil 1. Önerilen derin öğrenme modeli mimarisi

Seçilen EEG kanalından gelen ham sinyaller, STFT ve logaritma ölçekleme uygulanarak, belirli dalgaları ve frekans bileşenlerini temsil eden zaman-frekans görüntülerine dönüştürülmektedir.

Zaman-frekans görüntülerinden öznitelikleri çıkarmak için Transformer kodlayıcılardan yararlanılmaktadır. Öz-dikkat temelli bir model olan Transformer'in, özellikle doğal dil işlemede olmak üzere farklı sıralı modelleme görevlerinde iyi performans gösterdiği çeşitli çalışmalarla gösterilmiş bulunmaktadır (Vaswani, 2017). Bu çalışmada, zaman boyutu boyunca bir zaman-frekans görüntüsü spektral sütun içeren bir dizi olarak kabul edilmektedir ve bu sütun, doğal dil işleme görevinde işlenen bir cümledeki kelimeler vektörü gibi ele alınmaktadır. Transformer modeli temelde bir kodlayıcı ve bir kod çözücünden oluşmaktadır. Kod çözücü genellikle tahmin görevlerinde kullanıldığından, bu çalışmada önerilen modelde sadece kodlayıcı bileşeni kullanılmıştır. Transformer kodlayıcı, çok başlı dikkat modülü ve ileri beslemeli bir ağı sahiptir. Transformer kodlayıcı ile birlikte yineleme bileşenlerine gerek duyulmamakta, zamansal bilgileri kullanabilmek için girişte konumsal kodlamalar eklenmektedir.

Transformer kodlayıcı içerisinde yer alan çok başlı dikkat modülü farklı konumlardaki vektörler arasındaki bağımlılıkları yakalamaktadır. Bu modülde, görüntünün üç ayrı kopyası oluşturularak girdi olarak kullanılmıştır. Bu üç kopyanın hesaplamada farklı anlamları olduğu için, bunlar sırasıyla sorgu (Q), anahtar (K) ve değer (V) olarak adlandırılmıştır. Burada Q, K ve V bu çalışmada aynı verileri içermektedir. Daha sonra, Q, K ve V'nin her biri frekans alanında H adet segmente bölünmekte ve sonraki hesaplamalar her bir segment üzerinde gerçekleştirilmektedir. Bu durumda çok başlı dikkat modülü H adet başlık içermektedir. Bu yapı modelin daha detaylı bilgilere odaklanmasını sağlamaktadır. Her bir başlığın farklı frekans alanlarından özellikler öğrenmesine olanak tanımaktadır. Her bir başlıkta, sorgu, anahtar ve değerden alınan segmentler lineer katmana beslenmektedir. Lineer katmanın çıkışı ise dikkat mekanizması tarafından işlenmektedir.

Dikkat mekanizması, uyku evrelerindeki her konumun özellikleri ile diğer konumlardaki özellikler arasındaki ilişkiyi nokta çarpımı yoluyla hesaplamaktadır. Nokta çarpımının sonucu, aralarındaki ilişkinin gücünü yansıtmakta ve dikkat olarak adlandırılmaktadır. Her bir H başlıktaki dikkat hesaplama sonuçları birleştirilmekte ve sonuç başka bir tam bağlı katman tarafından girişle aynı boyuta eşlenmektedir. Bu katmanın çıktısı dropout katmanına iletilmektedir.

Çok başlı dikkat modülünün çıktısını girdi olarak alan iki adet tam bağlı katmandan oluşan bir blok, uyku evreleri sınıflandırmasını gerçekleştirmek için önceki yapıda öğrenilen özellikleri tanımakta ve birleştirmektedir.

İki tam bağlantılı katmanda da, ReLU aktivasyon işlevi kullanılmakta ve ardından dropout katmanı gelmektedir. En sonunda ise her bir sınıf için çıktı olasılıkları üretmek için softmax işlevi kullanılmaktadır.

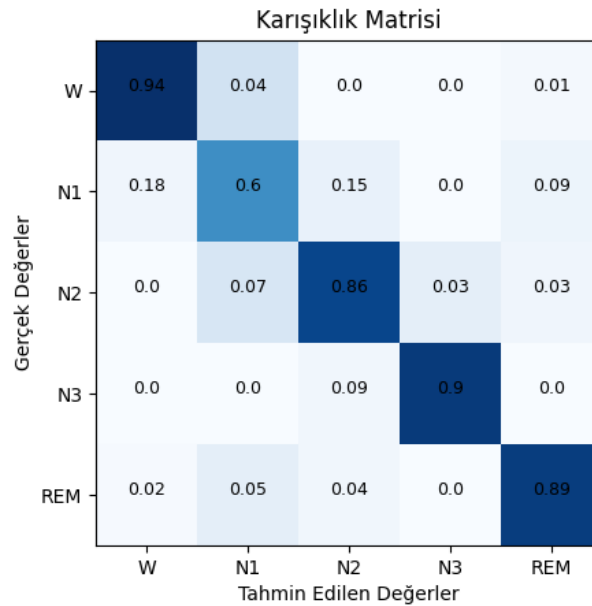
### 3. Bulgular ve Yorumlar

Önerilen modeli değerlendirmek için, SleepEDF Expanded açık erişim veri seti üzerinde deneyler gerçekleştirilmiştir. SleepEDF Expanded (Goldberger, 2000), EEG, EOG ve EMG kanallarını da içeren 197 tam gece uyku kaydı içerir. PSG dosyaları, EEG (Fpz-Cz ve Pz-Oz elektrot konumlarından), EOG (yatay), çene EMG'si ve olay işaretlerini içeren bütün gece polisnografik uyku kayıtlarıdır. Hipnogram dosyaları, PSG'lere karşılık gelen uyku evreleri kümesini ve ek açıklamaları içermektedir. Hipnogram adı verilen bu evreler kümesi W, R, 1, 2, 3, 4, M (Hareket süresi) ve ? (İşaretlenememiş) değerlerinden oluşmaktadır. Tüm hipnogramlar, iyi eğitilmiş teknisyenler tarafından manuel olarak işaretlenmiştir. EEG sinyalleri 100 Hz'de örneklenmiştir.

PSG sinyallerindeki her bir 30 saniyelik dilim, 256 noktalı STFT ile zaman-frekans görüntüsüne dönüştürülmüştür. Pencere işlevi olarak %50 örtüşme oranına sahip 2 saniyelik bir Hamming penceresi seçilmiştir. Log-power spektrumlarına dönüştürmek için spektrumda logaritma ölçeklendirme kullanılmıştır. EEG verilerinden hesaplanan zaman-frekans görüntüsü, tüm zaman-frekans çiftlerinde sıfır ortalama ve birim varyans olacak şekilde normalize edilmiş ve modele girdi olarak verilmiştir. Önerilen derin öğrenme ağının Transformer kodlayıcılarında, bir ileri besleme katmanında  $H = 8$  dikkat başlığı ve 1024 gizli katman kullanılmıştır. Transformer kodlayıcıların her bir alt katmanı için 0.1'lik dropout oranı kullanılmıştır. Son iki tam bağlı katmanda 1024 gizli katman ve 0.5 dropout oranı kullanılmıştır.

Model PyTorch 1.13.1 kullanılarak oluşturulmuş ve eğitim GeForce RTX 3090 GPU üzerinde gerçekleştirilmiştir. Doğrulama yöntemi olarak k-katlı çapraz doğrulama tercih edilmiştir. Eğitim sırasında 64'lük bir minibatch boyutu kullanılmıştır. Eğitim sırasında erken durdurma stratejisi uygulanmıştır ve doğrulama veri kümesinin doğruluğu 10 epoch boyunca artmazsa eğitim süreci durdurulmuştur. Genel model performansı doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skor metrikleri ile değerlendirilmiştir.

Önerilen modelin performansını göstermek için karışıklık matrisi ve yukarıda bahsedilen metrikleri içeren bir tablo kullanılmıştır. Sonuçlar, Şekil 2'deki karışıklık matrisi ve Tablo 1'de yer alan performans metrikleri ile gösterilmektedir. Şekil 2'de yer alan karışıklık matrisinde, satırlar ve sütunlar, sırasıyla gerçek değerleri ve tahmin edilen sonuçları temsil etmektedir. Karışıklık matrisinin köşegeninde yer alan sayılar, modelin doğru sınıflandırdığı evrelerin yüzdelik değerlerini göstermektedir. Buna göre, veri seti içerisinde en az sayıda evre sayısına sahip olan N1 dışında kalan aşamaların yüksek doğrulukla sınıflandırıldığı görülmektedir.



Şekil 1. Karışıklık matrisi

Modelin her bir sınıf için sahip olduğu doğruluk, kesinlik, duyarlılık ve F1 skor değerleri ise Tablo 1 üzerinde gösterilmektedir. Tablo 1 incelendiğinde modelin en yüksek doğrulukta N3 sınıfını değerlendirdiği görülmektedir. Modelin kesinlik ve doğruluğunun harmonik ortalaması olan F1 skoru makine öğrenmesi ve derin öğrenme modellerinin performansını değerlendirmek için kullanılan önemli bir ölçektir ve özellikle dengesiz sınıflandırma problemlerinde faydalıdır (Hand, 2001). F1 skoru ölçüğüne göre model en yüksek doğrulukta W evresini, en düşük doğrulukta N1 evresini sınıflandırmaktadır. Modelin genel F1 skor ölçüğü ise 0.84 olarak ölçülmüştür.

**Tablo 1.** Modelin her bir sınıf için sahip olduğu doğruluk, kesinlik, duyarlılık ve F1 skor değerleri

Sınıflar	Doğruluk	Kesinlik	Duyarlılık	F1-Skor
W	%96.29	0.93	0.95	0.94
N1	%92.56	0.56	0.57	0.56
N2	%93.04	0.84	0.86	0.85
N3	%97.74	0.95	0.91	0.93
REM	%96.05	0.92	0.89	0.91

#### 4. Sonuç

Bu çalışmada, polisomnografi kayıtlarından EEG verileri ile otomatik uyku evreleri sınıflandırması için Transformer kodlayıcı tabanlı bir derin öğrenme modeli önerilmiştir. Model, tek kanallı öznitelik çıkarma ve sınıflandırma bloklarından oluşmaktadır. Tek kanallı öznitelik çıkarma bloğunda Transformer kodlayıcılar EEG kanalının zaman-frekans görüntülerinden öznitelik çıkarmak için kullanılmıştır. Deneysel sonuçlar, önerilen modelin yüksek performansa sahip olduğunu göstermiştir. Sonuçlar, önerilen modelin klinik uygulamalar için tercih edilmeye hazır olduğunu göstermektedir. Bu bildiride sunulan ön sonuçlar dikkate alındığında, PSG kayıtlarında yer alan diğer kanalların da eklenmesiyle klinik çalışmalarda kullanılabilecek daha yüksek performanslı bir modelin üretilebileceği değerlendirilmektedir.

#### Kaynaklar

- Chen, P. C., Zhang, J., Thayer, J. F., & Mednick, S. C. (2022). Understanding the roles of central and autonomic activity during sleep in the improvement of working memory and episodic memory. *Proceedings of the National Academy of Sciences*, 119(44).
- Chriskos, P., Frantidis, C. A., Nday, C. M., Gkivogkli, P. T., Bamidis, P. D., & Kourtidou-Papadeli, C. (2021). A review on current trends in automatic sleep staging through bio-signal recordings and future challenges. *Sleep Medicine Reviews*, 55.
- Figueiro, M. G., & Pedler, D. (2023). Cardiovascular disease and lifestyle choices: Spotlight on circadian rhythms and sleep. *Progress in Cardiovascular Diseases*.
- Fiorillo, L., Puiatti, A., Papandrea, M., Ratti, P. L., Favaro, P., Roth, C., ... & Faraci, F. D. (2019). Automated sleep scoring: A review of the latest approaches. *Sleep Medicine Reviews*, 48, 101204.
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C. K., & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet - Components of a new research resource for complex physiologic signals. *Circulation*, 101(23): E215-E220.
- Hand, D. J., Till, R. J. (2001). A Simple Generalisation of the Area Under the ROC Curve for Multiple Class Classification Problems. *Machine Learning*, 45(2): 171-186.
- Iber, C. (2007). The AASM manual for the scoring of sleep and associated events: Rules, Terminology and Technical Specifications.
- Malekzadeh, M., Hajibabae, P., Heidari, M., & Berlin, B. (2022, January). Review of deep learning methods for automated sleep staging. In 2022 IEEE 12th Annual Computing and Communication Workshop and Conference (CCWC), pp. 80-86.
- Ozen, G. Z., SULTANOV, R., Ozen Y., & Gunes, Z. Y. (2020). A Convolutional Neural Network Based on Raw Single Channel EEG for Automatic Sleep Staging. *Sakarya University Journal of Computer and Information Sciences* 3(2): 149-158.
- Rundo, J. V., & Downey III, R. (2019). Polysomnography. *Handbook of Clinical Neurology*, 160: 381-392.

- Sekkal, R. N., Bereksi-Reguig, F., Ruiz-Fernandez, D., Dib, N., & Sekkal, S. (2022). Automatic sleep stage classification: From classical machine learning methods to deep learning. *Biomedical Signal Processing and Control*, 77:
- Sri, T. R., Madala, J., Duddukuru, S. L., Reddipalli, R., & Polasi, P. K. (2022, Nisan). A Systematic Review on Deep Learning Models for Sleep Stage Classification. In 2022 6th International Conference on Trends in Electronics and Informatics (ICOEI), pp. 1505-1511.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. In Proceedings of the 31st International Conference on Neural Information Processing Systems, Long Beach, California, USA, pp. 6000–6010.
- Wolpert, E. A. (1969). A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects. *Electroencephalography & Clinical Neurophysiology*, 26(2): 644-644.