

Derin Öğrenme ve Makine Öğrenmesi Yöntemleriyle Polisomnografi Sinyallerinden Uyku Evrelerinin Sınıflandırılması

Sinan ALTUN^{1*} 

Öz

Uyku, fiziksel ve zihinsel sağlığımızın günlük olarak yenilenmesi için önemli bir aktivite zamanıdır ve yaşamımızın üçte birini kaplar. Uyku bozuklukları, psikiyatrik bozuklukları şiddetlendirebilir veya semptomlarına neden olabilir. Bunlardan ilki uyku apnesi olabilir. Diğer bir neden ise huzursuz bacak sendromudur. Depresyon, anksiyete, ağrı ve bazı fiziksel problemler de uykusuzluğa neden olabilir. Uyku apnesi, sinir sistemi probleminden veya soluk yolu tıkanıklığından kaynaklanabilir. Uyku evrelerini incelemek, uyku ile ilgili bozuklukların teşhisinde çok önemlidir. Uyku evreleri de uyku sırasında kişinin yanında olunarak bir profesyonel tarafından belirlenir. Ortalama 8 saatlik uyku evre teşhis süresi düşünüldüğünde, bu bir profesyonel için oldukça uzun bir süredir. Ayrıca uyku evrelerinin tanımlanması ciddi bir uzmanlık ve bilgi birikimi gerektirmektedir. Literatürde tanımlanan hastalıkların teşhis ve tedavi sürecini otomatik olarak yapan bilgisayarlı teşhis sistemi teorik araştırmalara dayalı olarak uygulanmaya başlandı. Bu çalışma, insan sağlığını doğrudan etkileyen uyku bozukluklarının teşhisinde önemli parametreler olan uyku evrelerini otomatik olarak oluşturmak için derin öğrenme ve makine öğrenmesi tekniklerini kullanmayı amaçlamaktadır. Bu çalışmada, rastgele orman algoritması en başarılı sınıflandırmayı (doğruluk = 0,974, duyarlılık = 0,932, özgüllük = 0,983) gerçekleştirmiştir. Bu gelişmiş sınıflama başarısı, uykuya ilişkili bozuklukların teşhisinde/tedavisinde önemli bir faktör olan uyku evrelerini otomatik olarak belirleyebilen bilgisayar destekli bir teşhis sistemi oluşturmanın uygulanabilirliğini göstermektedir.

Anahtar Kelimeler: Polisomnografi, Derin öğrenme, Makine öğrenmesi, Uyku bozuklukları, Uyku evreleri.

Classification of Sleep Stages from Polysomnography Signals with Deep Learning and Machine Learning Methods

Abstract

Sleep is an important time of activity for the daily renewal of our physical and mental health, and it occupies a third of our lives. Sleep disorders can exacerbate or cause symptoms of psychiatric disorders. The first of these may be sleep apnea. Another cause is restless legs syndrome. Depression, anxiety, pain, and some physical problems can also cause insomnia. Sleep apnea can be caused by a nervous system problem or airway obstruction. Studying sleep stages is crucial in diagnosing sleep-related disorders. Sleep stages are also determined by a professional by being with the person during sleep. Considering the average sleep stage diagnosis time of 8 hours, this is quite a long time for a professional. In addition, the definition of sleep stages requires serious expertise and knowledge. The computerized diagnosis system, which automatically diagnoses and treats the diseases described in the literature, has started to be implemented based on theoretical research. This study aims to use deep learning and machine learning techniques to automatically generate sleep stages, which are important parameters in the diagnosis of sleep disorders that directly affect human health. In this study, the random forest algorithm performed the most successful classification (accuracy = 0.974, sensitivity = 0.932, specificity = 0.983). This advanced classification success demonstrates the feasibility of creating a computer-aided diagnostic system that can automatically identify sleep stages, which is an important factor in the diagnosis/treatment of sleep-related disorders.

Keywords: Polysomnography, Deep learning, Machine learning, Sleep disorders, Sleep stages.

¹Kahramanmaraş İstiklal Üniversitesi, Yapı İşleri ve Teknik Daire Başkanlığı, Kahramanmaraş, Türkiye. s.altun@yaani.com


¹<https://orcid.org/0000-0002-2356-0460>

1. Giriş

Uyku oldukça karmaşık bir yapıdır ve fiziksel ve psikolojik yaşam kalitesinde önemli bir faktördür. Uyku araştırmasına yardımcı olacak popüler bir yöntem, “uyku evrelemesi” kavramıdır. Uyku evrelerinin sınıflandırılması uzun süredir uyku mimarisini anlamak için bir yöntem olarak kabul edilmiştir ve uyku araştırmalarında standart hale gelmiştir. (Silber ve ark. 2007). Uyku aşamalarını sınıflandırmak için en yaygın yaklaşım, bir uyku uzmanı tarafından gerçekleştirilen manuel sınıflandırmadır. Bu prosedürü gerçekleştirmek için, kişi uyurken uykuyu değerlendiren uzmandan alınan polisomnogram (PSG) bilgilerine ihtiyaç vardır.

PSG, birden çok biyosinyal verisi içeren çok kanallı bir sinyal topluluğu olarak uyku araştırmalarında yaygın olarak kullanılmaktadır. Sinyal topluluğunda; Elektroensefalografi (EEG), Elektrookülografi (EOG), Elektromiyografi (EMG), oksijen doygunluk bilgisi, Elektrokardiyografi (EKG) ve solunum sinyali bilgisini içermektedir (Lu vd., 2022). PSG veri toplamanın amacı uyku ile ilişkili bozuklukları teşhis etmektir. Uyku uzmanları bu işaretleri kullanarak hastalarındaki uyku problemlerini teşhis edebilir. Uyku uzmanı tarafından detaylı ve dikkatli bir muayene gerektiren bu işlem zaman alıcı ve yorucudur. Süreci hızlandıracak bilgisayar destekli tanı sistemleri sayesinde uyku bozuklukları ve uyku ile diğer rahatsızlıklar arasındaki bağ hızlıca ve yüksek doğrulukla ortaya konabilir.

Çalışmamızda PSG işaretleri ile uyku dönemlerinin sınıflandırılması yapılacaktır. Sınıflandırma işlemi yapılmadan önce çeşitli öne işleme teknikleri uygulanarak her bir hasta için 5 milyonun üzerindeki işaretlerden özellikler çıkartılarak veri seti oluşturulacaktır. Bu veri seti hem klasik makine öğrenmesi hem de Uzun Kısa Dönem Hafıza (UKDH) derin öğrenme yöntemi ile sınıflandırılacaktır. Şekil 1’ de çalışmanın görsel olarak anlatıldığı blok diyagram yer almaktadır.



Şekil 1. Çalışmanın blok diyagramı

2. Önceki Çalışmalar

EEG sinyallerini kullanarak etkili uyku izleme, uyku apnesi, uykusuzluk, horlama, uykusuz ventilasyon ve huzursuz bacak sendromu gibi uyku bozukluklarının teşhisinde önemlidir. Bu nedenle,

EEG tabanlı otomatik uyku aşaması puanlama yöntemlerinin geliştirilmesi, son yıllarda yoğun araştırma ilgisini çekmiştir. Bu sorunları ele almak için, çok kanallı doku rengi analizine dayalı olarak uyku aşamalarını otomatik olarak sınıflandıran bir zeka modeli önermişlerdir. MILBP ile çıkarılan bilgiler, EEG uyku evrelerini ayırt etmek için bölümlere ayrılır. Çıkarılan öznitelikler test edilir ve EEG uyku evrelerinde kullanılan en etkili öznitelikler sunulur. Seçilen özellikler, belirlenen uyku aşamalarına göre EEG sinyallerini sınıflandırmak için her bir sınıflandırıcı için en uygun ağırlıkları seçmek için kullanılan bir genetik algoritmaya entegre edilmiş bir dizi sınıflandırıcıya beslenir. İki karşılaştırmalı uyku veri setindeki deneysel sonuçlar, önerilen modelin 0,96 ve 0,95 doğruluk ve 0,94 ve 0,93 F1 puanları ile çeşitli temel yöntemlere kıyasla en iyi performansı gösterdiğini göstermektedir (Abdulla vd., 2023).

Kalp atış hızı değişkenliği (Heart rate variability (HRV)), uyku evreleri ve apne olayları tarafından modüle edilir. Çocuklarda yapılan önceki bir çalışma, obstrüktif uyku apnesi (obstructive sleep apnea (OSA)) ve kontrol grupları arasında uyku evrelerindeki geleneksel HRV parametrelerini karşılaştırdığı makalede anlatılmaktadır. Ancak hem uyku evrelerini hem de apne olaylarını içeren HRV tabanlı karakterizasyon gerçekleştirilmemiştir. Çalışmada önerdikleri modelin, HRV, OSA'ya özgü parametreler değerlendirilmemiştir. Bu nedenle, bu çalışmanın amacı klasik ve pediatrik OSA'ya özgü uyku evreleri ve apne olaylarını içeren HRV parametrelerini karakterize etmek ve karşılaştırmak olduğu anlatılmaktadır. Childhood Adenotonsillectomy Trial (CHAT) veri tabanından toplam 1610 elektrokardiyogram, HRV parametrelerini çıkarmak için 10 dakikalık bölümlere ayrıldı. Segmentler uyku evrelerine (uyanıklık, W; hızlı olmayan göz hareketleri, NREMS ve REMS segment başına bir apne olayının altında, e/s; 1-5 e/s; 5-) ayrıldı ve apne olaylarının varlığı değerlendirilmişlerdir. NREMS, REMS'de daha az belirgin olan apne olaylarının artan sıklığı ile HRV parametrelerinde önemli değişiklikler gösterdiği makalede açıklanmaktadır (Martín-Montero vd., 2023).

Uyku bozuklukları, Birleşik Krallık'ta ve dünya genelinde yaygındır ve 13 ülkeden alınan uyku verileri, yetişkinlerin yalnızca %55'inin uykusundan memnun olduğunu gösterdiği anlatılmaktadır. Dünyanın en ciddi hastalıklarından biri olan diyabet, uyku sorunu yaşatır. Özellikle glisemik kontrol ile uyku süresi ve kalitesi arasında bir ilişki bulunmuştur. Diyabetin uyku aşamalarını ve ilişkili performansı nasıl etkilediği şu anda bilinmemektedir. Yapılan çalışma, diyabetik yetişkinlerde ve kontrol katılımcılarında polisomnografi ile ölçülen belirli uyku aşamalarıyla ilişkili spektral güç ilişkilerini karakterize etmeyi amaçlamaktadır. Bu çalışma, eşleştirilmiş bir çift tasarımı kullanılarak uyku sırasında kalp sağlığına ilişkin çok gruplu verilerin ikincil veri analizini içerir. Örnek 414 katılımcı (211 erkek, 203 kadın, ortalama yaş 70.0, %95, 207 diyabet hastası ve 207 eşleştirilmiş kontrol grubundan oluşmaktadır). Sonuçlar, diyabetik hastalarda hafif uyku, özellikle evre 2 NREM uykusu, süre ($p=0,05$) ve orantı ($p=0,04$), yavaş dalga aktivitesi ($p=0,03$) ve delta gücü ($p=0,04$)


gösterdiği ayrıca 1. evre NREM uykusu sırasında Yavaş dalga uykusunun süresi diyabette ($p=0.09$), delta gücü ($p<0.01$), yavaş dalga aktivitesi ($p=0.02$) ve teta gücü ($p<0.01$) diyabette azaldığı makalede açıklanmaktadır (Johnson vd., 2022).

Uyku evrelerinin skorlanması, uyku bozukluğunun etkili bir şekilde teşhis edilmesi ve müdahale edilmesi için büyük önem taşımaktadır. Bununla birlikte, mevcut otomatik uyku evreleme yöntemleri genellikle zayıf model genelleme yeteneklerinden ve taşınabilir algılama cihazlarından muzdarip olduğu anlatılmaktadır. Makalede, elektrofizyolojik sinyallerine dayalı yeni bir otomatik uyku değerlendirme sistemi önermektedirler. Alından, alın elektroensefalogramı 1 (Fh1), alın elektroensefalogramı 2 (Fh2) ve merkezi alın elektrookülogramı (Fhz) adı verilen üç sinyal kanalı alınır. Spektral, istatistiksel ve entropi özellikleri, Ayrık Dalgacık Dönüşümü (ADD) yöntemleri kullanılarak çıkarılır. Light Gradient Enhancement Machine (LGB), Random Forest (RF) ve Support Vector Machine (SVM) kullanılarak dört uyanıklık durumu, hafif uyku (LS), derin uyku (DS) ve hızlı göz hareketi (REM) sınıflandırmışlardır. Önerilen yöntemin performansı, uyku EDFX veri tabanı ve polisomnografi ve 28 denekten alınan alın sinyalleri dahil olmak üzere tescilli veriler kullanılarak doğrulanmışlardır. Bh1, Fh2 ve Fhz kombinasyonlarını kullanan genel sınıflandırma doğruluğu, 0,857'lik bir kappa katsayısı ile %90,25'e olduğu açıklanmıştır (Guo vd., 2022).

Uyku evresine özgü müdahaleler genellikle uyku işlevini ve bunun altında yatan mekanizmaları aydınlatmak için kullanılır. Bu prosedürde hızlı göz hareketi uykusunun doğru sınıflandırılması esastır. Çalışmada, tek kanallı elektroensefalografi kullanarak uyku aşamalarını gerçek zamanlı olarak sınıflandırmak için bir sistemin in vivo uygulamasını rapor etmektedirler. Bu, deneyde kullandıkları her fare için önceden yapılandırma olmaksızın %90 hassasiyet ve %86 hassasiyetle hızlı göz hareketi uykusuna özgü müdahaleleri mümkün kıldığı açıklanmaktadır. Daha yüksek frekanslı örnekleme ve zaman çözünürlüğü ile sınıflandırılabilir bir sistem türettiklerini anlatmaktadırlar. Bu tak-çalıştır uyku evreleme sistemi, uyku işlevini incelemek için tam otomatik, doğru ve ölçeklenebilir bir araç sağlayarak oldukça elverişli bir yöntem olduğu açıklanmıştır (Koyanagi vd., 2022).


3. Materyal

Bu çalışmada, Physionet web sitesinde herkesin erişimine açık olan veri seti, hastane ortamında gerekli görülen polisomnografik sinyallerin kaydedilmesi ile oluşturulan 'Snooze, You Win: the PhysioNet/Computing in Cardiology Challenge 2018' veri seti kullanılmıştır (Ghassemi ve ark. 2018). Bu veri seti 1983 kişiye ait PSG bilgisinden oluştuğu söylene de 994 kişinin bilgileri tam olarak erişilebilmektedir ve çalışmada 994 kişinin PSG işaretleri kullanılmıştır. Şekil 2' de örnek bir PSG görüntüsü yer almaktadır.



Şekil 2. Örnek polisomnografi görüntüsü (Driver vd., 005)

Çalışmada kullandığımız 'Snooze, You Win: the PhysioNet/Computing in Cardiology Challenge 2018' veri setini Matlab programından elde edilen görüntüsü ise Şekil 3' te yer almaktadır. Eksen üzerindeki 1'den 9'a kadar olan sayılar uyku evrelerini gösterir. Uyanma 5, Rem uyku 4, NonRem3 Uyku 3, NonRem2 Uyku 2, NonRem1 Uyku 1 ve tanımsız olarak etiketlenen kısım 9'dur.



Şekil 3. Veri setinden örnek bir PSG görüntüsü

Kayıtta 13 kanal bilgisi bulunmaktadır. Kanal 1 -6 arasında EEG sinyalinin içerir. EEG sinyalleri uluslararası 10-20 standartlarına göre yerleştirilmiştir. 7. Kanal EOG verilerinin elde edildiği ve sadece sol göz için EOG verileri alınan kanaldır. Kanal 8- 10 EMG sinyallerini içerir. Kanal 8 çene EMG verilerini içerir, kanal 9 abdominal EMG verilerini içerir ve kanal 10 göğüs EMG verilerini içermektedir. Kanal 11 hava akımı bilgisini, Kanal 12 ise oksijen doygunluğu bilgisini ve kanal 13 EKG bilgisini içerir. Oksijen doygunluğu dışındaki sinyaller, 200 Hz frekansında kaydedilmiştir.

Oksijen doygunluğu bilgisi 200 Hz olarak tahmin edilerek diğer sinyallerle senkronize edilmiştir (Ghassemi ve ark. 2018).

Veri setinde oluşturulan etiket dosyaları, uyku uzmanlarının ilgili sinyallere göre her dönem için uyku evrelerini belirlemesi sonucunda oluşturulmuştur. Uyku aşaması sınıflandırması için bir kriter olarak, her bir dönemin çerçeve genişliği 30 saniyedir.

Uyku evresi araştırmasını inceleyen Alan Rechtschaffen ve Anthony Kales, "Handbook of Standardized Terminology, Techniques, and Scoring Systems for Sleep Stages in Human Subjects", 2007 yılında Amerikan Uyku Tıbbı Akademisi tarafından revize edildi. Artık bir yöntem olarak kabul ediliyor ve uluslararası olarak kullanılıyor. Bu çalışmada kullanılan sınıflandırma yöntemi, Amerikan Uyku Tıbbı Akademisi tarafından belirlenen kriterlere göre geliştirilmiştir. Bu standarda göre uykunun 5 aşaması vardır. Bu aşamalar Wake, NonRem1, NonRem2, NonRem3 ve Rem olarak adlandırılır (Colten and Altevogt 2006), (AASM Manual).

Uykunun her aşaması, belirli beyin dalgalarına ve sinirsel aktiviteye bağlıdır. Tipik bir gecede, sağlıklı bir insan, sabahları daha uzun, daha derin bir REM aşamasıyla, NREM ve REM adı verilen uykunun tüm aşamalarından geçer. EEG daha yavaştır, ancak bu aşamada, REM dışı uykunun ikinci aşamasına özgü kısa elektriksel aktiviteler vardır. Bu, uykunun en derin aşamasıdır (Colten and Altevogt 2006), (AASM Manual).

Bu uyku evresinde kişiyi uyandırmak oldukça zordur. Bazen rüyalar REM dışı uyku sırasında ortaya çıkar. Bu aşamada kol ve bacak kasları geçici olarak felç olur ve hayal edilen hareketleri fiziksel olarak gerçekleştiremez hale gelir. Hem REM hem de REM dışı uyku, büyük olasılıkla hafıza onarımı ve yenilenmesi için gereklidir (Colten and Altevogt 2006).

EEG aktivitesi ile ilgili olarak, NonRem1 uykusu hem alfa hem de teta dalgaları ile ilişkilidir. NonRem1 uykusunun erken evreleri, nispeten düşük frekanslarda (8-13 Hz) yüksek genlikli dalgalar üretir. Bu dalgalara alfa dalgaları denir. Bu beyin dalgası aktivitesi paterni, sinyali alan kişinin o sırada çok rahatlamış ancak uykuya dalmamış biri olduğunu gösterir. aktivite artar. Teta dalgaları, alfa dalgalarından daha düşük frekanslı (4-7 Hz) ve daha yüksek genlikli beyin dalgalarıdır. NonRem1 Birini uykusundan uyandırmak kolaydır (Šušmáková, 2004).

NonRem2, Teta dalgaları hala beyin aktivitesine hakimdir uykusuna geçiş sırasında vücut derin bir gevşeme durumuna girer (Šušmáková 2004). Öğrenme ve hafıza sağlayan, yüksek frekanslı beyin dalgalarının Uyku içcikleri denir (Fogel ve Smith 2011). NonRem2 uykusunun belirlenmesini sağlayan K dalga biçimleri de bu aşamada meydana gelir.

NonRem3 uyku aşaması, derin uyku veya yavaş dalga uykusu olarak adlandırılırken düşük frekans (4 Hz'e kadar) ve yüksek genlikli delta dalgaları üretir. Bu sürede, kalp atış hızı ve solunum hızı önemli ölçüde düşer. NonRem3 sırasında, kişiyi uyandırmak diğer aşamalardaki kadar kolay olmayacaktır. İlginç bir şekilde, NonRem3 sırasında artan alfa EEG aktivitesine sahip kişiler, çok

uzun süre uyusalar dahi uyandıktan sonra uykularını alamadıklarını belirtmektedirler (Stone ve ark. 2008).

Hızlı göz hareketleri, REM uykusu olarak sınıflandırılır (AASM Kılavuzu). REM ile ilişkili sinyaller, uyanırken haldeki işaretlere çok benzer ve aşamada, rüya görülebilir. Dolaşım ve nefes almayı sağlayan kaslar dışında kalan kasların felç olması ile ilişkilendirilen uyku evresidir. REM uykusunda normalde istemli kas hareketi yoktur. Beyin aktivitesi yoğun olduğu ve kas hareketinin olmadığı REM paradoksal uyku olarakta adlandırılmaktadır (Colten ve Altevogt, 2006).

4. Metod

4.1. Ön İşleme

Veri setinde yer alan 994 hastanın her birinin, PSG görüntüsünde, 13 kanal ve her kanalda da 5 milyonun üzerinde işaret bulunmaktadır. Bu işaretlerin herhangi bir ön işleme tabi tutulmayarak sınıflandırılması, sonucu etkilemeyen değerlerinde işlenmesinden dolayı oldukça zaman alacak ve bilgisayara gereksiz bir yük oluşturacaktır. Literatür incelendiğinde, çalışmamızdaki gibi çok sayıda işaret içeren verilerin kullanıldığı çalışmaların neredeyse tamamı ön işleme tabi tutulmaktadır. Çalışmamızda da veri seti ön işleme tabi tutularak özellik vektörleri çıkartılıp sınıflandırma yapılacaktır.

4.1.1. Seyrek Filtreleme Algoritması

Seyrek filtre algoritması (Sparse Filtering Algorithm (SFA)), $n \times p$ boyutunda veri matrisi ile başlar. Her satır bir gözlemi temsil eder ve her sütun bir ölçümü temsil eder. Sütunlar ayrıca özellikler veya tahmin ediciler olarak da adlandırılır. Algoritma daha sonra ya ilk rasgele p -by- q ağırlık matrisi W elde eder ya da başlangıç ağırlıkları ad-değer çiftinde iletilen ağırlıklar matrisini kullanır. q , seyrek filtrenin hesapladığı istenen özelliklerin sayısıdır. Bu algoritma, bellek kısıtlı bir standart Broyden-Fletcher-Goldfarb-Shanno (LBFGS) yarı-Newton iyileştirici kullanarak seyrek filtreleme objektif işlevini en aza indirmeye çalışır (Nocedal ve Wright, 2006). Bu iyileştirici, Yineleme Sınırı (IterationLimit) yinelemeleri gerektirir. Normu Adım toleransı (StepTolerance) değerinden düşük olan bir adım atarsanız veya geçerli noktadaki gradyan normu, skaler τ ile çarpılan Azalış Toleransı (GradientTolerance) değerinden daha düşük olarak hesaplanırsa yinelemeleri erken durdurulur. Denklem (1)'de GradientTolerance fonksiyonu yer almaktadır. Denklemde; $|f|$ amaç fonksiyonunun normunu, $\|g_0\|_\infty$ başlangıç gradyanının sonsuz normunu ifade eder.

$$\tau = \max\left(1, \min\left(|f|, \|g_0\|_\infty\right)\right) \quad (1)$$

Amaç fonksiyonu, her veri noktası için aynı anda birkaç sıfır olmayan özellik elde etmeye ve sonuçta ortaya çıkan her özelliğin neredeyse eşit ağırlığa sahip olmasını sağlamaya çalışır (Ngiam vd., 2011). Çoğu durumda, 5'ten birkaç yüze nispeten küçük bir IterationLimit değeri ayarlamak yeterli işlevsellik sağlayacaktır. Optimize edicinin devam etmesine izin vermek, çıkarılan özellikler yeni verilere iyi bir şekilde genelleştirilmezse aşırı eğitime yol açabilir. Seyrek Filtre nesnesini oluşturduktan sonra, giriş verilerini yeni çıktı özelliklerine eşlemek için transform yöntemi kullanılır. Amaç fonksiyonunu hesaplamak için seyrek filtre algoritması aşağıdaki adımları kullanır. Amaç fonksiyonu, optimize edicinin değiştirdiği n'ye p veri matrisi X'e ve ağırlık matrisi W'ye bağlıdır. Ağırlık matrisi W, p-by-q boyutlarına sahiptir. p, orijinal özelliklerin sayısı ve q, istenen özelliklerin sayısıdır.

n' ye q matrisi $x*w'$ yi hesaplanır. F matrisini elde etmek için $x*w'$ nin her bir elemanına yaklaşık mutlak değer işlevini uygulanır $\Phi(u) = \sqrt{u^2 + 10^{-8}}$. Φ mutlak değer fonksiyonuna çok yakın, düzgün, negatif olmayan simetrik bir fonksiyondur.

F'nin sütunlarını normalleştiren ve yaklaştıran L^2 normudur. $\tilde{F}(i, j)$ matrisi Denklem (2)'de görüldüğü gibi normalleştirilir.

$$\|F(j)\| = \sqrt{\sum_{i=1}^n (F(i, j))^2 + 10^{-8}} \quad (2)$$

$$\tilde{F} = F(i, j) / \|F(j)\|$$

$\tilde{F}(i, j)$ 'in satırlarını yaklaşık olarak L^2 norm'a normalleştirilir. Denklem (3)' e göre $\hat{F}(i, j)$ hesaplanır.

$$\hat{F}(i, j) = \tilde{F}(i, j) / \|\tilde{F}(i)\| \hat{F}(i, j) \quad (3)$$

Matristeki tüm öğelerin toplamı olan amaç fonksiyonu $h(W)$ 'yi $F(i, j)$ matrisinin 1-normu olarak hesaplanır. Denklem (4)'te fonksiyon yer almaktadır.

$$h(W) = \sum_{j=1}^q \sum_{i=1}^n \hat{F}(i, j) + \lambda \sum_{j=1}^q w_j^T w_j \quad (4)$$

4.1.2.Yeniden Yapılandırmadan Bağımsız Bileşen Analiz Algoritması

Yeniden Yapılandırmadan Bağımsız Bileşen Analizi (Reconstruction ICA Algorithm (RICA)) algoritması, bir amaç fonksiyonunu en aza indirmeye dayanır. Algoritma, girdi verilerini çıktı

özelliklerine eşler (Coelli ve ark., 2023). Denklem (6)' da RICA algoritmasının fonksiyonu yer almaktadır. Burada; x , p uzunluğunda bir sütun vektörünü, μ , sabit bir terimi temsil eden p uzunluğunda bir sütun vektörünü, s , elemanları istatistiksel olarak birbirinden istatistiksel olarak bağımsız sıfır ortalama birim varyans rastgele değişkenler olan q uzunluğunda bir sütun vektörünü, A , p -by- q boyutunda bir karışım matrisini ifade eder.

$$x = \mu + As \quad (6)$$

Amaç işlevi, Kontrast fonksiyonunu ad-değer çifti kullanılarak belirtilen karşıtlık işlevini kullanır. Kontrast işlevi, mutlak değer gibi görünen düzgün bir dışbükey işlevdir. Default Kontrast fonksiyonu $g = \frac{1}{2} \log \cosh(2x)$ şeklindedir. Lambda adı-değer çiftinin değeri olarak λ düzenleme parametresi ile X ve q çıktı özelliklerinin n -by- p veri matrisi için, p -by- q matrisinin W amaç fonksiyonu Denklem (7)' de yer almaktadır. Denklemden; $\sigma_j, \pm 1$ olarak bilinen bir sabittir. $\sigma_j = +1$ için, h amaç fonksiyonunu en aza indirmek, w 'nin histogramının 0'da (süper Gauss) keskin bir şekilde zirve yapmasına neden olur. $\sigma_j = -1$ için, h amaç fonksiyonunu en aza indirmek, w 'nin histogramını 0 (Gauss altı) civarında düzleştirir.

$$h = \frac{\lambda}{n} \sum_{i=1}^n \|WW^T x_i - x_i\|_2^2 + \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^q \sigma_j (w_j^T x_i) \quad (7)$$


λ sıfır ise, amaç fonksiyonunun yarı-minimumu h sıfır olabilir. Böylece sorgu, W 'yi 1'e normalize ederek h 'yi en aza indirir. Yani, W 'nin her w_j sütunu v_j sütun vektörü Denklem 8' e göre hesaplanır. v_j tarafından küçültülmüş sorgu sonuçlarının minimum W matrisi, X girdi verisini XW çıktı özelliklerine dönüştürür.

$$w_j = \frac{v_j}{\sqrt{v_j^T v_j + 10^{-8}}} \quad (8)$$

4.2. Uzun Kısa Dönem Hafıza Derin Öğrenme

Metindeki kelimelerin anlamı ve metnin genel anlamı önceki bilgiler kullanılarak anlaşılabilir. Harfleri eksik olan her kelime, önceki bilgiler kullanılarak tamamlanabilir. Ardışık iki cümlenin ikinci kelimesinde bir kelime eksikse, bu kelime okunabilir. İlk cümlenin anlamından ve ikinci cümledeki kelimelerden anlayabilirsiniz. Yapay sinir ağları kalıcı bellek sağlayamadıkları için kelime tamamlama ve anlamsal tamamlama gibi sorunları etkin bir şekilde çözemezler. Yinelemeli sinir

ağları, bilginin sürekliliğini sağlayarak bu sorunları çözer. Bilginin sürekliliği, yinelenen her ağ hücresi içindeki döngülerle sağlanır. Tekrarlayan ağlar, birçok hücre içermeleri ve veriler üzerinde derin öğrenme gerçekleştirmeleri bakımından geleneksel sinir ağlarından farklıdır. Literatürde yinelenmeli ağ oluşturma, konuşma tanıma ve dil modelleme gibi alanlarda çok başarılı olunan çalışmalar mevcuttur. 1997'de Hochreiter ve Schmidhuber tarafından geliştirilen ve yinelenen ağ hücrelerine ek bir döngü ekleyen UKDH işlemi ile ortadan kaldırılmıştır. UKDH derin öğrenme yöntemi, sorunuza bir çözüm bulmak için tüm uzun süreli veya kısa süreli belleğinize bakar ve sonucu şu şekilde verir. Şekil 4'te görüldüğü gibi. UKDH hücre yapısının 'mavi' ile gösterilen bir giriş kapısı, 'yeşil' ile gösterilen bir unutmama kapısı, 'sarı' ile gösterilen bir çıkış kapısı ve 'c' ile gösterilen bir depolama hücresi vardır. Unutmama kapısı, ne kadar bilgi gönderileceğini belirler. 0 ile 1 arasında bir değer alır; burada 1, verilerin olduğu gibi gönderildiğini ve 0, hiçbir bilginin gönderilmediğini garanti eder. Giriş kapısının 'tanh' işlevi kullanılarak güncellenen veriler. Son çıkış kapısında ise ilk iki kapıdan geçen veri -1 ile 1 arasında bir "tanh" fonksiyonu ile çarpılarak bize sonuç verilir (Altun ve Alkan, 2022).




Şekil 4. UKDH mimarisi.

4.3. Rastgele Orman

Breiman tarafından 2001 yılında geliştirilen bu algorithmada, bir sınıflandırıcının amacı tek bir karar ağacı oluşturmak değil, her biri farklı bir eğitim setinde eğitilmiş birçok ağacın kararlarını birleştirmektir. Farklı eğitim setleri için aynı dağılıma sahip rastgele öznelik seçimi kullanılır. Bir karar ağacı oluşturulurken her seviyede özellikler belirlendiğinden, her ağaç özellikleri belirlemek için bazı hesaplamalar yapar ve bunlar daha sonra diğer ağaçların özellikleriyle birleştirilerek en sık kullanılan fonksiyon seçilir. Seçilen özellikler ağaca dahil edilir ve aynı işlem diğer seviyelerde tekrarlanır. Algoritmayı başlatmak için kullanıcının her düğümde kaç değişken kullanacağına ve kaç ağaç geliştireceğine karar vermesi gerekir. Rastgele Orman (RO), ağaç oluşturmak için CART (Sınıflandırma ve Regresyon Ağaçları) algoritmasını kullanır. Düğümler ve dallar bu algoritmanın

özelliklerine göre oluşturulur (Daş vd., 2014). Rastgele orman modelinin yapısı Şekil 5'te gösterilmektedir (Subudhi, 2020).



Şekil 5. Rastgele orman dal yapılanması.

4.4. k En Yakın Komşu

K-En Yakın Komşu (k-EYK) algoritması, en iyi bilinen ve yaygın olarak kullanılan makine öğrenimi algoritmalarından biridir. Sınıflandırma, seçilen özellik ile en yakın özellik arasındaki yakınlığa dayalıdır. Burada elde edilen K değeri 3 veya 5 gibi bir sayı ile temsil edilir. Denklem (9)'da gösterilen Öklid mesafesi, nesnelere arasındaki mesafeyi belirlemek için yaygın olarak kullanılır. Burada 'X_i' birinci ölçülen verinin konumudur, 'X_j' ikinci ölçülen verinin konumudur ve 'p' veri kümesindeki işlenen veri sayısıdır (Altun vd., 2021; Sunnetci ve Alkan, 2023).

$$d_{(i,j)} = \sqrt{\sum_{k=1}^p (X_{ik} - X_{jk})^2} \quad (9)$$

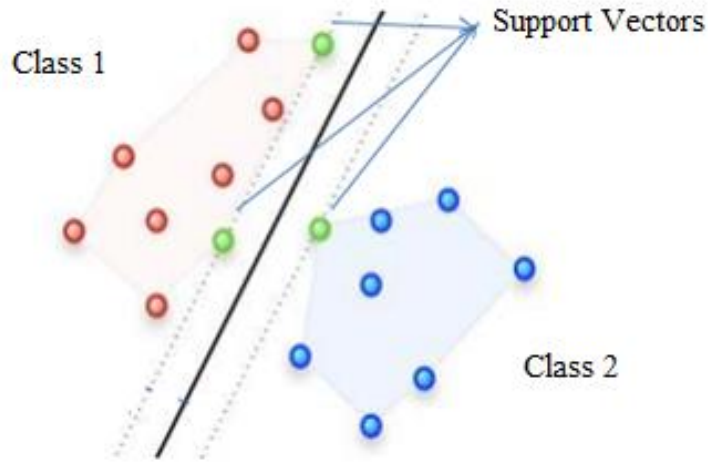
k-EYK, tanımlanan verilere göre tanımlanması gereken yeni bir nesne geldiğinde, önce K değerine bakılır. K sayıları genellikle eşit olmayacak şekilde tek sayı olarak seçilir. Yeni gelen veriler ile diğer veriler arasındaki mesafeyi hesaplamak için kosinüs, Öklid mesafesi veya Manhattan mesafesi gibi yöntemler kullanılmaktadır (Arslan ve Arslan, 2021).

4.5. Destek Vektör Makineleri

Destek vektör makineleri (DVM'), Vapnik (1995) tarafından keşfedilen ve veriye dayalı araştırma alanlarında kullanılan bir makine öğrenimi yaklaşımıdır. DVM, istatistiksel öğrenme teorisine dayanmaktadır. Öncelikle iki veri sınıfı arasında mümkün olduğunca ayırım yapmak için kullanılır. Bu amaçla karar limitleri veya hiperdüzlemler belirlenir. Doğrusal olmayan veri kümeleri için DVM, doğrusal hiper düzlemleri temsil edemez. Yani çekirdek numarası kullanılır. Çekirdek yöntemleri, doğrusal olmayan veriler üzerinde makine öğrenimini önemli ölçüde geliştirir (Sunnetci ve Alkan; 2022). Çekirdek yönteminde, DVM tahmincisi (y) işlemleri Denklem (10)'da ifade edilir.

$$y = (K_{xi} * W_{jk}) + b(1) \quad (10)$$

Denklem 2'de, 'b' DVM ağının sapma terimidir ve 'W_{jk}' ağırlık vektörü olarak adlandırılır. 'K_{xi}', giriş vektörünü yüksek boyutlu bir özellik uzayına eşleyen doğrusal olmayan bir fonksiyondur. Basitleştirilmiş bir SVM mimarisi Şekil 6'da gösterilmiştir. DVM'nin çalışma prensibi, iki sınıf arasındaki en iyi ayırmadır. Bu ayırımı Şekil 6'da görüldüğü gibi iki boyutlu bir veri setinin destek vektörleri ile yapıyoruz (Demirci, 2019).



Şekil 6. DVM makine öğrenme yönteminin destek vektörleri.

4.6. Sınıflandırma Metrikleri

Konfüzyon matrisi, verilerin sınıflandırılması sonucunda en az iki çıktı olduğunda performans ölçüsü olarak yaygın olarak kullanılan bir performans metriğidir. Tablo 1 doğruluk, kesinlik ve hassasiyet için performans ölçümlerini hesaplarken kullanılan karışıklık matrisini göstermektedir.

Tablo 1. Başarı metriklerinin hesaplanmasında kullanılan değerler.

Tahmin Değerleri	Gerçek Değerler		
	Pozitif		Negatif
	Doğru	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Yanlış	Yanlış Negatif (YN)	Doğru Negatif (DN)

Doğruluk değerleri, modeldeki doğru tahmin edilen verilerin tüm veri setine oranından hesaplanır. Denklem (11) doğruluk puanının Tablo 1'deki değerlere göre nasıl hesaplandığını gösterir (Powers 2008).

$$Doğruluk = \frac{DP+DN}{DP+YP+DN+YN} \quad (11)$$

Özgüllük, tahmin edilen pozitif değerlerden kaçının gerçekte pozitif olduğunu ifade eder (Yargı, 2021). Denklem (12)'de özgüllük puanının Tablo 1'deki değerlere göre nasıl hesaplandığını gösterir.

$$Özgüllük = \frac{DP}{DP+YP} \quad (12)$$

Duyarlılık, olumlu tahmin edilen işlem sayısının bir ölçüsüdür (Gülcan O., 2020). Denklem 13, duyarlılık puanının Tablo 1'deki değerlere göre nasıl hesaplandığını gösterir.

5. Deneysel Çalışmalar

Veri setinde yer alan 13 kanalın tamamı kullanılarak öznelikler çıkartılmıştır. Çalışmanın özünü PSG işaretleri olduğu için çalışmada EEG, EOG, EMG, EKG gibi sınırlar oluşturulmamıştır. 13x5 milyon± boyutunda oluşturulan matrislerden Seyrek Filtreleme Algoritması (SFA) ve Yeniden Yapılandırılmadan Bağımsız Bileşen Analizi (Reconstruction ICA Algorithm (RICA)) ile özellik haritaları oluşturulmuştur. Sınıflandırma 5 kat çapraz doğrulama ile yapılmıştır. 994 kişinin 5 farklı uyku evresi sınıflar olarak kullanılmıştır.

Özellik haritaları derin öğrenme ve klasik makine öğrenme yöntemleri ile sınıflandırılmaya çalışılmıştır. Derin öğrenme yöntemi olarak işaret sınıflandırılmasında sıkça kullanılan UKDH yöntemi ile çalışılmıştır. Bütün yapay zekâ temelli makine öğrenmesi sınıflandırma yöntemlerinde olduğu gibi bu çalışmamızda da, derin öğrenme yöntemi klasik yöntemlerden daha başarılı olamayacağı ortaya konmuştur.

Tablo 2'de yöntem başarıları yer almaktadır. Sınıflandırma çalışmalarında yalnızca doğruluk değerinin verilmesi sonuçların yorumlanması için yeterli olamayacağından Tablo 2' de doğruluk

değerinin yanı sıra duyarlılık ve özgüllük değerleri de verilmiştir. Çalışmamızda, uyku evrelerinin sınıflandırılmasında en başarılı yöntem Rastgele Orman olmuştur. Aslında literatüre bakıldığında gerek işaret gerekse görüntü matrislerinden özellik haritaları çıkarılarak yapılan biyomedikal çalışmalar oldukça yüksek başarılar sunmaktadır. 4 adet yöntemin tamamı aslında yüksek sınıflandırma başarısı elde etmiştir. 4 yöntem içerisinde en düşük başarıyı yakalayan DVM yönteminin başarısı %85,02 olup bu küçümsenemeyecek bir sınıflandırma başarısıdır. Yöntemin hesapladığı özgüllük değerine bakıldığında %88,9 gibi bir değer hesaplanmış olup, daha yüksek doğruluk elde eden k-EYK yönteminden daha yüksektir. Ancak uçurum bir fark bulunmamaktadır. Burada ki fark, 994 kişinin 5 uyku evresinin doğru hesaplanmasından kaynaklanmaktadır. En başarılı yöntem olan RO %97,3 sınıflandırma başarısı elde etmiştir. Bu başarı oldukça yüksektir. RO tarafından hesaplanan duyarlılık ve özgüllük değerlerine bakıldığında, doğruluktaki yüksek başarı orada da yer almaktadır. Bu da sınıflandırma evresinin doğru şekilde tahmin edildiğini göstermektedir.

Tablo 2. Yöntemlerin başarıları.

Method	Doğruluk %	Duyarlılık %	Özgüllük %
SFA/RICA+UKDH	91	90,5	90,3
SFA/RICA+k-EYK	88	93	81,37
SFA/RICA+DVM	85,02	81,2	88,9
SFA/RICA+Rastgele Orman	97,4	93,2	98,3

6. Sonuçlar ve Öneriler

Uyku, fiziksel ve zihinsel sağlığımızın günlük olarak yenilenmesi için önemli bir aktif zamandır ve hayatımızın üçte birini kaplar. Sağlıklı uyku, gücümüzü tazeleyen, beynimizi ve bedenimizi yarınlara hazırlayan psikobiyolojik bir süreçtir. Bu da gün içinde mutlu, huzurlu ve hatta başarılı olmamızı, geçmiş yaşamlarımızı, duygu ve düşüncelerimizi yeniden düzenlememizi, planlar yapmamızı, zorlukları çözmemizi yani yeni bir güne hazırlanmamızı sağlar. Uyku sürecinin aksamasının kişinin genel sağlığı ve günlük yaşamı üzerinde doğrudan olumsuz etkileri olabileceği doğrudur. Uyku, fiziksel ve zihinsel sağlık için önemlidir. İhtiyacımız olan uyku miktarı yaşımıza ve kişimize bağlıdır. Uyku ihtiyacı yaşla birlikte azalır. Yetersiz uyku veya kalitesiz uyku birçok soruna neden olabilir. Uyku bozuklukları ile birlikte karar verme güçlükleri ve ruh hali değişimleri görülebilir. Depresyon ve anksiyete gibi psikiyatrik bozukluklar da genellikle uyku bozuklukları ile ilişkilidir. Psikolojik Faktörler (özellikle stres, kaygı, ruhsal hastalıklar...), yaşam tarzı (kafein/alkol

kullanımı, ilaçlar, çalışma saatleri, vardiyalı ya da gece çalışma...), çevresel faktörler (ışık, ses, rahatsız yatak, sık uyanma zorunluluğu (emzirme, bakım sorumlulukları vb...), bedensel hastalıklar (Ağrı bozuklukları, kramplar, reflü, solunum zorlukları,...) uyku bozukluklarına yol açabilir.

Uyku süresi, kalitesi ve zamanlama sorunları ile birlikte günlük işleyişi etkileyen bir grup bozukluktur. Uykusuzluk, huzursuz bacak sendromu, narkolepsi ve obstrüktif uyku apnesi gibi tek yaygın uyku bozukluğu değildir. Uyku bozuklukları, psikiyatrik bozuklukları şiddetlendirebilir veya semptomlarına neden olabilir. Uykusuzluk birkaç gün sürerse geçici, 1-3 hafta sürerse kısa süreli, 3 haftadan uzun sürerse kronik olarak sınıflandırılır. Bunlardan ilki uyku apnesi olabilir. Diğer bir sebep ise huzursuz bacak sendromudur. Ayrıca depresyon, anksiyete, ağrı ve bazı fiziksel problemler de uykusuzluğa neden olabilir. Uyku apnesi sinir sistemindeki bir problem nedeniyle veya solunum yollarındaki bir tıkanıklık nedeniyle oluşabilir. Uyku apnesi olan kişilerin uyku esnasında sık sık nefes alışverişleri durur. Uyku apnesi ile nefesi duran kişi, boğulma hissi ile ya uyanır ya da tam uyanıklığa geçerse bile daha yüzeysel bir uykuya geçer. Bu şekilde uyku apnesi nedeniyle uykunun kesintiye uğraması, ertesi gün uykulu olmaya, dinlenmemiş uyanmaya yol açar. Huzursuz Bacak Sendromu (HBS): Lokalizasyonu kolay olmayan bu duyguyu ifade etmeye çalışırlar. Öncelikle bacaklardadır, hareketle azalır ve yanma, çekme, karıncalanma, karıncalanma, karıncalanma, ağrı ve uyuşma gibi çeşitli terimler kullanır. Bahsedilen özellikleri nedeniyle HBS uykuya dalmayı oldukça zorlaştıran bir rahatsızlıktır. Diyabet, böbrek hastalığı, romatoid artrit, disk hastalığı, omurilik yaralanması veya diğer hastalıklar da HBS'ye neden olabilir. HBS semptomları, varlığı fark edildiğinde ve nedeni tedavi edildiğinde iyileşebilir. Psikoz, depresyon, bipolar bozukluk, anksiyete bozuklukları ve alkol/madde ile ilişkili bozukluklar gibi birçok ruhsal hastalıkta uyku bozuklukları görülebilir.

Yukarıda uyku düzensizliğine nelerin neden olduğu ve uyku düzensizliği ile nelerin olabileceği özetlenmiştir. Belki de birçok insanın üzerinde durmadığı uyku düzeni ve uyku evreleri doğrudan doğruya sağlığımızı dolaylı olarak ta sosyal hayatımızı etkilemektedir. Uyku kaynaklı hastalıkların teşhisi için, uyku evrelerinin incelenmesi oldukça önemlidir. Uyku evreleri de uzman bir kişi tarafından kişinin uykusu sırasında yanında bulunarak belirlenmesi ile gerçekleştirilmektedir. Ortalama 8 saatlik bir periyot olduğu düşünülürse, bir uzmanın ayırması gereken oldukça uzun bir zamandır. Ayrıca uyku evrelerinin tanımlanması ciddi bir uzmanlık ve bilgi birikimi de gerektirmektedir.

Gerek görüntü işleme gerekse biyo işaretler kullanılarak hastalık tanısında objektif bir bakış açısı, zaman ve doğru tanı açısından oldukça önemlidir. Literatürde hastalık teşhis/tedavi süreçlerinde otomatik karar veren bilgisayar destekli tanı sistemleri artık teorik çalışmalardan uygulamaya geçmeye başlamıştır. Bu çalışmada da, insan sağlığını doğrudan ve sosyal hayatını dolaylı olarak etkileyen uyku düzensizliği teşhisinde önemli bir parametre olan uyku evreleri derin öğrenme ve

makine öğrenmesi teknikleri ile otomatik yapılmaya çalışılmıştır. Diğer bilgisayar destekli tanı sistemlerinde olduğu gibi burada da elbette tanı/tedavi kararları en son doktora aittir. Yapılan çalışma ile ‘Snooze, You Win: the PhysioNet/Computing in Cardiology Challenge 2018’ hazır veri setinde Rastgele Orman algoritması en başarılı sınıflandırmayı gerçekleştirmiştir (doğruluk=0.974, duyarlılık=0.932, özgüllük=0.983). Elde edilen bu yüksek sınıflandırma başarısı uyku kaynaklı hastalıkların teşhis/tedavisinde önemli bir faktör olan uyku evrelerinin belirlenmesini otomatik yapabilen bir bilgisayar destekli tanı sisteminin oluşturulabileceğini ortaya koymaktadır. İleriki çalışmalarda farklı veri setlerinde önerilen model kullanılarak çalışma genişletilmesi planlanmaktadır.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Abdulla, S., Diykh, M., Siuly, S., Ali, M. (2023). An intelligent model involving multi-channels Spectrum Patterns based features for automatic sleep stage classification. *International Journal of Medical Informatics*, 171, 105001. <https://doi.org/10.1016/j.ijmedinf.2023.105001>
- Altun, S., Alkan, A. (2022). MR spektroskopisi kullanılarak beyin tümörü tespitinde lstm tabanlı derin öğrenme uygulaması. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*. <https://doi.org/10.17341/gazimmfd.1069632>
- Altun, S., Alkan, A., Altun, H. (2021). The investigation of wisc-r profiles in children with border intelligence and intellectual disability with machine learning algorithms. *Pamukkale University Journal of Engineering Sciences*, 27(5), 589–596. <https://doi.org/10.5505/pajes.2020.53077>
- Arslan, H., Arslan, H. (2021). A new COVID-19 detection method from human genome sequences using CPG island features and KNN classifier. *Engineering Science and Technology, an International Journal*, 24(4), 839–847. <https://doi.org/10.1016/j.jestch.2020.12.026>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/a:1010933404324>
- Coelli, S., Medina Villalon, S., Bonini, F., Velmurugan, J., López-Madrona, V. J., Carron, R., Bartolomei, F., Badier, J.-M., Bénar, C.-G. (2023). Comparison of beamformer and ICA for Dynamic Connectivity Analysis: A simultaneous Meg-SeeG Study. *NeuroImage*, 265, 119806. <https://doi.org/10.1016/j.neuroimage.2022.119806>

- Colten, H.R., Altevogt B.M., 2006. *Sleep Disorder and Sleep Deprivation: An Unmet Public Health Problem*. National Academies Press, Washington DC. S(33-39).
- Daş B., Türkoğlu İ., (2014, Kasım). DNA dizilimlerinin sınıflandırılmasında karar ağacı algoritmalarının karşılaştırılması. *Eleco 2014 Elektrik – Elektronik – Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*(s. 381-383). Bursa.
- Demirci M., (2019). Destek vektör makineleri ve m5 karar ağacı yöntemleri kullanılarak yağış-akış ilişkisinin tahmini. *DÜMF Mühendislik Dergisi*, 10(3),1113-1124. <https://doi.org/10.24012/dumf.525658>
- Driver, H. S., Mclean, H., Kumar, D. V., Farr, N., Day, A. G., Fitzpatrick, M. F. (2005). The influence of the menstrual cycle on upper airway resistance and breathing during sleep. *Sleep*, 28(4), 449–456. <https://doi.org/10.1093/sleep/28.4.449>
- Fogel, S. M., Smith, C. T. (2011). The function of the sleep spindle: A physiological index of Intelligence and a mechanism for sleep-dependent memory consolidation. *Neurosci Biobehav Rev*, 35(5), 1154–1165. <https://doi.org/10.1016/j.neubiorev.2010.12.003>
- Ghassemi, M., Moody, B., Lehman, L.-wei, Song, C., Li, Q., Sun, H., Westover, B., Clifford, G. (2018). You Snooze, you win: The PHYSIONET/computing in cardiology challenge 2018. *2018 Computing in Cardiology Conference (CinC)*. <https://doi.org/10.22489/cinc.2018.049>
- Guo, H., Di, Y., An, X., Wang, Z.,; Ming, D. (2022). A novel approach to automatic sleep stage classification using forehead electrophysiological signals. *Heliyon*, 8(12). <https://doi.org/10.1016/j.heliyon.2022.e12136>
- Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Johnson, J. M., Curtis, F., Durrant, S. J. (2022). Characterising the relationship between sleep stages and associated spectral power in diabetes. *Sleep Epidemiology*, 2, 100048. <https://doi.org/10.1016/j.sleep.2022.100048>
- Koyanagi, I., Tezuka, T., Yu, J., Srinivasan, S., Naoi, T., Yasugaki, S., Nakai, A., Taniguchi, S., Hayashi, Y., Nakano, Y.,; Sakaguchi, M. (2023). Fully automatic REM sleep stage-specific intervention systems using single EEG in Mice. *Neuroscience Research*, 186, 51–58. <https://doi.org/10.1016/j.neures.2022.10.001>
- Lu, C., Sun, C., Xu, Y., Chen, C., Li, Q. (2022). Polysomnography findings in preschool children with obstructive sleep apnea are affected by growth and developmental level. *International Journal of Pediatric Otorhinolaryngology*, 162, 111310. <https://doi.org/10.1016/j.ijporl.2022.111310>
- Martín-Montero, A., Armañac-Julián, P., Gil, E., Kheirandish-Gozal, L., Álvarez, D., Lázaro, J., Bailón, R., Gozal, D., Laguna, P., Hornero, R., Gutiérrez-Tobal, G. C. (2023). Pediatric sleep apnea: Characterization of apneic events and sleep stages using heart rate variability. *Computers in Biology and Medicine*, 154, 106549. <https://doi.org/10.1016/j.combiomed.2023.106549>
- Ngiam, J., Chen, Z., Bhaskar, S. A., Koh, P. W., Ng, A. Y. (2011). Sparse filtering. *Neural Information Processing Systems*, 24, 1125–1133. <https://papers.nips.cc/paper/4334-sparse-filtering.pdf>
- Nocedal, J., Wright, S. J. (2006). *Numerical optimization*. Verlag New York:Springer.
- Powers W., Ailab A. (2008). Evaluation: from precision, recall and f-measure to roc informed ness, markedness and correlation, *J. Mach. Learn. Technolgy*, 2, 2229-3981.
- Silber, M. H., Ancoli-Israel, S., Bonnet, M. H., Chokroverty, S., Grigg-Damberger, M. M., Hirshkowitz, M., Kapen, S., Keenan, S. A., Kryger, M. H., Penzel, T., Pressman, M. R., Iber, C. (2007). The visual scoring of sleep in adults. *Journal of Clinical Sleep Medicine*, 03(02), 121–131. <https://doi.org/10.5664/jcsm.26814>
- Stone, K. C., Taylor, D. J., McCrae, C. S., Kalsekar, A., Lichstein, K. L. (2008). Nonrestorative sleep. *Sleep Medicine Reviews*, 12(4), 275–288. <https://doi.org/10.1016/j.smr.2007.12.002>
- Subudhi A., Dash B. M., Sabut S. (2020). Automated segmentation and classification of brain stroke using expectation-maximization and random forest classifier. *Biocybernetics and Biomedical Engineering*, 40(1), 277-289. <https://doi.org/10.1016/j.bbe.2019.04.004> .
- Sünneci, K. M., Alkan, A. (2022). Lung cancer detection by using probabilistic majority voting and Optimization Techniques. *International Journal of Imaging Systems and Technology*, 32(6), 2049–2065. <https://doi.org/10.1002/ima.22769>
- Sünneci, K. M., Alkan, A. (2023). Biphasic majority voting-based comparative covid-19 diagnosis using chest X-ray images. *Expert Systems with Applications*, 216, 119430. <https://doi.org/10.1016/j.eswa.2022.119430>
- Šušmáková, K., 2004. Human sleep and sleep EEG, *Measurement in Biomedicine*, 4(2), 69-74.

- URL1:<https://medium.com/@gulcanogundur/do% C4% 9Fruluk-accuracy-kesinlik-precision-duyarl% C4% B11% C4% B1k-recall-ya-da-f1-score-300c925feb38>, (Eriřim Tarihi: 24 Aralık 2022).
- URL2: <https://ch.mathworks.com/help/stats/cvpartition.html> (Eriřim Tarihi:28.12.2022).
- URL3: <https://physionet.org/content/challenge-2018/1.0.0/> (Eriřim Tarihi:8.1.2023).
- URL4: <https://static1.squarespace.com/static/5459a5d0e4b09a5cc2e5497a/t/54f8d3dbe4b03ea829c7ef53> (Eriřim Tarihi:8.1.2023).
- Yaręı V., Postalcıoęlu S., (2021). EEG iřareti kullanılarak baęımlılıęa yatkınlıęın makine öğrenmesi teknikleri ile analizi. *El-Cezerê Journal of Science and Engineering*, 8(1), 142-154, DOI :10.31202/ecjse.787726. <https://dergipark.org.tr/en/download/article-file/1263790> .