



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 16.11.2022
Kabul Tarihi : 29.11.2022

Received Date : 16.11.2022
Accepted Date : 29.11.2022

OBSTRÜKTİF UYKU APNESİ TESPİTİNDE POLİSOMNOGRAFİYE ALTERNATİF YENİ YÖNTEMLER

NEW ALTERNATIVE METHODS TO POLYSOMNOGRAPHY IN THE DETECTION OF OBSTRUCTIVE SLEEP APNEA

İsrafil KARADÖL¹ (ORCID: 0000-0002-9239-0565)

¹Kilis 7Aralık Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektrik Ve Enerji Bölümü, Kilis, Türkiye

*Sorumlu Yazar / Corresponding Author: İsrafil KARADÖL, israfilkaradol@kilis.edu.tr

ÖZET

Son yıllarda beslenme alışkanlıklarına bağlı olarak ortaya çıkan aşırı kilo ve obeziteden dolayı obstrüktif uyku apnesinin yaygınlaştığı tahmin edilmektedir. Yaygınlaşan bu hastalığın tespit edilmemesi sonucunda felç, diyabet, kardiyovasküler bozukluk, sinir sistemi hastalıkları ve uykusuzluğa bağlı iş kazaları görülmektedir. Obstrüktif uyku apnesi teşhisinde kullanılan altın standart yöntem; uyku kliniklerinde yapılan polisomnografi testleridir. Polisomnografi testinde, kişi bir gece hastanede misafir edilerek fizyolojik sinyalleri izlenmektedir. Fakat bu süreç, maliyetli ve toplumun geneli için erişilebilir değildir. Bu çalışmanın amacı, polisomnografi testine alternatif olarak geliştirilen yeni yöntemleri incelemek ve bu yöntemlerin performanslarını değerlendirmektir. Yapılan inceleme ve değerlendirme sonucunda bir veya birkaç fizyolojik sinyal ile obstrüktif uyku apnenin tespit edilebileceği görülmüştür. Bu yöntemler hastaya temas gerektiren ve gerektirmeyen olarak sınıflandırılarak detaylı incelenmiştir. Sonuç olarak, obstrüktif uyku apne teşhisi için yapılan makaleleri mühendislik temelli değerlendirdiğimizde makine öğrenmesine dayalı derin öğrenmenin ön plana çıktığı görülmüştür. Ayrıca obstrüktif uyku apne tespiti için kullanılan diğer yöntemlere kıyasla, hastaya temas gerektirmeyen yöntemlerin yetersiz olduğu sonucuna ulaşılmıştır.

Anahtar Kelimeler: obstrüktif uyku apnesi, polisomnografi, fizyolojik sinyaller, sinyal işleme

ABSTRACT

In recent years, it is estimated that obstructive sleep apnea has become widespread due to excess weight and obesity due to dietary habits. As a result of not detecting this widespread disease, stroke, diabetes, cardiovascular disorder, nervous system diseases and work accidents due to insomnia are observed. The gold standard method used in the diagnosis of obstructive sleep apnea; are polysomnography tests performed in sleep clinics. In the polysomnography test, the person is kept in the hospital for one night and their physiological signals are monitored. But this process is costly and not accessible to the general public. The aim of this study is to investigate the new methods developed as an alternative to the polysomnography test and to evaluate the performance of these methods. As a result of the investigation and evaluation, it has been seen that obstructive sleep apnea can be detected with one or more physiological signals. These methods have been examined in detail by classifying them as requiring or not requiring patient contact. As a result, when we evaluated the articles for the diagnosis of obstructive sleep apnea on an engineering basis, it was seen that deep learning based on machine learning came to the fore. In addition, it was concluded that methods that do not require patient contact are inadequate compared to other methods used to detect obstructive sleep apnea.

Keywords: obstructive sleep apnea, polysomnography, physiological signals, signal processing

GİRİŞ

Gelişmiş toplumların en önemli özelliklerinden biriside iyi yetişmiş ve sağlıklı bireylerden oluşmasıdır. Bu toplumların birey sağlığına verdikleri önemden dolayı tıbbi teknolojiler öncelikli yatırım alanlarından birisidir. Tıbbi teknolojiler, birçok hastalığın tedavisinde ve teşhisinde önemli bir rol oynamaktadır. Bu alanda, tıbbi görüntüleme ve sinyal işleme büyük öneme sahiptir(Uçar, 2017). Tıbbi görüntüleme teknolojileri, sinyal işleme teknolojilerine göre basit yapıdadır. Fakat sinyal işleme teknolojileri karmaşık bir yapıya sahiptir bu nedenle genellikle matematiksel modeller kullanılarak teşhisler yapılmaktadır.

Uyku doğal bir dinlenme yöntemi olup insan yaşamının yaklaşık 1/3'ünü kapsamaktadır. Dolayısıyla uyku sırasında yaşanan sorunlar insan hayatını olumsuz yönde etkilemektedir(Dursunoğlu & Dursunoğlu, 2010). Uyku bozuklukları, Uluslararası Uyku Bozuklukları Sınıflandırması (International Classification of Sleep Disorders) tarafından, 7 farklı kategoriye ayrılmıştır(Mendonça et al., 2019). Uyku sırasında meydana gelen solunum bozuklukları, uyku bozukluğu hastalıkları içerisinde en yoğun görülen türdür. Uyku ile ilişkili solunum bozuklukları; obstrüktif (tıkayıcı) uyku apnesi, hipopne, santral (merkezi) uyku apnesi ve mikst uyku apnesidir. (Mendonça et al., 2019). Obstrüktif uyku apnesi; uyku sırasında ağız ve burun bölgesindeki dokuların sarkarak 10 saniye boyunca solunum yollarının kapanması olarak tanımlanmaktadır. Hipopne ise uyku sırasında ağız ve burun bölgesindeki dokuların sarkarak 10 saniye ve daha fazla süreyle, hava akışındaki %50'den daha azalma olarak tanımlanmaktadır(Gürüler, 2012). Santral uyku apnesi; beyin tarafından otomatik olarak kontrol edilen kas hareketlerinin (göğüs kafesi ve diyafram) durması veya yavaşlaması sonucundaki yetersiz solunum olarak tanımlanmaktadır(Geçkil, 2022). Mikst uyku apnesi; santral uyku apnesi ile başlayarak obstrüktif uyku apnesi ile devam eden apne çeşididir(Karamustafaoğlu, Akan & Saatçi, 2014). Uykudaki solunum bozuklukları arasında en sık karşılaşılan apne çeşidi, obstrüktif uyku apne (OUA)'dir.

Uyku esnasındaki solunum bozukluğunun şiddeti, uyku saati başına ortalama obstrüktif apne ve hipopne sayısı olarak hesaplanan Apne-Hipopne İndeksi (AHİ) ile belirlenmektedir. Eğer saatteki apne sayısı $5 < AHİ < 15$ hafif, $15 < AHİ < 30$ orta ve $30 < AHİ$ ise şiddetli OUA olarak tanımlanmaktadır(Leppänen et al., 2017; Senaratna et al., 2017). Bir hastanın OUA olarak tanımlanabilmesi için AHİ indeksi orta veya şiddetli gurubunda yer almalıdır. OUA'nın, cinsiyete göre görülme sıklığı incelendiğinde erkeklerde yaş guruplarına göre 30-49 ve 50-70 aralıklarında sırasıyla %10 ve %17'dir(Leppänen et al., 2017; Senaratna et al., 2017). Kadınlarda ise OUA'nın görülme sıklığı 30-49 yaş arasında %3, 50-70 yaş arasında ise %9'dur. Bu sonuçlara göre hastalığın erkeklerde görülme ihtimali daha yüksektir. OUA'nın en genel belirtileri uyku sırasında horlama ve solunum tıkanmasına bağlı sık uyanmalar olarak gösterilmektedir(Yıldız, 2021). OUA hastalarının kaliteli bir uyku geçirmemeleri hem psikolojik hem de fiziksel olarak kişilerin günlük hayatını olumsuz etkilemektedir. Ayrıca bu hastalar da zamanla kalp ile ilgili problemler ortaya çıkmakta ve hatta uyku sırasında ölümler görülebilmektedir.

OUA tespitinde kullanılan altın standart yöntem olarak polisomnografi kabul edilmektedir. Polisomnografide gece boyunca hastaların nefes hava akışı, solunum hareketleri (göğüs kafesi ve diyafram hareketleri), horlama ses sinyalleri, oksijen doygunluğunu (SpO₂), elektroensefalogramı (EEG), elektrookülogramı (EOG), elektromiyografisi (EMG), elektrokardiyogramı (EKG) ve vücut pozisyonları kayıt altına alınmaktadır. Kayıt altına alınan bu veriler önceleri uyku konusunda uzmanlaşmış doktorlar tarafından yorumlanarak teşhisler koyulmaktaydı. Fakat son yıllarda tıp elektroniği alanındaki birçok gelişme meydana gelmiştir. Polisomnografi verileri, sinyal işleme ve yapay zeka metotları kullanılarak OUA hastalarına otomatik teşhis koyulmaktadır(Nguyen et al., 2022).

Polisomnografi test sonuçlarının son teknolojiler sistemler ile yorumlanması ve teşhis edilmesi doktorlar açısından büyük kolaylık sağlamaktadır. Fakat aynı teknolojik gelişmeler polisomnografi testlerine giren kişilere çok fazla kolaylık getirmemiştir. Çünkü bu testlere giren kişiler gece boyunca hastane ortamında uyumak zorundadır. Ayrıca uyumadan önce teste giren kişilerin fizyolojik ölçümlerinin gerçekleştirilmesi amacıyla vücuduna birçok kablo bağlantısı yapılmaktadır. Bu durumlardan dolayı kişiler uyumakta zorluk çekmekte ve bazı durumlarda polisomnografi testinin tekrar edilmesi gerekmektedir. Bu test sürecinin sürekli olarak bir teknisyen tarafından gözlem gerektirmesi süreci pahalı kılmaktadır. Ayrıca tüm hastalara yetecek kadar yeterli klinik bulunmaması hastaların uzun süreler beklemesine neden olmaktadır. Polisomnografi testlerinin hasta üzerindeki bu dezavantajlarından dolayı son yıllarda daha az fizyolojik parametre ile hastanın kendi kendine evinde rahatça uygulayabileceği yöntemler araştırılmıştır(Kapoor & Greenough, 2015). Araştırmalar sonucunda uyanırken veya

hastaya herhangi bir temas gerektirmeden OUA teşhis edilebileceği görülmüştür. Yapılan bu çalışmada OUA teşhisi için önerilen yöntemler gözden geçirilerek, başarıları ve uygulama kolaylıkları değerlendirilmiştir.


Bu çalışma 5 bölümden oluşmaktadır. Giriş bölümünde yapılan çalışma hakkında genel bilgilendirme yapılarak yapılan çalışmanın ana hatları ayrıntılı olarak verilmiştir. Metot bölümünde yapılan derleme çalışması için incelenen dergiler ve kullanılan anahtar kelimeler verilmiştir. Hastaya temas gerektiren obstrüktif apne tespit yöntemleri başlığı altında, polisomnografi testlerine alternatif olarak geliştirilen elektrokardiyograma dayalı, oksijen saturasyonuna dayalı, nazal hava akısına dayalı ve diğer yöntemler incelenmiştir. Hastaya temas gerektirmeyen obstrüktif apne tespit yöntemleri başlığı altında mikrofona, video ve kızılötesi algılamaya ve biyo-radara dayalı yöntemler incelenmiş ve performansları değerlendirilmiştir. Sonuç bölümünde yapılan incelemeler sonucunda elde edilen bulgular detaylı olarak yorumlanmış ve OUA tespitindeki literatürdeki son gelişmeler yorumlanmıştır.

METOT

Bu derleme 2006-2023 yılları arasında yayınlanan makaleleri kapsamaktadır. Bu yıllar arasındaki yayın taraması için Web of Science, PubMed, IEEE Explorer, IEEE, ScienceDirect ve çeşitli dergilerde yapılan literatür incelenmiştir. Aramayı yapmak için Google Akademikte kullanılan anahtar kelimeler “obstrüktif uyku apnesi”, “elektrokardiyogram ile obstrüktif uyku apnesi”, “oksijen saturasyonu ile obstrüktif uyku apnesi”, “nazal hava akışı ile obstrüktif uyku apnesi”, “obstrüktif uyku apnesi teşhisi”, “ses ile obstrüktif uyku apnesi”, “video ile obstrüktif uyku apnesi”, “kızılötesi ile obstrüktif uyku apnesi” ve “radar ile obstrüktif uyku apnesi”dir. Anahtar kelimelere göre bulunan bu makalelerin, tam makale incelemesi için uygun olanları seçmek amacıyla makale başlıkları ve özetleri tarandı. Daha sonra polisomnografi testleri için yapılan çalışmalar elendi. Kalan toplam 74 orijinal araştırma makalesi bu kriterleri karşıladı ve tam metin olarak detaylı bir şekilde incelendi. Bu kriterlere göre belirlenen makaleler hastaya temas gerektiren ve hastaya temas gerektirmeyen olarak 2 guruba ayrıldı. Hastaya temas gerektiren yöntemler kendi içinde elektrokardiyograma dayalı, oksijen saturasyonuna dayalı, nazal hava akısına dayalı ve diğer yöntemler olarak 4 guruba ayrıldı. Hastaya temas gerektirmeyen yöntemler ise mikrofona, video-kızılötesi algılamaya ve biyo-radara dayalı olmak üzere 3 guruba ayrıldı. Guruplara ayrılan eserlerde kullanılan yöntemler detaylı olarak incelendi ve bu eserlerin OUA belirlemedeki performansları değerlendirildi.

HASTAYA TEMAS GEREKTİREN OBSTRÜKTİF APNE TESPİT YÖNTEMLERİ

İlk olarak literatürdeki çalışmaları değerlendirdiğin de OUA tespiti için polisomnografi testlerinin ev ortamına taşımak istendiği görülmektedir(Kapoor & Greenough, 2015). Fakat Polisomnografi testlerinin sağladığı uyku evrelerinin belirlenmesi ve hastalıkların teşhisinin ev ortamında mümkün olmadığı görülmüştür. Bu nedenle literatür çalışmaları daha çok polisomnografi terslerindeki bazı fizyolojik özellikleri kullanarak OUA tespitine yönelmişlerdir. Bu alanda 41 tane çalışma yapılmıştır. Yapılan araştırmaların yıllara göre dağılımları Şekil 1’de verilmiştir. Hastaya temas gerektiren çalışmalar elektrokardiyograma dayalı, nabız oksimetresine dayalı, nazal hava akısına dayalı ve diğer yöntemler olarak alt başlıklara ayrılmıştır.



Şekil 1. Hastaya Temas Gerektiren Makalelerin Yıllara Göre Dağılımı

Elektrokardiyograma Dayalı

Literatür taramalarında kardiovasküler parametrelerin kullanılarak daha ucuz ve basit şekillerde OUA tespit edilebileceği görülmüştür. Bu alanda tek girişli EKG sinyali kullanarak makine öğrenmesi yöntemi ile OUA belirlenmesi üzerine birçok çalışma mevcuttur (Bozkurt et al., 2020; Chen et al., 2021, 2022; Li et al., 2018; Sani, 2021; Sharma, Agarwal & Acharya, 2018; Zarei & Asl, 2019). Sürrel vd. (2018), tek kanallı bir EKG kaydı kullanarak 1'er dakikalık aralıklarla otomatik ölçüm yapan elektronik devre tasarlamışlar ve bu tasarımı giyilebilir elbiseye monte etmişlerdir. Yapılan bu tasarım performans açısından değerlendirildiğinde, %88,2 doğruluk, %80,0 duyarlılık ve %93,9 özgüllüğe sahiptir. Lin vd. (2022), OUA algılamak için makine öğrenmesi tabanlı ve EKG sinyallerinden türetilen özellikler çantası (BoF) kullanan bir algoritma önerdi. Bu çalışmada sınıflandırma ve özellik çıkarma için bazı makine öğrenme yaklaşımları kullanılmıştır. Yapılan çalışmanın 0,1-50 Hz ve 8-50 Hz frekans bantları için doğrulukları sırasıyla %90,5 ve %91,4 olarak hesaplanmıştır. Yeh vd. (2022), EKG sinyalini işleyerek OUA saptamak için tek boyutlu bir CNN modeli önermişlerdir. Önerilen yaklaşım %87,9 doğruluk göstermiştir. Mısra vd. (2022), EKG sinyalini işleyerek OUA saptamak için tek boyutlu bir CNN modelinde 1-D kanal dikkat evrişim sinir ağı tasarımı önerdi. Önerilen modelin OUA tespiti için doğruluğu %93,01, özgüllüğü %93,10 ve duyarlılığı %92,93'tür. Li vd. (2018), tek uçlu bir EKG sinyali kullanarak OUA'yı tespit etmek için derin öğrenme sinir ağı ve gizli markov modelini kullanan hibrit bir yöntem önerdi. Önerilen yöntem, segment başına OUA tespiti için %85 doğruluk ve duyarlılık için %88,9 göstermiştir. Sheta vd. (2021), derin öğrenme ve makine öğrenmesi kullanarak tek girişli EKG sinyali ile OUA tespiti üzerine yeni bir yaklaşım önerdi. Önerilen metodun OUA belirlemede %86,25 doğruluk elde edilmiştir. Cao ve Lv (2022), tek girişli EKG sinyali ile tek boyutlu çok görevli öznelik füzyon evrişimli sinir ağına dayalı bir OUA algılama yöntemi önerdi. Önerilen yöntemin doğruluğu, duyarlılığı ve özgüllüğü sırasıyla %91,93, %90,32 ve %91,63 hesaplanmıştır.

Nabız Oksimetresine Dayalı

Bireylerin solunumunda görülen ani değişimler, doğrudan kalp ve damar sisteminde takip edilebilecek değişimler oluşturmaktadır. Kalp ve damar sistemindeki bu değişimler yaygın olarak nabız oksimetresi ile takip edilmektedir. Nabız oksimetresi, parmağa yerleştirilen bir sensör ile kandaki oksijen saturasyonunu (SpO2) ölçülerek hastanın arteriyel oksijen saturasyonunu analiz etmektedir. OUA tespiti amacıyla bu yöntem yaygın olarak kullanılmaktadır (Hairston, 2017; Sharma, Kumbhani, Tiwari, et al., 2022; Sharma, Kumbhani, Yadav, et al., 2022). Vaquerizo-Villar vd. (2022), nabız oksimetre sinyalleriyle beslenen CNN tabanlı bir derin öğrenme modeli önerdi. Önerilen modelin doğruluk performansı %83,1'dir. Literatürde Makine öğrenmesi tabanlı benzer çalışmalar mevcuttur (Gutiérrez-Tobal et al., 2021; Leino et al., 2021; Paul et al., 2022; Vaquerizo-Villar et al., 2021). Zhu vd. (2022), elektrokardiyogram ve kan oksijen saturasyon sinyallerindeki apne olaylarını belirlemek amacıyla çapraz doğrulama algoritması ve rastgele orman sınıflandırıcısı ile öz yinelenmeli öznelik eleme yöntemi önerdi. Önerilen metod, OUA teşhisinde %97,5 doğruluk, %95,9 duyarlılık, %98,4 özgüllük göstermiştir. Jiménez-García vd. (2022), OUA tespiti için hava akımı ve oksimetre sinyallerini kullanan 2 boyutlu CNN derin öğrenme algoritması önerdi. Önerilen metod, OUA teşhisinde %84,10 ile %90,26 arasında doğruluğa sahiptir. Gutiérrez-Tobal vd. (2021), oksimetre sinyallerini kullanarak LSBoost tabanlı bir makine öğrenmesi modeli ile OUA tespiti önerdi. Önerilen modelin hafif, orta ve şiddetli OUA teşhisindeki doğrulukları sırasıyla %87,2-96,6, %81,1-%87,6 ve %91,6-94,6 aralığında değişkenlik göstermiştir.

Nazal Hava Akışına Dayalı

Solunumla ilgili polisomnografi parametrelerinden nazal hava akımı sinyali OUA tespitinde büyük önem arz etmektedir (Ciolek et al., 2015; de Almeida et al., 2006; Gutierrez-Tobal et al., 2016). Bu alanda Jin ve Sanchez-Sinencio (2015), nazal hava akışını ölçmek için dönüştürücü olarak bir mikro-elektro-mekanik sistemli basınç sensörü ile apne algılama algoritmasına dayalı yöntem önerdi. Önerilen yöntem OUA teşhisinde %100 duyarlılık ve %85,9 özgüllük göstermiştir. Yan vd. (2022), nazal hava akımı sinyallerini makine öğrenmesi yöntemleri (karar ağacı, rastgele orman (RF) ve XGBoost) ile sınıflandırarak OUA teşhisini önerdi. Önerilen metod OUA tespitinde %82,76 doğruluk ve %85,97 hassasiyete sahiptir. Kumar vd. (2016), nazal hava akışını ölçmek için dönüştürücü olarak bir mikro-elektro-mekanik sistemli basınç sensör tasarımı önerdi. Önerilen basınç sensörü ile hava akışına göre ileriki çalışmalarda OUA teşhis edilebileceği vurgulanmıştır. Han vd. (2008), OUA olaylarının tespiti için nazal hava akışı sinyalinin 2. türevlerinin ortalama büyüklüğüne bakılan yeni bir algoritma önerdi. Önerilen algoritma 21 PSG test setine uygulanmış ve %92'lik doğruluk performansı göstermiştir. Huang vd. (2017), nazal hava akışı sinyalinin sistematik ve düzensiz gürültüsünü ortadan kaldırmak için kayan pencere ve kısa zaman dilimi yöntemlerini kullanan bir algoritma önerdi. Önerilen algoritma OUA tespitinde %97,6 duyarlılığa sahiptir. Selvaraj ve Narasimhan (2013), nazal hava akımı solunum sinyalinin filtrelenmesine ve istatistiksel dağılımına dayalı


özellikleri çıkaran ve apne olaylarını saniye bazında tespit eden yeni bir algoritma önerdi. Önerilen metottun duyarlılık ve pozitif prediktif değer sırasıyla %83,6 ve %72,3 olarak bulunmuştur. Yue vd. (2021), nazal basınç hava akımı sinyallerini otomatik olarak algılamak için derin öğrenme artık ağ temelinde çok çözünürlüklü artık ağ (Mr-ResNet) adı verilen yeni bir model önerdi. Önerilen modelin duyarlılığı, özgüllüğü ve doğruluğu sırasıyla %90,8, %90,5 ve %91,2 olarak bulunmuştur.

Diğer Yöntemler

Bazı araştırmacılar OUA tespiti için hastaya doğrudan temas gerektirmeyen çeşitli sensörler geliştirmiş ve kullanmışlardır. Mack vd. (2006), balistokardiyografiye (BCG) dayalı fizyolojik sinyallerin analizi için solunum süreciyle ilgili vücut hareketini tespit eden invazif olmayan bir sistem önerdi. Önerilen bu sistem apnelerin saptanmasında %89,2 duyarlılık ve %94,6 özgüllük elde etmiştir. Penzel ve Sabil (2017), trakeal ses sensörleri kullanılarak vücut yüzeyi titreşimleri ile OUA tespiti önerdi. Kalkbrenner vd. (2018), OUA tespiti için trakeal ses ve hareket verilerinin kaydedilmesine dayalı bir sinyal işleme yöntemi önerdi. Önerilen yöntem OUA tespitinde %92,8'lik duyarlılıkta ve %99,7'lik özgüllüktedir. Shin vd. (2010), BCG'ye dayalı bir dengeleme tüpüne sahip bir hava yatağı tasarlamışlar ve her nefes yoğunluğuna göre elde edilen elektriksel sinyali otomatik olarak normal, uyarılma veya apne olarak sınıflandıran bir algoritma önermişlerdir. Önerilen metodun OUA teşhisindeki duyarlılık ve pozitif tahmini sırasıyla %93 ve %88'dir. Hwang vd. (2014), çıkış sinyali solunum fazlarına göre değişen poliviniliden florür film tabanlı sensör bulunduran yatak şiltesi önerdi. OUA'yı saptamak için solunum sinyalinin standart sapmasına göre bir eşik uyguladı. Önerilen yöntem dakika OUA tespiti için ortalama %72,9 duyarlılık, %90,6 özgüllük, %85,5 doğruluğa sahiptir. Nakano vd. (2019), trakeal ses kayıtlarını kullanarak konvolüsyonel katmanlara sahip derin sinir ağı ile OUA sınıflandırılmasını ve tespitini önerdi. Önerilen metodun OUA tespitindeki tanısal duyarlılık ve özgüllüğü sırasıyla %92 ve %76'dır. Moradhasel vd. (2023), derin öğrenme ile ilk defa çene elektromiyogram spektromlarının sınıflandırılması kullanarak OUA teşhis etmeyi önerdi. Önerilen metod %99 doğrulukta sonuçlanmıştır. Shen vd. (2022) tek boyutlu, çok görevli, çok dikkatli artık büzülme evrişim sinir ağı (1D-MMRsNet) modeline ve maliyete duyarlı sınıflandırıcıya dayalı giyilebilir bileklik fotopleitismografi ile OUA tespiti önerdi. Önerilen metodun doğruluk, duyarlılık ve özgüllüğü sırasıyla %95,65, %88,89 ve %97,30 olarak belirlenmiştir.

HASTAYA TEMAS GEREKTİRMEYEN OBSTRÜKTİF APNE TESPİT YÖNTEMLERİ

Polisomnografi klinik uygulamalarında altın standart yöntem olarak kabul edilmektedir (Haidar et al., 2020). Bu teknikte, kalp hızı, solunum, oksijen saturasyonu ve uyku durumu gibi birçok fizyolojik sinyal gece boyunca kaydedilmektedir. Bu yöntemin doğru tanı sağlayabilmesine rağmen kullanımıyla ilgili hala bazı zorluklar mevcuttur (Setiawan & Lin, 2022). Polisomnografi testlerinin, uzun süreli (bir gece) klinik ortamında gerçekleştirilmesi bu terslerin hastalar için erişilebilir olmasını engellemekte ve maliyeti arttırmaktadır. Ayrıca ölçüm sürecinde çeşitli fizyolojik verilerin toplanması, vücuda birden fazla sensör takılması gerekir, bu da denekler için rahatsızlığa neden olmaktadır. Bu nedenlerden polisomnografi testine alternatif olarak geliştirilen yeni yöntemler araştırılmıştır. Yapılan literatür taramalarında hastaya herhangi bir temas olmadan obstrüktif apnenin tespit edilebileceği görülmüştür. Bu alanda 33 tane çalışma yapılmıştır. Yapılan araştırmaların yıllara göre dağılımları Şekil 2'de verilmiştir. Hastaya temas gerektirmeyen yöntemler; mikrofona, video ve kızılötesi algılamaya ve biyo-radara dayalı olmak üzere 3 alt başlıkta incelenmiştir.



Şekil 2. Hastaya Temas Gerektirmeyen Makalelerin Yıllara Göre Dağılımı

Mikrofona Dayalı Yöntemler

OUA genel olarak horlama ile birlikte görülmektedir. Bu nedenle mikrofona dayalı yöntemler, uyku ile ilgili hastalıkların teşhis ve tedavi takibi için önemli bir yere sahiptir. Kim vd. (2019), uyku sırasında duvara monte edilmiş mikrofona sesleri kaydetmiş ve kaydedilen sesleri lojistik regresyon ile sınıflandırarak OUA tespiti için önerdi. 3 farklı yaş gurubu üzerinde yapılan çalışmanın yaş guruplarına göre ortalama doğruluk, duyarlılık ve özgüllüğü sırasıyla %84, %76 ve %82'dir. Dafna vd. (2013), OUA tespiti için amaçla horlama olan ve horlama olmayan sesleri yoğunlaştırıcı mikrofona kaydedilen sesleri makine öğrenmesi tabanlı AdaBoost ile sınıflandırmayı önerdi. Önerilen metodun horlama olan ve horlama olmayan sesleri sınıflandırmasındaki doğruluk oranı %98,4 olarak elde edilmiştir. Ben-Israel vd. (2012), temassız bir mikrofona kaydedilen horlama sinyallerini gauss karışım modeli kullanarak sınıflandıran horlama analiz algoritması önerildi. Önerilen metod horlama doğruluğu %87 ila %92 arasında değişkenlik göstermiştir. Zhang vd. (2018), temassız mikrofona kaydedilen akutik sesleri makine öğrenme modelinde işleyerek uyku aşamalarını tespit etmek amacıyla spektrogram ve mel-frequency cepstral cofactor öznelik çıkarma yaklaşımlarını kullanmayı önerdi. Önerilen metod OUA tespiti için önemli bir yere sahip olan uyku aşamalarını belirlemede %70,59 doğruluğa ulaşmıştır. Xue vd. (2020), mikrofona kaydedilen akutik sesleri kanonik korelasyon analizi ile Relief-F algoritması kullanarak işlemiş ve makine öğrenme metoduyla (karar ağacı, destek vektör makineleri, K-en yakın komşu ve topluluk sınıflandırıcı kullanarak) uyku aşamalarını tespit etmeyi önermiştir. Önerilen metod uyku aşamalarını belirlemede %75,2 doğruluk performansına sahiptir. Karunajeewa vd. (2011), horlama sesleriyle OUA tespiti için yüksek dereceli istatistiklere dayalı algoritma kullanılarak türetilen horlama parametreleriyle beslenen bir lojistik regresyon modeli önerdi. Önerilen metod, %92,3 doğruluk, %89,3 hassasiyet ile apnesi olan ve olmayan kişileri ayırabilmiştir. Sola-Soler vd. (2007), OUA olan hastaları sınıflandırmak için bir lojistik regresyon modelini önermiş ve önerilen modelde %93'ten daha yüksek bir duyarlılık elde etmiştir. Kang vd. (2018), horlama, apne ve sessizlik olaylarını tespit etmek için doğrusal tahmin kodlama ve mel-frekans cepstral katsayı özelliklerini kullanan hibrit bir sinir ağı önerdi. Önerilen yöntemin doğruluğu; horlama, apne ve sessizlik olaylarının tespiti için sırasıyla %90,65, %90,99 ve %90,30 olarak hesaplanmıştır. Hou vd. (2021), uyku sırasında mikrofona kaydedilen horlama sesini dikdörtgen bant genişliği korelasyon boyutunda değerlendirmeyi önerdi. Önerilen metod OUA şiddet düzeylerinin tanısında %87,5 doğruluk göstermiştir. Ding vd. (2023), horlama seslerini sınıflandırarak, apne-hipopne horlamalarını saptamak için önceden eğitilmiş hibrit VGG19 ve uzun kısa süreli bellek (LSTM) modeli önerdi. Lui vd. (2022), horlama seslerinin mel-frekans cepstral katsayılarına dayalı akustik özelliklerini çıkardı. Akustik özellikleri çıkarılan seslerin sınıflandırması için makine öğrenmesi temelli en yakın komşu (KNN) metodunu önerdi. Önerilen metod 42 hasta üzerinde denenmiş ve %85,5'lik doğruluk performansı göstermiştir. Lin vd. (2022), OUA tespiti için horlama sesinin mel-filtre bankasında öznelikleri çıkarmayı ve hibrit derin sinir ağı ile sınıflandırmayı önerdi. Önerilen yöntemin OUA tespiti için ortalama sınıflandırma doğruluğu %74,27 olarak hesaplanmıştır.

Şu ana kadar incelenen tüm çalışmalar gece boyunca kaydedilen parametrelerin analizine dayanmıştır. Bu duruma alternatif olarak bazı araştırmacılar solunum sistemiyle eşgüdümlü olarak çalışan ses üretim sisteminin apneden etkilenebileceğini varsayımlardır. Bu amaçla kişi uyanırken alınan ses kayıtlarını incelemişlerdir. İncelemeler sonucunda; Pozo vd. (2009), konuşma spektrumlarındaki gauss karışım modeli örüntü tanınmasını kullanarak nazal ve nazal olmayan sesli harfleri modelleyerek OUA tespiti için önerdi. Önerilen yöntem şiddetli apne tespitinde %81'lik doğru sınıflandırma performansı göstermiştir. Ruby vd. (2018), OUA tespiti için konuşma seslerini çeşitli sınıflandırıcılar içeren yapay sinir ağına işlemeyi önerdi. Önerilen sistem konuşma sesleriyle OUA teşhiste %76,5 doğruluk performansı göstermiştir. Botelho vd. (2019), konuşma seslerini çeşitli makine öğrenimi algoritmaları ile sınıflandırarak OUA tespiti için önerdi. Önerilen yöntem doğruluğu %75 ile %84,4 arasında değişkenlik göstermiştir. Ding vd. (2021), aynı yöntemle fakat farklı sınıflandırıcılar kullanarak OUA tanımlamada %78 doğruluk elde etmişlerdir. Ruby vd. (2020), Konuşma seslerini lineer bir regresyon kullanarak sınıflandırmayı önerdi. Önerilen yöntem %77,14 doğruluk performansı göstermiştir. Pang vd. (2020), konuşma seslerinden OUA şiddet sınıflandırması için ikinci dereceden diskriminant analizi sınıflandırıcısını önerdi. Önerilen parametrelerle %85 ile %95,4 arası doğruluk performansı göstermiştir.

Video Ve Kızılötesi Algulamaya Dayalı Yöntemler

Solunum aktivitesi, insanlarda sağlık durumunu değerlendirmek için kritik öneme sahiptir. Solunum hızı (RR) önemli bir yaşamsal işarettir. Normal RR, istirahat halindeki sağlıklı yetişkinlerde 12-20 nefes/dakika arasında değişirken, bu aralığın dışındaki RR, konjestif kalp yetmezliği gibi olaylarla güçlü bir şekilde ilişkilidir (Flenady,

Dwyer & Applegarth, 2017). Ayrıca, solunum aktivitesinin izlenmesi, obstrüktif uyku apnesi teşhis etmek için de kullanılmaktadır. Scebbia vd. (2021), OUA'yı tespit etmek için multispektral kameralar ile RR'yi tahmin etmeyi amaçlayan multispektral veri füzyonuna dayalı yeni bir algoritma önerdi. Önerilen metodun F1 sınıflandırması 0,75 ile 0,86 aralığında değişkenlik göstermiştir. Jayatilaka vd. (2019), video işleme ile bebeklerde uyku apnesini tespit etmek için canny kenar eşik algoritması ile yapay sinir ağı kullanan bir model önerdi. Önerilen metod RR'yi algılamada %86 doğruluğa sahiptir. Lorato vd. (2021), yüz/vücut işaretlerine dayalı olmayan otomatik bir solunum akışı piksel dedektörü ile gabor filtresinin birleştirildiği otomatik OUA teşhis yöntemi önerdi. Önerilen metod OUA algılanmasında %73 hassasiyet göstermiştir. Zhu vd. (2019), kızılötesi videodan çıkarılan solunumla ilgili hareket özelliklerini rastgele orman algoritması ile sınıflandıran bir metod önerdi. Önerilen yöntemin doğruluk ve hassasiyeti sırasıyla %76 ve %80'dir. Akbarian vd. (2020, 2021), OUA teşhisi için kızılötesi videosunu analiz eden, 3B evrişimli sinir ağı (CNN) mimarisine sahip bir derin öğrenme algoritması önerdi. Önerilen metod OUA teşhisi için %86 doğruluk performansı göstermiştir. Zhu vd. (2019), kızılötesi video kayıtlarının hareket analizine dayalı bir algoritma önerdi. Önerilen algoritma, uyuyan her katılımcıda seçilen özellik noktalarının yer değiştirmelerini izlenmesine, ana bileşen analizini kullanarak solunum hızını hesaplanmasına ve bağımsız bileşen analizini kullanarak kalp atış hızının hesaplanmasını olanak sağlamıştır. Önerilen metod solunum hızı tahmininde %89,9 performans göstermiştir. Veauthier vd. (2019), üç boyutlu görsel verileri makine öğrenmesi yaklaşımıyla sınıflandırarak OUA tespit edilmesini önerdi. Önerilen metod OUA tespiti için %90 duyarlılık göstermiştir.

Biyomedikal Radara Dayalı Yöntemler

Biyomedikal radar, yaşamsal belirti algılama uygulamaları için geliştirilmiştir. Bu radarlarla gerçekleştirilen temassız ölçümler, kişileri mevcut uyku izleme cihazlarında kullanılan ek elektrotlardan kurtarır. Ayrıca mikrodalgaların yüksek hassasiyeti ve doğruluğu, uyku sırasında küçük hayati belirtileri ve vücut hareketi değişikliklerini yakalama yeteneğini sağlar. Zhuang vd. (2022), frekans modülasyonlu sürekli dalga radarına dayalı OUA tespit yöntemi önerdi. Önerilen metotta verileri sınıflandırılması için makine öğrenimi yöntemleri kullanılmıştır. Önerilen metod OUA tespitinde %95,53 doğruluk, %72,60 duyarlılık ve %97,32 özgüllüğe sahiptir. Toften vd. (2021), uyku apnesi olaylarını yapay sinir ağına karışıklık matrisi ile sınıflandırmak için somnofy (radar tabanlı uyku monitörü) ve nabız oksimetresini birleştirmeyi önerdi. Önerilen metod doğrulanmasında 0.81'lik bir Cohen kappa değeri elde edilmiştir. Abdul vd. (2015), 4.2 GHz impulse radyo ultra geniş bant IR-UWB radar sistemi ve lineer diskriminant sınıflandırıcı ile OUA teşhisini önerdi. Önerilen metod apne ve normal dönemlerin tespitinde yaklaşık %70'lik bir doğruluğa sahiptir. Koda vd. (2015), OUA otomatik olarak algılamak için radar verilerine bir destek vektör makinesi algoritması uygulamayı önerdi. Önerilen yaklaşımda %79.5 doğruluk ve %71,2 hassasiyet elde edilmiştir. İslam vd. (2020), OUA otomatik olarak algılamak üç farklı makine öğrenimi sınıflandırıcısıyla entegre temassız doppler radar sistemi önerdi. Önerilen yaklaşım 5 hasta üzerinde %93,75 doğruluk performansı göstermiştir.

SONUÇ

Polisomnografi testlerine alternatif olarak literatürde birçok çalışma yapılmıştır. Bu alanda polisomnografiye alternatif olarak vücut pozisyonu, oksijen saturasyonu, elektromiyogram ve elektroensefalogram gibi fizyolojik sinyallerden biri veya birkaçı ile apne teşhisine yönelik birçok araştırma yapılmıştır. Bu çalışmalar içerisinde yer alan hastaya temas gerektiren yöntemler genel olarak %90 ve üzerinde doğruluk performansı göstermiştir. Bu yöntemlerde hastanın kendi kendine kayıt yapması ve hastaya temas gerektirmesi ölçümde bazı zorluklara neden olmuştur. Bu sorunun üstesinden gelmek amacıyla OUA tespiti için hastaya temas gerektirmeyen yöntemler önerilmiştir. Önerilen yöntemler genel olarak %85 ve üzerinde doğruluk performansı göstermiştir. Tüm bu ölçüm uyku sırasında gerçekleştirilmektedir. Bu duruma alternatif olarak, kişi uyanırken birkaç dakikalık konuşma sesi ile apnenin tespit edildiği çalışmalar yapılmıştır. Yapılan bu çalışmalar genel olarak %70-%80 arasında doğruluk performansı göstermiştir. Sonuç olarak hastaya temas gerektirmeyen yöntemlerin yetersiz olduğu görülmüştür. Ayrıca konuşma ile OUA sınıflandırılması ve tespit edilmesindeki doğruluk performansının artırılması gerektiği sonucuna varılmıştır. İleriki çalışmalarda, literatürde eksiklikleri giderebilmek için hastaya temas gerektirmeyen OUA tespiti yöntemleri üzerine çalışmalar yapılması öngörülmektedir.

KAYNAKLAR

Akbarian, S., Ghahjaverestan, N. M., Yadollahi, A., & Taati, B. (2020). Distinguishing Obstructive Versus Central Apneas in Infrared Video of Sleep Using Deep Learning: Validation Study. *Journal of Medical Internet Research*, 22(5), 1–14. <https://doi.org/10.2196/17252>

- Akbarian, S., Ghahjaverestan, N. M., Yadollahi, A., & Taati, B. (2021). Noncontact Sleep Monitoring With Infrared Video Data to Estimate Sleep Apnea Severity and Distinguish Between Positional and Nonpositional Sleep Apnea: Model Development and Experimental Validation. *Journal of Medical Internet Research*, 23(11), e26524. <https://doi.org/10.2196/26524>
- Ben-Israel, N., Tarasiuk, A., & Zigel, Y. (2012). Obstructive apnea hypopnea index estimation by analysis of nocturnal snoring signals in adults. *Sleep*, 35(9), 1299–1305. <https://doi.org/10.5665/sleep.2092>
- Botelho, M. C., Trancoso, I., Abad, A., & Paiva, T. (2019, May). Speech as a biomarker for obstructive sleep apnea detection. In ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 5851-5855). IEEE.
- Bozkurt, F., Uçar, M. K., Bozkurt, M. R., & Bilgin, C. (2020). Detection of Abnormal Respiratory Events with Single Channel ECG and Hybrid Machine Learning Model in Patients with Obstructive Sleep Apnea. *Irbm*, 41(5), 241–251. <https://doi.org/10.1016/j.irbm.2020.05.006>
- Cao, K., & Lv, X. (2022). Multi-task feature fusion network for Obstructive Sleep Apnea detection using single-lead ECG signal. *Measurement: Journal of the International Measurement Confederation*, 202(March), 111787. <https://doi.org/10.1016/j.measurement.2022.111787>
- Chen, X., Chen, Y., Ma, W., Fan, X., & Li, Y. (2021, December). SE-MSCNN: A Lightweight Multi-scaled Fusion Network for Sleep Apnea Detection Using Single-Lead ECG Signals. In 2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM) (pp. 1276-1280). IEEE.
- Chen, X., Chen, Y., Ma, W., Fan, X., & Li, Y. (2022). Toward sleep apnea detection with lightweight multi-scaled fusion network. *Knowledge-Based Systems*, 247. <https://doi.org/10.1016/j.knosys.2022.108783>
- Ciolek, M., Niedzwiecki, M., Sieklicki, S., Drozdowski, J., & Siebert, J. (2015). Automated detection of sleep apnea and hypopnea events based on robust airflow envelope tracking in the presence of breathing artifacts. *IEEE Journal of Biomedical and Health Informatics*, 19(2), 418–429. <https://doi.org/10.1109/JBHI.2014.2325997>
- Dafna, E., Tarasiuk, A., & Zigel, Y. (2013). Automatic detection of whole night snoring events using non-contact microphone. *PLoS ONE*, 8(12). <https://doi.org/10.1371/journal.pone.0084139>
- de Almeida, F. R., Ayas, N. T., Otsuka, R., Ueda, H., Hamilton, P., Ryan, F. C., & Lowe, A. A. (2006). Nasal pressure recordings to detect obstructive sleep apnea. *Sleep and Breathing*, 10(2), 62–69. <https://doi.org/10.1007/s11325-005-0042-x>
- Ding, L., Peng, J., Song, L., & Zhang, X. (2023). Biomedical Signal Processing and Control Automatically detecting apnea-hypopnea snoring signal based on VGG19 + LSTM. *Biomedical Signal Processing and Control*, 80(P2), 104351. <https://doi.org/10.1016/j.bspc.2022.104351>
- Ding, Y., Wang, J., Gao, J., Fang, Q., Li, Y., Xu, W., Wu, J., & Han, D. (2021). Severity evaluation of obstructive sleep apnea based on speech features. *Sleep and Breathing*, 25(2), 787–795. <https://doi.org/10.1007/s11325-020-02168-0>
- Dursunoğlu, D., & Dursunoğlu, N. (2010). Kalp yetersizliği ve uyku apnesi. *Türk Kardiyoloji Dernegi Arsivi*, 38(2), 135–143.
- Flenady, T., Dwyer, T., & Applegarth, J. (2017). Accurate respiratory rates count: So should you! *Australasian Emergency Nursing Journal*, 20(1), 45–47. <https://doi.org/10.1016/j.aenj.2016.12.003>
- Geçkil, A. A. (2022). Tedaviyle ortaya çıkan santral uyku apnesi (Te-Csa). *Journal of Medical Topics & Updates*, 1(1), 28–31.
- Gürüler, H. (2012). *Ekg işaretlerinden ysa ve korelasyon matrislerine dayali tikayici uyku apnesi teşhisi*. Doktora Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Elektrik ve Bilgisayar Eğitimi Ana Bilim Dalı, Sakarya 87s.
- Gutierrez-Tobal, G. C., Alvarez, D., Del Campo, F., & Hornero, R. (2016). Utility of AdaBoost to Detect Sleep Apnea-Hypopnea Syndrome from Single-Channel Airflow. *IEEE Transactions on Biomedical Engineering*, 63(3), 636–646. <https://doi.org/10.1109/TBME.2015.2467188>

- Gutiérrez-Tobal, G. C., Álvarez, D., Vaquerizo-Villar, F., Crespo, A., Kheirandish-Gozal, L., Gozal, D., del Campo, F., & Hornero, R. (2021). Ensemble-learning regression to estimate sleep apnea severity using at-home oximetry in adults. *Applied Soft Computing*, *111*, 107827. <https://doi.org/10.1016/j.asoc.2021.107827>
- Haidar, R., Koprinska, I., & Jeffries, B. (2020, July). Sleep apnea event prediction using convolutional neural networks and Markov chains. In 2020 International Joint Conference on Neural Networks (IJCNN) (pp. 1-8). IEEE.
- Hairston, I. S. (2017). The Use of WatchPAT™ for Home Sleep Testing Assessment of Sleep-Related Disordered Breathing (SDB) in Heart Disease Patients - Clinical & Operational Benefits. In *Itmar Medical*.
- Han, J., Shin, H. B., Jeong, D. U., & Park, K. S. (2008). Detection of apneic events from single channel nasal airflow using 2nd derivative method. *Computer Methods and Programs in Biomedicine*, *91*(3), 199–207. <https://doi.org/10.1016/j.cmpb.2008.04.012>
- Hou, L., Pan, Q., Yi, H., Shi, D., Shi, X., & Yin, S. (2021). Estimating a Sleep Apnea Hypopnea Index Based on the ERB Correlation Dimension of Snore Sounds. *Frontiers in Digital Health*, *2*(February), 1–8. <https://doi.org/10.3389/fdgth.2020.613725>
- Huang, W., Guo, B., Shen, Y., & Tang, X. (2017). A novel method to precisely detect apnea and hypopnea events by airflow and oximetry signals. *Computers in Biology and Medicine*, *88*(February), 32–40. <https://doi.org/10.1016/j.compbiomed.2017.06.015>
- Hwang, S. H., Lee, H. J., Yoon, H. N., Jung, D. W., Lee, Y. J. G., Lee, Y. J., Jeong, D. U., & Park, K. S. (2014). Unconstrained sleep apnea monitoring using polyvinylidene fluoride film-based sensor. *IEEE Transactions on Biomedical Engineering*, *61*(7), 2125–2134. <https://doi.org/10.1109/TBME.2014.2314452>
- Islam, S. M., Rahman, A., Yavari, E., Baboli, M., Boric-Lubecke, O., & Lubecke, V. M. (2020, January). Identity authentication of OSA patients using microwave Doppler radar and machine learning classifiers. In 2020 IEEE Radio and Wireless Symposium (RWS) (pp. 251-254). IEEE.
- Javaid, A. Q., Noble, C. M., Rosenberg, R., & Weitnauer, M. A. (2015, December). Towards sleep apnea screening with an under-the-mattress IR-UWB radar using machine learning. In 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA) (pp. 837-842). IEEE.
- Jayatilaka, G., Weligampola, H., Sritharan, S., Pathmanathan, P., Ragel, R., & Nawinne, I. (2019, December). Non-contact infant sleep apnea detection. In 2019 14th Conference on Industrial and Information Systems (ICIIS) (pp. 260-265). IEEE.
- Jiménez-García, J., García, M., Gutiérrez-Tobal, G. C., Kheirandish-Gozal, L., Vaquerizo-Villar, F., Álvarez, D., Del Campo, F., Gozal, D., & Hornero, R. (2022). A 2D convolutional neural network to detect sleep apnea in children using airflow and oximetry. *Computers in Biology and Medicine*, *147*(June), 105784. <https://doi.org/10.1016/j.compbiomed.2022.105784>
- Jin, J., & Sanchez-Sinencio, E. (2015). A home sleep apnea screening device with time-domain signal processing and autonomous scoring capability. *IEEE Transactions on Biomedical Circuits and Systems*, *9*(1), 96–104. <https://doi.org/10.1109/TBCAS.2014.2314301>
- Kalkbrenner, C., Eichenlaub, M., Rüdiger, S., Kropf-Sanchen, C., Rottbauer, W., & Brucher, R. (2018). Apnea and heart rate detection from tracheal body sounds for the diagnosis of sleep-related breathing disorders. *Medical and Biological Engineering and Computing*, *56*(4), 671–681. <https://doi.org/10.1007/s11517-017-1706-y>
- Kang, B., Dang, X., & Wei, R. (2017, December). Snoring and apnea detection based on hybrid neural networks. In 2017 International Conference on Orange Technologies (ICOT) (pp. 57-60). IEEE.
- Kapoor, M., & Greenough, G. (2015). Home sleep tests for obstructive sleep apnea (OSA). *Journal of the American Board of Family Medicine*, *28*(4), 504–509. <https://doi.org/10.3122/jabfm.2015.04.140266>
- Karamustafaoğlu, G., Akan, A., & Saatçi, E. Polisomnografi Sinyallerinin İşlenmesi ile Uyku Apnesinin Otomatik Teşhisi, *14. Tıp Teknolojileri Ulusal Kongreleri* (pp. 295–298).
- Karunajeewa, A. S., Abeyratne, U. R., & Hukins, C. (2011). Multi-feature snore sound analysis in obstructive sleep apnea-hypopnea syndrome. *Physiological Measurement*, *32*(1), 83–97.

3334/32/1/006

Kim, J. W., Kim, T., Shin, J., Choe, G., Lim, H. J., Rhee, C. S., Lee, K., & Cho, S. W. (2019). Prediction of obstructive sleep apnea based on respiratory sounds recorded between sleep onset and sleep offset. *Clinical and Experimental Otorhinolaryngology*, *12*(1), 72–78. <https://doi.org/10.21053/ceo.2018.00388>

Leino, A., Nikkonen, S., Kainulainen, S., Korkalainen, H., Töyräs, J., Myllymaa, S., Leppänen, T., Ylä-Herttuala, S., Westeren-Punnonen, S., Muraja-Murro, A., Jäkälä, P., Mervaala, E., & Myllymaa, K. (2021). Neural network analysis of nocturnal SpO2 signal enables easy screening of sleep apnea in patients with acute cerebrovascular disease. *Sleep Medicine*, *79*, 71–78. <https://doi.org/10.1016/j.sleep.2020.12.032>

Leppänen, T., Töyräs, J., Mervaala, E., Penzel, T., & Kulkas, A. (2017). Severity of individual obstruction events increases with age in patients with obstructive sleep apnea. *Sleep Medicine*, *37*, 32–37. <https://doi.org/10.1016/j.sleep.2017.06.004>

Li, K., Pan, W., Li, Y., Jiang, Q., & Liu, G. (2018). A method to detect sleep apnea based on deep neural network and hidden Markov model using single-lead ECG signal. *Neurocomputing*, *294*, 94–101. <https://doi.org/10.1016/j.neucom.2018.03.011>

Lin, C. Y., Wang, Y. W., Setiawan, F., Trang, N. T. H., & Lin, C. W. (2022). Sleep apnea classification algorithm development using a machine-learning framework and bag-of-features derived from electrocardiogram spectrograms. *Journal of Clinical Medicine*, *11*(1). <https://doi.org/10.3390/jcm11010192>

Lin, X., Cheng, H., Lu, Y., Luo, H., Li, H., Qian, Y., Zhou, L., Zhang, L., & Wang, M. (2022). Contactless sleep apnea detection in snoring signals using hybrid deep neural networks targeted for embedded hardware platform with real-time applications. *Biomedical Signal Processing and Control*, <https://doi.org/10.1016/j.bspc.2022.103765>

Liu, Y., Feng, Y., Li, Y., Xu, W., Wang, X., & Han, D. (2022). Automatic classification of the obstruction site in obstructive sleep apnea based on snoring sounds. *American Journal of Otolaryngology - Head and Neck Medicine and Surgery*, *43*(6), 103584. <https://doi.org/10.1016/j.amjoto.2022.103584>

Lorato, I., Stuijk, S., Meftah, M., Kommers, D., Andriessen, P., van Pul, C., & de Haan, G. (2021). Automatic separation of respiratory flow from motion in thermal videos for infant apnea detection. *Sensors*, *21*(18), 1–16. <https://doi.org/10.3390/s21186306>

Mack, D. C., Alwan, M., Turner, B., Suratt, P., & Felder, R. A. (2006, April). A passive and portable system for monitoring heart rate and detecting sleep apnea and arousals: Preliminary validation. In 1st Transdisciplinary Conference on Distributed Diagnosis and Home Healthcare, 2006. D2H2. (pp. 51-54). IEEE.

Mendonça, F., Mostafa, S. S., Ravelo-García, A. G., Morgado-Dias, F., & Penzel, T. (2019). A Review of Obstructive Sleep Apnea Detection Approaches. *IEEE Journal of Biomedical and Health Informatics*, *23*(2), 825–837. <https://doi.org/10.1109/JBHI.2018.2823265>

Misra, A., Rani, G., & Dhaka, V. S. (2022). *Obstructive Sleep-Apnea Detection using Signal Preprocessing and 1-D Channel Attention Network*. 5–10.

Moradhasel, B., Sheikhan, A., Aloosh, O., & Jafarnia Dabanloo, N. (2023). Spectrogram classification of patient chin electromyography based on deep learning: A novel method for accurate diagnosis obstructive sleep apnea. *Biomedical Signal Processing and Control*, *79*(P2), 104215. <https://doi.org/10.1016/j.bspc.2022.104215>

Nakano, H., Furukawa, T., & Tanigawa, T. (2019). Tracheal sound analysis using a deep neural network to detect sleep apnea. *Journal of Clinical Sleep Medicine*, *15*(8), 1125–1133. <https://doi.org/10.5664/jcsm.7804>

Nguyen, A.-T., Nguyen, T., Le, H.-K., Pham, H.-H., & Do, C. (2022, November). A novel deep learning-based approach for sleep apnea detection using single-lead ECG signals. *2022 APSIPA Annual Summit and Conference*. <http://arxiv.org/abs/2208.03408>

P Pang, K. G., Hsung, T. C., Law, A. K. W., & Choi, W. W. (2020, September). Optimal vowels measurements for Obstructive Sleep Apnea Detection Using Speech Signals. In 2020 IEEE 3rd International Conference on Information Communication and Signal Processing (ICICSP) (pp. 143-147). IEEE.

Paul, T., Hassan, O., Alaboud, K., Islam, H., Rana, M. K. Z., Islam, S. K., & Mosa, A. S. M. (2022, December). ECG and

- SpO₂ Signal-Based Real-Time Sleep Apnea Detection Using Feed-Forward Artificial Neural Network. *In AMIA Annual Symposium Proceedings* (pp. 379–385).
- Penzel, T., & Sabil, A. K. (2017). The use of tracheal sounds for the diagnosis of sleep apnoea. *Breathe*, *13*(2), e37–e45. <https://doi.org/10.1183/20734735.008817>
- Pozo, R. F., Murillo, J. L. B., Gmez, L. H., Gonzalo, E. L., Ramírez, J. A., & Toledano, D. T. (2009). Assessment of Severe Apnoea through Voice Analysis, Automatic Speech, and Speaker Recognition Techniques. *Eurasip Journal on Advances in Signal Processing*, 2009. <https://doi.org/10.1155/2009/982531>
- Sani, S. (2021, November). A New Approach for Identifying Patients with Obstructive Sleep Apnea Using K-Nearest Neighbor Classification. In 2021 International Conference on e-Health and Bioengineering (EHB) (pp. 1-4). IEEE.
- Scebba, G., Da Poian, G., & Karlen, W. (2021). Multispectral Video Fusion for Non-Contact Monitoring of Respiratory Rate and Apnea. *IEEE Transactions on Biomedical Engineering*, *68*(1), 350–359. <https://doi.org/10.1109/TBME.2020.2993649>
- Selvaraj, N., & Narasimhan, R. (2013, July). Detection of sleep apnea on a per-second basis using respiratory signals. In 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 2124-2127). IEEE.
- Senaratna, C. V., Perret, J. L., Lodge, C. J., Lowe, A. J., Campbell, B. E., Matheson, M. C., Hamilton, G. S., & Dharmage, S. C. (2017). Prevalence of obstructive sleep apnea in the general population: A systematic review. *Sleep Medicine Reviews*, *34*, 70–81. <https://doi.org/10.1016/j.smrv.2016.07.002>
- Senthil Kumar, P. K., Nithya, V. K., & Vimala Juliet, A. (2016). Micro system with mems sensor for detecting sleep Apnea. *ARPN Journal of Engineering and Applied Sciences*, *11*(3), 2097–2101.
- Setiawan, F., & Lin, C.-W. (2022). A Deep Learning Framework for Automatic Sleep Apnea Classification Based on Empirical Mode Decomposition Derived from Single-Lead Electrocardiogram. *Life*, *12*(10), 1509. <https://doi.org/10.3390/life12101509>
- Sharma, M., Agarwal, S., & Acharya, U. R. (2018). Application of an optimal class of antisymmetric wavelet filter banks for obstructive sleep apnea diagnosis using ECG signals. *Computers in Biology and Medicine*, *100*(April), 100–113. <https://doi.org/10.1016/j.combiomed.2018.06.011>
- Sharma, M., Kumbhani, D., Tiwari, J., Kumar, T. S., & Acharya, U. R. (2022). Automated detection of obstructive sleep apnea in more than 8000 subjects using frequency optimized orthogonal wavelet filter bank with respiratory and oximetry signals. *Computers in Biology and Medicine*, *144*(February), 105364. <https://doi.org/10.1016/j.combiomed.2022.105364>
- Sharma, M., Kumbhani, D., Yadav, A., & Acharya, U. R. (2022). Automated Sleep apnea detection using optimal duration-frequency concentrated wavelet-based features of pulse oximetry signals. *Applied Intelligence*, *52*(2), 1325–1337. <https://doi.org/10.1007/s10489-021-02422-2>
- Shen, Q., Yang, X., Zou, L., Wei, K., Wang, C., & Liu, G. (2022). Multi-Task Multi-Attention Residual Shrinkage Convolutional Neural Network for Sleep Apnea Detection Based on Wearable Bracelet Photoplethysmography. *IEEE Internet of Things Journal*. <https://doi.org/10.1109/JIOT.2022.3195777>
- Sheta, A., Turabieh, H., Thaher, T., Too, J., Mafarja, M., Hossain, M. S., & Surani, S. R. (2021). Diagnosis of obstructive sleep apnea from ECG signals using machine learning and deep learning classifiers. *Applied Sciences (Switzerland)*, *11*(14). <https://doi.org/10.3390/app11146622>
- Shin, J. H., Chee, Y. J., Jeong, D. U., & Park, K. S. (2010). Nonconstrained sleep monitoring system and algorithms using air-mattress with balancing tube method. *IEEE Transactions on Information Technology in Biomedicine*, *14*(1), 147–156. <https://doi.org/10.1109/TITB.2009.2034011>
- Ruby S.M., Dafna, E., & Zigel, Y. (2018). Obstructive Sleep Apnea (OSA) classification using analysis of breathing sounds during speech. *European Signal Processing Conference, 2018-Septe*(1403), 1132–1136. <https://doi.org/10.23919/EUSIPCO.2018.8553353>
- Ruby S. M., Dafna, E., & Zigel, Y. (2020). Diagnosis of Obstructive Sleep Apnea Using Speech Signals from Awake

Subjects. *IEEE Journal on Selected Topics in Signal Processing*, 14(2), 251–260. <https://doi.org/10.1109/JSTSP.2019.2955019>

Sola-Soler, J., Jane, R., Fiz, J. A., & Morera, J. (2007, August). Automatic classification of subjects with and without sleep apnea through snoring analysis. In 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (pp. 6093-6096). IEEE.

Surrel, G., Aminifar, A., Rincón, F., Murali, S., & Atienza, D. (2018). Online Obstructive Sleep Apnea Detection on Medical Wearable Sensors. *IEEE Transactions on Biomedical Circuits and Systems*, 12(4), 762–773. <https://doi.org/10.1109/TBCAS.2018.2824659>

Toften, S., Kjellstadli, J. T., Tyvold, S. S., & Moxness, M. H. S. (2021). A Pilot Study of Detecting Individual Sleep Apnea Events Using Noncontact Radar Technology, Pulse Oximetry, and Machine Learning. *Journal of Sensors*, 2021. <https://doi.org/10.1155/2021/2998202>

Uçar, M. K. (2017). *Obstrüktif Uyku Apne Teşhisi için Makine Öğrenmesi Tabanlı Yeni Bir Yöntem Geliştirilmesi*. Doktora Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, Sakarya 139s.

Vaquerizo-Villar, F., Alvarez, D., Gutierrez-Tobal, G. C., Campo, F. Del, Kheirandish-Gozal, L., Gozal, D., Penzel, T., & Hornero, R. (2022, June). A convolutional neural network to classify sleep stages in pediatric sleep apnea from pulse oximetry signals. In 2022 IEEE 21st Mediterranean Electrotechnical Conference (MELECON) (pp. 108-113). IEEE.

Vaquerizo-Villar, F., Alvarez, D., Kheirandish-Gozal, L., Gutierrez-Tobal, G. C., Barroso-Garcia, V., Santamaria-Vazquez, E., Campo, F. Del, Gozal, D., & Hornero, R. (2021). A Convolutional Neural Network Architecture to Enhance Oximetry Ability to Diagnose Pediatric Obstructive Sleep Apnea. *IEEE Journal of Biomedical and Health Informatics*, 25(8), 2906–2916. <https://doi.org/10.1109/JBHI.2020.3048901>

Veauthier, C., Ryczewski, J., Mansow-Model, S., Otte, K., Kayser, B., Glos, M., Schöbel, C., Paul, F., Brandt, A. U., & Penzel, T. (2019). Contactless recording of sleep apnea and periodic leg movements by nocturnal 3-D-video and subsequent visual perceptive computing. *Scientific Reports*, 9(1), 1–11. <https://doi.org/10.1038/s41598-019-53050-3>

Xue, B., Deng, B., Hong, H., Wang, Z., Zhu, X., & Feng, D. D. (2020). Non-Contact Sleep Stage Detection Using Canonical Correlation Analysis of Respiratory Sound. *IEEE Journal of Biomedical and Health Informatics*, 24(2), 614–625. <https://doi.org/10.1109/JBHI.2019.2910566>

Yan, X., Wang, L., Zhu, J., Wang, S., Zhang, Q., & Xin, Y. (2022, August). Automatic Obstructive Sleep Apnea Detection Based on Respiratory Parameters in Physiological Signals. In 2022 IEEE International Conference on Mechatronics and Automation (ICMA) (pp. 461-466). IEEE.

Yeh, C. Y., Chang, H. Y., Hu, J. Y., & Lin, C. C. (2022). Contribution of Different Subbands of ECG in Sleep Apnea Detection Evaluated Using Filter Bank Decomposition and a Convolutional Neural Network. *Sensors*, 22(2). <https://doi.org/10.3390/s22020510>

Yıldız, M. (2021). Uyku Apnesi Tespitinde Yenilikler. *Natural & Applied Sciences Journal*, 3, 132–138.

Yue, H., Lin, Y., Wu, Y., Wang, Y., Li, Y., Guo, X., Huang, Y., Wen, W., Zhao, G., Pang, X., & Lei, W. (2021). Deep learning for diagnosis and classification of obstructive sleep apnea: A nasal airflow-based multi-resolution residual network. *Nature and Science of Sleep*, 13, 361–373. <https://doi.org/10.2147/NSS.S297856>

Zarei, A., & Asl, B. M. (2019). Automatic Detection of Obstructive Sleep Apnea Using Wavelet Transform and Entropy-Based Features from Single-Lead ECG Signal. *IEEE Journal of Biomedical and Health Informatics*, 23(3), 1011–1021. <https://doi.org/10.1109/JBHI.2018.2842919>

Zhang, Y., Chen, Y., Hu, L., Jiang, X., & Shen, J. (2017, November). An effective deep learning approach for unobtrusive sleep stage detection using microphone sensor. In 2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI) (pp. 37-44). IEEE.

Zhu, J., Zhou, A., Gong, Q., Zhou, Y., Huang, J., & Chen, Z. (2022). Detection of Sleep Apnea from

Electrocardiogram and Pulse Oximetry Signals Using Random Forest. *Applied Sciences (Switzerland)*, 12(9). <https://doi.org/10.3390/app12094218>

Zhu, K., Li, M., Akbarian, S., Hafezi, M., Yadollahi, A., & Taati, B. (2019). Vision-Based Heart and Respiratory Rate Monitoring during Sleep-A Validation Study for the Population at Risk of Sleep Apnea. *IEEE Journal of Translational Engineering in Health and Medicine*, 7(October), 1–8. <https://doi.org/10.1109/JTEHM.2019.2946147>

Zhu, K., Yadollahi, A., & Taati, B. (2019, July). Non-contact apnea-hypopnea index estimation using near infrared video. In 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 792-795). IEEE.

Zhuang, Z., Wang, F., Yang, X., Zhang, L., Fu, C. H., Xu, J., Li, C., & Hong, H. (2022). Accurate contactless sleep apnea detection framework with signal processing and machine learning methods. *Methods*, 205(January 2022), 167–178. <https://doi.org/10.1016/j.ymeth.2022.06.013>