



Wavelet Dalgacık Dönüşümü ile Tıkayıcı Uyku Apnesi Tahmini ve Epok Sürelerinin Etkisi

Mehmet Balcı¹, Adem Gölcük^{2*}, Serkan Küçüktürk³, Şakir Taşdemir⁴, Hüsamettin Vatansev⁵, Hülya Vatansev⁶

¹ Konya Teknik Üniversitesi, Teknik Bilimler MYO, Bilgisayar Teknolojileri Bölümü, Konya, Türkiye (ORCID: 0000-0002-9552-5883), mbalci@ktun.edu.tr

² Selçuk Üniversitesi, Teknoloji Fakültesi, Biyomedikal Mühendisliği Bölümü, Konya, Türkiye (ORCID: 0000-0002-6734-5906), adem.golcuk@selcuk.edu.tr

³ Karamanoğlu Mehmetbey Üniversitesi, Tıp Fakültesi, Tıbbi Biyoloji Bölümü, Karaman, Türkiye (ORCID: 000-0001-8445-666X), skuccukturk@kmu.edu.tr

⁴ Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, Türkiye (ORCID: 0000-0002-2433-246X), stasdemir@selcuk.edu.tr

⁵ Selçuk Üniversitesi, Tıp Fakültesi, Tıbbi Biyokimya Bölümü, Konya, Türkiye (ORCID: 0000-0002-0230-3414), hvatansevs@selcuk.edu.tr

⁶ Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesi, Göğüs Hastalıkları Bölümü, Konya, Türkiye (ORCID: 0000-0002-8382-3904), hvatansev1@konya.edu.tr

(3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications June 11-13, 2021)

(DOI: 10.31590/ejosat.954003)

ATIF/REFERENCE: Balcı, M., Gölcük, A., Küçüktürk, S., Taşdemir, Ş., Vatansev, H. ve Vatansev, H. (2021). Wavelet Dalgacık Dönüşümü ile Tıkayıcı Uyku Apnesi Tahmini ve Epok Sürelerinin Etkisi, *Avrupa Bilim ve Teknoloji Dergisi*, (26), 276-283.

Öz

Tıkayıcı uyku apnesi halk arasında uykuda nefes durması olarak da bilinen çok ciddi bir halk sağlığı sorunudur. Bu sağlık sorununun tespit edilmesi ciddi laboratuvar tetkikleri gerektirmektedir. Polisomnografi (PSG) olarak adlandırılan bu tetkik sisteminde hastadan gece boyunca birçok fizyolojik veri toplanarak kaydedilir. Daha sonra bu veriler incelenerek teşhis için kullanılır. Bu çalışmada yaşları 34 ile 73 arasında ve vücut kitle endeksleri 24,6 ile 49,3 arasında değişen 24 hastadan elde edilen gerçek veriler kullanılmıştır. Bu hastaların 17'si ciddi, 6'sı orta, 1'i de hafif derecede uyku apnesi teşhisi koyulmuş bireylerdir. 24 hastanın hastanenin uyku servisinde uyuma ve veri toplama için geçirdiği süre ortalama 5 saat 8 dakika 3 saniyedir. Bu çalışmada PSG ile toplanan fizyolojik verilerden olan pressure flow, pressuse snore ve thorax sinyalleri kullanılmıştır. Bu sinyaller önce epoklara ayrılmış, daha sonra ön işlemlerden geçirilmiştir. Farklı epok sürelerinin kullanıldığı çalışmada, her sinyalden wavelet dalgacık dönüşümü yöntemi ile sinyal özellikleri çıkarılarak bir özellikler veri seti oluşturulmuştur. Oluşturulan bu veri seti kullanılarak hastanın uyku sırasında meydana gelecek apnelerin önceden tahmin edilmesi amacıyla bir sistem geliştirilmiştir. Farklı sınıflandırıcıların da kullanıldığı bu sistemde ham sinyallerin bölümlendirilmesinde kullanılan epok sürelerinin tahmin başarısına etkisi araştırılmıştır. Epok süresi 30 saniye olarak belirlendiğinde %88 doğruluk oranı elde edilirken, epok süresi 15 saniye olarak belirlendiğinde tahmin doğruluğu %93,3 olarak hesaplanmıştır. Epok süresi 5 saniye olarak belirlendiğinde ise tahmin başarısı %97,2 olarak gerçekleşmiştir. Sonuçlar, epok sürelerinin kısaltılmasının tahmin başarısını artırdığını göstermektedir. Bunun nedeni olarak apne olayının meydana geldiği ana daha yakın bir zaman diliminde elde edilen fizyolojik verilerin, meydana gelecek apneyi daha iyi tanımlamasıdır.

Anahtar Kelimeler: Tıkayıcı uyku apnesi, Sinyal işleme, Wavelet dalgacık dönüşümü, Sınıflandırma, Apne tahmin

Effects of Obstructive Sleep Apnea Prediction and Epoch Duration with Wavelet Wavelet Transform

Abstract

Obstructive sleep apnea is a very serious public health problem, also known as respiratory arrest during sleep. Detection of this health problem requires serious laboratory tests. In this examination system called polysomnography (PSG), many physiological data are collected from the patient during the night and recorded. Then, these data are examined and used for diagnosis. Actual data obtained from 24 patients with body mass indexes between 24.6 and 49.3 and ages between 34 and 73 were used in this study. Seventeen of these patients are individuals who have been diagnosed with severe sleep apnea, 6 of them moderate, and 1 of them mild sleep apnea. The average time 24 patients spend sleeping and data collection in the hospital's sleep service is 5 hours, 8 minutes and 3 seconds. Pressure flow, pressuse snore and thorax signals, which are among the physiological data collected by PSG, were used in this study.

* Sorumlu Yazar: Selçuk Üniversitesi, Teknoloji Fakültesi, Biyomedikal Mühendisliği Bölümü, Konya, Türkiye, ORCID: 0000-0002-6734-5906, adem.golcuk@selcuk.edu.tr

These signals were first separated into epochs and then pre-processed. In the study, in which different epoch durations were used, a property data set was created by extracting signal properties from each signal with wavelet transform method. Using this data set, a system has been developed to predict apneas that will occur during sleep. In this system, in which different classifiers are used, the effect of epoch times used in segmentation of raw signals on prediction success has been investigated. When the epoch duration was determined as 30 seconds, 88% accuracy was obtained, while the prediction accuracy was calculated as 93.3% when the epoch duration was determined as 15 seconds. When the epoch duration was determined as 5 seconds, the prediction success was 97.2%. The results show that shortening the epoch times increases prediction success. The reason for this is that the physiological data obtained in a period closer to the moment when the apnea event occurs, better describe the apnea that will occur.

Keywords: Obstructive apnea, signal processing, discrete wavelet transform, classification, apnea predict

1. Giriş

Apne, uykuda solunum bozukluğu rahatsızlıklarının toplumda en sık görülenlerinden birisidir. Uyku sırasında nefes durması olarak bilinen apne, Amerikan Uyku Tıbbı Akademisi (American Academy of Sleep Medicine, 2012) tarafından, kişinin havayolundaki soluk akışının 10 saniye boyunca ve en az %90 oranında azalması olarak tanımlanmıştır. Tıkayıcı uyku apnesi sendromu, 3 farklı apne tipi arasında en sık rastlanan uykuda solunum bozukluğudur. Bir bireye tıkayıcı uyku apnesi tanısı koyulabilmesi için hastanelerin uyku servislerinde polisomnografi (PSG) adı verilen detaylı bir tetkik uygulanmaktadır. Polisomnografi, hastaya birçok sensörün bağlandığı ve gece boyunca uyku sırasında hastadan birçok fizyolojik verilerin toplanmasını sağlayan elektronik kopye bir sistemdir. Polisomnografi kayıtları uyku uzmanı hekimler tarafından skorlama olarak adlandırılan incelemeden geçirilir. Skorlama sonuçlarına göre hastanın gece boyunca geçirdiği apne sayısı tespit edilir. Bu sayının saatlik ortalamasını gösteren apne-hipopne indeksi (AHI) değerine göre hastaya apne tanısı koyulur. Ayrıca AHI değerinin bulunduğu aralığa hastalığın şiddet seviyesi belirlenir (del Campo et al., 2006; Douglas et al., 1992).

Tıkayıcı uyku apnesi hastalığının tedavisi için hastalara evlerinde uyurken kullanmaları için havayoluna pozitif hava basıncı uygulayan cihazlar reçete edilir. Bu cihazların birçok türü olmakla beraber, genel olarak pozitif airway Pressure (PAP) cihazı olarak isimlendirilir. PAP cihazlarının, apneleri otomatik algılayarak havayoluna uygulanan basıncı otomatik olarak ayarlayan tiplerine APAP ya da Otomatik CPAP ismi verilmektedir. APAP cihazları, hastanın apneye girmesini takiben tıkanıklık derecesine göre uygulanan hava basıncını ayarlar.

Bu çalışmada APAP cihazlarının çalışma tarzının geliştirilmesi adına bir sistem ortaya koyulmuştur. Yukarıda da bahsedildiği üzere, klasik APAP cihazları hasta apneye girdikten sonra tıkanan havayolunu açmak üzerine bir çalışma sistemine sahiptir. Bu çalışmada ortaya koyulan sistem ise hasta henüz apneye girmeden havayolunda meydana gelecek tıkanmaları önceden tahmin eden bir sistemdir.

Biyomedikal sinyaller durağan olmayan sinyallerdir. Bu yüzden sinyallerin işlenmesinden önce sinyallerin belirli aralıklarla bölünmesi gerekmektedir. Epok adı verilen her sinyal bölümünün süresi, yapılacak çalışmanın sonuçlarını da etkilemektedir. Polisomnografi sinyallerinin değerlendirilmesinde epok süresi standart olarak 30 saniye kabul edilmektedir. Bu çalışmada gerçekleştirilen sinyal işleme çalışmalarında farklı epok süreleri üzerinde çalışmalar yapılmıştır. Epok süreleri 30 saniye, 15 saniye ve 5 saniye olarak üç farklı sinyal işleme ve sınıflandırma çalışması yapılmış ve elde edilen apne tahmin sonuçları karşılaştırılmıştır. Epok süresinin apne tahminini nasıl etkilediği üzerinde durulmuştur.

1.1. Literatür Taraması

Uyku apnesi tahmini için yapılmış en eski çalışmalardan biri Dagum ve Galper tarafından yapılan çalışmadır. Bu çalışmada, bayesian belief network modeli kullanılarak kalp atış hızı, göğüs hacmi, oksijen saturasyonu ve uyku durumu verileri ile apne tahmin modeli geliştirilmeye çalışılmıştır (Dagum & Galper, 1995).

Apne tahmini üzerine yapılan önemli çalışmalardan biri de Bock ve Gough tarafından yapılan çalışmadır. Kalp hızı, solunum ve oksijen saturasyonu verilerinin kullanıldığı çalışmada, continuous positive airway pressure (CPAP) cihazların dinamik olarak geliştirilmesinde apne tahmininin önemi vurgulanmıştır (Bock & Gough, 1998).

Waxman ve ark., 2010 tarafından yapılan çalışmada LAMSTAR yapay sinir ağı kullanarak apne ve hipopne için otomatik tahmin ile apne ve hipopne atakları öngörülme çalışılmıştır. Yapılan çalışmada dalgacık dönüşümüne dayalı ön işleme ile bir dizi polisomnografi çalışmasından elde edilen altı fizyolojik sinyal kullanılmıştır. Burada geleceğe ait tahminler yapabilmek için 30 saniyelik periyotlar kullanılmıştır. Böylece gelecekteki 60 saniyelik zaman dilimlerine varan doğru tahminler yapılabilmektedir. Sistem apne ataklarını öngörmede %80,6 ve hipopne ataklarını öngörmede ise %74,4 kadar duyarlılık göstermiştir. (Waxman et al., 2010).

Molin ve ark. (2021) tarafından uyku apnesi üzerine yapılmış güncel bir çalışmada 42 hastadan gece boyunca solunum verileri akıllı telefonlar vasıtasıyla kaydedilerek apne riski tahmin edilmeye çalışılmıştır. Hızlı fourier dönüşümü kullanılan çalışmada Random Forest sınıflandırıcı %93 ve Support Vector Machine sınıflandırıcı %90 başarı elde etmiştir (Molin et al., 2021).

Literatürde PSG verilerinin analizine dayanan çalışmaların çoğu uyku apnesinin tespit edilmesini ya da bilgisayar sistemlerine dayalı ön tanı koyulmasını amaçlamaktadır. Yapılan araştırmalarda PSG verilerini yapay zekâ yöntemleri ile analiz ederek, henüz ortaya çıkmamış yaklaşan apneleri öngörebilen geniş kapsamlı çalışmalarda ise tatmin edici bir başarı oranı ile karşılaşılmalıdır. Bu açıdan bakıldığında bu çalışmanın önemi daha fazla ön plana çıkmaktadır.

2. Materyal ve Metot


2.1. Veri Seti

Çalışmada Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Hasatanesi'ne başvuran ve apne teşhisi koyulan 15 erkek ve 9 bayandan oluşan 24 hastaya ait gerçek PSG verileri kullanılmıştır. Bu hastaların yaşları 34-73 arasında, vücut kitle endeksleri 24,6-49,3 arasında değişmektedir. Hastaların 1'i hafif, 6'sı orta ve 17'si ciddi seviyede apne tanısı almış bireylerdir. Hastalar veri toplanması amacıyla ortalama 5 saat 8 dakika 3 saniye uyku servisinde uyutulmuşlardır. Hastaların ciddiye seviyelerin dağılımı Şekil 1'de gösterilmiştir.

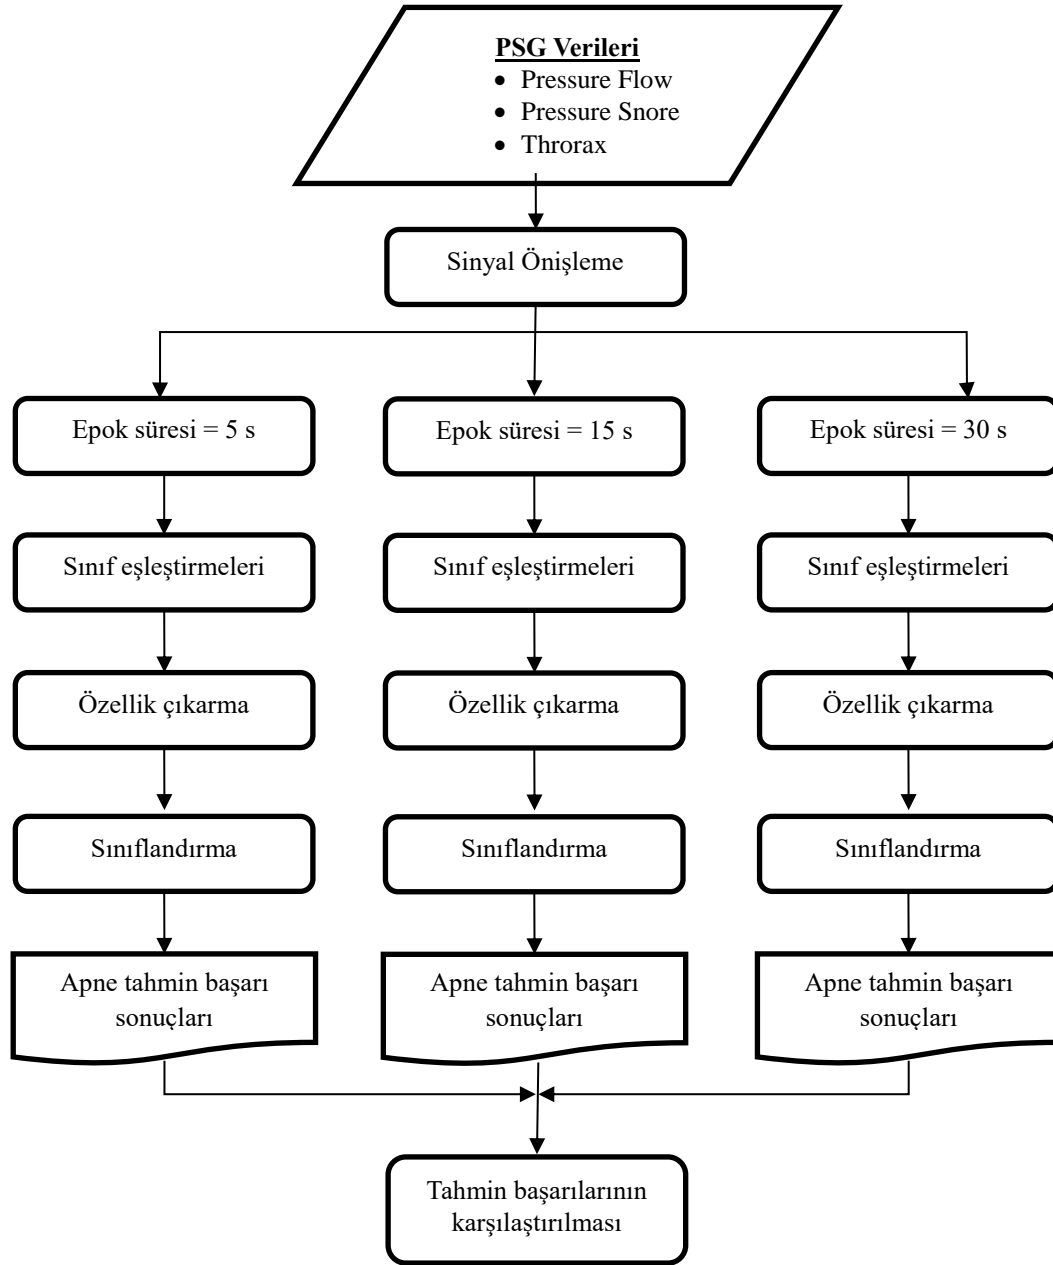
Polisomnografi sistemi içerisinde birçok fizyolojik verinin yer aldığı kompil bir veri toplama sistemidir. Bu çalışmada tıkaçıcı uyku apnesine gösterge olabilecek 3 tip PSG sinyali kullanılmıştır. Bu sinyallerin seçilmesi literatür çalışmaları ve uzman hekim tavsiyesine dayanarak yapılmıştır. Bunlar, havayolundaki akışı gösteren pressure flow, hastanın horlama durumunu pressure snore ve göğüs hareketlerini gösteren thorax sinyalleridir. Pressure flow ve pressure snore sinyalleri 256 Hz., Thorax sinyali ile 32 Hz. örnekleme frekansıyla kaydedilen sinyallerdir.

2.2. Yöntemler

Çalışmada kullanılan yöntemler ve akış diyagramı şekil 2'de gösterilmiştir.



Şekil 1. Apne Ciddiyet Seviyeleri Dağılımı



Şekil 2. Çalışmanın akış diyagramı

2.2.1. Sinyal önışleme

Hastanenin uyku sevisinden alınan PSg sinyalleri öncelikle epoklara ayrılmıştır. Çalışmada 30, 15 ve 5 saniye olarak üç farklı epok süresi belirlenerek her bir epok süresi için ayrı ayrı çalışma yapılmıştır. Epoklara ayrılan ham sinyaller daha sonra bir dizi ön işlemden geçirilmiştir. Bu işlemler, cihazdan kaynaklanacak şebeke geriliminin bastırılması, sinyaldeki kaymaların giderilmesi amacıyla DC bilşenlerin temizlenmesi ve her sinyaldeki anlamlı verilerin tespit edilmesi amacıyla sinyallere özel filtreleme yapılması şeklindedir. Filtreleme için 3. Dereceden butterworth filtre kullanılmıştır. Çalışmada kullanılan her sinyal tipi için kullanılacak filtreleme aralıkları literatürde yapılan çalışmalar sonucunda tespit edilmiştir. Bu kapsamda pressure flow sinyali için alt kesim frekansı 0,05 Hz., üst kesim frekansı 5 Hz. olan bir bant geçiren filtre (Díaz et al., 2014; Huang et al., 2017), pressure snore sinyali için kesim frekansı 10 Hz. olan bir yüksek geçiren filtre (Hyo-Ki Lee et al., 2013),

thorax sinyali için ise üst kesim frekansı 0,5 Hz. (De la Fuente et al., 2019) olan bir alçak geçiren filtre uygulanmıştır.

2.2.2. Sınıf eşleřtirmeleri

Çalışmada kullanılmak üzere hastanelerin uyku servislerinde tıkcaycı uyku apnesi rahatsızlığı teşshisi koyulmuş hastalara ait veriler kullanılmıştır. Hastaneden alınan ham veriler içerisinde hastaların uyku sırasında ne zaman apne geçirdiğini gösteren skorlama bilgileri de yer almaktadır. Ham verilerin epoklara ayrılmasından sonra her epoktaki verilere karşılık o epoktaki skorlama verisi, sınıf değeri olarak tayin edilmiştir. Böylece her epoktaki ham veri ile o epoktaki verilerle ortaya çıkan apne durumunu göstere sınıf verisi eşleřtirilerek vir veri seti haline getirilmiştir. Ancak çalışmanın amacı, hep epoktaki sınıf değerini yani apne oluşup oluşmadığını değil, bir sonraki epokta yani daha sonraki zaman diliminde oluşacak henüz ortaya çıkmamış apneleri tahmin edebilen bir sistem geliřtirmektir. Bu amaçla art arda gelen iki epoktaki veriler ile ikinci epoktaki sınıf

değerinin tahmin edilmesi gerekmektedir. Böylece ortaya çıkmamış apnenin önceki epoktaki veriler kullanılarak tahmin edilmesi sağlanmış olmaktadır. Art arda gelen ki epoktaki verilerin birleştirilerek kullanılmasında ama ise veri sızıntısını

önlemek ve daha sağlıklı çalışan bir sistem geliştirmektir. Bu amaçla veri setlerinde yapılan sınıf eşleştirmesi aşağıda şekil 3'te gösterilmiştir.

	Epok 1	Epok 2	Epok 3	Epok 4	Epok 5	Epok 6
1	Blue	Blue	Red	Green	Yellow	Purple
2	Blue	Blue	Red	Green	Yellow	Purple
3	Blue	Blue	Red	Green	Yellow	Purple
4	Blue	Blue	Red	Green	Yellow	Purple
5	Blue	Blue	Red	Green	Yellow	Purple
6	Blue	Blue	Red	Green	Yellow	Purple
7	Blue	Blue	Red	Green	Yellow	Purple
8	Blue	Blue	Red	Green	Yellow	Purple
...	Blue	Blue	Red	Green	Yellow	Purple
Class:		?	?	?	?	?


Şekil 3. Önceden apne tahmini için sınıf eşleştirmeleri

2.2.3. Wavelet dalgacık dönüşümü ile özellik çıkarma

Sinyal işleme uygulamalarını en önemli adımlarından biri sinyalden sinyali anlamlı şekilde temsil eden özelliklerin çıkarılmasıdır. Özellik çıkarma işlemleri gerek zaman domeninde gerekse frekans domeninde sinyallerin incelenmesini sağlayan birçok farklı teknik bulunmaktadır. Bu çalışmada, Wavelet Dalgacık Dönüşümü olarak bilinen ve sinyallerin frekans domeninde incelenmesine olanak sağlayan bir yöntem kullanılmıştır. Dalgacık dönüşümü yöntemi, düşük frekanslarda geniş bir pencere, yüksek frekanslarda ise sıkıştırılmış bir pencere kullanır (Vetterli & Kovačević, 1995). Dalgacık dönüşümü, esnek zaman frekans bilgisi elde edilmesini sağladığı için biyomedikal sinyallerin incelenmesinde önemli bir yere sahiptir (Türkoğlu, 2002). Bu yöntem kısa zamanlı fourier dönüşümüne (KZFD) benzer bir prensibe dayanır ve KZFD'deki sinyali pencerelere ayırma yerine bir dalgacık fonksiyonu kullanır (Miner, 1998). Ayrık dalgacık dönüşümü, ana dalgacığın belirli genişlemelerinde sinyali inceleyerek daha hızlı analiz yapılmasına olanak sağlar. Ayrık dalgacık dönüşümü, yüksek frekanslarda yüksek zaman çözünürlüğü ve düşük frekans çözünürlüğü, alçak frekanslarda ise yüksek frekans çözünürlüğü ve düşük zaman çözünürlüğünü sağlar (Özmen, 2013). DWT aşağıdaki formülle ifade edilir.


$$D_{j,k}(f, \Psi_{j,k}) = 2^{-j/2} \int_{-\infty}^{\infty} f(x) \Psi(2^{-j}x - k) dx \quad (2.1)$$

Bu yöntemde sinyal ilk önce filtreleme ile alçak ve yüksek frekans bileşenlerine ayrılır. Alçak frekans bileşenlerine "approximation", yüksek frekans bileşenlerine ise "detail" ismi verilir (Arı et al., 2008). Bu durum aşağıda Şekil 4'te gösterilmiştir.



Şekil 4. Sinyalin bileşenlerine ayrılması

Yukarıda gösterilen bileşenlerine ayırma işlemi, sinyal üzerinde çok seviyeli olarak istenildiği kadar uygulanabilir (Koçyiğit & Korürek, 2005). Aşağıda Şekil 5'te çok seviyeli ayrıştırma gösterilmiştir.



Şekil 5. Çok seviyeli ayrıştırma (Arı et al., 2008; Özmen, 2013)

2.2.4. Sınıflandırma

Sınıflandırma veri setinde yer alan sınıf değerleri belli olan değerlerle makine öğrenmesi eğitimi sağlandıktan sonra, sınıf değeri belli olmayan verilerin sınıflarının tahmin edilmesi işlemidir. Özellikle biyomedikal karar destek sistemlerinde en sık kullanılan makine öğrenmesi yöntemlerinden birisi sınıflandırmadır. Bu çalışmada apnelerin önceden tahmin edilebilmesi için art arda gelen epokları birleştirilmesi ve sınıf değerlerinin eşleştirilmesi işlemi yapılmıştır. Burada epok süresi olarak belirlenen zaman

diliminin ne kadar olduğu da önemlidir. Bu bağlamda ham veriler 5, 15 ve 30 saniyelik farklı epok süreleri kullanılarak 3 farklı veri seti oluşturulmuştur. Oluşturulan bu üç veri setinde bir sonraki epoktaki apne olayını tahmin edebilecek şekilde sınıf eşleştirme işlemi yapılmıştır. Daha sonra üç veri seti üzerinde de 7 farklı sınıflandırıcı (Artificial Neural Network (ANN), Support Vector Machine (SVM), Random Forest (RF), Naive Bayes (NB), K Nearest Neighborhood (KNN), Decision Tree (DT) ve Logistic Regression (LR)) kullanılarak sınıflandırma işlemi uygulanmıştır.

3. Araştırma Sonuçları

Bu çalışmada PSG sisteminden elde edilen Pressure Flow, Pressure Snore ve Thorax sinyalleri kullanılmıştır. Bu sinyaller 5, 15 ve 30 saniyelik farklı epok süreleri kullanılarak 3 farklı veri seti oluşturulmuştur. Daha sonra elde edilen bu veri setleri yukarıda anlatılan sınıf eşleştirme, özellik çıkarma işlemleri uygulanmıştır. Üç veri setinden elde edilen özellik veri setlerinin bilgileri tablo 1’de sunulmuştur.

Tablo 1. Üç veri setinden çıkarılan özellik veri setleri

	Epok=5 s	Epok=15 s	Epok=30 s
Özellik sayısı	123	292	547
Kayıt (satur) sayısı	110007	34574	15838

Özellik çıkarma işlemlerinden sonra her özellikler verisi üzerinde normalizasyon işlemi uygulanmış ve veri setinde dengeli bir dağılım elde edilmiştir. Son olarak da 7 farklı sınıflandırıcı kullanılarak bir her epoktaki veri ile bir sonraki epokta meydana gelebilecek apne olayı tahmin edilmeye çalışılmıştır. Her epok süresi için özellik çıkarma işlemlerinden sonra oluşan veri setleri ve bu veri setleri kullanılarak sınıflandırma sonucu elde edilen apne tahmin başarı sonuçları aşağıda sunulmuştur. Sınıflandırma sonuçları AUC, CA, Precision, Recall ve F1 ile gösterilmiştir. AUC, ROC eğrisinin altındaki alanı gösterir, CA, sınıflandırma doğruluğudur. Sınıflandırma doğruluğu, doğru tahmin edilen sınıf sayısının tüm verilere ait sınıf sayısına oranıdır. Precision, pozitif olarak

tahmin edilen sınıfların gerçekte kaç tanesinin pozitif olduğunu gösterir. Recall, pozitif olarak tahmin etmemiz gereken sınıflardan kaçının pozitif olarak tahmin edildiğini gösteren değerdir. F1, Precision ve Recall değerlerinin harmonik ortalamasını gösterir. F1 kullanmanın amacı, eşit olarak dağıtılmayan veri kümelerinde yanlış model seçimini önlemektir. F1, tüm hata maliyetlerini içeren bir ölçüm aracıdır.

Epok sürelerinin 5 saniye olarak alındığı veri setinden wavelett dalgacık dönüşümü özellik çıkarma yöntemi ile 123 özellik vektörünün yer aldığı 110007 satır veriden oluşan bir özellik veri seti oluşmuştur. Bu veri seti ile elde edilen apne tahmin başarısını gösteren sınıflandırma sonuçları Tablo 2’de gösterilmiştir.

Tablo 2. Epok süresi 5 s. için sınıflandırma sonuçları

Model	AUC	CA	F1	Precision	Recall
Random Forest	0,862	0,972	0,961	0,969	0,972
K Nearest Neighbourhood	0,784	0,971	0,957	0,960	0,971
Logistic Regression	0,650	0,970	0,956	0,942	0,970
Decision Tree	0,500	0,970	0,956	0,942	0,970
Artificial Neural Network	0,720	0,956	0,955	0,953	0,956
Support Vector Machine	0,709	0,946	0,949	0,951	0,946
Naive Bayes	0,796	0,819	0,877	0,959	0,819

Epok sürelerinin 15 saniye olarak alındığı veri setinden wavelett dalgacık dönüşümü özellik çıkarma yöntemi ile 292 özellik vektörünün yer aldığı 34574 satır veriden oluşan bir

özellik veri seti oluşmuştur. Bu veri seti ile elde edilen apne tahmin başarısını gösteren sınıflandırma sonuçları Tablo 3’te gösterilmiştir.

Tablo 3. Epok süresi 15 s. için sınıflandırma sonuçları

Model	AUC	CA	F1	Precision	Recall
Random Forest	0,910	0,933	0,919	0,931	0,933
Decision Tree	0,785	0,919	0,907	0,905	0,919
K Nearest Neighbourhood	0,708	0,905	0,861	0,846	0,905
Logistic Regression	0,635	0,904	0,860	0,827	0,904
Support Vector Machine	0,781	0,899	0,892	0,887	0,899
Artificial Neural Network	0,728	0,876	0,874	0,872	0,876
Naive Bayes	0,782	0,706	0,766	0,890	0,706

Epok sürelerinin 30 saniye olarak alındığı veri setinden wavelett dalgacık dönüşümü özellik çıkarma yöntemi ile 547

özellik vektörünün yer aldığı 15838 satır veriden oluşan bir özellik veri seti oluşmuştur. Bu veri seti ile elde edilen apne

tahmin başarısını gösteren sınıflandırma sonuçları Tablo 4'te gösterilmiştir.

Tablo 4. Epok süresi 30 s. için sınıflandırma sonuçları

Model	AUC	CA	F1	Precision	Recall
Random Forest	0,908	0,880	0,864	0,878	0,880
Decision Tree	0,821	0,853	0,844	0,841	0,853
Logistic Regression	0,554	0,806	0,725	0,704	0,806
Support Vector Machine	0,753	0,804	0,797	0,792	0,804
K Nearest Neighbourhood	0,639	0,804	0,728	0,713	0,804
Artificial Neural Network	0,666	0,765	0,760	0,755	0,765
Naive Bayes	0,729	0,655	0,692	0,812	0,655

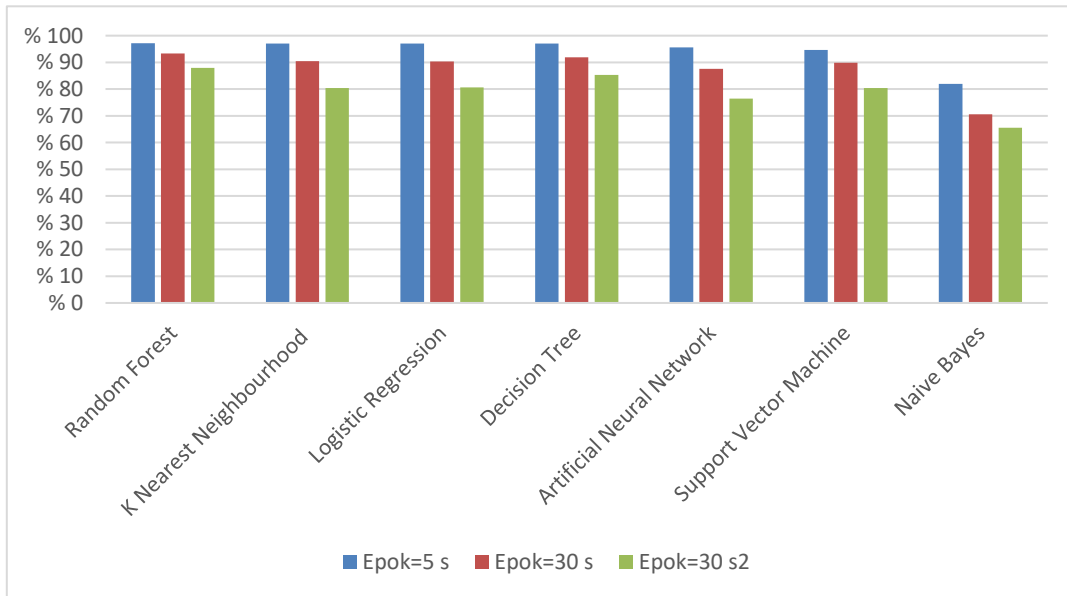
Üç farklı epok süresi ile önceden epne tahmini için yapılan sınıflandırma işlemlerinden elde edilen sınıflandırma başarılarının karşılaştırmalı olarak Tablo 5'te sunulmuştur.

Tablo 5. Üç farklı epok süresi için sınıflandırma başarılarının karşılaştırması

Model	Epok=5 s CA	Epok=15 s CA	Epok=30 s CA
Random Forest	0,972	0,933	0,880
K Nearest Neighbourhood	0,971	0,905	0,804
Logistic Regression	0,970	0,904	0,806
Decision Tree	0,970	0,919	0,853
Artificial Neural Network	0,956	0,876	0,765
Support Vector Machine	0,946	0,899	0,804
Naive Bayes	0,819	0,706	0,655

Tablo 5'ten görülebildiği gibi üç farklı epok süresi ile yapılan sınıflandırma işlemlerine göre, henüz meydana gelmemiş apnelerin önceden tahmin edilebilmesinde en başarılı sonuç epok süresinin 5 saniye olarak belirlendiği veri setinden elde edilmiştir. Ayrıca, diğer iki sonuçla birlikte toplu olarak

incelendiğinde epok süresinin kısalmasının tahmin başarısını yükselttiği görülmektedir. Üç farklı epok süresi ile hazırlanmış veri setlerinin 7 farklı sınıflandırıcı ile elde edilmiş sınıflandırma başarıları grafiği şekil 6'da sunulmuştur.



Şekil 6. Farklı epok süreleri ile epne tahmin başarılarının karşılaştırması

4. Sonuç

Bu çalışmada, en önemli halk sağlığı sorunlarından biri olan uykuda solunum bozukluğu üzerinde çalışılmıştır. Uykuda solunum bozukluklarının en sık görülen tipi olan tıkaçıcı uyku

apnesi hastanelerin PSG sistemleri ile hastadan alınan fizyolojik verilerle teşhis edilmektedir. Belli bir zaman dilimindeki biyomedikal sinyallerin değerlerdirilerek o zaman dilimindeki verilere dayalı olarak apne ortaya çıkıp çıkmadığını belirlemek bir sorundur. Ancak, bir zaman dilimindeki verilerle daha

sonraki bir zamanda ortaya çıkabilecek olası apneleri öngörmek ise daha karmaşık bir sorundur. Bu çalışmada tıkaçıcı uyku apnesi teşhisinde kullanılması uygun olan ve PSG sistemi ile hastalardan alınan Pressure Flow, Pressure Snore ve Thorax sinyalleri kullanılarak henüz ortaya çıkmamış ve daha sonraki zamanlarda oluşabilecek apneleri öngörecektir bir sistem geliştirilmeye çalışılmıştır.

İlk önce tüm biyomedikal sinyaller sinyal önışlemeden geçirilmiştir. Daha sonra, biyomedikal sinyallerin işlenmesinde sinyallerin epoklara ayrılması gerektiği için üç farklı epok süresi kullanılarak sinyaller epoklara ayrılmış ve üç farklı veri seti oluşturulmuştur. Oluşturulan her veri seti için sınıf değerleri eşleştirmesi yapılmıştır. Sınıf değerleri eşleştirmesi yapılırken, bir epoktaki sinyal verisi ile bir sonraki epokta meydana gelebilecek olası apne varlığı sınıf değeri olarak atanmıştır. Bu tasarım, epok süresinin 5 s olarak belirlendiği veri setinde en az 5 en çok 10 saniye sonraki anpelerin, epok süresinin 15 s olarak belirlendiği veri setinde en az 15 en çok 30 saniye sonraki anpelerin ve epok süresinin 30 s olarak belirlendiği veri setinde en az 30 en çok 60 saniye sonraki anpelerin öngörülebilmesinin alt yapısını oluşturmuştur. Bir sonraki adımda ise, wavelet dalgacık dönüşümü yöntemi ile üç veri setinde de özellik çıkarma yapılmıştır. Farklı epok süreleri için oluşturulan veri setlerine ait bilgiler tablo 1’de gösterilmiştir. Her üç veri seti üzerinde 7 farklı sınıflandırıcı (Artificial Neural Network (ANN), Support Vector Machine (SVM), Random Forest (RF), Naive Bayes (NB), K Nearest Neighborhood (KNN), Decision Tree (DT) ve Logistic Regression (LR)) kullanılarak sınıflandırma işlemi uygulanmıştır. Yapılan sınıflandırma sonuçları tablo2, tablo 3 ve tablo 4’te detaylı olarak görülmektedir. Üç farklı epok süresi ile yapılan sınıflandırma işlemlerinin sonuçlarına bakarak apne tahminindeki başarıların karşılaştırılması tablo 5 ve şekil 6’da gösterilmiştir. Bu sonuçlara göre en başarılı tahmin performansı epok süresinin 5 saniye olarak belirlendiği veri setinden elde edilmiştir. Ayrıca, epok süresinin azalmasının performan artışına da katkı sağladığı söylenebilir. Bu durum, ortaya çıkacak olası apneye daha yakın sinyal verilerinin apnenin daha kuvvetli bir habercisi olduğunu ortaya koymaktadır. Üç farklı veri setinde de 7 sınıflandırıcıdan en başarılı olanı random forest olarak görülmektedir. Bunun nedeninin random forest sınıflandırıcıların, dağınık veri setlerinde daha başarılı sonuçlar üretebilme özelliğinden kaynaklandığı söylenebilir.

5. Teşekkür

Bu çalışmayı 1505 Üniversite-Sanayi İşbirliği Destek Programı kapsamında 5190006 proje numarası ile destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu’na (TÜBİTAK) ve 18101016 proje numarası ile destekleyen Selçuk Üniversitesi, Bilimsel Araştırma Projeleri koordinatörlüğüne teşekkürlerimizi sunarız.

Kaynakça

- American Academy of Sleep Medicine. (2012). *The AASM Manual for the Scoring of Sleep and Associated Events The 2007 AASM Scoring Manual vs. the AASM Scoring Manual v2.0*.
- Arı, N., Özen, Ş., & Çolak, Ö. H. (2008). *Wavelet Theory*. Palme.
- Bock, J., & Gough, D. A. (1998). Toward prediction of

- physiological state signals in sleep apnea. *IEEE Transactions on Biomedical Engineering*, 45(11). <https://doi.org/10.1109/10.725330>
- Dagum, P., & Galper, A. (1995). Time series prediction using belief network models. *International Journal of Human-Computer Studies*, 42(6). <https://doi.org/10.1006/ijhc.1995.1027>
- De la Fuente, C., Weinstein, A., Guzman-Venegas, R., Arenas, J., Cartes, J., Soto, M., & Carpes, F. P. (2019). Use of accelerometers for automatic regional chest movement recognition during tidal breathing in healthy subjects. *Journal of Electromyography and Kinesiology*, 47. <https://doi.org/10.1016/j.jelekin.2019.05.016>
- del Campo, F., Hornero, R., Zamarrón, C., Abasolo, D. E., & Álvarez, D. (2006). Oxygen saturation regularity analysis in the diagnosis of obstructive sleep apnea. *Artificial Intelligence in Medicine*, 37(2). <https://doi.org/10.1016/j.artmed.2005.10.005>
- Díaz, J. A., Arancibia, J. M., Bassi, A., & Vivaldi, E. A. (2014). Envelope Analysis of the Airflow Signal To Improve Polysomnographic Assessment of Sleep Disordered Breathing. *Sleep*, 37(1). <https://doi.org/10.5665/sleep.3338>
- Douglas, N. ., Thomas, S., & Jan, M. . (1992). Clinical value of polysomnography. *The Lancet*, 339(8789). [https://doi.org/10.1016/0140-6736\(92\)91660-Z](https://doi.org/10.1016/0140-6736(92)91660-Z)
- 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. <https://doi.org/10.1016/j.combiomed.2017.06.015>
- Hyo-Ki Lee, Jeon Lee, Hojoong Kim, & Kyoung-Joung Lee. (2013, July). Automatic snoring detection from nasal pressure data. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. <https://doi.org/10.1109/EMBC.2013.6611136>
- Koçyiğit, Y., & Korürek, M. (2005). EMG signal classification using wavelet transform and fuzzy logic classifier. *ITU Journal Series D: Engineering*, 4(3), 25–31.
- Miner, N. E. (1998). *An Introduction to Wavelet Theory and Analysis*. <https://doi.org/10.2172/1896>
- Molin, N. L., Molin, C., Dalpatadu, R. J., & Singh, A. K. (2021). Prediction of obstructive sleep apnea using Fast Fourier Transform of overnight breath recordings. *Machine Learning with Applications*, 4. <https://doi.org/10.1016/j.mlwa.2021.100022>
- Özmen, G. (2013). *The Evaluation of The Muscle Fatigue in The Cervical Region with Surface Electromyogram Information*. The Graduate School of Natural and Applied Science of Selçuk University.
- Türkoğlu, İ. (2002). *An Intelligent pattern recognition for nonstationary signals based on the time-frequency entropies*. Firat University, Institute of Science and Technology.
- Vetterli, M., & Kovačević, J. (1995). *Wavelets and Subband Coding*. Prentice Hall PTR.
- Waxman, J. A., Graupe, D., & Carley, D. W. (2010). Automated Prediction of Apnea and Hypopnea, Using a LAMSTAR Artificial Neural Network. *American Journal of Respiratory and Critical Care Medicine*, 181(7). <https://doi.org/10.1164/rccm.200907-1146OC>