

Destek Vektör Makineleri Kullanarak Uyku Seslerinin Çoklu Sınıflandırılması

Erkin KILIÇ¹, Aykut ERDAMAR^{2*}

ÖZET: Uyku sürekliliği ve uyku hijyeni, insanların günlük yaşantısını doğrudan etkilemektedir. Uyku sırasında ortaya çıkan horlama, öksürme, tıksırma gibi uyanmaya neden olan sesler genellikle uyku hastalıklarıyla ilintilidir. Horlama gibi gürültülü ses paternleri hasta ile aynı ortamda uyuyan diğer insanların da uyku kalitesini olumsuz yönde etkileyebilmektedir. Hastaların fizyolojik sinyalleri ve uyku sesleri polisomnografi ile kayıt edilir. Ardından tüm sonuçlar uzman doktor tarafından incelenir ve sonuçlarına göre uygun teşhis konulur. Görsel veya işitsel skorlama mesleki deneyim gerektiren, oldukça zor, zaman alan ve yorucu bir süreçtir. Bu nedenle, uykudaki seslerin otomatik sınıflandırılması üzerine yapılan çalışmalar önem kazanmaktadır. Sunulan çalışmada, uyku seslerini hızlı ve güvenilir bir şekilde analiz edebilen, otomatik olarak sınıflandırabilen bilgisayar destekli tanı algoritmasının geliştirilmesi amaçlanmıştır. Altı farklı uyku ses paterni (nefes alma/verme, öksürme, basit horlama, dubleks düşük frekans horlama, dubleks yüksek frekans horlama ve tripleks horlama) zaman bölgesinden elde edilen öznelikler kullanılarak makine öğrenmesine dayanan bir algoritmayla otomatik olarak sınıflandırılmaktadır. Önerilen algoritma üç aşamadan oluşur: Birinci aşamada ham ses sinyallerine kontrol ve ön işleme yapılır. İkinci aşamada dalga formu analizleri yapılarak öznelikler edilir. Son aşamada ise destek vektör makineleri kullanılarak sınıflandırma işlemi yapılır. Çalışma sonucunda, altı farklı uyku sesi paterni ortalama % 90.20 doğruluk oranıyla sınıflandırılmıştır.

Anahtar Kelimeler: Uyku Sesleri, Basit Horlama, Dubleks Horlama, Tripleks Horlama, Sınıflandırma

Multi Classification of Sleep Sounds using Support Vector Machines

ABSTRACT: Sleep continuity and sleep hygiene directly affect people's daily lives. The sounds that cause awakening such as snoring, coughing, and obstruction during sleep are generally related to sleep diseases. Noisy sound patterns, such as snoring, can negatively affect the sleep quality of other people who sleep in the same environment as the patient. Physiological signals and sleep sounds of patients are recorded by polysomnography. Then all results are examined by the sleep physician and appropriate diagnosis is made according to the results. Visual or auditory scoring is a very difficult, time-consuming and tiring process that requires professional experience. Hence, studies on the automatic classification of sleep sounds become important. In the presented study, it is aimed to develop a computer-aided diagnostic algorithm that can analyze sleep sounds quickly and reliably and classify them automatically. Six different sleep sound patterns (breathing / exhaling, coughing, simple snoring, duplex low frequency snoring, duplex high frequency snoring and triplex snoring) are automatically classified with an algorithm based on machine learning using the time-domain features. The proposed algorithm consists of three stages: In the first stage, raw sound signals are checked and pre-processed. In the second stage, features are obtained with waveform analysis. At the last stage, classification is done by using support vector machines. As a result of the study, six different sleep patterns were classified with an average accuracy rate of 90.20 %.

Keywords: Sleeping Sounds, Simple Snoring, Duplex Snoring, Triplex Snoring, Classification.

¹ Erkin KILIÇ (Orcid ID: 0000-0002-7183-5879), Milli Savunma Bakanlığı Yerleşkesi, Askeri Sağlık Hizmetleri Genel Müdürlüğü, Ankara, Türkiye

² Aykut ERDAMAR (Orcid ID: 0000-0001-8588-480X), Başkent Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Ankara, Türkiye

*Sorumlu Yazar/Corresponding Author: Aykut Erdamar, e-mail: aerdamar@baskent.edu.tr

Bu çalışma Erkin KILIÇ'ın Yüksek Lisans tezinden üretilmiştir. Tezden çıkan öncü sonuçları da içeren ve kullanılan başka bir yöntemeye dayanan bildiri bulunmaktadır ve 02-05 Mayıs 2018 tarihlerinde İzmir'de düzenlenen "26th Signal Processing and Communications Applications Conference (SIU)" başlıklı konferansta sözlü olarak sunulmuştur.

GİRİŞ

Uyku, “çevreden algısal bağların kopması ve yanıt verme mekanizmasının geçici süreliğine durması sonucu oluşan bir davranış biçimi” olarak tanımlanan, geri çevrilebilir temel insani bir ihtiyaçtır (Doukas et al., 2012; Keenan et al., 2013). Uyku sürekliliği ve uyku hijyeni, insanların günlük yaşantısını doğrudan etkilemektedir. Uyku hastalıklarına bağlı olarak gelişebilen ve uyku sırasında ortaya çıkan horlama, öksürme, tıksırma gibi sesler uyanmaya sebep olan temel nedenlerin başında gelmektedir. Bu sesler sıklıkla, akut veya kronik solunum yolu hastalıkları ile solunum yollarındaki yumuşak dokuların (yutak, küçük dil, damak gibi) gevşeyerek titreşime neden olmasından kaynaklanmaktadır. Uyku esnasında ses çıkarma problemi, farklı yaş gruplarında görülebilmektedir. Özellikle horlama, atmış yaş grubu erkeklerin % 60’ında, kadınların % 40’ında görülmektedir (Dafna et al., 2013). Uyku esnasında ortaya çıkan, uyanmaya sebep olabilecek bu sesler, hastanın ve aynı ortamda uyuyan diğer insanların da uyku kalitesini olumsuz yönde etkileyebilmektedir. Günümüzde bu sağlık sorununa yönelik olarak birçok tedavi yöntemi vardır (Counter and Wilson, 2004). Uygun tedavi yönteminin uygulanabilmesi amacıyla doğru teşhis oldukça önemlidir. Fizyolojik sistem ile ilintili olarak, uyku esnasında ortaya çıkan tüm problemler, uyku hastalıkları olarak ifade edilir. Uyku hastalıklarına teşhis konulabilmesi için, hasta uyku laboratuvarında bir gece uyutulmalı ve fizyolojik verileri kaydedilmelidir. Bu fizyolojik verilerin kaydedilmesi için çok kanallı bir kayıt sistemi olan polisomnografi (PSG) cihazı kullanılmaktadır. Uyku süresince kaydedilen fizyolojik verilerin analizi, uyku tıbbı konusunda uzmanlaşmış hekim tarafından gerçekleştirilmekte ve analiz sonuçlarına göre uygun teşhis konulmaktadır (Jones, 2005; Berry et al., 2012). Bu süreçte fizyolojik parametrelere ilaveten, PSG’de bulunan elektrotlarla hastanın ses kaydı da alınmaktadır. Ancak, alınan bu ses kaydı, sadece boğazda oluşan ses titreşiminin analiz edilmesi amacıyla kullanılabilir. Uzman doktorun, hastanın uyku esnasında çıkardığı sesleri dinlemek istemesi halinde, haricen bir mikrofon ve ses kaydedici kullanılması gerekmektedir (Dafna et al., 2013). Ancak, bu durumda iki temel problem ile karşılaşmaktadır. Birinci problem, PSG’den alınan fizyolojik parametreler ile harici ses kaydediciden alınan ses kaydını senkronize etmenin oldukça zor olmasıdır. Bu senkronizasyon işleminin doğru şekilde yapılamaması, uzman doktorun teşhis koyma sürecinde hata yapmasına sebebiyet verebilir. İkinci problem ise, ortalama uyku süresinin 6–8 saat olmasından dolayı, uzman doktorun ses kaydının tamamını dinleyerek teşhis koyabilmesinin pratikte zor olmasıdır (Alshaer et al., 2014).

Görsel veya işitsel skorlamanın mesleki deneyim gerektiren, oldukça zor, zaman alan ve yorucu bir süreç olması nedeniyle uykuda ortaya çıkan seslerin otomatik sınıflandırılması üzerine yapılan çalışmalar önem kazanmaktadır. Literatürde uyku esnasında çıkan seslerin tespit edilmesi ve sınıflandırılması ile ilgili olarak az sayıda çalışma bulunmaktadır. Bu çalışmalar genellikle, Mel-frekansı katsayıları, doğrusal öngörücü kodlama ve ses yoğunluğu gibi standart akustik analiz yöntemlerini kullanarak ses kaydı içerisinde horlama tespiti üzerinedir (Fiz et al., 1996; Wilson et al., 1999; Deller and Proakis., 2000; Dafna et al., 2013). Uykudaki seslerin sınıflandırması üzerine de farklı çalışmalar da gerçekleştirilmiştir. Horlama seslerini otomatik olarak analiz etmek amacıyla gerçekleştirilen bir çalışmada apne hipoapne indeksi, sinyal gürültü oranı ve pozitif öngörücü değer temel öznitelik olarak alınmış, yapay sinir ağları ile sınıflandırma gerçekleştirilmiştir (Jane et al., 2003). Başka bir çalışmada ise, horlama şikayeti olan hastalarda enerji, gürültü seviyesi, süre ve özilinti fonksiyonu öznitelikleri kullanılmıştır (Jones, 2005). 2006 yılında sunulan diğer çalışmada alınan ses kayıtları, gizli Markov modeli ve spektral analiz yöntemleri ile analiz edilerek, nefes alma, horlama, çarşaf sesi ve sessizlik olarak dört farklı ses sınıflandırılmıştır (Duckitt et al., 2006). Başka bir çalışmada ise, sıfır kesme oranı yöntemi kullanılarak ses kayıtlarındaki aktivite bölgeleri belirlenmiş, bu bölgelerde alt bant enerji analizi

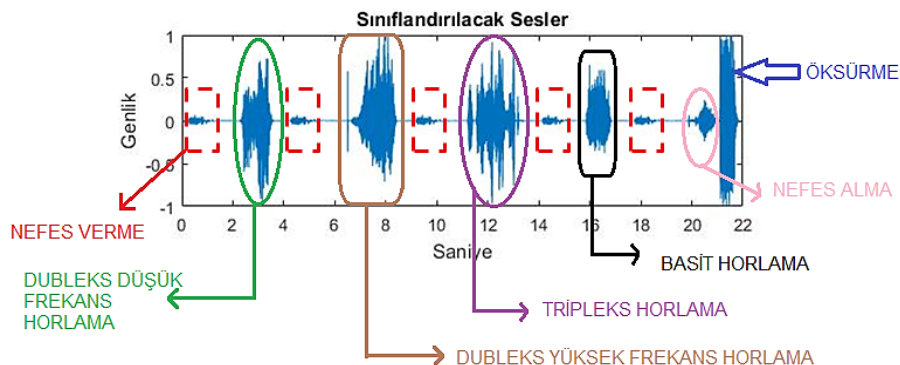
gerçekleştirilmiş ve horlama / horlama değil olarak sınıflandırma yapılmıştır (Cavusoglu ve ark., 2007). Sessizlik, horlama ve nefes alma seslerini sınıflandırmayı hedefleyerek zaman ve frekans düzleminde analizler gerçekleştirilen diğer bir çalışmada ise % 96.78 doğruluk oranı ile sınıflandırma yapılmıştır (Karunajeewa et al., 2008). Trake mikrofonu kullanılarak gerçekleştirilen diğer bir çalışmada da, bulanık mantık yöntemi kullanılarak “C anlamlı kümesi” metoduyla ses kaydından horlama tespiti % 98.6 doğruluk oranıyla gerçekleştirilmiştir (Azarbarzin and Moussavi., 2011). Hasta ile temas etmeyen bir mikrofon kullanılarak ses kayıtlarının alındığı diğer bir çalışmada zaman, periyodiklik, süre, enerji ve frekans öznitelikleri çıkartılarak yatak sesi, horlama, dış ortam sesi ve öksürme olarak dört farklı parametre % 98.2 doğruluk oranıyla sınıflandırılmıştır (Dafna et al., 2013). Nefes alma, nefes verme, nefes alırken horlama, nefes verirken horlama, hırıltı, diğer sesler ve duyulamayan seslerden oluşan yedi farklı ses tipinin incelendiği diğer bir çalışmada elde edilen öznitelikler kullanılarak üç farklı sınıflandırıcı kullanılmıştır. Sonuçlara göre; uyku sesleri konusunda ikiden fazla parametrenin sınıflandırılması durumunda, en yüksek doğruluk oranının % 85.4 olarak elde edildiği bildirilmiştir (Alshaer et al., 2014).

Sunulan çalışmada, uyku esnasında çıkan altı farklı ses paterninin yüksek doğruluk oranıyla otomatik olarak sınıflandırılmasına yönelik olarak yeni bir karar destek algoritması geliştirilmesi amaçlanmıştır. Çalışmada, hastalarda sıklıkla gözlenen ve uzman doktorun skora konusuna en çok desteğe ihtiyaç duyacağı ses türleri seçilmiştir. Akustik karakteristiği birbirine oldukça yakın olan basit horlama, dubleks düşük frekans horlama, dubleks yüksek frekans horlama ve tripleks horlama, horlama türlerine ilaveten nefes alma/verme ve öksürme sesleri sınıflandırma amacıyla kullanılmıştır.

MATERYAL VE YÖNTEM

Çalışmada Kullanılan Ses Kayıtları

Bu çalışmada kullanılan ses kayıtları, açık erişimli internet kaynaklarından (<https://www.freesound.org/> ve <http://soundbible.com/>) elde edilmiştir. Nefes verme, basit horlama, dubleks düşük frekans horlama, dubleks yüksek frekans horlama, tripleks horlama ve öksürme sesi olmak üzere uyku esnasında çıkan altı farklı ses tipi kaydedilmiştir. Akustik karakteristiği birbirine oldukça yakın olan basit horlama, dubleks düşük frekans horlama, dubleks yüksek frekans horlama ve tripleks horlama türlerine ilaveten nefes alma/verme ve öksürme sesleri sınıflandırma amacıyla kullanılmıştır. Kullanılan ses paternlerinin bir örneği Şekil 1’de görülmektedir. Analizler öncesinde tüm ses kayıtlarının, uygunluğu değerlendirilmiş ve farklı sesleri içeren toplam 839 bölüt çıkartılmıştır. 390 bölüt sınıflandırıcının eğitilmesinde, 449 bölüt ise sınıflandırıcının test edilmesi amacıyla kullanılmıştır. Ses kayıtlarının süreleri, kayıt cihazları, kayıt ortamları birbirlerinden tamamen farklıdır. İşaret işleme aşamasında bu farklılıkların ortadan kaldırılması amacıyla tüm kayıtlar kontrol ve ön işleme aşamalarından geçirilerek standardize edilmiştir (Kılıç, 2017).



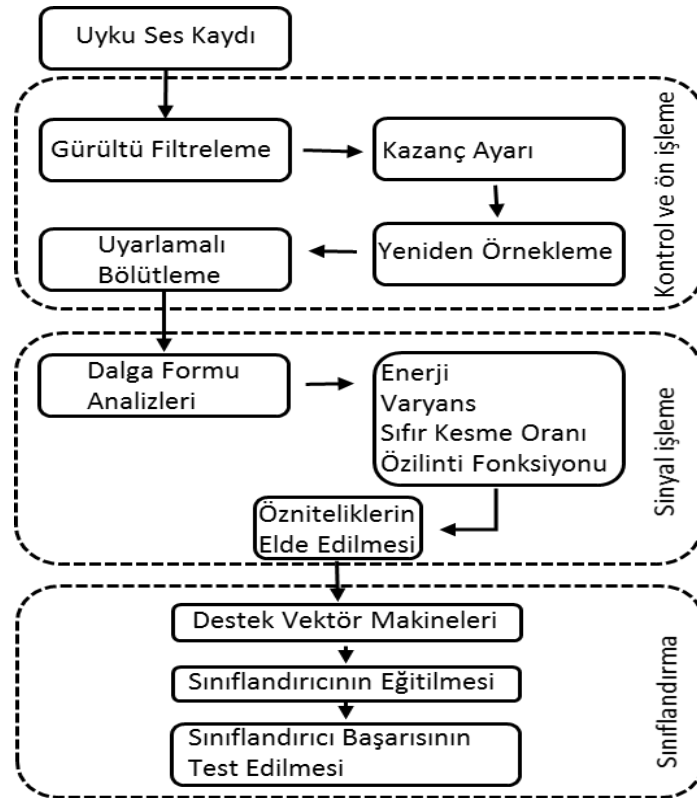
Şekil 1. Sınıflandırılacak farklı tipteki uyku sesleri.

Önerilen Algoritma

Sunulan çalışmada, uyku esnasında ortaya çıkan altı farklı tipteki sesin, zaman bölgesindeki özelliklerinden elde edilen öznitelikler ve makine öğrenmesine dayanan bir algoritma otomatik olarak sınıflandırılmasını gerçekleştirmektedir. Üç aşama içeren önerilen algoritmanın akış diyagramı Şekil 2'de görülmektedir. Birinci aşamada ham ses sinyallerine kontrol ve ön işleme yapılarak sinyal işlemeye hazır hale getirilir. İkinci aşamada dalga formu analizleri yapılarak öznitelikler edilir. Son aşamada ise destek vektör makineleri kullanılarak sınıflandırma işlemi yapılır. Önerilen algoritmanın her aşaması ve uygulanan yöntemler aşağıdaki alt bölümlerde açıklanmaktadır. Bu algoritma MATLAB kullanılarak geliştirilmiştir.

Kontrol ve ön işleme

Ses kayıtlarının tamamı öncelikle gruplara ayrılmış ve numaralandırılmıştır. Her bir ses kaydındaki, dış ortam sesleri kesilerek sinyalden çıkartılmıştır. Sonrasında her bir ses kaydı “.mp3” formatına dönüştürülerek, bilgisayar sisteminde kapladığı alan, minimum kayıpla azaltılmıştır. Sonraki aşamada, sesin “Stereo” veya “Mono” olarak kaydedildiği kontrol edilmiş ve tüm ses dosyaları tek kanal içerecek şekilde “Mono” olarak yeniden biçimlendirilmiştir. Bu işlem için “Stereo” seslerin içerdiği iki kanala ait ses sinyalleri toplanarak tek bir kanal elde edilmiştir (Kılıç, 2017).



Şekil 2. Geliştirilen algoritmanın akış şeması.

Gürültü filtreleme

Ses sinyallerinin elde edilmesi amacıyla kullanılan mikrofonlar en hassas titreşimlere bile duyarlı olabilmektedir. Bu nedenle, hem insan kulağının duyamayacağı sesler, hem elektromanyetik gürültüler ses sinyali üzerinde gürültülerin oluşmasına neden olabilmektedir (Cavusoglu ve ark., 2007). Fourier transformu kullanılarak kayıtlardaki gürültü tipleri belirlenmiştir. Periyodik gürültüler çentik filtre kullanılarak temizlenmiştir. Mikrofonun ortamdaki titreşimleri algılaması sonucu oluşan ve sıfır (taban) hattı üzerindeki titreşim ve/veya artefaktlar için transfer fonksiyonu Eşitlik 1’de verilen özyinelemeli bir

filtre tasarlanmış ve $\omega=0$ frekansı (DC bileşenler) sinyallerden temizlenirken diğer sinyal bileşenlerinin korunması sağlanmıştır.

$$H(z) = \frac{1-z^{-1}}{1-0.995z^{-1}} \quad (1)$$

Kazanç (dB) ayarı

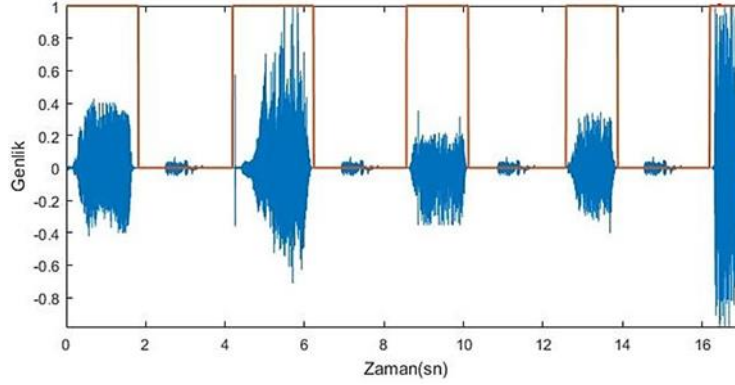
Ses kayıtları farklı kayıt koşullarına sahip olduğu için kayıtlar arasında ham kayıtlar arasındaki farklılıkları ortadan kaldırmak için tüm kayıtlara kazanç ayarı yapılmıştır. Bunun için öncelikle tüm ses kayıtları, $[-1, 1]$ genlik aralığında normalize edilmiştir. Normalizasyon işlemi sonrası, her bir ses kaydı için ayrı ayrı maksimum ve minimum kazançlar belirlenmiştir. Belirlenen kazanç değerleri, tüm ses kayıtlarında parametre bazlı olarak gruplandırılmıştır. (Örneğin; öksürme en yüksek kazançta sahipken, nefes verme en düşük kazançta sahiptir.) Gruplama sonrasında, en yüksek kazançta sahip parametre ana parametre olarak kabul edilmiş ve maksimum genliği 1 olarak kabul edilmiştir. Diğer parametreler ise, kazanç bazında, ana parametreyle göre oranlanmış ve orandan elde edilen yüzdelik değer ile genlikleri çarpılmıştır. Bu işlem sonrası her bir ses kaydı tekrar derlenmiştir.

Yeniden örnekleme

Açık erişimli internet veri tabanlarından elde edilen ses kayıtları farklı kayıt cihazları alındığından dolayı, ses kayıtlarının örnekleme frekansları çeşitlilik göstermektedir. Literatür incelendiğinde, uyku sesleri ile ilgili çalışmalarda genellikle 8 kHz örnekleme frekansı kullanıldığı görülmüştür (Jones ve ark., 2005; Dafna ve ark., 2013). Fourier analizleri sonucunda anlamlı en yüksek frekansın 3,5 – 4 kHz aralığında olduğu görülmüştür. Maksimum 4 kHz anlamlı frekans içeren bir sinyal için, Nyquist teoremine göre 8 kHz örnekleme frekansı yeterlidir. Ancak, yeniden örnekleme sonrası ses kayıtları tekrar dinlendiğinde, işitsel olarak ses kalitesinde kayıp olmayan örnekleme frekansının 16 kHz olduğu değerlendirilmiş ve örnekleme frekansı 16 kHz olarak belirlenmiştir.

Uyarlamalı bölütleme fonksiyonu

Çalışmada karşılaşılan diğer bir zorluk ise farklı uyku ses paternlerinin farklı sürelerde olmasıdır. Ses paternlerinin otomatik sınıflandırılması amaçlandığı sinyal işleme aşamasında bu durum çok kritiktir. Çünkü öznelikler her bir patern için ayrı ayrı elde edileceği için sesin başladığı ve bittiği zaman lokasyonunun belirlenmesi gereklidir. Bu işlem manuel olarak yapılamayacağı için ve ses paternleri farklı uzunluklarda olduğu için ses kayıtlarını otomatik olarak bölütlere ayıracak uyarlamalı bir fonksiyon geliştirilmiştir. Uyarlamalı bölütleme fonksiyonu (UBF) literatürdeki iki çalışmanın avantajları kullanılarak geliştirilmiştir (Yu et al., 2012; Qian et al., 2015). İlk çalışmada, sinyal aktivitesine göre belirlenen kesim noktası aracılığıyla sinyalin başlangıç ve bitiş noktaları belirlenmiştir. Kesim noktası belirlenmesi için, en düşük genliğe sahip sinyal olan nefes verme kullanılmıştır. Bu yöntemin dezavantajı horlama sesinin başlangıç ve bitiş noktasının, nefes vermeye akustik olarak çok benzemesinden kaynaklanan hatalı işaretleme ve oluşan kayıp bölgelerdir (Qian et al., 2015). Oluşabilecek bu bölgeleri yok etmek için bu yöntem ek olarak sinyalin enerjisi kullanılmış ve enerjiye bağlı kesim noktası belirlenmiştir. Ayrıca, süre bazlı kesim uygulanmış ve horlamanın 0,6 – 4 saniye aralığı olduğu belirlenmiştir. Bu aralıktaki enerji değerleri çekilerek otomatik bölütleme yapılmıştır (Lee et al., 2012; Yu et al., 2012). Literatürdeki bu iki çalışmanın avantajlı yönleri baz alınarak yeni bir UBF tanımlanmıştır. Skorlama işlemi sırasında kullanılacağı için UBF ile elde edilen tüm bölütler tek tek görsel ve işitsel olarak doğrulanmıştır. Şekil 3'te geliştirilen UBF ile yapılan işleme ait bir örnek görülmektedir. Süreleri farklı olmasına rağmen her ses paterni otomatik olarak işaretlenmiştir. Uyku esnasında çıkan sesin bulunduğu konum "1" olarak belirlenmiş, nefes vermelerin bulunduğu konum "0" olarak belirlenmiştir.



Şekil 3. Geliştirilen UBF ile yapılan bölütleme örneği. Her ses patni otomatik olarak başlangıç ve bitiş noktalarına göre belirlenmektedir.

Dalga Formu Analizleri

Dalga formu analizlerinin tamamı filtrelenmiş sinyal üzerinde pencereleme yapılarak gerçekleştirilmiştir. Analizler sonucu elde edilen sonuçlar, sınıflandırıcının eğitilmesi aşamasında öznitelik olarak kullanılmıştır.

Pencereleme

UBF ile tiplere ayrılan seslere dalga formu analizlerini uygulamak için her ses tipine ait bölüt içinde de ayrıca pencereleme işleme yapılmıştır. Bölüt başlangıç ve bitiş noktası içinde kalan her ses tipinin zamandaki ani değişikliklerini belirleyebilmek için pencereleme işlemi örtüşmeli olarak gerçekleştirilmiştir. Literatürde 50–300 msn aralığında farklı uzunluklarda pencereler kullanılmıştır (Lee et al., 2012; Yu et al., 2012). Çözünürlük ve hız optimizasyonu sağlamak amacıyla yapılan denemeler sonucunda pencere boyutu 100 msn, örtüşme oranı da % 50 olarak belirlenmiştir.

Enerji

Enerji, sinyalin zamandaki anlık değişimleri hakkında bilgi vermektedir. Eşitlik 2’de verilen sonlu uzunluktaki sayısal bir işaretin enerji ifadesine göre; enerji sinyali oluşturan her örneğin mutlak değerlerinin kareleri toplamı olarak tanımlanır (Proakis and Monolakis, 1996; Rangayyan, 2015). Eşitlik 2’de, E enerjisi, $x(n)$ örnekleri N ise sonlu aralığın sınırlarını göstermektedir.

$$E = \sum_{-N}^N |x(n)|^2, -N < n < N \quad (2)$$

Varyans

Varyans sinyalin örnek değerlerin, sinyalin aritmetik ortalamasına olan uzaklığını ifade eder. Aritmetik ortalama, bir sinyali oluşturan tüm değerlerin toplamının, sinyaldeki veri sayısına bölünmesini ifade eder (Eşitlik 3) (Rangayyan, 2015). Varyans, dağılıma ait her bir değer için dağılımın ortalamasından uzaklığını ifade eder. Varyans standart sapmanın (σ) karesi olarak Eşitlik 4’de verilmiştir. Burada, $x(n)$ örnekleri, μ ortalamayı ve N değer sayısını ifade etmektedir.

$$\mu = \frac{1}{N} \sum_{n=1}^N x(n) \quad (3)$$

$$V = \sigma^2 = \frac{1}{N} \sum_{n=1}^N |x(n) - \mu|^2 \quad (4)$$

Sıfır kesme oranı

Sinyalin sıfır genlik seviyesinden (taban hattı) kaç defa geçtiğini sıfır kesme oranı (SKO) ile belirlenebilir. SKO sinyalin frekansı ile doğrudan bağlantılıdır. Frekanstaki anlık değişime bağlı olarak SKO değişir. SKO bir sinyaldeki aktivite değişiminin belirlenebilmesi amacıyla kullanılabilir. Ancak, SKO DC sapmadan, taban hattı üzerindeki değişimlerden ve düşük frekans artifaktlardan etkilenebilir. Bu nedenle, filtrelenmiş sinyale uygulanması önerilmektedir (Rangayyan, 2015). SKO aşağıdaki basamaklar uygulanarak hesaplanmıştır.

- Ses kaydı, 100 milisaniye uzunluğunda, 50 milisaniye örtüşmeli olarak pencerelenir.
- Her pencere içerisindeki ilk değerın işareti (pozitif veya negatif) belirlenir.
- Pencere sonuna kadar sırasıyla her örnek değerinin işareti belirlenir.
- İşaretin pozitiften negatife veya negatiften pozitifte değiştiği her zaman noktası sayılarak SKO değerine atanır.

Özilinti fonksiyonu


Özilinti fonksiyonu (ÖF) sinyalin kendisi ile benzerliğinin ölçüsünü vermektedir. Her pencerenin kendisinden bir sonraki pencereye ilintisi (benzerliği) ÖF kullanılarak belirlenmiştir. Sonlu süreli bir sinyal için Eşitlik 5’de ifadesi verilen ÖF ifadesinde $x(n)$ örnekleri, N sinyalin içerdiği örnek sayısını ifade etmektedir (Proakis and Monolakis, 1996). Benzerlik sonucu “1” değerine normalize edilmiştir. Bu şekilde örtüşmeli pencerelerin benzerliği maksimum 1 minimum 0 olmaktadır.

$$r_{xx}(l) = \sum_{n=l}^{N-|k|-1} x(n)x(n-l) \quad (5)$$

Destek Vektör Makineleri

Destek Vektör Makineleri (DVM), teorisi 1960’lı yıllarda Vladimir Vapnik tarafından önerilen ve 1995 - 1999 yılları arasında Cortes ve Vapnik tarafından algoritması geliştirilmiş bir örüntü tanıma ve sınıflandırma yöntemidir (Vapnik, 2000; Kecman, 2001; Wu et al., 2008). DVM, öznelik uzayındaki iki sınıfı en uygun şekilde ayırt etmeyi mümkün kılacak hiperdüzlemler bulma ilkesine dayanmaktadır. Yeterince yüksek bir boyuta uygun doğrusal olmayan bir eşleme ile iki kategoriden alınan veriler her zaman bir hiperdüzlem ile ayrılabilir (Cortes and Vapnik, 1995; Wu et al., 2008). Kenar boşluğu (margin), bir hiperdüzlem tarafından tanımlanan iki sınıf arasındaki boşluk veya ayırma miktarı olarak tanımlanır ve geometrik olarak, hiperdüzlemdeki herhangi bir noktaya en yakın veri noktaları arasındaki en kısa mesafedir. Şekil 4, iki boyutlu bir girdi uzayı için en uygun (optimal) hiperdüzlemin geometrik bir yapısını göstermektedir. w ve b sırasıyla en uygun hiper düzlemde ağırlık vektörünü ve sapmayı (bias) gösterir. Karşılık gelen hiperdüzlem $w^T x + b = 0$ olarak tanımlanabilir. x örneğinden en uygun hiperdüzleme istenen geometrik mesafe ise $r = g(x)/\|w\|$ olarak tanımlanır. Burada, $g(x) = w^T x + b$ hiperdüzlem tarafından tanımlanan ayırt edici işlemdir. Sonuç olarak DVM, sırasıyla iki sınıftan en kısa geometrik uzaklıklarla belirlenen ayırma kenar boşluğunu (ρ) (Eşitlik 6) maksimize ederek en uygun hiperdüzlem için w ve b parametrelerini bulmayı amaçlamaktadır (Bazzani et al., 2001; Wu et al., 2008).

$$\rho = 2r^* = \frac{2}{\|w\|} \quad (6)$$




Şekil 4. Doğrusal olarak ayrılabilir bir durum için DVM'deki en uygun hiperdüzlemin gösterimi (Wu et al., 2008).

Veri setinin doğrusal bir fonksiyonla ayrılabilmesi durumunda doğrusal olmayan DVM kullanılmaktadır. Özellikle, fizyolojik kökenli durağan olmayan sinyallere ait veri setinin hiperdüzlem ile doğrusal olarak ayrılması özneliklere bağlı olsa da genellikle zordur (Ayhan ve Erdoğan, 2014; Kantar and Erdamar, 2019). Verileri doğrusal olarak ayrılabilir hale getirmek için, verilerin giriş uzayından daha yüksek boyutlu bir öznelik uzayına doğrusal olmayan dönüşümüne olanak sağlayan ve iç çarpıma dayanan uygun bir çekirdek (kernel) fonksiyonu tanımlanmaktadır (Wu et al., 2008). Öznelik uzayında bir hiperdüzlem oluşturmak için önce n-boyutlu girdi vektörünü (x), N-boyutlu bir öznelik vektörüne (ϕ) dönüştürmek gerekir ($\phi: \mathbb{R}^n \rightarrow \mathbb{R}^N$) (Cortes and Vapnik, 1995; Burges, 1998). Daha sonra dönüştürülmüş vektörler kümesi için bir N-boyutlu doğrusal ayırıcı w ve b yapılandırılır ($\phi(x_i) = \phi_1(x_i), \phi_2(x_i), \dots, \phi_N(x_i), i = 1, \dots, l$). Bilinmeyen bir vektörün sınıflandırılması, önce vektörün ayırma boşluğuna dönüştürülmesi ve daha sonra $f(x) = w \cdot \phi(x) + b$ fonksiyonunun işaretinin alınmasıyla yapılır. Destek vektör ağırları, Hilbert uzayındaki iç çarpımlar ile elde edilmektedir. $\phi(u) \cdot \phi(v) \equiv K(u, v)$ olmak üzere, farklı nokta çarpımlar isteğe bağlı Eşitlik 7 ile verilen karar düzlemlerine sahip farklı öğrenme makineleri oluşturulabilir (Cortes and Vapnik, 1995).

$$f(x) = \sum_{i=1}^l y_i \alpha_i K(x, x_i) \quad (7)$$

Burada x_i , giriş uzayındaki bir destek vektörünün görüntüsü, $K(x, x_i)$ çekirdek fonksiyonu ve α_i öznelik alanındaki bir destek vektörünün ağırlığıdır. Bu ağırlık katsayıları *Lagrange* çarpanları olarak da adlandırılır. Doğrusal olmayan DVM ağ yapısı Şekil 5'de verilmiştir.



Şekil 5. DVM algoritmasının ağ yapısının şematik gösterimi.

Bu çalışmada, yöntem kısmında açıklanan öznelikler ile yapılan analiz çalışmalarında bazı özneliklerin doğrusal bazılarının ise doğrusal olmayan dağılıma sahip oldukları belirlenmiştir. Bu nedenle, sınıflandırma işlemlerinde doğrusal ve ikinci derece doğrusal olmayan DVM sınıflandırıcıları kullanılmıştır. Ardından, elde edilen tüm öznelikler ile sınıflandırıcı eğitimi tamamlanmıştır. Eğitim

esnasında Temel Bileşen Analizi (TBA) kullanılmıştır. TBA, birbiri ile ilişkili olan çok sayıda değişkenden oluşan bir veri kümesinin boyutunu azaltırken, veriler arasındaki varyasyonu mümkün olduğunca arttırmaktadır. Bu işlemi gerçekleştirirken verileri karıştırarak yeni bir veri seti oluşturur. Böylelikle, sınıflandırıcı eğitiminde, birbiri ile ilişkili verilerin sıralı halde olmasından kaynaklanacak olan yanlış eğitimin önüne geçilebilmektedir (Jolliffe and Cadima, 2016).

Algoritma Başarısının Değerlendirilmesi

Sınıflandırma işleminin sonucunda elde edilen çıkış değerleri, gerçekleştirilen kör skorlama işlemi ile karşılaştırılarak algoritmanın başarısı değerlendirilmiştir. Eğitim ve test sonuçlarından doğru pozitifler (DP), yanlış pozitifler (YP), doğru negatifler (DN) ve yanlış negatifler (YN) elde edilmiştir. Geliştirilen algoritmanın test edilmesi amacıyla duyarlılık (Eşitlik 8), özgüllük (Eşitlik 9) ve doğruluk (Eşitlik 10) parametreleri hesaplanmıştır (Fawcett, 2006).

$$Duyarluluk = DP / (DP + YN) \quad (8)$$

$$Özgüllük = DN / (DP + YP) \quad (9)$$

$$Doğruluk = (DP + DN) / (DP + YP + DN + YN) \quad (10)$$

BULGULAR VE TARTIŞMA

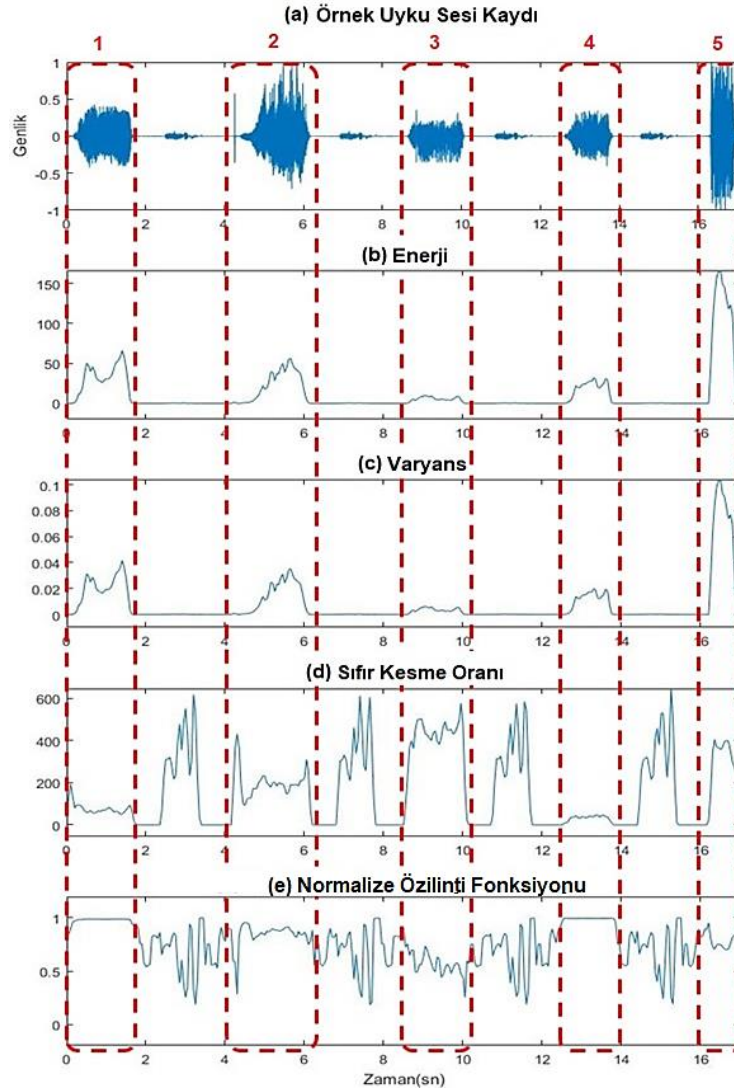
Dalga Formu Analizleri Sonucunda Elde Edilen Araştırma Bulguları

Dalga formu analizleri için örnek bir ses kaydının analiz sonuçları Şekil 6'da verilmiştir. Şekil üzerinde kırmızı kesikli çizgi işaretlemesiyle her uyku sesi paterni ve analiz sonuçları vurgulanmıştır.

Elde edilen grafikler incelendiğinde, sadece öksürme ve nefes verme seslerinin görsel olarak ayırt edilebildiği söylenebilir. Horlama seslerinin türlerini grafiği inceleyerek ayırt etmek pratikte oldukça zordur. Enerji ve varyans seviyeleri incelendiğinde nefes verme ve öksürme sesleri haricinde, sadece tripleks horlamada önemli ölçüde değişim olduğu görülmektedir. SKO analiz grafiğinde ise farklı ses tiplerinin birbirinden ayrıldığı görülmektedir. ÖF analiz sonucu incelendiğinde dubleks düşük frekans horlama ve basit horlama diğer ses türlerinden ayırt edici özellikleri olduğu söylenebilir. Klinikteki görsel skorlamaya benzer olarak bu şekilde yapılacak değerlendirmeler ile nicel sonuçlar elde etmek doğru değildir. Bu nedenle çalışmanın amacına uygun bir şekilde DVM sınıflandırıcı kullanılarak makine öğrenmeye dayalı sınıflandırma işlemleri yapılmıştır. Bu amaçla ilk olarak, enerji, varyans, SKO ve ÖF parametrelerinin UBF ile belirlenen zaman lokasyonu içindeki ortalama değerleri öznitelik olarak belirlenerek 390 bölüt ile eğitim veri seti oluşturulmuştur. Bu eğitim veri seti DVM sınıflandırıcı kullanılarak eğitilmiş ve % 91.8 eğitim doğruluğu elde edilmiştir. Daha sonra, eğitilen sınıflandırıcı ile eğitimde kullanılmayan 449 bölüt veri ile sınıflandırıcı test edilmiştir. Sınıflandırıcının test sonuçları özgüllük, hassasiyet ve doğruluk değerleri Çizelge 1'de verilmiştir.

Çizelge 1. DVM sınıflandırıcısı test sonuçları.

Sesin Türü	Özgüllük	Hassasiyet	Doğruluk
Nefes Verme	% 99.11	% 100	% 99.55
Basit Horlama	% 99.20	% 27.03	% 87.31
Dubleks Düşük Frekans Horlama	% 96.72	% 38.55	% 85.97
Dubleks Yüksek Frekans Horlama	% 77.65	% 60.00	% 77.06
Tripleks Horlama	% 99.28	% 86.67	% 98.44
Öksürme	% 96.49	% 22.73	% 92.87
Ortalama	% 94.74	% 55.83	% 90.20



Şekil 6. Örnek uyku sesi kaydı için dalga formu analizleri. (a) sırasıyla, “1” numaralı sinyal dubleks düşük frekans horlama, “2” numaralı sinyal dubleks yüksek frekans horlama, “3” numaralı sinyal tripleks horlama, “4” numaralı sinyal basit horlama, “5” numaralı sinyal öksürme ve boşlukta kalan sinyaller ise nefes verme örnekleridir, (b) enerji analizi, (c) varyans analizi (d) SKO (e) ÖF sonuçları sunulmuştur.

SONUÇ

Literatürde uyku esnasında çıkan seslerin sınıflandırılması ile ilgili oldukça az sayıda çalışma bulunmaktadır. Bu çalışmaların büyük bir çoğunluğu ses kaydı içerisinde horlama tespiti (horlama var-yok) üzerine yoğunlaşmıştır. Horlama tespiti amacıyla genellikle genlik-zaman analizleri ile sınıflandırma işlemi gerçekleştirilmiştir. Bu çalışmanın literatürdeki diğer çalışmalara göre farklılıklarından biri altı farklı uyku sesi modalitesinin (nefes verme, öksürme ve dört farklı horlama türü) makine öğrenmesine dayalı olarak yüksek doğruluk ve özgüllük oranıyla otomatik olarak sınıflandırılmasıdır. Basit horlama ve diğer horlama türleri arasındaki test sonuçlarında hassasiyetin göreceli düşük olduğu görülmektedir. Bunun sebebi ise horlama paterni türlerinin genlik ve frekans özellikleri ile zamansal değişim özelliklerinin birbirine yüksek oranlarda benzemesidir. Sonuç olarak, literatürdeki horlama tespiti konusundaki çalışmalara (Cavusoglu ve ark., 2007; Karunajeewa et al., 2008; Azarbarzin and Moussavi, 2011) göre daha yüksek başarı oranına sahip ve çoklu sınıflandırma işlemi gerçekleştiren diğer çalışmalardan (Dafna et al., 2013; Alshaer et al., 2014) farklı olarak horlama türlerini sınıflandırabilen bir karar destek algoritması geliştirilmiştir.

Çalışmanın özgün kısımlarından biri de geliştirilen UBF'dur. Farklı kaynaklardan elde edilen ve birçok ön işlemden geçirilen tüm kayıtları her bir bölütte tek bir ses paterni olacak şekilde bölütlere ayırmıştır. Böylece, uyku esnasında alınan bir ses kaydının hızlı, efektif ve doğru şekilde bölütlere ayrılmasını sağlayan yeni bir yöntem sunulmuştur.

Sonuç olarak, bu çalışmada uyku hastalıkları konusunda uzman doktora ön fikir verebilen, bütün bir uyku sesi kaydını hızlı ve efektif biçimde analiz ederek, yüksek doğrulukla otomatik olarak sınıflandırabilen yeni bir karar destek algoritması oluşturulmuştur. Çalışmanın sonucunda elde edilen bilgilerin gelecekte gerçekleştirilecek çalışmalara ışık tutacak nitelikte olduğu düşünülmektedir. Sunulan yöntemler ve geliştirilen algoritma kullanılarak, PSG ile senkronize çalışabilecek ve uzman doktora uyku esnasındaki sesler hakkında fikir verebilecek karar destek mekanizması içeren modüller tasarlanabilir. Hastanın kendi uyku ortamında ses kaydı almasını ve analiz etmesini sağlayacak sistemler tasarlanabilir.

KAYNAKLAR

- Alshaer H, Pandya A, Bradley TD, Rudzicz F, 2014. Subject Independent Identification of Breath Sounds Components Using Multiple Classifiers. 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Florence, Italy, May 04-09, 2014, pp: 3577–3581.
- Ayhan S, Erdoğan Ş, 2014. Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi, 9 (1): 175–201.
- Azarbarzin A, Moussavi ZMK, 2011. Automatic and Unsupervised Snore Sound Extraction From Respiratory Sound Signals. IEEE Transactions on Biomedical Engineering, 58(5): 1156–1162.
- Bazzani A, Bevilacqua A, Bollini D, Brancaccio R, Campanini R, Lanconelli N, Romani D, 2001. An SVM Classifier to Separate False Signals From Microcalcifications in Digital Mammograms. Physics in Medicine and Biology, 46 (6): 1651–1663.
- Berry RB, Budhiraja R, Gottlieb DJ, Gozal D, Iber C, Kapur VK, Tangredi M, 2012. Rules For Scoring Respiratory Events in Sleep: Update of the 2007 AASM Manual for the Scoring of Sleep and Associated Events. Journal of Clinical Sleep Medicine, 8 (5): 597–619.
- Burges CJ, 1998. A Tutorial on Support Vector Machines for Pattern Recognition. Data Mining and Knowledge Discovery, 2(2): 121-167.
- Cavusoglu M, Kamasak M, Erogul O, Ciloglu T, Serinagaoglu Y, Akcam T, 2007. An Efficient Method for Snore/nonsnore Classification of Sleep Sounds. Physiological Measurement, 28 (8): 841–853.
- Cortes C, Vapnik V, 1995. Support-Vector Networks. Machine Learning, 20(3): 273-297.
- Counter P, Wilson JA, 2004. The Management of Simple Snoring. Sleep Medicine Reviews, 8 (6): 433–441.
- Dafna E, Tarasiuk A, Zigel Y, 2013. Automatic Detection of Whole Night Snoring Events Using Non-Contact Microphone. PLoS ONE, 8 (12): e84139.
- Deller JR, Hansen JHL, Proakis JG, 1999. Discrete-Time Processing of Speech Signals. Wiley-IEEE Press, pp. 223-285, New York-United States.
- Doukas C, Petsatodis T, Boukis C, Maglogiannis I, 2012. Automated Sleep Breath Disorders Detection Utilizing Patient Sound Analysis. Biomedical Signal Processing and Control, 7 (3): 256–264.
- Duckitt WD, Tuomi SK, Niesler TR, 2006. Automatic Selection, Segmentation and Assessment of Snoring from Ambient Acoustic Data. Physiological Measurement, 27 (10): 1047–1056.
- Fawcett T, 2006. An Introduction to ROC Analysis. Pattern Recognition Letters, 27 (8): 861–874.

- Fiz JA, Abad J, Jané R, Riera M, Mañanas MA, Caminal P, Morera J, 1996. Acoustic Analysis of Snoring Sound in Patients with Simple Snoring and Obstructive Sleep Apnoea. *European Respiratory Journal*, 9 (11): 2365–2370.
- Jane R, Fiza JA, Sola-Soler J, Blanch S, Artis P, Morera J, 2003. Automatic Snoring Signal Analysis in Sleep Studies. *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Cancun, Mexico, September 17-21, 2003, pp:366–369.
- Jolliffe IT, Cadima J, 2016. Principal Component Analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374 (2016): 1-16.
- Jones TM, 2005. Acoustic Analysis of Snoring Before and After Palatal Surgery. *European Respiratory Journal*, 25 (6): 1044–1049.
- Karunajeewa AS, Abeyratne UR, Hukins C, 2008. Silence–breathing–snore Classification from Snore-related Sounds. *Physiological Measurement*, 29 (2): 227–243.
- Kecman V, 2001. *Learning and Soft Computing: Support Vector Machines, Neural Networks, and Fuzzy Logic Models*. MIT Press, pp. 121-189, Cambridge, MA-USA.
- Keenan SA, Hirshkowitz M, Casseres H, 2013. Monitoring and Staging Human Sleep. In *Encyclopedia of Sleep*, 5 (1): 71–79
- Kılıç E, 2017. Uyku Esnasında Çıkan Seslerin Sınıflandırılması. Başkent Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi (Basılmış).
- Lee LA, Yu JF, Lo YL, Chen YS, Wang DL, Cho CM, Li HY, 2012. Energy Types of Snoring Sounds in Patients with Obstructive Sleep Apnea Syndrome: A Preliminary Observation. *PLoS ONE*, 7 (12): e53481.
- Proakis JG, Monolakis DG, 1996. *Digital Signal Processing: Principles, Algorithms, and Applications*. Pentice Hall, USA.
- Qian K, Xu Z, Xu H, Wu Y, Zhao Z, 2015. Automatic Detection, Segmentation and Classification of Snore Related Signals from Overnight Audio Recording. *IET Signal Processing*, 9 (1): 21–29.
- Rangayyan RM, 2015. *Biomedical Signal Analysis*. John Wiley & Sons, Inc, pp.720, Hoboken, NJ-USA
- Ugur TK, Erdamar A, 2019. An Efficient Automatic Arousals Detection Algorithm in Single Channel EEG. *Computer Methods and Programs in Biomedicine*, 173: 131-138.
- Vapnik VN, 2000. *Methods of Pattern Recognition: In The Nature of Statistical Learning Theory*, Springer, pp. 123–180, New York-USA).
- Wilson K, Stoohs RA, Mulrooney TF, Johnson LJ, Guilleminault C, Huang Z, 1999. The Snoring Spectrum: Acoustic Assessment of Snoring Sound Intensity in 1,139 Individuals Undergoing Polysomnography. *Chest*, 115 (3): 762–770.
- Wu X, Kumar V, Ross QJ, Ghosh J, Yang Q, Motoda H, Steinberg D, 2008. Top 10 Algorithms in Data Mining. In *Knowledge and Information Systems*, 14 (1): 1-37.
- Yu JF, Chen YS, Li HY, 2012. The Characteristics of Snoring at Pharyngeal Anatomy in Natural Sleep: Snoring Duration. *Journal of Mechanics*, 28 (1): 91–95.