

## Tek kanallı EKG kayıtları analizinden uyku apne tespiti

**Abdulnasır YILDIZ\*<sup>1</sup>,**

<sup>1</sup> Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Diyarbakır

Makale Gönderme Tarihi: 20.10.2016

Makale Kabul Tarihi: 01.12.2016

### Öz

*Bu çalışmada, tek kanallı EKG kayıtlarının analizinden obstrüktif uyku apne (OUA) tespitini yapabilen bir otomatik örüntü tanıma sistemi önerilmiştir. Çalışmada her biri ortalama 8 saat süreden oluşan 60 EKG kaydı kullanılmıştır. Kayıtların 40'ı OUA hastası deneklerden 20'si ise normal deneklerden alınmıştır. Önerilen sistem ön işlem, özellik çıkarımı ve sınıflandırma olmak üzere üç temel aşamadan oluşur. Ön işlem aşamasında dalgacık dönüşümü tabanlı bir algoritma kullanılarak EKG kayıtlarının kalp hızı değişkenliği (KHD) olarak da adlandırılan R-R aralıkları değişkenliği belirlenmiştir. Özellik çıkarım aşamasında ise dalgacık dönüşümü ve entropi hesaplama yöntemleri belirlenmiş olan KHD örüntülerine uygulanarak EKG kayıtlarını temsil eden özellik vektörleri çıkarılmıştır. Sınıflandırma aşamasında ise Destek Vektör Makinesi (DVM) ve Yapay Sinir Ağı (YSA) sınıflandırıcıları kullanılarak OUA hastası ve normal EKG kayıtları belirlenen özellik vektörleri üzerinden birbirinden ayırt edilmiştir. Sınıflandırıcıların başarımı 5 katlı çapraz doğrulama testine göre değerlendirilmiştir. Bu değerlendirmeye göre DVM sınıflandırıcısının doğruluk başarımı % 98.3 ve YSA sınıflandırıcısının doğruluk başarımı ise %96.7 olarak gerçekleşmiştir. Elde edilen sonuçlar göz önüne alındığında önerilen sistemin OUA değerlendirilmesinde uzman hekime ön tanı imkânı sağlayabileceği düşünülmektedir.*

**Anahtar Kelimeler:** EKG; Uyku Apne; Dalgacık dönüşümü; Entropi; Sınıflandırma;

\*Yazışmaların yapılacağı yazar: Abdulnasır Yıldız. abnayil@dicle.edu.tr; Tel: (412) 241 10 00 (3511)

## Giriş

Obstrüktif uyku apne (OUA) sendromu uykuda görülen bir solunum bozukluğu olup uyku sırasında tekrarlanan üst solunum yolundaki tıkanmalar ve bu tıkanmaları izleyen uyanma dönemleri ile karakterize edilir (Amer. Acad. Sleep med. Task Force, 1999). OUA sendromunun yetişkin kadınlarda %2, yetişkin erkeklerde ise %4 oranında olduğu tahmin edilmektedir (Young vd.,1993). OUA sendromu, kişinin günlük yaşam kalitesini düşürüp ölümlerle sonuçlanabilecek birçok işyeri ve trafik kazalarına neden olduğu gibi birçok kardiyovasküler hastalığın gelişmesinde da risk faktörü olarak düşünülmektedir (Wu vd., 1996; Lattimore vd., 2003). Bu olumsuz tablo göz önüne alındığında OUA sendromunun erken tanı ve tedavisinin ne kadar önemli olduğu görülmüş olmaktadır.

OUA tanısı için “altın standart” tanı yöntemi uyku çalışması olarak da bilinen Polisomnografi (PSG) tekniğidir ( Amer. Acad. Sleep med. Task Force, 1999). Hastanelerin uyku laboratuvarlarında gerçekleştirilen bu teknik ile OUA şüphelisi kişiden gece boyunca eş zamanlı olarak kaydedilen çok sayıda fizyolojik parametre uzman hekimlerce değerlendirilerek tanı konulmaktadır. Ancak PSG tanı tekniği, maliyetli, zahmetli ve zaman alıcı bir yöntemdir. Bu da OUA tanısı için uyku çalışma tekniğine alternatif oluşturabilecek ucuz, daha az kayıt gerektiren ve aynı zamanda ev ortamında uygulanabilecek tanı tekniklerine ihtiyaç duyulduğunu göstermektedir.


Elektrokardiyogram(EKG) kalbin elektriksel aktivitesini yansıtan işaret olup tekrarlayan P, QRS ve T dalgalarından oluşur (Şekil 1). Daha önceki bazı çalışmalar, EKG işaretinden türetilen bazı bilgilerin OUA sendromunun tanısında kullanılabileceğini göstermiştir (Guilleminault vd., 1984; Roche vd., 1999; Penzel vd., 2002). Bu bilgilerden biri, Kalp Hızı Değişkenliği (KHD) olarak da adlandırılan EKG ‘nin ardışıl R-R aralıkları (kalp hızı) değişkenliğidir. Çalışmalar apnenin ilk dönemlerinde oluşan bradikardi ve apne sonrası ortaya çıkan taşikardinin R-R aralıklarında

periyodik değişimlere neden olduğunu bildirmişlerdir. KHD işaretinin EKG kaydının ardışık QRS dalgalarının tepe aralıklarından (R-R aralıkları) tespit edilebilmesi için öncelikle QRS dalgalarının EKG içerisindeki zaman konumlarının tespit edilmesi gerekir. Ancak QRS dalgasının zaman içerisinde fizyolojik değişkenlik arz etmesi, EKG’nin çeşitli gürültüler barındırması ve ayrıca EKG’nin P ve T dalgalarının yüksek genliği gibi sebeplerden dolayı QRS dalgasının tespiti kolay olmamaktadır. Literatürde QRS dalgasının konumu tespitine yönelik türev, sayısal fitre ve dalgacık dönüşümü tabanlı birçok teknik önerilmiştir (Köhler vd., 2002)

Tek kanallı EKG kayıtlarını kullanarak geliştirilecek bir otomatik örüntü tanıma sistemi ile kişinin OUA sendromlu olup olmadığını belirlemek geleneksel tanı tekniğine (polisomnografi) göre daha ekonomik ve pratik olacaktır. Çünkü böyle bir sistem uyku laboratuvarlarına gerek duyulmadan ev ortamında da uygulanabilecek bir sistem olacaktır. Son zamanlarda çeşitli yöntemler kullanarak EKG’den OUA tespitine yönelik çok sayıda çalışma yapılmıştır (de Chazal vd., 2004; Hossen vd., 2005; Mendez vd., 2009; Khandoker vd., 2009; Babaeizadeh vd., 2010; Sezgin, 2015a). Ayrıca, EKG kayıtlarının dışında, oksijen saturasyonu (Marcos vd., 2009), EEG (Liu vd., 2008) ve EMG (Sezgin, 2015b) gibi farklı türde fizyolojik kayıtlar kullanıp OUA tespitini yapan çalışmalarda literatürde mevcuttur.

Bu çalışmamızın amacı EKG kayıtlarından OUA tespitini yapabilen otomatik bir örüntü tanıma sistemi sunmaktır. Sunulan sistem ön işlem, özellik çıkarım ve sınıflandırma gibi üç temel aşamadan oluşmaktadır. Sistemin en önemli aşaması olan ön işlem aşamasında dalgacık dönüşümü tabanlı bir algoritma kullanılarak EKG’nin belirgin QRS dalgası (R tepesinin zamandaki konumu) tespit edilmiş ve bu tespitten yararlanarak ardışık R-R aralıkları değişkenliği (KHD işareti) türetilmiştir. Özellikle çıkarım aşamasında ise türetilen KHD

işaretlerine dalgacık dönüşümü ve entropi hesaplama tekniği uygulanarak her EKG kaydı veri boyutu 12 olan bir özellik vektörü ile temsil edilmiştir. Sınıflandırma aşamasında ise bu özellik vektörleri üzerinden EKG kayıtlarının OUA hastası olup olmadığını tespit etmek için hem destek vektör makinesi (DVM) sınıflandırıcısı hem de bir yapay sinir ağı (YSA) modeli olan çok katmanlı algılayıcı sınıflandırıcısı kullanılmıştır. Sınıflandırıcıların başarımları 5 katlı çapraz doğrulama testine göre gerçekleştirilmiştir. Böylelikle çalışmada kullanılan 60 EKG kaydının tümü hem eğitim hem de test için kullanılmıştır.



Şekil 1: Örnek EKG işareti

## Materyal ve Yöntem

### Kullanılan EKG Verileri

Bu çalışmada kullanılan EKG kayıtları "physionet apnea-ECG database" adlı veri bankasından alınmıştır (www.physionet.org). Veri bankası toplam 70 EKG kaydından oluşmaktadır. Kayıtlar gece uykusu esnasında yapılmış olup her kayıt yaklaşık 8 saattir. Uyku kayıtlarının tümü 32 denekten alınmıştır. Bu deneklerin 25'i erkek, 7'si ise kadındır. Deneklerin yaş aralığı 27 ile 63 arasında olup yaş ortalaması ise 43.8 civarındadır. Kayıtların deneklere göre dağılımı şu şekildedir: Dört denğin her birinden birer kayıt, 22 denğin her birinden ikişer kayıt, iki denğin her birinden üçer kayıt ve dört denğin her birinden dörder kayıt alınmıştır. Kayıtlar PSG tekniği dâhilinde alınmış ve değerlendirilmiştir. Kayıt esnasında elektrotların vücut yüzeyine yerleşim biçimi için standart  $V_2$  derivasyonu kullanılmıştır. EKG işaretleri 16 bitlik çözünürlük ile 100 Hz 'de örneklenerek sayısallaştırılmıştır.

EKG kayıtlarının OUA hastası kişiye ait olup olmadığının değerlendirilmesi uyku çalışma tekniğine göre yapılmıştır. Uyku çalışma tekniği ile EKG kayıtlarının her dakikası değerlendirilerek uyku apnesi barındırıp barındırmadığına bakılmıştır. Yapılan bu değerlendirme sonucunda kayıtlar aşağıda verildiği gibi 3 gruba ayrıştırılmıştır:

**A Grubu (OUA hastası grup):** Bu grupta yer alan EKG kayıtları OUA hastası olarak tanımlanmıştır. Kayıtların içerdiği uyku apneli dakika sayısı 100 ve üzeri, apne hipopne indeksi (AHI) ise 10 ve üzeri olarak değişmektedir. Bu gruptaki yer alan kayıt sayısı 40'dır.

**B Grubu (hafif OUA hastası grup):** Bu gruptaki EKG kayıtlar hafif OUA hastası olarak tanımlanmıştır. Grupta yer alan kayıtların uyku apneli dakika sayısı 5 ile 99 arasında, AHI ise 5 ve üzeri olarak değişmektedir. Grupta yer alan kayıt sayısı 10'dur.

**C Grubu (Sağlıklı veya Normal grup):** Bu grupta yer alan EKG kayıtları sağlıklı kayıtlar olarak tanımlanmıştır. Kayıtların uyku apneli dakika sayısı 5'in altındadır. Bu grupta yer alan kayıt sayısı 20'dir.

Bu çalışmada B grubunda yer alan kayıtlar hafif (mild) OUA hastası oldukları için çalışmaya dâhil edilmemiştir. Yapılan çalışma, 40 OUA hastası kayıt içeren A grubu ile 20 Normal (OUA hastası olmayan) kayıt içeren C grubunu kapsamaktadır.

### Ayrık Dalgacık Dönüşümü (ADD)

Dalgacık dönüşümü (DD), Kısa zamanlı Fourier dönüşümünün sabit genişlikteki pencere kaynaklı problemlerine ölçeklenebilir bir dalgacık fonksiyonu kullanarak çözüm getirir. Böylece analizi yapılacak işaret için bütün frekans aralıklarında optimum zaman-frekans çözünürlüğü sağlanır. ADD, Sürekli dalgacık dönüşümünün aşırı hesap gerektiren olumsuz tarafını ortadan kaldırmak için geliştirilmiştir. ADD'de, dalgacık katsayıları hesaplanması tüm olası ölçekleme ve öteleme parametreleri için

değil de bunların bir alt kümesini oluşturan belirli noktalardaki ayrı değerleri için yapılır. Bu işlemin gerçekleştirilmesi için filtreleme dayalı etkin bir algoritma geliştirilmiştir (Mallat, 1989). Çoklu çözünürlük olarak da bilinen bu algoritma ardışık yüksek geçiren ( $h[n]$ ) ve alçak geçiren ( $g[n]$ ) filtre çiftlerinden oluşur.

### Entropi

Entropi, termodinamik fiziğinin bir kavramı olup bir sistemin düzensizliğinin ölçüsü olarak tanımlanır. Bir sistemin düzenli bir yapıdan düzensiz bir hale geçmesi, o sistemin entropisini artırır. Yani sistemin düzensizliği ne kadar fazla ise, o sistemin entropisi de o kadar yüksek olmaktadır. Entropi kavramının işaret işleme alanına uyarlanması ilk olarak Shannon tarafından gerçekleştirilmiştir (Shannon, 1948). İşaret işleme alanındaki bu ilk uygulama ile birlikte, özellikle durağan olmayan bir işaretin düzensizlik veya karmaşıklık bilgisini tanımlamak için entropi ideal bir tanımlayıcı olarak görülmeye başlanmıştır (Türkoğlu, 2002).

### Çok Katmanlı Algılayıcı (ÇKA)

Güçlü bir sınıflandırıcı olarak kullanılabilen ÇKA, Rumelhart ve arkadaşları tarafından geliştirilen bir yapay sinir ağı modelidir. Kullandığı öğrenme algoritması nedeniyle hata yayma modeli veya geriye yayım modeli (back propagation network) olarak da bilinir (Rumelhart vd., 1989). ÇKA ileriye doğru bağlantılı olan giriş, ara ve çıkış olarak adlandırılan 3 katmandan oluşan ağ yapısına sahiptir. ÇKA ağı güdümlü öğrenme stratejisine göre çalışır. Yani, ağa eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi beklenen çıktılar uygulanır. Ağın görevi bu stratejiye dayalı bir öğrenme kuralı kullanarak kendisine gösterilen her girdiye karşılık beklenen çıktıyı üretmesini sağlayacak ağırlık değerlerini bulmaktır. ÇKA öğrenme kuralı olarak hata geriye yayma algoritmasını kullanır. Bu algoritma en küçük kareler yöntemine dayalı delta öğrenme algoritmasının ÇKA ağına uyarlanmış halidir.

### Destek Vektör Makinaları (DVM)

DVM, sınıflandırma ve doğrusal olmayan fonksiyon yaklaşımı problemlerinin çözümü için, ilk olarak Vapnik tarafından ortaya atılan (Vapnik,1995) ve sonradan diğer bilim adamlarınca geliştirilen, görece yeni bir yöntemdir (Smola ve Schölkopf, 1998). DVM başlıca üç bileşenden oluşmaktadır. Bunlar; istatistiksel öğrenme teorisi, optimizasyon algoritması ve çekirdek fonksiyonlarıdır. Bu bağlamda, DVM çekirdek fonksiyonlarıyla dönüştürülmüş olan nitelik uzayında iyi bir genelleme teorisinin ışığında ve optimizasyon teorisinin yardımıyla doğrusal olarak eğitilen bir öğrenme makinesi olarak tanımlanabilir. DVM yapısal olarak, düşük boyutlu bir giriş uzayından alınan veri örneklerini, yüksek boyutlu bir diğer uzaya doğrusal olmayan bir biçimde taşıyan bir dönüşümdür. Dönüşümü gerçekleyen makine, sistem ya da ağ, dönüşümü belirleyen bir çekirdek ile tanımlanır. Sınıflama problemlerinde, yeteri kadar yüksek boyutlu uzaya taşınan veriler doğrusal ayrıştırılabilir duruma gelir. En uygun doğrusal ayrıştırıcı düzlem, ayrıştıran düzlemler arasında sınıflara eşit ve maksimum mesafede olanıdır. Sınır (margin) olarak adlandırılan bu maksimum mesafe veya uzaklık; sınıflara ait veri örnekleri arasından ayrıştırıcı düzleme en yakın olan örneklerden belirlenir. Belirlenen örnekler “Destek Vektörler” olarak adlandırılır. Bu çalışmada, standart DVM sınıflandırıcısının yeniden düzenlenen bir versiyonu olan En Küçük Kareler Destek Vektör Makinası (EKK-DVM) kullanılmıştır (Suykens ve Vandewalle, 1999).

### Ön İşlem

EKG kayıtlarından OUA tespiti için sunulan sistemin ön işleme aşaması sistemin en önemli aşaması olup EKG kayıtlarından KHD (R-R aralıkları) işaretinin belirlendiği aşamadır. KHD işaretlerinin belirlenmesi için öncelikle EKG içerisinde yer alan QRS dalgalarının zaman içindeki konumlarının belirlenmesi gerekir. Ancak, QRS dalgasının 10- 25 Hz frekans bandı aralığında yapısal değişkenlik göstermesi, 0.5- 10 Hz frekans bandı aralığında bulunan P ve T dalgalarının genlik olarak QRS ile benzerlik

göstermesi (Köhler vd., 2002) ve EKG'nin çeşitli gürültüler barındırması (de Chazal vd., 2004) gibi sebeplerden dolayı QRS kompleksinin EKG içerisindeki konum tespiti kolay olmamaktadır. Dolayısıyla QRS dalgasının konum tespitinin doğru yapılabilmesi için bu problemlerin üstesinden gelecek bir algoritma geliştirmek şarttır. Bu çalışmada EKG işaretlerinin DD analizine dayalı basit bir algoritma kullanılarak EKG işaret kayıtları içerisindeki QRS dalgasının R tepe konumları tespit edilmiş ve tespit edilen bu tepe konumları kullanılarak KHD işareti elde edilmiştir.


#### a) EKG kayıtlarının DD ile Analizi

Örnekleme frekansı 100 Hz olan EKG işaretlerinin DD ile analizi için EKG işaretleri içerisindeki QRS dalgasına yapısal benzerliğinden dolayı Daubechies 6 (db6) dalgacığı tipi kullanılmıştır. EKG işaretlerinin ayrışım seviyelerinin sayısı ise 7 olarak belirlenmiştir. Bu durumda, EKG işareti D1-D7 detay ve A7 yaklaşık alt bantlarına ayrıştırılmıştır (Tablo 1).

**Tablo 1.** EKG işaretinin DD ayrışımındaki frekans bantlarının aralıkları

Alt bantlar	İdeal frekans aralıkları (Hz)
D1	25-50
D2	12.5-25
D3	6.25-12.5
D4	3.125-6.25
D5	1.5625-3.125
D6	0.78125-1.5625
D7	0.390625-0.78125
A7	0-0.390625


Bu ayrıştırma biçimi, her biri ortalama 8 saatten oluşan 60 EKG işaret kaydına dakika dakika uygulanmıştır. Şekil 2'de herhangi bir EKG işaret kaydının bir dakikalık kısmının 7. seviyeden db6 DD ayrıştırması görülmektedir.



Şekil 2. Bir dakikalık orijinal EKG işareti ve bu işaretin 7. seviyeden DD ayrıştırması.

DD ayrışımı ile elde edilen alt bantları karşılaştırıldığında, EKG'nin QRS dalgalarına ait enerjinin büyük oranda D2 detay alt bandında yoğunlaşmış olduğu, D2 detay alt bandında QRS dalgalarının R tepelerinin oldukça belirgin olduğu ve ayrıca D2 detay alt bandının P ve T dalgalarından büyük oranda sönülmüş olduğu açıkça görülmektedir. Bu özelliklerinden dolayı D2 detay alt bandı işareti QRS dalgalarının R tepe konumlarının tespitinde referans işaret olarak seçilmiştir. D2 detay alt bandının yanı sıra dikkat çeken diğer alt bant ise A7 yaklaşık bandıdır. A7 yaklaşık alt bandı orijinal EKG işareti ile karşılaştırıldığında bu alt bandın orijinal EKG işaretinin taban hattı sapmasına neden olan bileşene karşılık geldiği görülecektir. Literatürde "baseline wander" olarak ifade edilen ve frekans aralığı 0-0.5 Hz aralığında değişebilen EKG işaretlerinin taban hattı sapması (de Chazal vd., 2004), deneğin uyku esnasındaki hareketinden ve solunumundan kaynaklanan bir gürültü işaretidir. Bu gürültü işareti, EKG içerisindeki QRS dalgalarının konum tespitini zorlaştırdığı gibi aynı zamanda bu konumların gerçek taban hattına ( $y=0$ ) göre genliklerinin yanlış hesaplanmasına neden olur. İstenmeyen bu olumsuzlukları giderebilmek için bu olumsuzluklara neden olan taban hattı sapma gürültüsünün EKG işaretinden

arındırılması gerekir. EKG işaretinin taban hattı sapma gürültüsünden arındırılması için bu gürültüye karşılık gelen A7 yaklaşık bandı (0-0.39 Hz) işaretinin orijinal EKG işaretinden çıkarılması işlemine [(orijinal EKG kaydı) – (A7 yaklaşık alt bandı)] başvurulmuştur. Bu işlemin gerçekleştirilmesi ile Şekil 3’de görüldüğü gibi Taban Hattı Sapmasından Arındırılmış EKG (THSA-EKG) işareti elde edilmiş olur.



Şekil 3. (a) Orijinal EKG işareti, (b) THSA-EKG işareti

Bu çalışmada, EKG İşaret kayıtlarının DD analizi sonucu belirlenen D2 detay alt bant işareti ve THSA-EKG işareti birlikte kullanılarak QRS dalgalarının R tepe konumlarının tespit edilmiş ve tespit edilen bu konumlardan yararlanarak KHD işaretlerinin hesaplanması yapılmıştır.

#### b) R Tepe Konumlarının Tespiti ve KHD işaretinin Hesaplanması

QRS dalgaları R tepe konumlarını tespit eden ve tespit edilen bu tepe konumlardan KHD işaretlerini hesaplayan algoritma aşağıda adım adım verilmiştir:

1. Adım: EKG işaret kaydının bir dakikalık kısmının 7. seviyeden DD ayrıştırılmasıdır Bu ayrıştırma sonucunda QRS dalgaları R tepe konumlarının tespitinde kullanılacak işaretler belirlenir. Belirlenen bu işaretlerden biri D2 detay alt bandı işareti iken diğeri ise A7 yaklaşık alt bandı işaretinin orijinal EKG

işaretinden çıkarılması ile elde edilen THSA-EKG işaretidir.

2. Adım: D2 detay alt bant işareti kullanılarak ardışık QRS dalgalarının R tepe konumlarının tespit edilmesidir. Bu adımda öncelikle D2 detay alt bant işareti için bir eşik değeri belirlenir. Literatürde eşik değerinin hesaplanması için farklı yaklaşımlar bulunmaktadır. Bu çalışmada D2 işaretinin etkin değeri eşik değeri olarak seçilmiştir. 6000 örnekten oluşan D2 işaretinin eşik değerinin hesabı için kullanılan ifade aşağıda verilmektedir.

$$ED = 2 \cdot \sqrt{\frac{1}{6000} \sum_{n=1}^{6000} (D_2[n])^2} \quad (1)$$


Eşik değerin belirlenmesinin ardından, QRS dalgasının R tepesini belirlemeyi garantilemek için normal QRS dalgasının 2 katı genişliğinde olan 20 örneklilik (200ms) bir pencere ile D2 işareti baştan sona taranır. Her bir pencereye ait maksimum değer eşik değeri ile karşılaştırılır. Eğer maksimum değer eşik değerden büyük ise bu maksimum değer, konumu ile birlikte kaydedilir. Bu işlem D2 işaretinin ardışık ve birbirleriyle örtüşmeyen 20 örnek genişliğindeki tüm olası kısımları (pencereleri) için tekrarlanır. Ayrıca bu işlemin tekrarı esnasında aynı QRS dalgasına ait birden fazla konum tespitinin önüne geçebilmek için tespit edilen her iki ardışık konum arasındaki mesafeye bakılır. Eğer bu mesafe 20 örnek veya 20 örneğin altıda ise bu ardışık konumlardan enliği daha büyük olanı ilgili QRS dalgasının R tepe konumu olarak seçilir. Böylece D2 detay işareti üzerindeki tüm QRS dalgaları R tepe konumları ardışık olarak belirlenmiş olur. Ancak, Orijinal EKG işaretinin dalgacık dönüşüm ayrışımının D2 detay işareti kullanılarak belirlenmiş olan bu konumlar, DD'nin aşağı-yukarı örnekleme yapısından kaynaklanan faz kaymaları sebebiyle hatalı olabilmektedir. Bu çalışmada DD'den kaynaklanan konum hatalarının genelde 1 ile 10 örnek (10 ile 100 ms) arasında değişebildiği görülmüştür. Oluşabilecek bu konum hatalarını minimize etmek amacıyla aşağıda verilen 3. adım işlemleri gerçekleştirilir.

3. Adım: Bu adımda öncelikle QRS dalgalarına ait 2. adımda belirlenmiş olan R tepe konumları, THSA- EKG işaretleri üzerine haritalanır. Daha sonra haritalanan her konumun 10 örnek (100ms) sağ ve 10 örnek (100 ms) solu ile sınırlı pencereler içerisinde kalan THSA- EKG işaretine ait kısımların maksimum genliklerine ait konumlar belirlenir. Belirlenen bu konumlar EKG işaretleri üzerindeki QRS dalgalarının gerçek R tepe konumlarıdır. Böylelikle algoritmanın bu 3. adımıyla 1 dakikalık EKG kaydına ait ardışık QRS dalgalarının R tepe konumları saptanmış olur.

4. Adım: Kişinin yaklaşık 8 saatlik süreden oluşan EKG kaydının tüm ardışık QRS dalgaları R tepe konumlarının tespiti için yukarıda verilmiş olan 1- 3 adımları tekrarlanır.

5. Adım: Tespit edilen R tepe konumları kullanılarak ardışık R-R aralıkları hesaplanır (Şekil 4).

6. Adım: Hesaplanan R-R aralıklarının bir kısmı normal olmayabilir. Bu tip aralıklar, EKG kaydının aşırı gürültü içermesi nedeniyle R tepe konumlarının yanlış tespit edilmiş olmasından kaynaklı olabilecekleri gibi EKG'nin sahte (spuriuos) ve kayıp (missed) QRS dalgalarından da kaynaklanabilmektedirler. Bu tip aralıkları tercihen yok etmek gerekmektedir. Çalışmamızda, 0.5 saniyenin altındaki ve 1.5 saniyenin üzerindeki bu tip aralıklar anormal kabul edilip atılmıştır. Bu son işlemin uygulanması ile yaklaşık 8 saat süreli olan bir EKG kaydının KHD işareti elde edilmiş olur.



Şekil 4. Yaklaşık 8 saat süreli bir EKG kaydının hesaplanan R-R aralıkları veya KHD işareti.

### c) Yeniden Örnekleme ve Normalizasyon

Her biri yaklaşık 8 saat olan 60 EKG kaydının KHD işaretleri veri boyutu açısından birbirinden


farklıdır. Bu durum çalışmanın ilerleyen kısmında kullanılacak özellik çıkarım yöntemlerinin bu işaretlere uygulanabilirliğini güçleştirecektir. Bu nedenle kübik spline interpolasyon yöntemi ile örnek (nokta) sayıları 65536 olacak şekilde KHD işaretleri yeniden örneklenmiştir. Böylece işaretler veri boyutu açısından eşitlenmiştir. Yeniden örnekleme işleme için kübik spline interpolasyon yönteminin tercih edilmesinin sebebi ise diğer interpolasyon yöntemlerine göre kullanımının basit olması ve işaretlerin yüksek frekans bileşenlerini zayıflatmamasıdır.

Yeniden örnekleme işleminin ardından her KHD işaretine normalizasyon işlemi uygulanmıştır. Normalizasyon, işaretleri kişiye özgü özelliklerden bağımsız kılabilmek için başvurulan bir işlemdir. Burada KHD işaretlerinin normalizasyonu işlemi için aşağıda verilen ifade kullanılmıştır.

$$X = \frac{x - \mu}{\sigma} \quad (2)$$

Burada,  $\mu$  ve  $\sigma$  sırasıyla  $x$  işaretinin ortalama ve standart sapma değerleridir.  $X$  ise  $x$  işaretinin normalize edilmiş durumuna karşılık gelen işarettir. Denklem 2 ile gösterilen işlemin KHD işaretlerini uygulanması ile bu işaretler, ortalamaları 0 ve standart sapmaları da 1 olacak biçimde normalize edilmiş olurlar.

Buraya kadar gerçekleştirilen tüm işlemler sonucunda her biri yaklaşık 8 saat olan 60 EKG kaydının her birine ait KHD işareti yeniden örnekleme ve normalize edilmiş olur. Örnek bir EKG kaydına ait KHD işaretinin yeniden örnekleme ve normalize edilmiş biçimi Şekil 5'de gösterilmiştir.



Şekil 5. EKG kaydına ait örneklenmiş ve normalize edilmiş KHD işareti.

### Özellik Çıkartma

KHD işaretleri durağan olmayan işaretlerdir. Ayrıca bu işaretlerin uzun süreli EKG kayıtlarından elde ediliyor olması nedeniyle veri boyutları oldukça büyüktür. KHD işaretlerinin durağan olmamaları ve veri boyutlarının yüksek olması örüntü tanıma sisteminde kullanılacak sınıflandırıcıların eğitim sürelerini artıracaktır. Aynı zamanda bu sınıflandırıcıların genelleme ve ayırıştırma yeteneklerini de azaltacaktır. Bu olumsuzlukları giderebilmek için DD ve entropi hesaplama tekniği kullanılarak KHD işaretleri çok daha düşük boyutlu özellik vektörleri ile temsil edilmiştir.

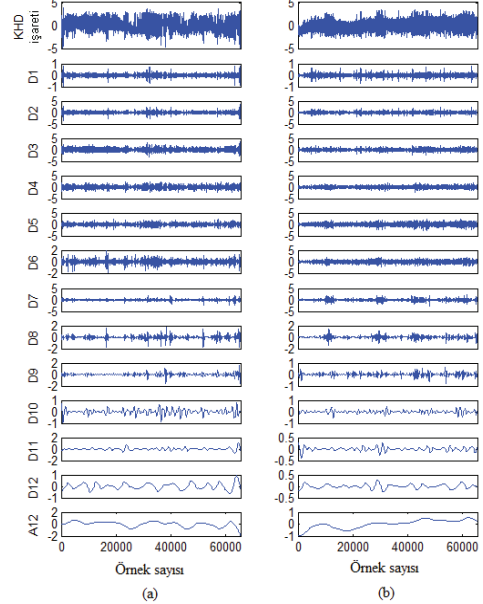
#### a) DD ile KHD İşaretlerinin Alt Bantlara Ayırıştırılması

Burada, her biri 65536 noktadan oluşan KHD işaretlerinin DD ile analizi için Daubechies 4 (db4) dalgacık tipi kullanılmıştır. İşaretlerin ayırıştırma seviyelerinin sayısı ise 12 olarak belirlenmiştir. Kullanılan dalgacık tipinin seçiminde önceki çalışmalar referans alınmıştır (Roche vd.,2003). İşaretlerin ayırıştırma seviyelerinin sayısı ise aşağıda verilen kritere göre belirlenmiştir (Türkoğlu,2002).

$$\frac{n}{2^m} \geq 2N \quad (3)$$

Burada  $n$  (65536) işaretlerin nokta sayısıdır.  $2N$  (16) seçilen dalgacık tipine bağlı olan ayırıştırma filtresinin bant genişliğidir.  $m$  (12) ise işaretlerin ayırıştırma seviyelerinin sayısıdır. Böylelikle özellik çıkarımının bu aşamasında db4 kullanılarak her EKG kaydına ilişkin KHD

işaretlerinin her birinin 12. seviyeden DD ayırıştırma gerçekleştirilmiştir. Bu ayırıştırma işlemi sonucunda her işaret, 12'si detay katsayıları ( $D_1$ - $D_{12}$ ) ve 1'i de yaklaşık katsayıları ( $A_{12}$ ) olmak üzere 13 alt bileşenine ayırıştırılmış olur. Şekil 6'da her biri farklı sınıfa ait 2 örnek EKG kaydının KHD işaretlerinin DD ayırıştırması verilmiştir.



Şekil 6. (a) Normal ve (b) OUA hastalıklı KHD işaretlerinin 12. seviyeden DD'leri.

#### b) KHD İşaretlerine Ait Alt Bantlar İçin Entropi Hesaplaması

Burada ise düzensizliğin ölçüsü olan entropi hesaplama tekniği kullanılarak her EKG kaydına ait KHD işaretlerinin DD ayırıştırması ile elde edilen detay katsayı bileşenlerinin entropi değeri hesaplanmıştır. Bu işlem ile yüksek veri boyutlu detay katsayı bileşenlerinin her biri bir entropi değeri ile temsil edilmiş olacaktır. Burada bu işlemi için norm entropi hesaplama tekniği kullanılmıştır. Bu tekniğin işaretlere ait detay katsayı bileşenlerine uygulama biçimi Denklem 4'de verildiği gibidir.

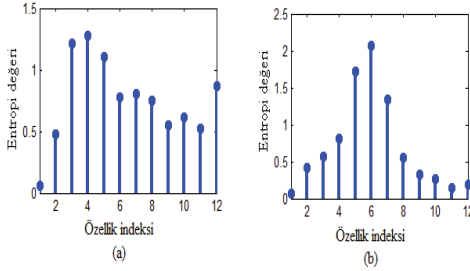


$$E_i = \sum_{n=1}^N |D_i[n]|^p, \quad i = 1, 2, \dots, 12 \quad (4)$$

Buradaki  $D_i$ , KHD işaretinin  $i$ . seviyedeki detay katsayı bileşenidir.  $N$  (65536) katsayı bileşenlerinin veri boyutudur.  $p$  bu çalışmada 7/5 olarak seçilen sabit bir değerdir.  $E_i$  ise KHD işaretinin  $i$ . seviyedeki detay katsayı bileşenin norm entropi değeridir. Denklem 4'deki ifadenin her EKG kaydına ait KHD işaretlerinin detay katsayı bileşenlerine uygulanması ile KHD işareti,

$$V_{\text{KHD}} = [E_1, E_2, \dots, E_{12}] \quad (5)$$

biçiminde veri boyutu 12 olan bir özellik vektörü ile betimlenmiş olur. Şekil 7'de her biri farklı sınıfa ait 2 örnek EKG kaydının KHD işaretlerini betimleyen özellikler verilmiştir.



Şekil 7. (a) Normal ve (b) OUA hastalıklı KHD işaretlerinin elde edilen özellik grafiksel gösterimi

### Sınıflandırma ve Başarım

Sunulan örüntü tanıma sisteminin son aşaması olan sınıflandırma aşamasında iki farklı sınıflandırıcı olan ÇKA ve EKK-DVM sınıflandırıcıları kullanılmıştır. Kullanılan ÇKA modeli 1 ara katmanlı olup bu katmandaki nöron sayısı 10 olarak seçilmiştir. Çıkış katmanındaki nöron sayısı ise 2 olarak seçilmiştir. Giriş katmanındaki nöron sayısını özellik vektörünün kendisi belirleyeceğinden bu sayı 12'dir. Ara ve çıkış katmanındaki nöronların aktivasyon fonksiyonu "Logaritmik sigmoid" olarak belirlenmiştir. Ağın eğitimi için "hata geriye yayma (Resilient)" öğrenme kuralı kullanılmıştır. Ağın öğrenme oranı ve toplam

karesel hata parametreleri sırasıyla 0.01 ve 0.0001 olarak seçilmiştir. EKK-DVM'in eğitiminde çekirdek fonksiyonu olarak radyal tabanlı çekirdek fonksiyonu kullanılmıştır. Kullanılan çekirdek fonksiyonunun genişlik parametresi olan  $\sigma$ 'nin değeri 10 ve sınıflandırıcının düzenleme parametresi olan  $C$ 'nin değeri ise 100 olarak belirlenmiştir. Sınıflandırıcıların etkinlik testi için 5- katlı çapraz doğrulama yöntemi kullanılmıştır. Çalışmada 40'ı OUA hastası ve 20'si normal olmak üzere toplam 60 EKG kaydı olduğu için, 5-katlı çapraz doğrulama testinde kullanılan her bir alt veri kümesi 12 EKG kaydına (8'i OUA hastası ve 4'ü Normal EKG kaydına) ait verileri içermektedir. Dolayısıyla 5 aşamadan oluşan testin her aşamasında 48 EKG kaydına ilişkin veriler sınıflandırıcının eğitimi için, 12 EKG kaydına ilişkin veriler ise sınıflandırıcının test edilmesi için kullanılmıştır.

Ayrıca her sınıflandırıcının test performansı istatistiksel parametrelerin hesaplanması ile değerlendirilmiştir. Bu parametreler aşağıda verilmiştir:

$$\text{Doğruluk} = \frac{GP + GN}{GP + YP + DN + YN} (\%) \quad (6)$$

$$\text{Kesinlik} = \frac{GN}{YP + GN} (\%) \quad (7)$$

$$\text{Duyarlılık} = \frac{GP}{GP + YN} (\%) \quad (8)$$

GP(gerçek pozitif), GN(gerçek negatif), YP (yanlış pozitif) ve YN (Yanlış negatif) kavramları çalışmamız açısından sırasıyla OUA hastası kişinin hasta olarak belirlenmesi, normal kişinin normal olarak belirlenmesi, normal kişinin OUA hastası olarak belirlenmesi ve OUA hastası kişinin normal olarak belirlenmesi biçiminde tanımlanmıştır.

5-katlı çapraz doğrulama testine göre sınıflandırıcıların OUA hastalığını tespit etmedeki başarımlarının konfüzyon matrisi ile gösterimi Tablo 2'de gösterildiği gibi gerçekleşmiştir. Sınıflandırıcıların istatistiksel

parametreler hesabına göre test başarımları ise Tablo 3’de görüldüğü gibi gerçekleşmiştir.

**Tablo 2.** Sınıflandırıcıların test başarımının konfüzyon matrisi ile gösterimi

Sınıflandırma Test		Gerçek Sonuçlar	
		OUA HASTASI	NORMAL
ÇKA	OUA HASTASI	39	1
	NORMAL	1	19
EKK-DVM	OUA HASTASI	40	1
	NORMAL	0	19

**Tablo 3.** Sınıflandırıcıların istatistiksel parametreler hesabına göre test başarımları sonuçları

Sınıflandırıcı	İstatistiksel Parametreler		
	Duyarlılık (%)	Kesinlik (%)	Doğruluk (%)
ÇKA	97.5	95	96.7
EKK-DVM	100	95	98.3

## Sonuç ve Değerlendirme

Bu çalışmada geleneksel tanı teknikleri ile teşhisi zaman alıcı ve maliyetli olan OUA hastalığının otomatik tespitini tek kanallı EKG kayıtlarından gerçekleştirebilen bir otomatik örüntü tanıma sistemi sunulmuştur. Sunulan sistemin ön işlem aşamasında dalgacık tabanlı bir algoritma kullanılarak EKG kayıtlarının KHD (R-R aralıkları) işaretleri elde edilmiş ve ardından bu işaretlere dalgacık dönüşümü ve entropi hesaplama tekniği bileşenlerinden oluşan bir özellik çıkarım yöntemi uygulanarak her EKG kaydı veri boyutu 12 olan bir özellik vektörü ile temsil edilmiştir. Sistemin son aşaması olan sınıflandırma aşamasında ise bir yapay sinir ağı olan ÇKA ve bir destek vektör makinesi olan EEK-DVM sınıflandırıcılar kullanılarak belirlenen özellik vektörleri

üzerinden OUA hastası EKG kayıtları normal EKG kayıtlarından ayırt edilmiştir. Sınıflandırıcıların doğruluk olarak test başarımları ÇKA için %96.7 olarak gerçekleşirken EKK-DVM için bu başarımlar %98.3 olarak gerçekleşmiştir. Elde edilen bu sonuçlara göre EKK-DVM sınıflandırıcısının başarımının az da olsa ÇKA’dan daha iyi olduğu görülmüştür. Her iki sınıflandırıcının başarımı kayda değerdir. Bu da sistemin ön işlem aşamasında önerilen dalgacık tabanlı algoritmanın R-R aralıklarının tespitinde denenebilir bir algoritma olduğunu gösterir. Ayrıca buradaki sonuçlar geçmişte yapılan benzer çalışmaların (Hossen vd.,2005; Khandoker vd., 2009) sonuçları ile kıyaslanabilir düzeydedir.

Bu çalışmada önerilen sistem ile sadece OUA tespiti yapılabilmektedir. Sistem OUA hastalığının şiddetini belirleyememektedir. Bu da mevcut çalışmamızın zayıf tarafını oluşturmaktadır. Çünkü hastalığın tanısı kadar uygun tedavi için şiddetinin bilinmesi büyük önem taşımaktadır. Gelecekte bu problem için çözümüne odaklı çalışmalar yapılması düşünülmektedir.

## Kaynaklar

- Amer. Acad. Sleep Med. Task Force, (1999). Sleep-related breathing disorders in adults: Recommendations for syndrome definition and measurement techniques in clinical research, *Sleep*, 22, 667–689.
- Babaeizadeh, S., White, D.P., Pittman, S.D. and Zhou, S.H., (2010). Automatic detection and quantification of sleep apnea using heart rate variability, *Journal of Electrocardiology*, 43, 535-541.
- de Chazal, P., Penzel, T. and Heneghan, C., (2004). Automated detection of obstructive sleep apnoea at different time scales using the electrocardiogram, *Physiol. Meas.*, 25, 967–983.
- Guilleminault, C., Connolly, S.J., Winkle, R., Melvin, K. and Tilkian, A., (1984). Cyclical variation of the heart rate in sleep apnoea syndrome. Mechanisms and usefulness of 24h electrocardiography as a screening technique, *Lancet*, 321, 126–131.
- Hossen, A., Ghunaimi, B.A. and Hassan, M.O., (2005). Subband decomposition soft- decision

- algorithm for heart rate variability analysis in patients with obstructive sleep apnea and normal controls, *Signal Processing*, 85, 95–106.
- Khandoker, A.H., Karmakar, C. K. And Palaniswami, M., (2009). Automated recognition of patients with obstructive sleep apnoea using wavelet-based features of electrocardiogram recordings, *Computers in Biology and Medicine*, 39, 88–96.
- Köhler, B.-U., Hennig, C., Orglmeister, R., (2002). The principles of software QRS detection, *IEEE Engineering in Medicine and Biology*, 21, 42-57.
- Lattimore, J.D., Celermajer, D.S. and Wilcox, I., (2003). Obstructive Sleep Apnea and Cardiovascular Disease, *Journal of the American College of Cardiology*, 41,1429-1437.
- Liu, D., Pang, Z. and Lloyd, S.R., (2008). A neural network method for detection of obstructive sleep apnea and narcolepsy based on pupil size and EEG, *IEEE Trans. Neural Network*, 19, 308-318.
- Mallat, S., (1989). A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Pattern Anal. and Machine Intell.*, 11, 674-693.
- Marcos, J.V., Hornero, R., Alvarez, D., del Campo, F. and Zamaron, C., (2009). Assessment of four statistical pattern recognition techniques to assist in obstructive sleep apnoea diagnosis from nocturnal oximetry, *Med. Eng. Phys.*, 31, 971–978.
- Mendez, M.O., Bianchi, A.M., Matteucci, M., Cerutti, S. and Penzel, T., (2009). Sleep Apnea screening by autoregressive models from a single ECG lead apnea study, *IEEE Trans. Biomed. Eng.*, 56, 2838-2850.
- Penzel, T., McNames, J., de Chazal, P., Raymond, B., Murray, A. and Moody, G., (2002). Systematic comparison of different algorithms for apnoea detection based on ECG recordings, *Med. Biol. Eng. Comp.*, 40, 402–407.
- Roche, F., Gaspoz, J.M., Court-Fortune, I., Minini, P., Pichot, V., Duverney, D., Costes, F., Lacour, J.R. and Barthelemy J.C., (1999). Screening of obstructive sleep apnoea syndrome by heart rate variability analysis, *Circulation*, 100(13), 1411–1415.
- Roche, F., Pichot, V., Sforza, E., Court-Fortune, I., Duverney, D., Costes, F., Garet, M. And Barthelemy, J-C.,(2003). Predicting sleep apnoea syndrome from heart period: A time–frequency wavelet analysis, *Eur. Respir. J.*, 22, 937–942.
- Rumelhart, D.E., Hinton, D.E. and Williams, R.J., (1986). Learning representation by backpropagating errors, *Nature*, 323, 533-536.
- Sezgin, N., (2015a). The Effect of Obstructive Sleep Apnea on the Electrocardiogram Signals, *3rd International Symposium on Innovative Technologies in Engineering and Science*, Valencia, 1300-1307.
- Sezgin, N., (2015b). EMG classification in OSAS and PLMS patients by using wavelet packet transform and extreme learning machine, *Turkish Journal of Electrical Engineering and Computer Sciences*, 23(3), 873-884.
- Shannon, C.E., (1948). A mathematical theory of communication, *Bell System Technical Journal*, 27, 623–656.
- Smola, A., Schölkopf, B., (1998). On a kernel-based method for pattern recognition, regression, approximation and operator inversion, *Algorithmica*, 22 , 211–231.
- Suykens, J.A.K. and Vandewalle, J., (1999). Least squares support vector machine classifiers, *Neural Processing Letters*, 9, 293–300.
- Türkkoğlu, İ., (2002). Durağan olmayan işaretler için zaman-frekans entropilerine dayalı akıllı örüntü tanıma, *Doktora Tezi*, F.Ü. Fen Bilimleri Enstitüsü, Elazığ.
- Vapnik, V.N., (1995). The Nature of Statistical Learning Theory, Springer-Verlag, New York.
- Wu, H. and Yan-Go F., 1996. Self-reported automobile accidents involving patients with obstructive sleep apnea, *Neurology*, 46:1254-1257.
- www.physionet.org.
- Young, T., Patla, M., Dempsey, J., Skatrud, J., Weber, S. and Badr, S., (1993). The occurrence of sleep-disordered breathing among middle-aged adults, *The New England Journal of Medicine*, 328, 1230-1235.

## Detection of sleep apnea from analysis of single channel ECG recordings

### Extended abstract

Obstructive sleep apnea (OSA) is a common sleep-related breathing disorder. The prevalence of OSA syndrome is known to be 4% in adult men and 2% in adult women. Polysomnography is the gold standard method used to diagnose OSA syndrome. This method is performed by assessment of large number of physiologic parameters recorded concurrently throughout the night in hospitals' sleep laboratories. However, this diagnostic method is expensive and laborious. This indicates that cheaper methods, which may be an alternative to conventional diagnostic methods, are needed. In this study, an alternative pattern recognition system that can detect sleep apnea (OSA) from analysis of single channel ECG recordings is proposed. The proposed system consists of three basic stages: pre-processing, feature extraction and classification. 60 ECG recordings collected from OSA syndrome and normal subjects, each of approximately 8 hours in duration, were used in the study. Of the records, 40 were obtained from patients with OSA and 20 from normal subjects.

In the pre-processing stage of the proposed system, the heart rate variability (HRV) of the ECG records was determined by using an algorithm based on discrete wavelet transform. Here, the wavelet transform was used to decompose the ECG signal into sub-bands. The D2 detail sub-band obtained by this decomposition result was scanned with a maximum finding algorithm to determine the R peaks, and then the HRV pattern of the ECG was obtained by calculating the distances between the R peaks that follow each other.

In the feature extraction stage, the feature vectors were determined by applying discrete wavelet transform and entropy calculation methods to the HRV pattern of ECG recording. In this stage, with using Daubechies 4 (db4) wavelet, HRV pattern of ECG recording was decomposed into the details D1-D12 sub-bands and one final approximation, A12 sub band. Then, entropy value of each details sub-bands was calculated by using norm entropy. Thus, each of the ECG recordings is represented with a feature vector consisting of 12 samples.

In the classification stage, two different classifiers were used to distinguish ECG recordings with OSA from normal ECG recordings through the specified feature vectors. One of these is a multilayer perceptron (MLP) classifier with an artificial neural network. This classifier, also known as back propagation algorithm, consists of input and output and intermediate layers. Except for the input layer, each layer consists of artificial neurons with non-linear activation function. The MLP utilizes a supervised learning strategy called back propagation for training the network. Another classifier used in the study is the support vector machine (SVM). SVM is a relatively new technique used for classification and regression tasks. Standard SVM moves the input data set, which cannot be linearly classified, into a high dimensional feature space by means of kernel functions. Then, in this space, the optimal separating plane is determined to separate the input data from each other. This optimal separation plane can be determined by using the solution of a quadratic programming problem.

The performance of the classifiers was evaluated according to the 5-fold cross-validation test. According to this evaluation, the accuracy performance of the SVM classifier was 98.3% and the accuracy performance of the MLP classifier was 96.7%. Based on the obtained results, it is considered that the proposed system has potential for recognition of patients with suspected OSA by using ECG recordings.

With the proposed system, it can be determined only whether the person is an OSA patient. However, the severity of the OSA syndrome cannot be determined with this system. This problem is the drawback of the system. In the future work, we will focus on solving this problem.

**Keywords:** ECG, Sleep apnea, Wavelet transform, Entropy, Classification