



Makine Öğrenmesi Algoritmaları Kullanılarak Vücut Analizi ile Uyku Apnesi Teşhisi

The diagnosis of Sleep Apnea with Body Analysis using Machine Learning Algorithm

Fatih Ahmet Şenel¹, Rahime Rana Saygın², Mustafa Saygın³, Önder Öztürk⁴.

¹ Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Isparta.

² Isparta Şehir Hastanesi Diyet Polikliniği, Isparta.

³ Süleyman Demirel Üniversitesi, Tıp Fakültesi, Fizyoloji ABD, Isparta.

⁴ Süleyman Demirel Üniversitesi, Tıp Fakültesi, Göğüs Hastalıkları ABD, Isparta.

Öz

Amaç: Bu çalışmada vücut analizi (TANİTA) verileri kullanılarak Apne-Hipopne İndeksine (AHI) göre Obstrüktif Uyku Apne Sendromu (OSAS) şiddetinin tahmin edilmesi amaçlanmıştır.

Gereç ve yöntemler: Bu çalışmada OSAS tanısı konulan ve diyet polikliniğine başvuran 239 adet hastanın, her biri için 23 adet vücut analizi verisi toplanmıştır. Erkek ve kadın hastalar ayrı ayrı değerlendirmeye tabi tutulmuştur. Daha sonra, farklı vücut analizi verisi seçimi algoritmaları kullanılarak, öznelik alt kümesi oluşturulmuştur. Sonuç olarak en başarılı sonuçların elde edildiği öznelik seçim yöntemi, Korelasyon Tabanlı Öznelik Seçimi yöntemidir. Öznelik seçiminden sonra farklı makine öğrenmesi algoritmaları kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Bu algoritmalar; Bayes Sınıflandırıcı Algoritması, Destek Vektör Makineleri, KStar Algoritması, Reptree Algoritması, ZeroR Algoritması ve Yapay Sinir Ağları algoritmalarıdır. Erkek ve kadın hastalarda ayrı ayrı sınıflandırma işlemleri gerçekleştirilmiştir. Bu çalışmada erkek ve kadın hastalar için, sınıflandırma işleminde en fazla etkili olan ilk dört öznelik kullanılmıştır. Erkek ve kadın hastalar için ayrı ayrı sınıflandırma modelleri oluşturulmuştur.

Bulgular: Erkek ve kadın hastalar için ayrı ayrı sınıflandırma modelleri oluşturulmuştur. Erkek hastalar için yaklaşık olarak %69, kadın hastalar için ise yaklaşık %67'lik bir başarı elde edilmiştir. Erkek hastalarda AHI sınıflandırmasının, kadın hastalara göre daha başarılı olduğu anlaşılmıştır. Sonuç: Sonuçlar incelendiğinde sınıflandırma yöntemleri kullanılarak vücut analizi verileri ile AHI tahmininin yapılabileceği öngörülmektedir. En iyi sınıflandırma sonuçları, Yapay Sinir Ağları ve ZeroR modelleri ile elde edilmiştir. Sonuçların daha iyi tahmin yüzdesine sahip olabilmesi için daha geniş hasta sayıları ile yeni çalışmalara ihtiyaç olduğunu düşünmekteyiz.

Anahtar Kelimeler: Vücut analizi, OSAS, makine öğrenmesi

Abstract

Aim: In this study, it was aimed to predict the severity of obstructive sleep apnea syndrome (OSAS) according to apnea-hypopnea index (AHI) using body analysis (TANITA) data.

Material and Method: Twenty-three parameters of body analysis were used for each patient who had been diagnosed with OSAS and admitted to diet polyclinic. Male and female patients were evaluated separately. Then, a subset of features was created using different body analysis data selection algorithms. As a result, the most successful result was obtained by Correlation-based Feature Selection. After feature selection, classification processes were performed using different machine learning algorithms. These algorithms are the Naive Bayes Classifier Algorithm, Support Vector Machine, KStar Algorithm, Reptree Algorithm, ZeroR Algorithm, and Artificial Neural Networks algorithms. Separate classification procedures were performed for male and female patients. In this study, the first four features that are most effective in the classification process were used for male and female patients. Separate classification models have been created for male and female patients.

Results: Separate classification models have been created for male and female patients. A success of approximately 69% for male patients and approximately 67% for female patients has been achieved. In male patients, AHI classification was found to be more successful than in female patients.

Conclusion: When the results are examined, it is predicted that the AHI estimation can be performed by using body composition data with the classification methods. The best classification method was obtained with Artificial Neural Networks and ZeroR models. We think that new studies with higher number of patients are needed to have a better estimation percentage of the results.

Keywords: Body analysis, OSAS, machine learning.

Dr. Öğretim Üyesi Fatih Ahmet ŞENEL

Süleyman Demirel Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü Çünür, Isparta

Tel: +90 246 2111390

E mail: fatihsenel@sdu.edu.tr



Giriş

Obstrüktif Uyku Apne Sendromu (OSAS), potansiyel olarak tekrarlayan horlama ile karakterize hayatı tehdit eden bozukluk ve apne epizodları, hava akımında 10 saniyeden fazla süreyle en az %80 azalma olarak tanımlanır. Uyku sırasında faringeal hava yolunun tekrarlayan çökmesi uyku parçalanmasına ve oksijen desatürasyonuna yol açar (1). İlişkili sonuçlar; gündüz uykululuğu, azalan bilişsel performans, yaşam kalitesi ve çalışma verimliliği, artan araba kazası riski ve olumsuz kardiyovasküler sonuçları içerir (2). OSAS hastalarında üst hava yolu tıkanıklığından sorumlu mekanizmalar oldukça araştırılmış ve henüz tam olarak anlaşılammıştır. Kraniofasial anatomik predispozan faktörlerin OSAS'ta nörolojik disfonksiyon ve obezite ile rol oynadığı öne sürülmektedir (3). OSAS, orta yaşlı erkeklerin %4-9'unda ve orta yaşlı kadınların %1-2'si görülür (4). OSAS gelişiminde obezitenin rolü geniş çapta gösterilmiştir: belirgin uyku apnesi, obez bireylerin yaklaşık %40'ında mevcuttur ve OSAS hastalarının %70'i obezdir (4). OSAS hastalarında kilo kaybı apne sıklığında önemli bir azalmaya yol açar (5,6). Vücut kitle indeksinde (VKİ) 1 SD'lik bir artış, OSAS riskinde dört kat artışla ilişkilidir (7) ve VKİ'deki artış, OSAS'ın şiddeti ile önemli ölçüde ilişkilidir (7,8). Obezite, artmış boyun çevresi ve üst hava yolunun dar kesit alanı, OSAS için risk faktörleri olarak bilinmektedir (9), ancak obez bireylerin hepsinin OSAS'tan etkilenmediği gözlenmiştir. Kadınlar, daha yüksek obezite oranlarına ve daha fazla genel vücut yağına sahip olmalarına rağmen, OSAS'ın erkeklerde tüm yetişkin yaş gruplarında kadınlardan iki ila sekiz kat daha yaygındır. Normal erkeklerde ve kadınlarda yağ dağılımını karşılaştıran bir manyetik rezonans görüntüleme (MRI) çalışması, erkeklerde toplam boyun yumuşak doku hacminin daha fazla olduğunu, erkeklerin boyunlarının bir bütün olarak vücutlarından daha yüksek oranda yağ içerdiğini ve erkeklerdeki mutlak yağ hacmi, palatal seviyede mandibula içindeki ön segmentlerde büyük bölgelere sahip olduğunu gösterdi (10). Bu nedenle bu çalışma, obeziteden ziyade OSAS gelişimi için üst

hava yoluna bitişik yağ birikimi modelinin potansiyel bir ana rolünü ortaya koymaktadır.

Çalışmamızda kolay, invaziv olmayan vücut analizi (TANİTA) ölçümü ile OSAS risk faktörü taşıyan ve semptomlara sahip hastaların, makine öğrenmesi algoritmaları kullanılarak sınıflandırılması amaçlanmıştır. Erkek ve kadın hastalar ayrı ayrı değerlendirilerek sonuçlar karşılaştırılmıştır.

Gereç ve yöntemler

Veri Seti

Bu çalışmada Isparta Şehir Hastanesi Uyku Bozuklukları polikliniğine başvuran ve OSAS tanısı konularak diyet polikliniğine yönlendirilen 239 adet hastadan oluşmaktadır. Hastaların her biri için TANİTA vücut analizi verisi (23 farklı parametre) kullanılmıştır. 142 adet erkek hasta ve 97 adet kadın hasta verileri ayrı ayrı sınıflandırma işlemlerine tabi tutuldu.

Modellerin Oluşturulması

Bu çalışmada altı adet sınıflandırma yöntemi (Bayes Sınıflandırıcı Algoritması, Destek Vektör Makineleri, KStar Algoritması, Reptree Algoritması, ZeroR Algoritması ve Yapay Sinir Ağları) kullanılarak sonuçların başarısı karşılaştırılmıştır. Tablo 1'de kullanılan algoritmalar ve açıklamaları verilmiştir.

Tablo 1. Kullanılan modeller ve açıklamaları

Model Adı	Açıklama
Naive Bayes	Bayes Sınıflandırıcı Algoritması
DVM	Destek Vektör Makineleri
KStar	KStar Algoritması
Reptree	Reptree Algoritması
ZeroR	ZeroR Algoritması
YSA	Yapay Sinir Ağları

Naive Bayes: Bayes teoremini esas alarak, olasılıksal olarak sınıflandırma işleminin yapıldığı makine öğrenmesi algoritmasıdır. Naive Bayes, veri setinde verilen girdi ve çıktı değerleri arasında bir olasılıksal ilişki kurarak, sınıflandırma işlemini gerçekleştirir.



DVM: DVM, iki ya da daha fazla sınıfı birbirinden ayırt etmek için, karar sınırlarının veya hiper düzlemlerin belirlenerek, sınıflandırma işlemi yapan bir makine öğrenme algoritmasıdır. DVM, doğrusal olarak ayrılan problemler için, doğrusal sınırlar tanımlayabilmekte, doğrusal olarak ayrılamayan problemler için kernel adı verilen çekirdek sınır belirleyicileri kullanılır.

KStar: Örnek tabanlı bir sınıflandırma algoritmasıdır. Entropi uzaklığı hesaplamasını kullanarak sınıflandırma işlemi gerçekleştirir. Her sınıftaki örneklerin ortalamasını dikkate alarak yeni örnekleri sınıflandırır.

Reptree: Karar ağaçlarının bir çeşiti olan Reptree algoritması, veri setini en iyi şekilde sınıflandırabilecek bir karar ağacının oluşturulması ile sınıflandırma işlemi gerçekleştirir. Hızlı çalıştığı için birçok sınıflandırma probleminde kullanılan makine öğrenmesi algoritmasıdır.

ZeroR: Bu algoritma en basit sınıflandırıcılardan biridir. Girdilerle ilgilenmek yerine çıktıda bulunan sınıflara ait örnek sayılarını dikkate alarak sınıflandırma işlemi yapar. Veri setindeki en fazla örnek hangi sınıfta ise, gelen verileri direk en fazla olan sınıfa dâhil eder.

YSA: YSA, insan beynindeki iletişimlerden esinlenilerek geliştirilmiş bir makine öğrenme algoritmasıdır. Nöron ve katmanlardan oluşan bir mimariye sahiptir. Her nöronun bağlı olduğu bir ağırlık değeri vardır. Veri setindeki girdilere karşılık en az hata ile çıktığı elde edebilmek için ağırlık değerlerinin ayarlanması prensibine göre çalışmaktadır.

Öznitelik Seçimi

Veri setimizde bulunan ve sonucu tahmin etmede en az katkısı olan öznitelikler, öznitelik seçme işlemine tabi tutularak elenmiştir. Böylece gereksiz ayrıntılarla ilgilenerek, sınıflandırma işleminin yavaşlanmasının önüne geçilmiş olmuştur. Korelasyon Tabanlı

Öznitelik Seçimi yöntemi kullanılarak, sınıflandırma işlemi için kullanılacak öznitelik sayısı dörde indirilmiştir. Tablo 2'de erkek ve kadın hastalar için seçilen öznitelikler verilmiştir.

Tablo 2. Öznitelik seçimi ile elde edilen sonuçlar

Erkek	Kadın
VKI	Kilo
Obezite Derecesi	Metabolizma Yaşı
Bel Çevresi	Yağ Yüzdesi
Hücre Dışı Sıvı	İdeal Kilo

Bulgular

Bu bölümde, her bir sınıflandırma yönteminden elde edilen en iyi sonuçlar verilmiştir. Burada tüm gruplar için AHİ'yi tahmin etme oranı yaklaşık olarak erkek hastalarda %69, kadın hastalarda ise %67 olarak bulunmuştur. En iyi tahmin yapan algoritmalar ise erkek hastalar için ZeroR algoritması, kadın hastalar için ise YSA'dır. Tablo 3'te AHİ tahmini için elde edilen tüm model sonuçları verilmiştir.

Tablo 3. Modelleme sonuçları

Model Adı	Doğruluk Yüzdesi	Erkek Hastalar		Kadın Hastalar		
		OMH	OKHK	Doğruluk Yüzdesi	OMH	OKHK
Naive Bayes	57.75	0.3148	0.417	57.73	0.3172	0.4342
DVM	68.31	0.3255	0.4211	59.79	0.3436	0.4421
KStar	60.56	0.3111	0.4552	61.86	0.2943	0.4522
Reptree	66.20	0.3243	0.4152	60.82	0.3387	0.4367
ZeroR	68.31	0.3249	0.4015	59.79	0.3762	0.4326
YSA	66.90	0.315	0.4022	67.01	0.3335	0.4181

OMH: ortalama mutlak hata. OKHK: ortalama karesel hataların karekökü

Tablodaki sonuçlar incelendiğinde, erkek hastalarda daha iyi sonuçların elde edildiği görülmüştür. Erkek hastalar için seçilen öznitelikler, kadın hastalardan farklıdır. Erkek ve kadın hastalarda AHİ'nin farklılık gösterdiği hem seçilen özniteliklerden hem de sınıflandırma sonuçlarından anlaşılmaktadır.



Tartışma

Obezitenin etkilerinin altında yatan kesin mekanizmalar OSAS'ın gelişimi konusunda hala belirsizdir. Bununla birlikte, üst hava yolu duvarlarında, yağ birikiminin veya hava yolu tonusunu düzenleyen merkezi mekanizmalardaki modifikasyonun sonucu olma ihtimali yüksektir. Leptin, yağ dokusunda salınan, sentezlenen ve sentezlenen dolaşımdaki bir hormondur. Plazma leptin konsantrasyonları, obezite hastalarında vücut yağ kütlesiyle doğru orantılı olarak artar ve leptin, kemoreflex fonksiyonunun düzenlenmesinde ve dolayısıyla solunum kontrolünde önemli bir etkiye sahiptir (11,12). Bununla birlikte, obez hastalar üzerinde yapılan birkaç çalışma, obezite derecesi ile OSAS şiddeti arasındaki ilişkinin sadece orta düzeyde olduğunu ve büyük ölçüde değiştiğini göstermiştir. Artmış VKİ'nin OSAS için cerrahi tedavinin başarısı için olumsuz bir prognostik faktör olduğu bulunmuştur (7). Akita vd. obez hastalarda VKİ ile AHİ veya desatürasyon oranı arasında anlamlı bir korelasyon gözlemlenmemiş, ancak VKİ'deki artışla birlikte AHİ artışına eğilim olduğunu göstermiştir (13). Bu gözlemler, obezitenin OSAS üzerindeki etkisini yalnızca aşırı yağ birikimi yoluyla olamayacağını göstermektedir.

Sonraki çalışmalarda, sadece vücut ağırlığının artmasının değil, aynı zamanda bölgesel yağ dağılımının da OSAS gelişiminde önemli rol oynadığı ileri sürülmüştür. Üst hava yolu ve parafarengeal bölgedeki yağ birikimi, parafarengeal boşluğun daralmasına yol açabilir ve yumuşak damak, dil ve faringeal duvarlarını yumuşatarak, üst hava yolu daralmasına ve uyku sırasında tıkanmaya yatkın hale getirebilmektedir (9,14). Ayrıca faringeal duvarların kas tonusu ve kemik ankraj yapısının OSAS gelişiminde önemli olduğu çalışmada gösterilmiştir (8).

Mevcut bulgular, sadece obezitenin değil, aynı zamanda yağın spesifik bölgesel dağılımının OSAS'ın gelişiminde kritik bir risk faktörü ve OSAS şiddeti için prognostik bir faktör olduğunu göstermektedir. Bu bulgular çerçevesinde TANİTA vücut analizi verileri ile yapılacak yapay zekâ analizleri OSAS has-

talari için bir ön tanı programı olarak kullanılabilir. Yapılan çalışma ile makine öğrenmesi algoritmaları kullanılarak OSAS hastaları için AHİ sınıflandırmasının yapılabileceği gösterilmiştir. En iyi sınıflandırma yöntemi Yapay Sinir Ağları ve ZeroR modelleri ile elde edilmiştir. Sonuçların daha iyi tahmin yüzdesine sahip olabilmesi için daha geniş hasta sayıları ile yeni çalışmalara ihtiyaç olduğunu düşünmekteyiz.

Etik Kurul

Bu çalışma için gerekli olan etik kurul izinleri alınmıştır.

Kaynaklar

1. O'Donnell CP, Schwartz AP, Smith PL. Upper airway collapsibility. *Am J Respir Crit Care Med* 2000;162:1606-07.
2. Wolk R, Shamsuzzaman AS, Somers VK. Obesity, sleep apnoea and hypertension. *Hypertension* 2003;42(6):1067-74.
3. Cistulli PA. Craniofacial abnormalities in obstructive sleep apnoea: implications for treatment. *Respirology* 1996; 3:167-74.
4. Kyzer S, Charuzi I. Obstructive sleep apnoea in obese. *World J Surg* 1998; 22:998-1001.
5. Kansanen M, Vanninen E, Tuunainen A, Pesonen P, Tuononen V, Hartikainen J, et al. The effect of a very-low-calorie diet-induced weight loss on the severity of obstructive sleep apnoea and autonomic nervous function in obese patients with obstructive sleep apnoea syndrome. *Clin Physiol* 1998;18(4):377-85.
6. Sampol G, Muñoz X, Sagalés MT, Martí S, Roca A, Dolors de la Calzada M, et al. Long-term efficacy of dietary weight loss in sleep apnoea/hypopnoea syndrome. *Eur Respir J* 1998;12(5):1156-9.
7. Rollheim J, Osnes T, Miljeteig H. The relationship between obstructive sleep apnoea and body mass index. *Clin Otolaryngol* 1997; 22:419-22.
8. Yu X, Fujimoto K, Urushibata K, Matsuzawa Y, Kubo K. Cephalometric analysis in obese and nonobese patients with obstructive sleep apnea syndrome. *Chest* 2003;124(1):212-8.
9. Busetto L, Enzi G, Inelmen EM, Costa G, Negrin V,



Sergi G, Vianello A. Obstructive sleep apnea syndrome in morbid obesity: effects of intragastric balloon. *Chest* 2005;128(2):618-23.

10. Whittle AT, Marshall I, Mortimore IL, Wraith PK, Sellar RJ, Douglas NJ. Neck soft tissue and fat distribution: comparison between normal men and women by magnetic resonance imaging. *Thorax* 1999;54(4):323-8.

11. Wolk R, Shamsuzzaman AS, Somers VK. Obesity, sleep apnoea and hypertension. *Hypertension* 2003;42(6):1067-74.

12. Schäfer H, Pauleit D, Sudhop T, Gouni-Berthold I, Ewig S, Berthold HK. Body fat distribution, serum leptin, and cardiovascular risk factors in men with obstructive sleep apnea. *Chest* 2002;122(3):829-39

13. Akita Y, Kawakatsu K, Hattori C, Hattori H, Suzuki K, Nishimura T. Posture of patients with sleep apnea during sleep. *Acta Otolaryngol Suppl* 2003;(550):41-5.

14. Lofaso F, Coste A, d'Ortho MP, Zerah-Lancner F, Delclaux C, Goldenberg F, Harf A. Nasal obstruction as a risk factor for sleep apnoea syndrome. *Eur Respir J* 2000;16(4):639-43