



Aditif Bayes Ağları Yöntemi ile Obstrüktif Uyku Apnesi Şiddetinin Tahminlenmesi

Estimation of Obstructive Sleep Apnea Severity Using Additive Bayesian Networks

Selen BOZKURT¹, Aslı BOSTANCI², Murat TURHAN²

¹ Akdeniz Üniversitesi Tıp Fakültesi, Biyoistatistik ve Tıp Bilişimi Anabilim Dalı, Antalya, Türkiye

² Akdeniz Üniversitesi Tıp Fakültesi, Kulak Burun Boğaz Hastalıkları ve Baş Boyun Cerrahisi Anabilim Dalı, Antalya, Türkiye

Yazışma Adresi
Correspondence Address

Aslı BOSTANCI
Akdeniz Üniversitesi Tıp Fakültesi,
Kulak Burun Boğaz Hastalıkları
ve Baş Boyun Cerrahisi Anabilim
Dalı, Antalya, Türkiye
E-posta: draslibostanci@gmail.com

Bu proje "Normal Araştırma Projesi" olarak Akdeniz Üniversitesi BAP Koordinasyon Birimi tarafından desteklenmiştir (Proje No: 1575).

Geliş tarihi \ Received : 20.02.2018
Kabul tarihi \ Accepted : 21.03.2018
Elektronik yayın tarihi : 25.09.2018
Online published

Bozkurt S, Bostancı A, Turhan M.
Aditif bayes ağları yöntemi ile obstrüktif uyku apnesi şiddetinin tahminlenmesi.
Akd Tıp D 2019;1:60-66.

Aslı BOSTANCI
ORCID ID: 0000-0002-1535-2661
Selen BOZKURT
ORCID ID: 0000-0002-3328-6231
Murat TURHAN
ORCID ID: 0000-0001-6140-1666

ÖZ

Amaç: Günümüzde makine öğrenmesi temelli tahmin modelleri, birçok farklı alanda yaygın bir şekilde kullanılmaktadır. Bu çalışmanın amacı obstrüktif uyku apnesi (OUA) şiddetinin tahminlenmesinde hastaların klinik özelliklerini içeren bir aditif bayes ağ modeli geliştirilmesidir.

Gereç ve Yöntemler: Bu çalışmaya Ocak 2014-Ağustos 2015 tarihleri arasında Akdeniz Üniversitesi Kulak-Burun-Boğaz Hastalıkları Anabilim Dalı'nda OUA ön tanısı ile polisomnografi yapılmış 338 hasta dahil edilmiştir. OUA şiddeti ile ilişkili tüm klinik değişkenler ve bu değişkenlerin birbirleriyle olan ilişkileri aditif bayes ağ modeli ile modellenmiştir.

Bulgular: Nihai Bayes modelindeki en önemli öngördürücü değişkenler, yumuşak damak ve uvula boyutu (Odds oranı (OR):10.94 [1.87 - 64.11]) ile mallampati skoru (OR: 4.5 [1.46 - 43.22]) idi. Nihai modelin 10 kat çapraz geçerlilik test sonucu, OUA şiddetinin 0.632 duyarlılık ve 0.529 seçicilik ile tahminlenebileceğini gösterdi. Ayrıca, geliştirilen modelin ağır OUA hastalarını sınıflandırmada 0.777 duyarlılık ve 0.646 seçiciliğe sahip olduğu saptandı.

Sonuç: Makine öğrenmesi temelli tahmin modelleri, klinik değişkenler arasındaki kompleks ilişkileri analiz ederek OUA tanısı ve şiddetinin tahmin edilmesini kolaylaştırabilir.

Anahtar Sözcükler: Aditif Bayes Ağları, Obstrüktif uyku apnesi, Klinik karar destek sistemleri

ABSTRACT

Objective: Currently, machine learning-based prediction models have been widely used in many different areas. The aim of this study is to develop an additive bayesian network model including characteristics of patients in order to estimate severity of obstructive sleep apnea (OSA).

Material and Methods: A total of 338 patients who underwent polysomnography due to pre-diagnosis of OSA at Akdeniz University Department of Otorhinolaryngology between January 2014 and August 2015 were enrolled to this study. All clinical variables related to severity of OSA, and relationships of these variables among each other were modelled by the additive Bayesian network model.

Results: The most important predictor variables in the final Bayesian model were the size of soft palate and uvula (Odds ratio (OR):10.94 [1.87 - 64.11]), and Mallampati score (OR: 4.5 [1.46 - 43.22]). The result of 10-fold cross-validated test for final model indicated that the severity of OSA can be estimated with a sensitivity of 0.632 and specificity of 0.529. In addition, it was determined that the developed model has 0.777 sensitivity and 0.646 specificity to classify severe OSA patients.

Conclusion: Machine learning-based prediction models may facilitate the estimation of diagnosis of OSA and its severity by analyzing complex relationships between clinical variables.

Key Words: Additive Bayesian Network, Obstructive Sleep Apnea, Clinical Decision Support Systems

GİRİŞ

Obstrüktif uyku apnesi (OUA) tekrarlayan üst solunum yolu obstrüksiyonları ile karakterize bir sendromdur (1). Uyku esnasında meydana gelen parsiyel ve komplet obstrüksiyonlar hipoksemi, hiperkapni ve uyku bölünmelerine yol açarak OUA ile ilişkili kardiyovasküler, metabolik ve nörokognitif sonuçların ortaya çıkmasına neden olur (1).

OUA genel erişkin popülasyonun yaklaşık %9-25'ini etkileyen yaygın bir hastalıktır (2). Toplumda OUA ile ilgili giderek artan farkındalığa ve tanı yöntemlerindeki gelişmelere rağmen yine de orta ve ağır OUA'lı bireylerin yaklaşık %80'ine tanı konulamamış olduğu tahmin edilmektedir (3). Tedavi edilmemiş olgulardaki komplikasyon riskleri göz önüne alındığında ise hızlı tanı ve tedavi oldukça kritik öneme sahiptir.

OUA tanısında polisomnografi (PSG) altın standart tanı yöntemidir. Ancak PSG uygulaması ve yorumlaması uzmanlık isteyen, zaman alıcı ve pahalı bir yöntemdir. Ülkemizdeki uyku laboratuvarı sayıları düşünüldüğünde bu durum uzun randevu listelerine neden olmaktadır. Dolayısıyla OUA hastalarını daha PSG yapmadan saptayabilmek ve potansiyel riskli olanlara PSG' de öncelik tanımak bu yükü azaltmada anahtar rol oynayabilir.

OUA hastalarının saptanmasında PSG dışı birtakım tarama testlerinden faydaniılmaktadır. Özellikle bilişim teknolojilerindeki hızlı gelişim makine öğrenme tekniklerinin bu alanda kullanımına imkân tanmaktadır (4).

Bu çalışmanın amacı, hastanın klinik özelliklerini içeren, makine öğrenmesi temelli bir yöntem olan bir aditif bayes ağ modeli geliştirmek ve bu modelin OUA şiddetinin tahminlenmesindeki rolünü değerlendirmektir.

GEREÇ ve YÖNTEMLER

Çalışma Tasarımı ve Olgular

Bu çalışmada, Ocak 2014 ve Ağustos 2015 tarihleri arasında Akdeniz Üniversitesi Tıp Fakültesi Kulak Burun Boğaz Hastalıkları Anabilim Dalı'nda OUA şüphesi ile PSG (Compumedics E-Series Profusion; Compumedics, Abbotsford, Victoria, Australia) yapılmış 1162 hastanın kayıtları retrospektif olarak incelendi. OUA (Apne Hipopne İndeksi, AHI>5) tanısı alan ve Epworth uykululuk skalası (EUS) anketi olan hastalar çalışmaya dâhil edildi. Uyku etkinliği yetersiz olan, santral uyku apne sendromu olan, ek hastalığı olan, demografik verileri ve fizik muayene bulguları eksik olan ve EUS anketini yanıtlamayan hastalar çalışma dışı bırakıldı. Sonuç olarak 338 hastadan elde edilen veriler analiz edildi.

Polisomnografi

Tüm hastalara bir gece uyku laboratuvarında PSG (Compumedics E-Series Profusion; Compumedics, Abbotsford, Victoria, Australia) yapılarak, EEG (C3-A2, C4-A1), sol ve sağ EOG, EMG (çene ve anterior tibial kas), EKG, torakoabdominal hareketler, oronazal hava akımı ve oksijen satürasyonu gibi birçok parametre kaydedildi. PSG kayıtları AASM 2012 (5) kriterlerine göre manuel olarak skorlandı.

İstatistiksel Analiz

Bu çalışmada, OUA şiddetini tahminlemek için aditif bayes ağları modeli kullanıldı. Aditif bayes ağ modeli, klasik bayes ağ modelindeki tüm değişkenlerin potansiyel bağımlı değişken olduğu genelleştirilmiş doğrusal regresyon modellerinin geliştirilmesiyle oluşturulur. Diğer yöntemlerden farklı olarak sadece bağımlı değişkene etki eden ortak değişkenleri değil, bunların birbiri ile ya da bağımlı değişken üzerindeki direkt ya da dolaylı ilişkisini aynı anda analiz edip ayrıştırabilmektedir (6). Bu yöntemin tek bir aon modelin seçildiği durumlardan daha iyi performans göstereceği düşünülmektedir (7).

Veri Seti

Hastaların demografik verileri, vücut kitle indeksi (VKİ), boyun çevresi (BÇ), sigara alışkanlığı, EUS anket skoru, nazal kavite, orofarinks (yumuşak damak ve uvula, tonsil boyutları, lateral faringeal duvar, Mallampati skoru) ve hipofarinks muayenesi (dil kökü ve lingual tonsil boyutları), mikrognați varlığı/yokluğu ve PSG verilerini içeren bir çalışma veri seti oluşturulmuştur. Çalışma veri setinde eksik veriye rastlanmadı.

Ardından hastalar uzman görüşüne ve literatür bilgisine dayalı olarak istatistiksel modelde aşırı uygunluğu (overfitting) ve aşırı uç değerlerin etkisini önlemek, yorum kolaylığı sağlamak ve işlem süresini kısaltmak için kategorilere ayrıldı. Yaş genç (18-35), orta yaşlı (36-55) ve ileri yaşlı (≥ 56) olarak üç gruba, VKİ normal kilolu (VKİ, 18,5-24,9 kg/m²), fazla kilolu (VKİ, 25-29,9 kg/m²), I. Derece obez (VKİ, 30-34,9 kg/m²), II. Derece obez (BMI, 35-39,9 kg/m²), III. Derece morbid obez (VKİ >40 kg/m²) olarak dört gruba ayrıldı (8). BÇ, önceden kabul görmüş bir sınıflama olmadığı için dört eşit gruba ayrıldı. EUS için kesim değeri 10 olarak belirlendi. Muayene bulguları da kendi içinde gruplandırıldı.

Değişkenlerin Belirlenmesi

OUA şiddetini sınıflandırmada kullanılacak olası değişkenler Tablo I'de sunulmuştur. Sürekli değişkenlerin normal dağılıma uygunluğu Kolmogorov-Smirnov testi ile incelendi. Örneklemi tanımlamak için, normal dağılıma uygun değişkenler ortalama \pm standart sapma, normal

Tablo I: OUA şiddetini sınıflandırmada kullanılacak olası değişkenler.

	Cinsiyet	E/K	
Klinik Veriler	Yaş, yıl	Genç	18-35
		Orta yaşlı	36-55
		İleri yaş	≥56
	Vücut Kitle İndeksi, kg/m ²	Normal kilolu	18.50-24.99
		Fazla kilolu	25- 29.99
		I.Derece obez	30.00-34.99
		II. Derece obez	35.00-39.99
		III. Derece morbid obez	≥40
	Boyun Çevresi, cm	I. çeyrek	33-39
		II. çeyrek	40-41
III. çeyrek		42-43	
IV. çeyrek		44-52	
Sigara alışkanlığı	Var/Yok		
Semptomlar	Epworth Uykululuk Skalası (EUS)	Normal	<10
		Anormal	≥10
Fizik Muayene Bulguları	Burun tıkanıklığı	Var/Yok	
	Yumuşak damak ve uvula	Elonge	
		Elonge ve Hipertrofik	
		Hipertrofik	
	Tonsil Boyutu	0	
		1	
		2	
		3	
	Lateral faringeal duvar kollapsı	Var/Yok	
	Mallampati skoru	0	
1			
2			
3			
Dil Kökü	Normal/ Hipertrofik		
Lingual Tonsil	Normal/ Hipertrofik		
Mikrognati	Var/Yok		

dağılıma uygun olmayan değişkenler ortanca (minimum-maksimum), kategorik değişkenler ise sayı ve yüzde ile belirtilmiştir. Parametrik test varsayımlarının sağlandığı durumlarda farklı OUA şiddetine sahip hastaların özellikleri “tek yönlü varyans analizi” ile parametrik test varsayımlarının sağlanmadığı durumlarda ise bu testin

parametrik olmayan alternatifi “Kruskal-Wallis” testi kullanılmıştır. Kategorik veriler ise “ki-kare anlamlılık testi” ya da “Fisher’s Exact test” ile incelenmiştir. Analizlerde farklılıkların belirlenmesi için %95 anlamlılık düzeyi (ya da $\alpha=0,05$ hata payı) kullanılmıştır.

Modelin Geliştirilmesi ve Test Edilmesi

Bayes Ağlar ve Aditif Bayes Ağları

Bayes ağları, olasılık teorisinin koşullu olasılık terimini temel alan Bayes teoremini kullanır. Bayes Ağları değişkenlerin düğümler (node), değişkenler arası olasılıksal ilişkilerin ise oklar aracılığıyla gösterildiği yönlü çevrimsiz olasılıksal ağlardır. Her bir düğüm bir rassal değişkene, oklar ise değişkenler arasındaki korelasyonlara karşılık gelir. Bayes Ağları'nda yer alan değişkenlerin sahip olabileceği çocuk ya da ebeveyn sayısı için herhangi bir kısıtlama bulunmamaktadır (9-12). Bir değişken için olasılık dağılımı ebeveyn düğümlerine bağlı olarak hesaplanır. Rassal değişkenler arasındaki ilişki bileşik olasılık dağılımı ile belirtilir.

Klasik bayes modellemesine ek olarak bir diğer yöntem de aditif bayes ağları modelidir. Bu model kategorik veriler için olan standart modellerden, içerisinde çok boyutlu regresyon modellerini de kullanmaları açısından farklıdır (7,13). Aditif bayes modeli, klasik bayes ağ modelindeki tüm değişkenlerin potansiyel bağımlı değişken olduğu genelleştirilmiş doğrusal regresyon modellerinin geliştirilmesiyle oluşturulur. Diğer yöntemlerden farklı olarak sadece bağımlı değişkene etki eden ortak değişkenleri değil, bunların birbiri ile ya da bağımlı değişken üzerindeki direkt ya da indirekt olan ilişkisini aynı anda analiz edip ayrıştırabilmektedir (6).

Bayes ağları, veriyi en iyi temsil eden grafiksel yapıyı veriden yapısal öğrenme algoritmalarıyla öğrenirler. Bu öğrenme algoritmaları olası tüm modellerden en iyisini seçmek için kurulmuştur ve sonuçta tek bir model seçilir. Fakat birbirine yakın değerlerde birçok olası yapısal model olduğunda bunlardan sadece birini seçmek yerine bunların hepsinin bir bütünleşik dağılım olduğu düşünülerek bir arada eklemeli olarak analizinin sağlanabilmesi için aditif bayes ağları yöntemi geliştirilmiştir. Bu yöntemin tek modelin seçildiği durumlardan daha iyi performans göstereceği düşünülmektedir (7).

Modelin Uygulanması ve Değerlendirilmesi: Çapraz Geçerlilik Yöntemi

Modellerin geliştirilmesi ve değerlendirilmesinde 10-çapraz geçerlilik yöntemi uygulanmıştır. Çapraz geçerlilik yönteminde veri seti k adet eşit parçaya ayrılmakta, bir sınıflandırıcı k-1 parça ile eğitilmekte ve geri kalan parçada sınıflandırıcı test edilerek bir hata değeri hesaplanmaktadır. K-çapraz doğrulamada hata tahmini, her parçadaki elde edilen hatanın ortalama değeri olarak elde edilmektedir. Çapraz doğrulama kestirim hatasının tahmininde çoğunlukla kullanılmaktadır (14). Birçok araştırmada çapraz geçerlilik yöntemi kullanılmasına rağmen, k-kat çapraz geçerlilik, k değeri küçük olduğunda gerçek veri

analizinde problem olduğu belirtilmiş ve bu nedenle önceki çalışmalarda önerildiği gibi bu çalışmada da çapraz doğrulama sayısı 10 olarak belirlenmiştir (14,15).

Değerlendirme

Model çıktılarının değerlendirilmesi amacıyla altın standart veri seti olarak kabul edilen OUA şiddeti bulgularıyla, geliştirilen modeller ile sınıflandırılan OUA şiddeti bulgularının uyumu incelenmiştir. Sınıflandırma sonuçları hata matrisleri ile gösterilmiştir. Geliştirilen modelin sonuçlarının doğruluğunun değerlendirilmesinde sınıflama testi performansı için biyoistatistikte kullanılan doğru pozitif oran, yanlış pozitif oran, duyarlılık ve özgüllük (seçicilik) ölçütlerinden ve ROC analizinden yararlanılmıştır.

Tüm analizler R yazılımı, version 3.1.2 (R Development Core Team, 2015) kullanılarak gerçekleştirilmiştir. Aditif bayes ağları yöntemi için R yazılımında bulunan "abn" paketi kullanılmıştır (16).

BULGULAR

Çalışmaya toplam 338 hasta dahil edilmiş ve bu hastalara ait tanımlayıcı istatistikler ile gruplar arası tek değişkenli karşılaştırma sonuçları Tablo II'de sunulmuştur. AHI alt grupları arasında yaş, cinsiyet ve sigara açısından anlamlı fark saptanmamıştır. Ağır OUA olan kişilerde VKİ, EUS ve Mallampati skorunun daha yüksek, tonsil büyüklüklerinin ve boyun çevrelerinin daha geniş olduğu görülmüştür. Hastaların muayene bulguları Şekil 1'de belirtilmiştir.

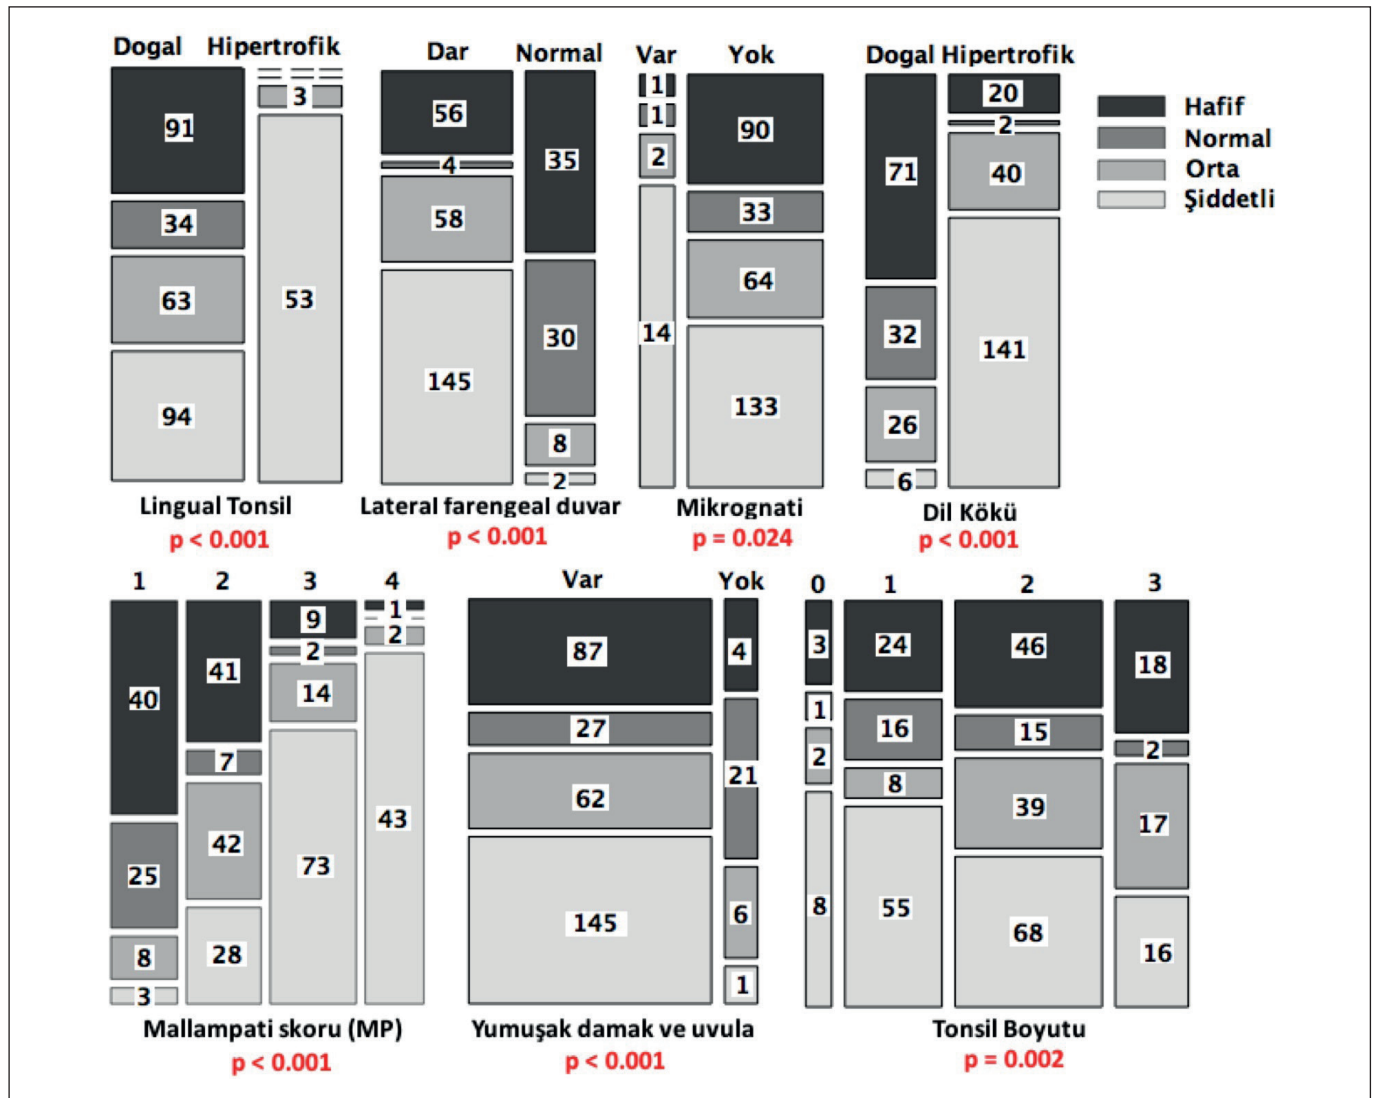
En iyi aditif bayes ağını bulmak için kullanılan paket içerisindeki marjinal olabilirlik oranı kullanan best.dag metodu ile tekrarlamalar (iteration) sonucu oluşturulan model Şekil 2'de verilmiştir. Geliştirilen aditif modeller içinde optimal olarak belirlenen son modelin duyarlılığı 0.532, seçiciliği ise 0.429'dur.

Bu modeldeki en önemli değişkenlerin yumuşak damak ve uvula boyutları (OR:10.94 [1.87-64.11]) ile mallampati skoru (OR: 4.5 [1.46-43.22]) olduğu görülmüştür. Geliştirilen son modelin 10 kat çapraz geçerlilikle değerlendirilmesi sonucu ortalama 0.632 duyarlılığa ve 0.529 seçiciliğe ulaştığı görülmüştür. Aynı modelin ağır OUA hastalarını ise 0.777 duyarlılık ve 0.646 seçicilikle sınıflandırabildiği görülmüştür.

Geliştirilen modelin şiddetli uyku apnesini sınıflandırmadaki başarısının ROC Eğrisi ile değerlendirilmesi ise Şekil 3'te sunulmuştur.

TARTIŞMA

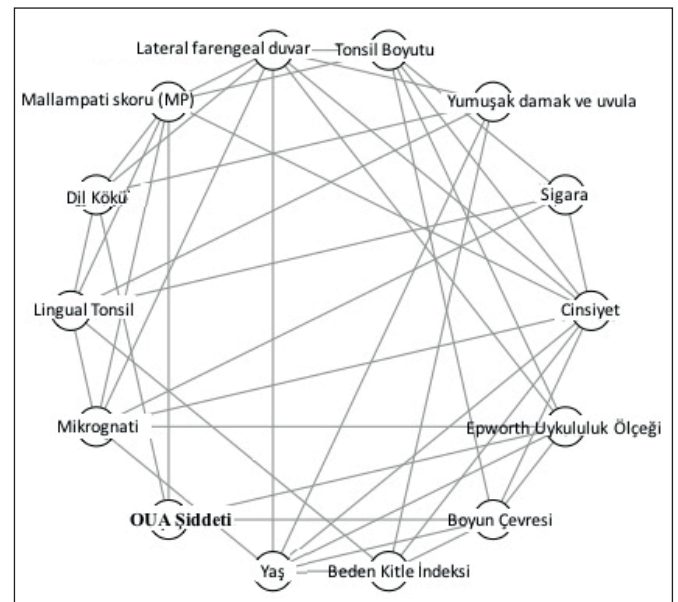
Bu çalışmada, hastanın demografik ve klinik özelliklerini bütünleşmiş bir şekilde içeren aditif bayes ağ modeli oluşturularak, bu modelin OUA şiddeti tahminlenmesindeki rolü araştırılmıştır. Fizik muayene bulgularından yumuşak



Şekil 1: Hastaların muayene bulguları.

damak ve uvula boyutları ile mallampati skorunun OUA şiddetini tahminlemede en iyi değişken olarak ortaya konulması çalışmamızın ana bulgusudur.

Günümüzde OUA görülme sıklığı ve sonuçları nedeniyle bir halk sağlığı sorunu haline gelmiştir. Gerçek hastaların saptanması ve hastalık şiddetinin doğru yorumlanması tedavi başarısını doğrudan etkilemektedir. Ancak OUA tanısını koymada hekimin incelediği değişken sayısı oldukça fazladır. Ayrıca gerçek tanıya tüm bu değişkenlerin bir bütün halinde analiz edilmesiyle ulaşılabilir. Bilişim teknolojilerdeki hızlı gelişim bu büyük ölçekli verilerin ileri istatistik yöntemleri ile analizini kolaylaştırmakta ve sağlık alanında olasılığa dayalı uzman sistemlerin geliştirilmesini sağlamaktadır. Dolayısıyla sağlık problemlerinin çözümü için, özellikle tanı aşamasında, hekimlerin kararına destek olabilecek makine öğrenmesi temelli çalışmalar oldukça önem kazanmaktadır.




Şekil 2: Aditif Bayes Ağ Modeli.

Tablo II: Hastaların demografik özellikleri.

	Normal	Hafif	Orta	Ağır	P
Yaş, yıl	44.85 ± 10.05	47.73 ± 11.50	49.17 ± 11.90	50.38 ± 10.30	0.032
Cinsiyet, n (%)					
Kadın	18 (52.94)	69 (75.82)	50 (75.76)	118 (80.27)	0.011
Erkek	16 (47.06)	22 (24.18)	16 (24.24)	29 (19.73)	
VKİ, kg/m ²	27.41 ± 3.27	28.20 ± 3.40	29.90 ± 4.31	32.28 ± 4.90	<0.001
Boyun çevresi, cm	38.59 ± 2.73	40.02 ± 2.32	40.91 ± 2.81	42.67 ± 3.22	<0.001
EUS	5.76 ± 3.41	7.69 ± 4.82	9.72 ± 5.10	12.72 ± 6.51	<0.001

VKİ: Vücut kitle indeksi, **EUS:** Epworth uykululuk skalası

**Şekil 3:** ROC Eğrisi.

Son zamanlarda karar destek sistemleri mühendislik, tıp gibi bilimin birçok farklı alanında yaygın bir şekilde kullanılmaktadır. Ancak OUA konusunda makine öğrenmesi temelli tahmin modellerinin kullanıldığı sınırlı sayıda çalışma bulunmaktadır. Bu çalışmalarda genellikle OUA varlığı tahminlenmeye çalışılmış olup, OUA şiddetine yönelik çalışma sayısı azdır (17-20).

Literatürde Musman ve ark. (18) OUA şiddetinin tahminlenmesi için multinomial logistic regresyon ve doğrusal regresyon yöntemlerini kullanmışlardır. Geliştirilen model, bağımlı değişken olarak belirlenen AHI' deki değişimin sadece %39'nu açıklamada yeterli olmuştur. Leite ve ark. (17) ise 2014 yılında yaptıkları çalışmalarında tahmin doğruluğu yüksek üç farklı model geliştirmişlerdir. Ancak bu çalışmadaki veri sayısı oldukça az olup, geliştirilen bayes ağları modelinde değişkenlerin kendi aralarındaki korelasyonları hesaba katılmamıştır. Ardından bu yanlı sonucu

engellemek ve en iyi modeli seçmek için çalışma yeniden düzenlenerek tekrarlanmıştır (19). Fakat yine çalışma örnekleme kısıtlı tutulmuş ve de tahmin değerlerinde düşüş olduğu görülmüştür. Ayrıca modelde içerilen değişken sayısının yetersiz olduğu belirtilmiştir.

OUA şiddetine tahminlemeye yönelik beş farklı makine öğrenme metodunun kullanıldığı bir önceki çalışmamızda klasik Bayes ağları yönteminin duyarlılık, seçicilik ve ROC altında kalan değerlerinin diğer modellere göre daha yüksek olduğu görülmüştür (4). En düşük performans ise istatistiksel anlamlı fark bulunmamakla birlikte yapay sinir ağları ile elde edilmiştir. Yine de tüm yöntemlerin çıktuları incelendiğinde OUA şiddetinin makine öğrenmesi yöntemleri ile kabul edilebilir doğru pozitif ve yanlış pozitif oranları ile sınıflandırılabilirliği gösterilmiştir. Bu sınıflandırmada modellerin birbirine kıyasla dikkat çekici bir üstünlüğü saptanmamış olup, değişken setleri içerisinde muayene bulgularının sınıflandırmada en açıklayıcı olduğu gözlenmiştir.

Aditif bayes ağları modeli diğer yöntemlerin aksine sadece bağımlı değişkene etki eden ortak değişkenleri değil, bunların birbiri ile ya da bağımlı değişken üzerindeki direkt ya da indirekt olan etkisini aynı anda analiz edip ayrıştırılabilen bir yöntemdir. Değişkenler arası ilişkilerin önceden tahminlenemediği çok değişkenli durumlarda bu modelin klasik yöntemlere göre daha faydalı olabileceği düşünülmektedir.

Literatürde klinik verileri (demografik bilgiler, semptom ve muayene bulguları) bütünleşmiş biçimde içeren bir aditif bayes ağ modeli geliştirerek OUA şiddetini tahminlemeye çalışan bir çalışma yoktur. Dolayısıyla çalışmamız bu açıdan bir ilk olma özelliği taşımaktadır. Ayrıca bu çalışmada test/ eğitim seti ayrımı yapılmış, literatürde önerilen 10-kat çapraz geçerlilik yöntemi kullanılmıştır. Yine bu çalışma OUA şiddeti tahminlemesi amacıyla yapılan çalışmalar içindeki en geniş veri setine sahip çalışmadır. Çalışmamızın

retrospektif olması, örneklemdaki sağlıklı kişi sayısının az olması çalışmamızın kısıtlılıklarındandır. Bu durum PSG kararında OUA'nın üç majör kriterinin göz önüne alınması ve muhtemel OUA dışı hastaların daha baştan semptom sorgusu ile elenmesiyle açıklanabilir. Ayrıca bu çalışmada OUA tanısına etki edebilecek ek hastalıkları olan hastalar yanılığa sebep olmamak için çalışma dışı bırakılmıştır.

SONUÇ

Bu çalışmada, makine öğrenmesi temelli bir tahmin modeli olan aditif bayes yöntemi kullanılarak, hastaların klinik verilerinden OUA şiddetinin öngörülebileceği gösterilmiştir

Bu yöntem, yüksek risk grubundaki olguların zaman ve maliyetten tasarruf edilerek erken tanısını sağlayabilir.

KAYNAKLAR

- Jordan AS, McSharry DG, Malhotra A. Adult obstructive sleep apnoea. *Lancet* 2014; 383:736-47.
- Peppard PE, Young T, Barnet JH, Palta M, Hagen EW, Hla KM. Increased prevalence of sleep-disordered breathing in adults. *Am J Epidemiol* 2013; 177:1006-14.
- Young T, Evans L, Finn L, Palta M. Estimation of the clinically diagnosed proportion of sleep apnea syndrome in middle-aged men and women. *Sleep* 1997; 20:705-6.
- Bozkurt S, Bostanci A, Turhan M. Can statistical machine learning algorithms help for classification of obstructive sleep apnea severity to optimal utilization of polysomnography resources? *Methods Inf Med* 2017; 5:308-18.
- Berry RB, Budhiraja R, Gottlieb DJ, et al. Rules for scoring respiratory events in sleep: Update of the 2007 AASM Manual for the Scoring of Sleep and Associated Events. Deliberations of the Sleep Apnea Definitions Task Force of the American Academy of Sleep Medicine. *J Clin Sleep Med* 2012; 8: 597-619.
- Fu LD, Tsamardinos I. A comparison of Bayesian network learning algorithms from continuous data. *AMIA Annu Symp Proc* 2005: 960.
- Li J, Zhang C, Wang T, Zhang Y. Generalized Additive Bayesian Network Classifiers. *IJCAI* 2007; 913-8.
- World Health Organization. BMI Classification. Global database on body mass index, 2006.
- Jensen FV. *Bayesian Network and Decision Graphs*. New York: Springer-Verlag, 2001.
- Bayat S, Cuggia M, Rossille D, Kessler M, Frimat L. Comparison of Bayesian network and decision tree methods for predicting access to the renal transplant waiting list. *Stud Health Technol Inform* 2009; 150:600-4.
- Friedman N, Geiger D, Goldszmidt M. Bayesian Network Classifiers. *Machine Learning* 1997; 29:131-63.
- Buntine W. Theory refinement on Bayesian networks. *Proceedings of Seventh Conference on Uncertainty in Artificial Intelligence*. Los Angeles: Morgan Kaufmann, 1991.
- Lewis FI, Pittavino M, Furrer R. Data Modelling using Additive Bayesian Networks.
- Refaeilzadeh P, Tang L, Liu H. Cross-validation. *Encyclopedia of database systems*: New York: Springer, 2009:532-38.
- Fushiki T. Estimation of prediction error by using K-fold cross-validation. *Statistics and Computing* 2009; 21(2):137-46.
- The R Development Core Team. *R: A language and environment for statistical computing*. Vienna, Austria: R Foundation for Statistical Computing, 2006.
- Leite L, Santos CC, Rodrigues PP. Can we avoid unnecessary polysomnographies in the diagnosis of obstructive sleep apnea? A Bayesian Network Decision support tool. *Computer-Based Medical Systems (CBMS), 2014 IEEE 27th International Symposium on; 27-29 May 2014, New York, NY, USA*.
- Musman S, Passos VM, Silva IB, Barreto SM. Evaluation of a prediction model for sleep apnea in patients submitted to polysomnography. *J Bras Pneumol* 2011; 37:75-84.
- Rodrigues PP, Santos DF, Leite L. Obstructive sleep apnea diagnosis: The Bayesian Network Model Revisited. *Computer-Based Medical Systems (CBMS), 2015 IEEE 28th International Symposium on; 22-25 June 2015, Sao Carlos, Brazil*.
- Sim DYY, Teh CS, Banerjee PK. Prediction model by using Bayesian and Cognition-driven Techniques: A study in the context of obstructive sleep apnea. *Procedia - Social and Behavioral Sciences* 2013; 97:528-37.