

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRONİK VE BİLGİSAYAR EĞİTİMİ ANABİLİM DALI

DOKTORA TEZİ

**UYKUDA SOLUNUM BOZUKLUKLARININ TEŞHİSİ VE
SINIFLANDIRILMASININ YUMUŞAK HESAPLAMA
ALGORİTMALARI KULLANILARAK GERÇEKLENMESİ**

OĞUZHAN TİMUŞ

KOCAELİ 2015

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE BİLGİSAYAR EĞİTİMİ ANABİLİM DALI

DOKTORA TEZİ

**UYKUDA SOLUNUM BOZUKLUKLARININ TEŞHİSİ VE
SINIFLANDIRILMASININ YUMUŞAK HESAPLAMA
ALGORİTMALARI KULLANILARAK GERÇEKLENMESİ**

OĞUZHAN TİMÜŞ

Doç.Dr. Emine BOLAT
Danışman, Kocaeli Üniv.

Prof.Dr. Melih İNAL
Jüri Üyesi, Kocaeli Üniv.

Doç.Dr. Serhat YILMAZ
Jüri Üyesi, Kocaeli Üniv.

Doç.Dr. Deniz ŞAHİN
Jüri Üyesi, Kocaeli Üniv.

Yrd.Doç.Dr. Seda POSTALCIOĞLU
Jüri Üyesi, Abant İzzet Baysal Üniv.

3.0
Melih İnal
Serhat Yılmaz
Deniz Şahin
Seda Postalcioğlu

Tezin Savunulduğu Tarih: 05.06.2015

ÖNSÖZ ve TEŞEKKÜR

Uyku sırasındaki solunumun düzensizliği hem sağlığın bozulmasına hem de yaşam kalitesinin düşmesine neden olmaktadır. Uyku hastalıkları arasında en sık karşılaşılan Obstrüktif Uyku Apne Sendromu (OUAS) her yaşta ve etnik grupta görülebilen bir hastalıktır. OUAS teşhisinde altın standart olarak kabul edilen Polisomnografi (PSG) incelemesi uzun zaman alan ve masraflı bir yöntemdir. OUAS hastalığının görülme sıklığının fazla olması ve uyku laboratuvarlarının sayısının yetersizliği de göz önüne alınınca Elektrokardiyografi (EKG) analizi gibi ekonomik, pratik ve güvenilir teşhis çözümleri üzerindeki çalışmalar önem kazanmaktadır.

Bu çalışmada, EKG sinyali OUAS teşhisi ve derecesinin belirlenmesi amacıyla yumuşak hesaplama algoritmalarına dayalı farklı modeller geliştirilerek analiz edilmiş ve hekime yardımcı olacak güvenilir bir örüntü tanıma modeli önerilmiştir.

Çalışmalarım süresince her türlü desteği bana sunan, tezim ile ilgili yaptığım çalışmaların tüm aşamalarında yanımda olan, danışmanım Doç.Dr. Emine BOLAT'a ve tez izleme komitesi üyesi hocalarım Prof.Dr. Melih İNAL ve Doç.Dr. Serhat YILMAZ ile başta Prof.Dr. Haşim BOYACI ve Tek. Hikmet AKKAYA olmak üzere tüm Kocaeli Üniversitesi Tıp Fakültesi Uyku Laboratuvarı personeline teşekkür ederim. Bugünlere gelmemde büyük emekleri olan annem ve ağabeyime saygılarımı sunarım.

Değerli eşim Gülbahar ile prenseslerim Beril ve Beray'a verdikleri destek için çok teşekkür ederim.

Haziran - 2015

Oğuzhan TİMÜŞ

İÇİNDEKİLER

ÖNSÖZ ve TEŞEKKÜR.....	i
İÇİNDEKİLER.....	ii
ŞEKİLLER DİZİNİ	v
TABLolar DİZİNİ.....	vii
SİMGELER DİZİNİ VE KISALTMALAR.....	viii
ÖZET	x
ABSTRACT	xi
GİRİŞ.....	1
1. GENEL BİLGİLER.....	8
1.1. Uyku	8
1.2. Uyku Evreleri.....	8
1.2.1. Uyanıklık	9
1.2.2. Evre 1 (NREM-1).....	10
1.2.3. Evre 2 (NREM-2).....	10
1.2.4. Evre 3 (NREM-3) ve Evre 4 (NREM-4).....	11
1.2.5. REM	11
1.3. Uykuda Solunum Bozuklukları.....	12
1.3.1. Basit horlama	13
1.3.2. Üst solunum yolu rezistansı sendromu.....	13
1.3.3. Uyku apnesi	13
1.4. Solunum Parametreleri	15
1.5. Apne Esnasında Gözlemlenen ve Kaydedilen Fizyolojik Sinyaller.....	16
1.5.1. EEG sinyalleri.....	17
1.5.2. EOG sinyalleri	19
1.5.3. EMG sinyalleri.....	20
1.5.4. Solunum sinyalleri	21
1.5.5. Oksijen saturasyonu	23
1.5.6. EKG sinyalleri	24
1.6. Apne ve EKG İlişkisi.....	28
1.7. Yumuşak Hesaplama	28
1.8. Örüntü Tanıma Sistemi.....	30
1.8.1. Öznelik belirleme.....	32
1.8.2. Sınıflandırma	32
1.9. Sınıflandırmada Kullanılan Yöntemler	33
1.9.1. K en yakın komşu algoritması (k-nearest neighbor, kNN).....	33
1.9.2. Çok katmanlı almaç (multi layer perceptron, MLP).....	35
1.9.3. Destek vektör makineleri (support vector machines, SVM)	37
1.9.4. C4.5 karar ağacı (C4.5 decision tree, C4.5).....	40
2. KAPSAM ve YÖNTEM.....	42
2.1. Tez Çalışmasında Kullanılan Veriler	42
2.2. Tez Çalışmasında İzlenen Süreç	46
2.2.1. Eğitim süreci.....	46
2.2.2. Test süreci.....	49

2.3. Verilerin İşlenmesinde Kullanılan Yöntemler	49
2.3.1. Fourier dönüşümü	50
2.3.2. Ayrık fourier dönüşümü	50
2.3.3. Hızlı fourier dönüşümü	51
2.3.4. Güç spektrumu ve periodogram.....	51
2.3.5. Sinyal enerjisi	52
2.3.6. Ortalama değer.....	52
2.3.7. Etkin değer.....	53
2.3.8. Varyans.....	53
2.3.9. Standart sapma	54
2.3.10. Ortalama mutlak sapma (mean absolute deviation, MAD).....	54
2.3.11. Ortanca değer (median)	55
2.3.12. Çeyrek değerler genişliği (interquartile range, IQR)	55
2.3.13. Teager enerji operatörü (TEO)	55
2.4. EKG Sinyali Analizi.....	56
2.4.1. R tepelerinin belirlenmesi.....	57
2.4.2. Kalp atım hızı değişimi (KAHD) sinyalinin elde edilmesi	59
2.4.3. EKG'den türetilmiş solunum (ETS) sinyalinin elde edilmesi	62
2.4.4. KAHD ve ETS sinyallerinden elde edilen öznelilikler	63
3. BULGULAR ve TARTIŞMA.....	67
3.1. KAHD Zaman Analizinden Elde Edilen Bulgular	72
3.1.1. Model 1	73
3.1.2. Model 2.....	75
3.1.3. Model 3.....	77
3.1.4. Model 4.....	79
3.2. KAHD Zaman ve Frekans Analizinden Elde Edilen Bulgular	81
3.2.1. Model 5.....	81
3.2.2. Model 6.....	83
3.2.3. Model 7.....	85
3.2.4. Model 8.....	87
3.3. KAHD ve ETS Zaman Analizinden Elde Edilen Bulgular	89
3.3.1. Model 9.....	89
3.3.2. Model 10.....	91
3.3.3. Model 11.....	93
3.3.4. Model 12.....	95
3.4. KAHD ve ETS Zaman ve Frekans Analizinden Elde Edilen Bulgular.....	97
3.4.1. Model 13.....	97
3.4.2. Model 14.....	99
3.4.3. Model 15.....	101
3.4.4. Model 16.....	103
3.5. Test Sonuçları.....	105
3.5.1. OUAS teşhisi sonuçları	105
3.5.2. OUAS derecelerinin belirlenmesi sonuçları.....	109
3.5.3. OUAS sınıflandırma sonuçları.....	115
3.5.4. Literatürdeki başarımlar	116
4. SONUÇLAR VE ÖNERİLER.....	118
4.1. OUAS Teşhisi	119
4.2. OUAS Sınıflandırma	120
4.3. Sonuçlar	121

4.4. Öneriler	122
KAYNAKLAR.....	123
KİŞİSEL YAYIN VE ESERLER.....	128
ÖZGEÇMİŞ.....	129

ŞEKİLLER DİZİNİ

Şekil 1.1. Uyku çalışmasında elektrot yerleşimleri	9
Şekil 1.2. Polisomnografide uyanıklık evresi	10
Şekil 1.3. Polisomnografide Evre 1	10
Şekil 1.4. Polisomnografide Evre 2	11
Şekil 1.5. Polisomnografide Evre 3	12
Şekil 1.6. Polisomnografide Evre 4	12
Şekil 1.7. Polisomnografide REM evresi	13
Şekil 1.8. OUA PSG Grafikleri	14
Şekil 1.9. CSA PSG Grafikleri	15
Şekil 1.10. MSA PSG Grafikleri	15
Şekil 1.11. EEG'de elektrot yerleşimindeki 10-20 sistemi	18
Şekil 1.12. Delta dalgası	18
Şekil 1.13. Teta dalgası	18
Şekil 1.14. Alfa dalgası	19
Şekil 1.15. Beta dalgası	19
Şekil 1.16. Gama dalgası	19
Şekil 1.17. EOG ölçüm yöntemi	20
Şekil 1.18. Termistör	22
Şekil 1.19. Solunum bantları	22
Şekil 1.20. Normal durumda solunum sinyalleri.....	23
Şekil 1.21. Apne durumunda solunum sinyalleri	23
Şekil 1.22. Pulse oksimetreler	24
Şekil 1.23. İnsan üzerinde oluşturulan Einthoven Üçgeni	25
Şekil 1.24. Polarize hücrenin elektriksel durumu.....	25
Şekil 1.25. a) Uyarılan hücre, b) Tam depolarize hücre ve c) Repolarize hücre.....	26
Şekil 1.26. EKG sinyali	27
Şekil 1.27. Hastaya ait 20 saniyelik ETS sinyali ve solunum sinyalleri.....	29
Şekil 1.28. Örüntü tanıma sistemi.....	31
Şekil 1.29. Farklı k parametreleri için kNN davranışı.....	35
Şekil 1.30. n girişli, bir gizli katmanlı ve iki çıkışlı bir MLP örneği.....	36
Şekil 1.31. Aktivasyon fonksiyonları (a) log-sigmoid, (b) tan-sigmoid.....	37
Şekil 1.32. SVM sınıflandırıcısı ve destek vektörler.....	38
Şekil 2.1. ProFusionPSG2 programı ekran kesiti	44
Şekil 2.2. ProFusionPSG2 EDF aktarma ara yüzü	44
Şekil 2.3. Eğitim ve test sürecinde izlenen adımlar	47
Şekil 2.4. (a) EKG sinyali, (b) TEO uygulanmış EKG sinyali, (c) R tepeleri	56
Şekil 2.5. EKG sinyali üzerinde belirlenen R tepeleri	57
Şekil 2.6. Bir saatlik EKG sinyalinde belirlenen RR aralıkları	59
Şekil 2.7. İki dakikalık EKG kaydı üzerinden türetilmiş KAHD sinyali	60
Şekil 2.8. LF ve HF frekans bölgeleri ile istirahat ve aktiviteye göre değişimleri	61
Şekil 2.9. (a) Orijinal EKG, (b) Taban hattı kayması düzeltilmiş EKG	63
Şekil 2.10. EKG ve ETS sinyali (20 saniyelik)	64

Şekil 3.1. Modellerin eğitimi	68
Şekil 3.2. Model 1 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	74
Şekil 3.3. Model 2 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	76
Şekil 3.4. Model 3 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	78
Şekil 3.5. Model 4 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	80
Şekil 3.6. Model 5 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	82
Şekil 3.7. Model 6 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	84
Şekil 3.8. Model 7 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	86
Şekil 3.9. Model 8 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	88
Şekil 3.10. Model 9 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	90
Şekil 3.11. Model 10 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	92
Şekil 3.12. Model 11 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	94
Şekil 3.13. Model 12 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	96
Şekil 3.14. Model 13 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	98
Şekil 3.15. Model 14 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	100
Şekil 3.16. Model 15 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	102
Şekil 3.17. Model 16 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma	104

TABLolar DİZİNİ

Tablo 1.1. PSG örnekleme oranları	17
Tablo 1.2. Katı hesaplama ile yumuşak hesaplamının karşılaştırılması	30
Tablo 1.3. SVM çekirdek fonksiyonları.....	39
Tablo 2.1. Eğitim veritabanına ait kayıt ve hasta bilgileri	43
Tablo 2.2. Test veritabanına ait kayıt ve hasta bilgileri	45
Tablo 2.3. KAHD'nin zaman analizi için önerilen istatistiksel öznitelikler	60
Tablo 2.4. KAHD sinyali zaman uzayı analizinden elde edilen öznitelikler	64
Tablo 2.5. KAHD sinyali frekans uzayı analizinden elde edilen öznitelikler	65
Tablo 2.6. ETS sinyalinin frekans uzayı analizinden elde edilen öznitelikler	65
Tablo 2.7. ETS sinyalinin zaman uzayı analizinden elde edilen öznitelikler	66
Tablo 3.1. Oluşturulan örüntü tanıma modelleri	68
Tablo 3.2. Modellerde kullanılan seçilmiş öznitelikler	69
Tablo 3.3. Modellere ait parametreler ve eğitim başarımları	70
Tablo 3.4. Model 1, kNN için k parametresi belirleme	73
Tablo 3.5. Model 2, MLP için hücre sayısı belirleme	75
Tablo 3.6. Model 3, SVM için C ve γ parametreleri belirleme	77
Tablo 3.7. Model 4, C4.5 için CF ve MS parametreleri belirleme	79
Tablo 3.8. Model 5, kNN için k parametresi belirleme	81
Tablo 3.9. Model 6, MLP için hücre sayısı belirleme	83
Tablo 3.10. Model 7, SVM için C ve γ parametreleri belirleme	85
Tablo 3.11. Model 8, C4.5 için CF ve MS parametreleri belirleme	87
Tablo 3.12. Model 9, kNN için k parametresi belirleme	89
Tablo 3.13. Model 10, MLP için hücre sayısı belirleme	91
Tablo 3.14. Model 11, SVM için C ve γ parametreleri belirleme	93
Tablo 3.15. Model 12, C4.5 için CF ve MS parametreleri belirleme	95
Tablo 3.16. Model 13, kNN için k parametresi belirleme	97
Tablo 3.17. Model 14, MLP için hücre sayısı belirleme	99
Tablo 3.18. Model 15, SVM için C ve γ parametreleri belirleme	101
Tablo 3.19. Model 16, C4.5 için CF ve MS parametreleri belirleme	103
Tablo 3.20. OUAS teşhisi karmaşıklık matrisi	106
Tablo 3.21. Grup bazlı OUAS teşhis sonuçları	107
Tablo 3.22. Sınıflandırıcı bazlı OUAS teşhis sonuçları	108
Tablo 3.23. A sınıfı hastaların karmaşıklık matrisi	109
Tablo 3.24. Grup bazlı orta/ağır derecede OUAS'lı (A sınıfı) tespit sonuçları	110
Tablo 3.25. Sınıflandırıcı bazlı orta/ağır OUAS (A sınıfı) tespit sonuçları	111
Tablo 3.26. B sınıfı hastaların karmaşıklık matrisi	112
Tablo 3.27. Grup bazlı hafif derecede OUAS'lı (B sınıfı) tespit sonuçları	113
Tablo 3.28. Sınıflandırıcı bazlı hafif OUAS (B sınıfı) tespit sonuçları	114
Tablo 3.29. Grup bazlı OUAS sınıflandırma sonuçları	115
Tablo 3.30. Sınıflandırıcı bazlı OUAS sınıflandırma sonuçları	116
Tablo 3.31. Literatürde OUAS teşhisi ile ilgili yapılan çalışmalar	116
Tablo 3.32. Literatürde OUAS sınıflandırma ile ilgili yapılan çalışmalar	117

SİMGELER DİZİNİ VE KISALTMALAR

ω	: Açısal Frekans, (rd/s)
f	: Frekans, (Hz)
Hz	: Hertz, (1/s)
μV	: Mikrovolt, (10^{-6} V)
ms	: Milisaniye, (10^{-3} s)
mV	: Milivolt, (10^{-3} V)

Kısaltmalar

AASM	: American Academy of Sleep Medicine (Amerikan Uyku Tıbbı Akademisi)
ADD	: Ayrık Dalgacık Dönüşümü
AFD	: Ayrık Fourier Dönüşümü
AHI	: Apne Hipopne İndeksi
Aİ	: Apne İndeksi
AZFD	: Ayrık Zamanlı Fourier Dönüşümü
AZFD	: Ayrık Fourier Dönüşümü
C4.5	: C4.5 Decision Tree (C4.5 Karar Ağacı)
CF	: Confidence Factor (Güven Faktörü)
CSA	: Central Sleep Apnea (Santral Uyku Apnesi)
DD	: Dalgacık Dönüşümü
EDF	: European Data Format
EEG	: Elektroensefalografi
EKG	: Elektrokardiyografi
EKK-DVM	: En Küçük Kareler Destek Vektör Makinesi
EMG	: Elektromiyografi
EOG	: Elektrookülografi
ETS	: EKG'den Türetilmiş Solunum
FD	: Fourier Dönüşümü
FFNN	: Feed Forward Neural Network (İleri Beslemeli Sinir Ağları)
GN	: Gerçek Negatif
GP	: Gerçek Pozitif
GSY	: Power Spectral Density (Güç Spektral Yoğunluğu)
HF	: Yüksek Frekans
HFD	: Hızlı Fourier Dönüşümü
Hİ	: Hipopne İndeksi
IQR	: Interquartile range (Çeyrek Değerler Genişliği)
KAHD	: Kalp Atım Hızı Değişimi
kNN	: k-Nearest Neighbor (K En Yakın Komşu Algoritması)
KZFD	: Kısa Zamanlı Fourier Dönüşümü
LDA	: Linear Discriminant Analysis (Doğrusal Diskriminat Analiz)

LF	: Düşük Frekans
MAD	: Mean Absolute Deviation (Ortalama Mutlak Sapma)
MLP	: Multi Layer Perceptron (Çok Katmanlı Almaç)
MRAE	: Mean Relative Absolute Error (Ortalama Göreli Mutlak Hata)
MSA	: Mixed Sleep Apnea (Mikst Uyku Apnesi)
NREM	: Non Rapid Eye Movement (Hızlı Göz Hareketleri Olmayan)
OUA	: Obstrüktif Uyku Apnesi
OUAS	: Obstrüktif Uyku Apne Sendromu
ÖİF	: Öz İlinti Fonksiyonu
PPG	: Fotopletismografi
PSG	: Polisomnografi
QDA	: İkinci Dereceden Diskriminat Analiz
RBF	: Radyal Tabanlı Fonksiyon
REM	: Rapid Eye Movement (Hızlı Göz Hareketleri)
RMS	: Root Mean Square (Karesel Ortalama Değer)
ROC	: Receiver Operating Characteristic (Alıcı Çalışma Karakteristiği)
SBI	: Solunum Bozukluğu İndeksi
SKO	: Sıfır Kesme Oranı
SpO ₂	: Kandaki Oksijen Satürasyonunu
SUAS	: Santral Uyku Apne Sendromu
SVM	: Support Vector Machines (Destek Vektör Makineleri)
TEO	: Teager Enerji Operatörü
TP	: Toplam Güç
ÜSYRS	: Üst Solunum Yolu Rezistansı Sendromu
VLF	: Çok Düşük Frekans
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları

UYKUDA SOLUNUM BOZUKLUKLARININ TEŞHİSİ VE SINIFLANDIRILMASININ YUMUŞAK HESAPLAMA ALGORİTMALARI KULLANILARAK GERÇEKLENMESİ

ÖZET

Uyku hastalıkları arasında en sık karşılaşılan ve toplumun %1-5'ini etkileyen Obstrüktif Uyku Apne Sendromu (OUAS) her yaşta ve etnik grupta görülebilen bir hastalıktır. Hastalığın teşhisinde altın standart olarak kabul edilen Polisomnografi (PSG) incelemesi uzun zaman alan ve masraflı bir yöntemdir. Elektrokardiyografi (EKG) analizinin uyku apnesi tespitinde basit ve etkili bir yöntem olması nedeniyle alternatif teşhis ve karar destek sistemleri için Kalp Atım Hızı Değişimi (KAHD) ile solunumu dolaylı olarak gösteren EKG'den Türetilmiş Solunum (ETS) sinyali analizine dayalı birçok araştırma yapılmıştır.

Bu çalışmada, yumuşak hesaplama algoritmaları ile gece uykusu sırasında oluşan apneleri EKG sinyali üzerinden yüksek doğrulukta sınıflandırarak, OUAS'ın teşhisi ve derecesinin belirlenmesinde hekime yardımcı olacak güvenilir bir örüntü tanıma sistemi oluşturmak amaçlanmıştır. Çalışmada, bir tanesi eğitim, diğeri de test amacıyla gerçek hasta kayıtlarından oluşan iki farklı veri apne tabanı kullanılmıştır. EKG sinyalinden elde edilen KAHD ile ETS sinyallerinin zaman ve frekans uzaylarındaki analizlerinden elde edilen öznitelikler dört farklı grup altında, k-En Yakın Komşu Algoritması (kNN), Çok Katmanlı Almaç (MLP), Destek Vektör Makineleri (SVM) ve C4.5 Karar Ağacı sınıflandırıcılarının kullanıldığı 16 örüntü tanıma modeli oluşturulmuştur. Her modül öznitelik seçimi ve sınıflandırıcı optimizasyonu sonrasında eğitilmiş ve test verileriyle test edilmiştir. Test sonucunda %100 doğrulukta OUAS teşhisi ile %97 doğrulukta OUAS derecesinin sınıflandırılması başarımlı sağlanmıştır.

Sonuç olarak, EKG sinyali üzerinden holter gibi pratik ve taşınabilir bir EKG kayıt cihazının kullanılması ile KAHD ve ETS sinyallerinin zaman uzayı analizinden seçilmiş özniteliklerin kullanıldığı, optimize edilmiş kNN sınıflandırıcısına dayalı model ile OUAS şüphesi olan hastaların güvenilir seviyede teşhisinin ve sınıflandırılmasının yapılabilmesi sonucuna varılmıştır.

Anahtar Kelimeler: Elektrokardiyografi (EKG), EKG'den Türetilmiş Solunum (ETS), Kalp Atım Hızı Değişimi (KAHD), Obstrüktif Uyku Apne Sendromu (OUAS), Örüntü Tanıma.

SLEEP RESPIRATION DISORDERS DIAGNOSIS AND CLASSIFICATION UTILIZING SOFT COMPUTING ALGORITHMS

ABSTRACT

Obstructive Sleep Apnea Syndrome (OSAS) is the most common among sleep disorders and affects 1-5% of population from all age and ethnic groups. Polysomnography (PSG) is accepted as the golden standard for OSAS diagnosis however it requires long time and it is an expensive technique. Since ECG is simple and efficient technology for sleep apnea detection, various researches have been conducted based on Heart Rate Variability (HRV) and ECG Derived Respiratory (EDR) for alternate diagnosis and decision support systems. The aim of this study, is to make a reliable pattern recognition system for physicians to diagnose and classify the degree of OSAS, based on soft computing techniques utilizing ECG.

The ECG recordings used in this study were collected from two different apnea databases; the first database was used for training and the second for testing. In total 16 pattern recognition models were formed by using four groups of features extracted from HRV and EDR analysis in frequency and time domains and using k-Nearest Neighbor (kNN), Multilayer Perceptron (MLP), Support Vector Machines (SVM) and C4.5 Decision Tree classifiers. Each module was trained and tested after feature selection and classifier optimization. In test results, 100% accuracy for diagnosis and 97% accuracy for classification of OSAS is achieved.

It is concluded that by analyzing ECG signals acquired from a portable ECG device such as holter, the pattern recognition model based on selected time domain features utilized with kNN classifier can be used for diagnosis and classification of OSAS suspected patients.

Keywords: Electrocardiography (ECG), ECG Derived Respiratory (EDR), Heart Rate Variability (HRV), Obstructive Sleep Apnea Syndrome (OSAS), Pattern Recognition.

GİRİŞ

Yeme, içme, barınma ve giyinme insanoğlunun temel ihtiyaçları olarak kabul edilmektedir. Yaşamımızın yaklaşık üçte birini uykuya ayırdığımızı göz önüne alırsak sağlıklı bir yaşamın temelini oluşturan, vücudu her gün fiziksel ve zihinsel olarak yenileyen bir dönem olan uyku en az temel ihtiyaçlarımız kadar önemlidir. İyi bir uykunun vazgeçilemez bir ögesi de düzenli solunumdur. Uyku sırasındaki solunumun düzensizliği hem sağlığın bozulmasına hem de yaşam kalitesinin düşmesine neden olmaktadır. Horlama, yorgunluk, bağışıklık sisteminin zayıflaması, yoğunlaşma bozukluğu, uykuda gerçekleşen ani ölümler gibi durumların kaynağında uykuda solunum bozuklukları yatmaktadır.

Günümüzde uyku apnesi, uykusuzluk, horlama ve huzursuz bacak sendromu başta olmak üzere seksenin üzerinde uyku hastalığı tespit edilmiştir. Obstrüktif uyku apne sendromu (OUAS) her yaşta ve etnik grup görülebilen, uyku hastalıkları arasında en sık karşılaşılan ve toplumun %1-5'ini etkileyen bir hastalıktır [1].

Uykuda solunum bozuklukları basit horlama ile başlayan üst solunum yolu rezistansı sendromu (ÜSYRS), OUAS ve santral uyku apne sendromu (SUAS) ile devam ederek daha da ilerleyen bir süreçtir ve tüm olguların %90-95'ini oluşturması sebebiyle uyku apne sendromu denildiğinde genel olarak OUAS anlaşılır [1].

Uykuda solunum bozuklukları; spektrumu basit horlama, üst solunum yolu rezistansı sendromu, obstrüktif uyku apne sendromu, santral uyku apne sendromu, overlap sendromu ve obezite hiperventilasyon sendromudur.

Uykuda solunum bozukluklarının teşhisinde klinik tanı, radyolojik tanı, endoskopik tanı, polisomnografi ve yardımcı tanı yöntemleri kullanılmaktadır. Uyku sırasındaki fizyolojik sinyalleri ölçmek ve kaydetmek için polisomnograf cihazı kullanılır. Genellikle uyku laboratuvarlarında kullanılan bu cihazdan alınan sinyallere polisomnografi (PSG) denir ve uykuda solunum bozukluklarının ayırt edilmesinde ve uyku apnesi sendromunun teşhisinde altın standart olarak kabul edilir. PSG ilk defa 1965 yılında Gastaut tarafından uygulanmış olup söz konusu dönemde uyku

bozukluklarının önemli bir halk sağlığı sorunu olmadığı değerlendirilse de günümüzde sadece Amerika Birleşik Devletleri'nde 40 milyon insanın uyku bozukluğundan rahatsız olduğu sanılmakta, bunun önemli bir bölümünün uykuda solunum bozukluğu oluşturmaktadır [1].

Hastalardan gece boyunca alınan standart PSG parametreleri; Elektroensefalografi (EEG), Elektromiyografi (EMG), Elektrookülografi (EOG), Elektrokardiyografi (EKG). oro-nasal hava akımı, toraks-abdominal hareketler, kandaki oksijen saturasyonunu (SpO₂) ve vücut pozisyonudur.

EEG, EMG-submentalis ve EOG sinyalleri hastanın uyku evrelerinin belirlenmesini ve bu evrelerde oluşabilecek patolojik bulguların değerlendirilmesini sağlar. Uyku apnesinin tespit edilmesi, tipinin ve süresinin belirlenmesi için oro-nasal hava akımı ve toraks-abdominal hareket (solunum çabası) sinyallerinden yararlanılmaktadır. Nabız ve EKG sinyalleri üzerinden de uyku apnesi tespiti yapılabilmektedir [1]. Apne oluşumu esnasında kalp atımında yavaşlama, apne sonlanmasından sonra da hızlanma oluşur. Bu nedenle EKG sinyalinden elde edilen Kalp Atım Hızı Değişimi (KAHD) verisinin analizi apne oluşumu ile ilgili önemli bilgiler içerir. KAHD'nin yanı sıra EKG'den elde edilen EKG genlik değerleri üzerinden solunumu dolaylı olarak gösteren EKG'den Türetilmiş Solunum (ETS) sinyali analizi ile de apne oluşumu tespit edilebilmektedir.

Uyku apnesi, uyku esnasında solunum sinyalinin maksimum genliğinin en az 10 saniye süresince durması veya en fazla %20 seviyelerinde seyretmesi durumudur. Uyku apnesinin hastalarda sık ve uzun süreli seyretmesine uyku apnesi sendromu denir. Toraks ve abdominal solunum çabasına göre obstrüktif uyku apnesi, santral uyku apnesi ve miks uyku apnesi olarak üç tipe ayrılır. Apne-Hipopne İndeksi (AHİ) uykunun kalitesini değerlendirmek ve hastalığın şiddetini belirlemek için kullanılan değerdir. AHİ, uyku esnasında oluşan apne ve hipopnelerin saatlik ortalamasıdır ve Solunum Bozukluğu İndeksi (SBI) de denir. AHİ değeri 5'ten büyük olan hastalara uyku apnesi tanısı konulmaktadır. AHİ üzerinden uyku apne dereceleri normal (AHİ<5), hafif/sınırdaki (5 ≤ AHİ < 15), orta (15 ≤ AHİ < 30) ve ağır apne (AHİ ≥ 30) olarak sınıflandırılır.

Literatürde uyku apnesi üzerinde yapılan çalışmaların çoğunluğu uyku apnesinin tespit ve sınıflandırılmasında EKG sinyallerini temel almıştır. Bu çalışmalarda yöntem olarak çoğunlukla RR aralıklarındaki zaman değişikliğini gösteren KAHD üzerinden frekans ve zaman uzayında yapılan analizler kullanılmıştır. Bunun başlıca nedeni KAHD'nin hem zaman hem de frekans uzayında birçok özneliğe sahip olması ve bu özneliklerden çok farklı yöntemler kullanılarak analiz yapılabilmesidir. KAHD'nin yanı sıra ETS'nin de zaman ve frekans uzayında analizi destekleyici veri içermesi nedeniyle söz konusu çalışmalarda kullanılan bir yöntemdir. EKG sinyalinin zaman ve frekans uzayındaki analizleri sinyal uzunluğuna bağlı olarak 1-5 dakika arasında kısa dönem veya 24 saatlik uzun dönem biçiminde yapılmaktadır.

Frekans uzayı analizlerinde KAHD'nin spektral bileşenleri veya RR aralıklarının spektral osilasyonu kullanılmaktadır [2-4]. KAHD'nin güç spektral yoğunluğunun hesaplanması sonrasında elde edilen yüksek frekans, alçak frekans ve çok alçak frekans bölgelerindeki güç değerleri ile yüksek frekans ve alçak frekans bölgelerindeki güç değerlerinin birbirine oranı üzerinden apne tespiti çalışmaları yapılmıştır [5-7]. KAHD spektral bileşenlerindeki değişimler üzerinden yapılan analizler ile apne tespit çalışmaları yapılmıştır [8, 9]. Roche ve diğ. [10] zaman-frekans bölgesi dalgacık dönüşümü analizi kullanarak yaptıkları çalışmada apne anındaki KAHD frekans değişimlerini inceleyerek Obstrüktif/Tıkalı Uyku Apnesi (OUA) teşhisi yapmıştır.

Literatürdeki çalışmalarda kullanılan hasta kayıtları genellikle PhysioNet [11] Apne-EKG veritabanından elde edilmiştir. KAHD'nin bir dakikalık frekans bölgesi analizlerinde de başarılı sonuçlar elde edilmiştir. Mendez ve diğ., PhysioNet apne veritabanından elde ettikleri 50 hasta kaydı üzerinden bir dakikalık epoklara ayrılan EKG sinyali üzerinden iki değişkenli özbağımlı model ile yaptıkları çalışmalarında, KAHD ile ETS (R tepesi alanı üzerinden hesaplanarak) güç spektrum yoğunlukları kullanarak kNN ile %85 [12], diğer çalışmalarında ise KAHD ile ETS (QRS kompleks alanı üzerinden hesaplanarak) güç spektrum yoğunlukları üzerinden YSA ve kNN ile %88 doğrulukta apne sınıflandırması gerçekleştirmişlerdir [13].

Zaman uzayı analizlerinde yapılan çalışmalarda da frekans uzayına benzer biçimde KAHD'den elde edilen istatistiksel ve geometrik yöntemler kullanılarak apne tespiti ve sınıflandırması yapılmıştır [14, 15]. Chazal ve diğ. 2003 yılında yayımlanan çalışmalarında KAHD ve ETS üzerinden elde ettikleri öznitelikleri kullanarak Doğrusal Diskriminat Analiz (LDA) ve İkinci Dereceden Diskriminat Analiz (QDA) yöntemi ile apneli hastaların normal hastalardan ayrılabilceği ve bir dakikalık epok analizi ile %90 doğrulukta sınıflandırma elde ettiklerini belirtmiştir [16]. 2004 yılında yayımlanan çalışmalarında ise aynı model üzerinden normal solunum ve düzensiz solunum şeklinde işaretlenmiş 15, 30, 45, 60, 75 ve 90 saniyelik farklı uzunluklardaki epoklar üzerinde analiz yapmış ve en yüksek doğrulukta sınıflandırmanın %90 ile 60 saniyelik epok uzunluğunda, en düşük doğrulukta sınıflandırmanın ise 15 ve 90 saniyelik epok uzunluklarında elde edildiğini bildirmiştir [17].

Yılmaz ve diğ. [18] 3 öznitelikle yaptıkları çalışmalarında KAHD bazlı sınıflandırmanın EKG sinyali üzerinden uyku evreleri ile obstrüktif apneli epokların sınıflandırılması için mümkün olduğunu bildirmiştir. Söz konusu çalışmada Gülhane Askeri Tıp Akademisi Psikiyatri Kliniği Uyku Laboratuvarından gece boyunca kaydedilen 17 hasta kaydından elde edilen EKG sinyallerini 30 saniyelik epoklara bölmüş, kNN, QDA ve SVM metotları kullanılarak yapılan sınıflandırmada 5 OSA hastası için apne bulunan epokların %89 doğrulukta tespiti sağlanmıştır.

Sani ve diğ. [19] 2010 yılında yayımlanan çalışmalarında Chazal ve diğ. [17] tarafından önerilen 8 öznitelik ile Yılmaz ve diğ. [18] tarafından önerilen 3 özniteliği karşılaştırma amaçlı olarak kullanarak analiz etmiştir. PhysioNet veritabanından elde edilen 70 hastaya ait EKG sinyallerinin bir dakikalık epoklara bölündükten sonra hesaplanan KAHD verisi üzerinden söz konusu öznitelikler çıkarılmıştır. Farklı sınıflandırma algoritmaları kullanılarak yapılan çalışma sonucunda Yılmaz ve diğ. [18] tarafından önerilen 3 öznitelik ile sınıflandırma doğruluğunun %3,59 daha fazla olduğu rapor edilmiştir.

Gürüler ve diğ. [20] EKG üzerinden OSA teşhisi için kullanılabilecek etkin özniteliklerin belirlenmesi amacıyla ilinti matrisi temelli öznitelik seçim fonksiyonu önermiştir. Söz konusu çalışmada, KAHD'nin analizinden zaman uzayı, frekans

uzayı ve doğrusal olmayan hesaplamalara ait öznelikler kullanılmış, gizli katmandaki sinir sayısı optimize edilmiş Çok Katmanlı Almaç (Multilayer Perceptron, MLP) ile sınıflandırma yapılmıştır.

Uyku esnasında meydana gelen apnelerin öngörülmesi ve apnelerin sınıflandırılmasında EKG sinyalinin yanı sıra başta oro-nazal hava akımı ve EEG olmak üzere diğer PSG parametrelerinden de yararlanılmaktadır. Erdamar [21], 2007 yılında yayımlanan doktora tezinde uyku apnesinin öngörülmesi ve dil kasının uyarılması amacıyla geliştirilen model çalışmasında solunum, EEG, EMG ve EKG sinyallerini kullanmıştır. Çalışmada söz konusu sinyallerin frekans analizinde klasik Fourier Dönüşümü (FD), Kısa Zamanlı Fourier Dönüşümü (KZFD), Ayrık Zamanlı Fourier Dönüşümü (AZFD) ve kestirim metotlarından yararlanılmıştır. Genlik analizlerinde ise sinyalin enerjisi, Öz İlinti Fonksiyonu (ÖİF), Teager Enerji Operatörü (TEO) ve sıfır kesme oranı (SKO) gibi yöntemleri kullanmıştır. Yapılan analizler sonucunda uyku apnesinin öngörülebilmesi için kullanılacak sinyal parametreleri elde edilmiştir. Farklı 90 hastadan elde edilen kayıtlar üzerinde test edilen model ile uyku esnasında meydana gelen ilk apnenin öngörülmesinde %60'ı aşkın başarı elde edilmiştir.

Akşahin [22], tezinde uyku apnesinin sınıflandırılması amacıyla 30 hastadan elde edilen 300 epokluk EEG, EKG, fotopletizmografi (PPG), solunum ve toraks-abdominal efor bandı sinyallerinden yararlanmıştır. Üç aşamada gerçekleştirilen çalışmada ilk olarak EEG sinyalleri bağıllık işlevi ve ikincil bağıl bilgi yöntemleriyle, daha sonra EKG ve PPG sinyalleri eş zamanlı hesaplanan KAHD ve çapraz güç spektral yoğunluğu yöntemleriyle, son olarak solunum ve toraks-abdominal efor bandı sinyalleri ise enerji, varyans ve öz ilinti işlevi yöntemleri ile analiz edilmiştir.

Söz konusu çalışmanın 3 aşamasında da YSA ile sınıflandırma yapılmış olup uyku sırasında oluşan apnenin çok düşük hata oranıyla sınıflandırılmasını sağlayacak yeni yöntemler sunulmuştur.

Yıldız [23] ise tezinde EEG sinyallerinden hastanın uyanıklık seviyesinin tespiti, EKG sinyallerinden elde edilen KAHD ve ETS sinyallerinden ise OUAS tespiti amaçlı otomatik örüntü tanıma sistemi üzerinde çalışma yapmıştır. Frekans uzayında

yapılan çalışmada Dalgacık Dönüşümü (DD) kullanılarak elde edilen öznitelikler Yapay Sinir Ağları (YSA) ve En Küçük Kareler Destek Vektör Makinesi (EKK-DVM) ile sınıflandırılmıştır. Öznitelik belirleme sonrasında sınıflandırıcı performansını arttırmak amacıyla öznitelik seçme algoritması kullanılmamıştır. EKG kayıtlarından hastanın OUAS hastası olup olmadığının tespiti için on iki farklı sınıflandırma modeli oluşturulmuş olup en iyi sınıflandırıcı başarımı KAHD'den elde edilen ve EKK-DVM ile sınıflandırılan model ile gerçekleştirilmiştir.

Uykuda solunum bozukluklarının teşhisinde hekimlere yardımcı olacak karar destek sistemleri üzerine çalışmalar yapılmıştır. Korpinen ve diğ., 1993 yılında "Sleep Expert" adını verdikleri çağrışimli bilgi tabanlı karar destek sistemi geliştirmiştir. Bahsedilen sistem 1990 yılında kabul edilmiş uluslararası uyku bozuklukları sınıflandırmalarına dayanmaktadır [24, 25].

Uykuda solunum sesleri de gece boyunca kaydedilen PSG sinyalleri arasındadır. Bu sinyaller üzerinden yapılan çalışmalarda uyku sırasında oluşan öksürme, tıkanıklık ve horlama gibi durumlardaki solunum seslerinin sınıflandırılması yapılmıştır [26, 27].

Halen kullanılmakta olan ticari PSG programlarının otomatik olarak uyku apnesi teşhis ve sınıflandırmasındaki doğruluk oranının düşük olması nedeniyle, uzmanlar tarafından güvenilir kabul edilmemekte, kesin tanı ve sınıflandırmada her bir hasta için gece boyunca uykuda kaydedilmiş ortalama sekiz saatlik, üç bin sayfaya yakın PSG kaydının uzman personel tarafından bilgisayar ekranında incelenmesi gerekmektedir.

Bu çalışmada, yumuşak hesaplama algoritmaları ile gece uykusu sırasında oluşan apneleri EKG sinyali üzerinden yüksek doğrulukta sınıflandırarak, OUAS'ın teşhisi ve derecesinin belirlenmesinde hekime yardımcı olacak güvenilir bir örüntü tanıma sistemi oluşturmak amaçlanmıştır.

Tez çalışması üç aşamada yapılmıştır. Birinci aşamada literatür taraması yapılmış, uyku fizyolojisi ile dolaşım ve solunum sistemleri incelenmiştir. İkinci aşamada çalışmada kullanılacak PSG sinyalleri European Data Format (EDF) olarak adlandırılan formatta elde edilmiş, MATLAB [47] programına aktarılmış ve sayısal

sinyal işleme yöntemleri incelenmiştir. Üçüncü aşamada ise hastalara ait PSG kayıtlarından kullanılacak sinyaller ayrılmış, öznitelikler çıkarılmış, öznitelik seçici algoritmalar yoluyla sınıflandırmada kullanılacak öznitelikler seçilmiş, farklı yumuşak hesaplama algoritmaları optimize edilerek sınıflandırma yapılmış ve sonuçları değerlendirilmiştir.

Bu tez çalışması kapsamında; Bölüm 1’de, uyku, uyku evreleri, uykuda solunum bozuklukları, solunum parametreleri, uyku apnesi esnasında gözlemlenen ve kaydedilen fizyolojik sinyaller ile ilgili genel bilgiler ele alınmıştır. Ayrıca yumuşak hesaplama, örüntü tanıma sistemi ve tez çalışması kapsamında kullanılan sınıflandırma yöntemleri hakkında genel bilgiler verilmiştir.

Bölüm 2’de, tez çalışmasında kullanılan verilerin alınması ve ayrıştırılması ile verilerin işlenmesinde kullanılan yöntemlerin tanıtımı yapılmış, EKG sinyali analizi ve kullanılacak özniteliklerin KAHD ile ETS sinyallerinden elde edilmesi kapsamında uygulanan yöntemler anlatılmıştır.

Bölüm 3’te, EKG sinyalinden türetilen KAHD ve ETS sinyallerinin zaman ve frekans uzaylarındaki analizleri ile elde edilen özniteliklerin gruplanması ve oluşturulan modellerin eğitimleri ve testler sonucundaki sınıflandırma başarımları verilmiştir.

Bölüm 4’te, tez çalışması ile elde edilen sonuçlar ve öneriler sunulmuştur.

1. GENEL BİLGİLER

Sağlıklı bir yaşamın temelini oluşturan, vücudu her gün fiziksel ve zihinsel olarak yenileyen bir dönem olan uyku için yaşamımızın üçte birini ayırmaktayız. İyi bir uykunun vazgeçilemez bir ögesi de düzenli solunumdur. Uyku sırasındaki solunumun düzenli olmaması hem sağlığın bozulmasına hem de yaşam kalitesinin düşmesine neden olmaktadır. Horlama, yorgunluk, uykuda gerçekleşen ani ölümler gibi durumların kaynağında uykuda solunum bozuklukları yatmaktadır.

Uyku bozukluklarının teşhis ve tedavilerinde uyku sırasındaki fizyolojik sinyalleri ölçen ve kaydeden polisomnograf cihazı kullanılır. Genellikle uyku laboratuvarlarında kullanılan bu cihazdan alınan sinyallere PSG denir ve uyku hastalığının ayırt edilmesinde ve uyku apnesi sendromunun teşhisinde altın standart olarak kabul edilir.

1.1. Uyku

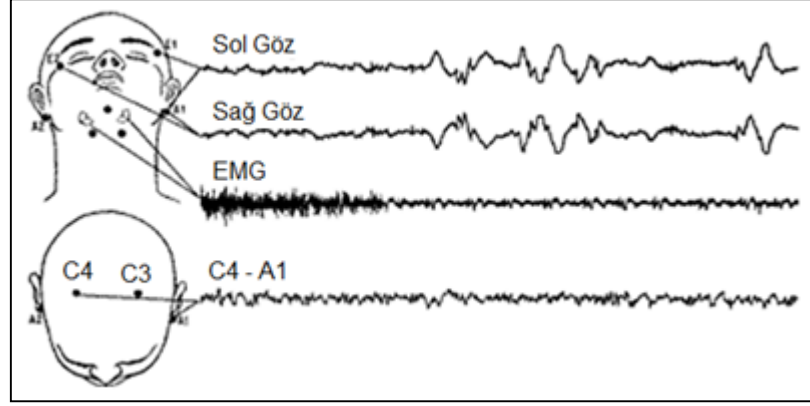
Uyku, bilincin dış dünyaya karşı kısmen veya tamamen yitirildiği, tepki ve etkinliğin azaldığı bünyenin dinlenme durumudur. Uyku, vücudun hasarlı hücrelerinin yenilenmesine, büyüme hormonunun salgılanmasına, bağışıklık sisteminin düzenlenmesine ve beynin dinlenmesine zemin oluşturur.

Uykunun tanımlanmasında fizyolojik ve davranışsal belirleyicilerden yararlanılmaktadır. Fizyolojik belirleyiciler temelde EEG, EMG ve EOG sinyallerindeki değişimlerden gözlemlenmektedir [28]. Davranışsal belirleyiciler ise; hareketlerde azalma ya da hareketsizlik, gözlerin kapanması, dış uyaranlara karşı tepkide azalma, karakteristik uyku postürü, bilinç kaybı sayılabilir [21].

1.2. Uyku Evreleri

Uyku memeliler ve kuşlar için hızlı göz hareketleri (REM) ve hızlı göz hareketleri olmayan (NREM) olmak üzere iki ana evreden oluşmaktadır. Uyku evrelerinin sınıflandırılmasında EEG, EOG ve EMG ile gözlemlenen fizyolojik belirleyiciler kullanılmaktadır (Şekil 1.1). Sağlıklı bir insanın normal bir gece uykusu, REM ve

NREM evrelerini içeren ve 90-120 dakikalık periyotlarla gerçekleşen 4-6 döngüden oluşur [28,29]. Uyku süresi ile farklı uyku evrelerinde geçirilen süre yaşa göre değişiklik gösterir. REM evresinde geçirilen süre yaş ilerlerken nispeten sabit kalsa da, NREM evresinde geçirilen süre yaşla beraber azalır [21].




Şekil 1.1. Uyku çalışmasında elektrot yerleşimleri [28]

Rechtschaffen ve Kales'in [29] 1968 yılında standart hale getirdiği ve 2007 yılına kadar uygulanan kurallara göre uyku evreleri REM ile NREM-1, 2, 3, 4 olmak üzere 5 evreden oluşmaktadır. Amerikan Uyku Tıbbı Akademisi (American Academy of Sleep Medicine, AASM) tarafından 2007 yılında yayımlanan "Uyku ve İlişkili Olayları Skorlama Kılavuzu" ile günümüzde geçerli olan uyku evreleri ve uyku evrelerini skorlama kuralları belirlenmiştir. Rechtschaffen ve Kales skorlama kuralları ile geliştirilen AASM skorlama kuralları, NREM-4 evresi NREM-3 evresi altında birleştirilmiş ve uyku evre sayısı 4 olmuş, arousal ve solunum, kardiyak ve hareket olayları eklenmiştir.

AASM kurallarına göre standart hale getirilmiş uyku evreleri ve özellikleri aşağıdaki maddelerde sunulmuştur.

1.2.1. Uyanıklık

Uyanıklık esnasında EEG kanallarında 8-13 Hz frekanslı alfa dalgalarının belirgin olduğu, diğer kanallarda ise düzensiz aktivitelerin olduğu evredir. Alfa dalgaları Bölüm 1.5.1'de detaylı olarak açıklanmıştır. Uyanıklık evresine ait EEG, EOG ve EMG kayıtları Şekil 1.2'de gösterilmiştir.



Şekil 1.2. Polisomnografide uyanıklık evresi [28]

1.2.2. Evre 1 (NREM-1)

Uyanıklıkla uyku arasındaki dönemdir. Kaslar aktiftir, gözler yavaşça yuvarlanır ve hafifçe açılır ve kapanır. EEG kanallarında alfa dalgaları azalır, karışık frekanslı ve düşük genlikli dalgalar gözlemlenir. EOG kanalında ise yavaş göz hareketleri tespit edilebilir [28]. Evre 1'e ait EEG, EOG ve EMG kayıtları Şekil 1.3'te gösterilmiştir.

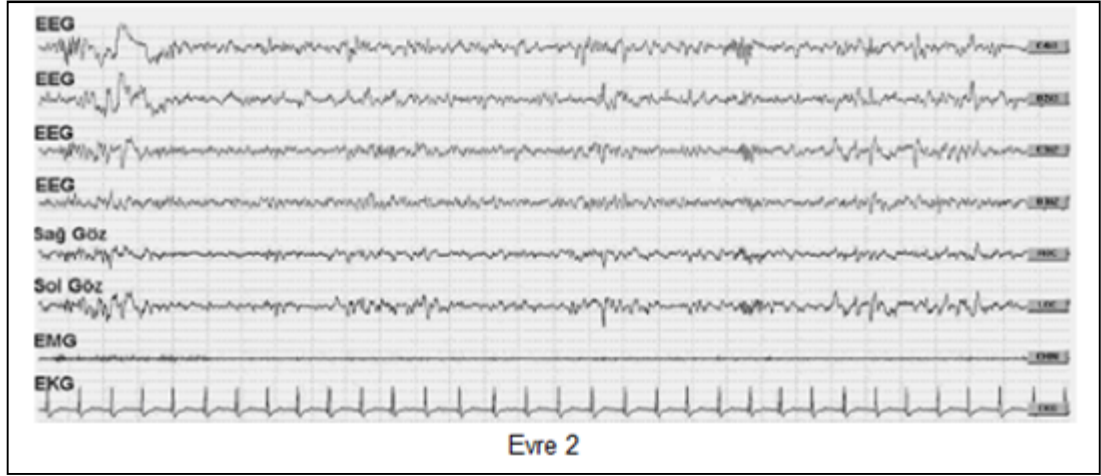


Şekil 1.3. Polisomnografide Evre 1 [28]

1.2.3. Evre 2 (NREM-2)

Uykunun büyük bir bölümünü teşkil eder. Bu evrede teta dalgası aktiviteleri gözlemlenir ve uyku gittikçe ağırlaşır. Teta dalgaları Bölüm 1.5.1'de detaylı olarak açıklanmıştır. Bir önceki evredeki alfa dalgalarının uyku içcikleri ve K-kompleksi

denilen ani aktivitelerle bozulması ile belirlenir. EOG kanalında göz hareketleri sonlanır. Evre 2'ye ait EEG, EOG ve EMG kayıtları Şekil 1.4'te gösterilmiştir.




Şekil 1.4. Polisomnografide Evre 2 [28]

1.2.4. Evre 3 (NREM-3) ve Evre 4 (NREM-4)


Yavaş-dalga uykusu veya delta uykusu olarak da isimlendirilir. Uykunun en derin olduğu evredir. Bu evrede düşük frekanslı ve yüksek genlikli delta dalgaları gözlemlenir. Delta dalgaları Bölüm 1.5.1'de detaylı olarak açıklanmıştır. EEG standartlarına göre delta dalgaları 0,5-4 Hz aralığında tanımlanmasına rağmen uyku standartlarına (hem Rechtschaffen ve Kales hem de AASM 2007 kılavuzuna) göre 0,5-2 Hz olarak tanımlanmaktadır. EEG sinyallerinde, 0,5-2 Hz frekans aralığında ve tepeden-tepeye genliği $75\mu\text{V}$ üzerinde olan delta dalgalarının epogun %20 ve üzerini oluşturması ile karakterize edilir. Halen birçok gösterimde delta dalgalarının %20-50 arasında EEG sinyalini kapsamaması Evre 3, %50 ve üzerini kapsamaması da Evre 4 olarak yer alsa da bu iki evre Evre 3 altında birleştirilmiştir. Evre 3'e ait EEG, EOG ve EMG kayıtları Şekil 1.5'de, Evre 4'e ait olan kayıtlar ise Şekil 1.6'da gösterilmiştir.

1.2.5. REM

Uyku süresinin %20-30 bölümünü oluşturan, rüyaların görüldüğü, hızlı göz hareketlerinin gözlemlendiği uyku evresidir. REM paralizi olarak da adlandırılan, göz ve solunum kasları dışındaki iskelet kas tonusunun sıfıra yaklaştığı evredir [27].



Şekil 1.5. Polisomnografide Evre 3 [28]



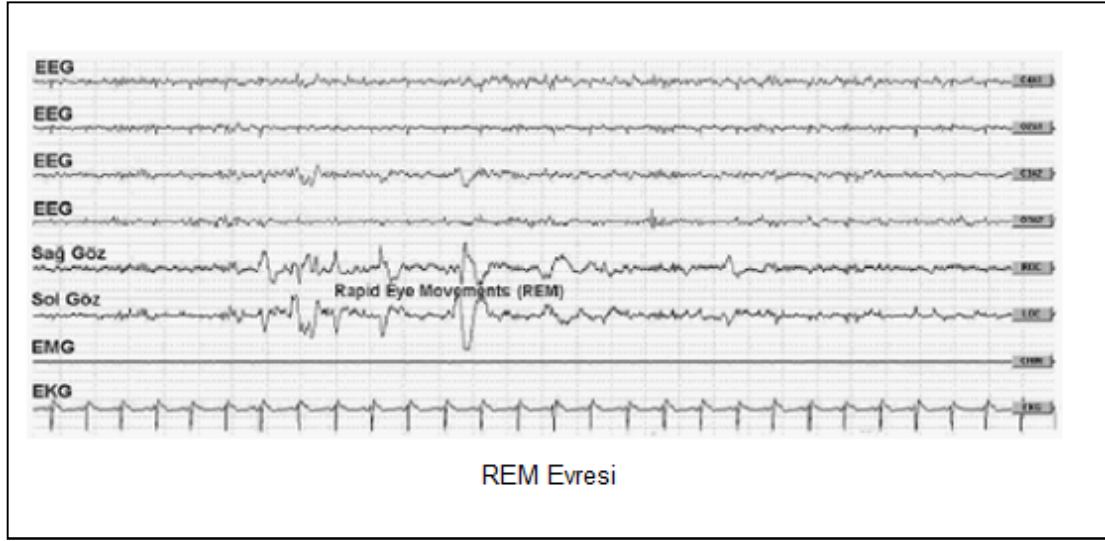
Şekil 1.6. Polisomnografide Evre 4 [28]

Kan basıncı, kalp ritmi, solunum sayısı ile solunum derinliğinde değişimler oluşur [21]. REM evresine ait olan kayıtlar Şekil 1.7'de gösterilmiştir.

1.3. Uykuda Solunum Bozuklukları

Uyku esnasında solunum düzeninde patolojik düzeydeki değişikliklere bağlı olarak gelişen, hastalığın ve ölüm oranının artmasına neden olan klinik tablolara uykuda solunum bozuklukları denmektedir [1].

Uykuda solunum bozuklukları basit horlama ile başlayan ÜSYRS, OUAS ve SUAS ile devam ederek daha da ilerleyen bir süreçtir [1].



Şekil 1.7. Polisomnografide REM evresi [28]

1.3.1. Basit horlama

Horlama, uyku sırasında soluk alırken boğaz ve burundan gürültülü sesler çıkarmak olarak tanımlanmaktadır. AASM kriterlerine göre ise horlama, üst solunum yolunun uyku esnasında titreşimi sonucu meydana gelen solunum sesidir. Her insanda karşılaşılsa da, horlama sıklıkla erkekler ve kilolu kişilerde daha sık görülür ve yaşın ilerlemesiyle şiddeti daha da artar [27].

Horlamanın temel nedeninin anatomik olarak küçük veya kapanmaya yatkın üst hava yolundaki yumuşak dokular olduğu düşünülmektedir. Üst hava yolu açıklığını sağlayan reflekslerin uyku başlangıcı ile birlikte zayıflaması, insanlarda horlamanın veya uyku apnesinin oluşumunu kolaylaştırmaktadır [27].

1.3.2. Üst solunum yolu rezistansı sendromu


Guilleminault tarafından 1993 yılında tanımlanmış uykuda solunum bozukluğu çeşididir. Üst solunum yolu direnci artışından oluşan arousallar ve sık uyku bölünmesi ile sonlanır. Gündüz aşırı uyku hali ve kalp problemlerine neden olur. Apne veya hipopneye neden olmadığı için klasik PSG teknikleri ile tespiti zordur.

1.3.3. Uyku apnesi

Uyku apnesi, uyku esnasında solunum sinyali maksimum genliğinin en az 10 saniye süresince durması veya en fazla %20 seviyelerinde seyretmesi durumudur. Uyku apnesinin hastalarda sık ve uzun süreli seyretmesine uyku apnesi sendromu denir.

Apne yetişkinlerde çoğunlukla uyurken ortaya çıkmaktadır. Uyku apnesi sendromuna sahip olan hastalarda apneler sık ve uzun süreli gerçekleşmektedir. Apneler çoğunlukla uykunun NREM-2 evresinde gözlenmektedir. Uyku esnasında meydana gelen apne türleri ve buna bağlı solunum parametreleri aşağıda tanımlanmıştır [6]:

Obstrüktif uyku apnesi (OUA); uyku esnasında oro-nazal hava akımının en az 10 saniye süre kesilmesine rağmen toraks ve abdominal solunum çabasının devam etmesi durumudur. Uyku esnasında üst solunum yollarında oluşan bir tıkanıklıktan kaynaklandığı değerlendirilmektedir. Şekil 1.8’de OUA durumundaki PSG grafikleri görülmektedir.




Şekil 1.8. OUA PSG Grafikleri [28]

Santral uyku apnesi (CSA); uyku esnasında oro-nazal hava akımının en az 10 saniye süre kesilmesi ve solunum çabasının olmaması, merkezi sinir sisteminden solunumla ilgili kaslara uyarı gitmemesi ve solunum güdüsünün kaybedilmesi durumudur. Şekil 1.9’da CSA durumundaki PSG grafikleri görülmektedir.

Mikst uyku apnesi (MSA); CSA tipinde başlayan daha sonra solunum çabasının akciğerlerde başlaması ile OSA tipinde devam eden ve oro-nazal hava akımının en az 10 saniye süre kesildiği durumdur. Şekil 1.10’da MSA durumundaki PSG grafikleri görülmektedir.



Şekil 1.9. CSA PSG Grafikleri [28]



Şekil 1.10. MSA PSG Grafikleri [28]

1.4. Solunum Parametreleri

Solunum ile ilgili olan temel parametreler aşağıda sunulmuştur.

Apne, uyku esnasında solunum sinyali maksimum genliğinin en az 10 saniye süresince durması veya en fazla %20 seviyelerinde seyretmesi durumudur. AASM 2007 kurallarına göre apne, hava akımının 10 saniye ve üzeri süre ile termal sensör tepe sinyalinde bazal genliğe göre %90 veya daha fazla düşme olarak tanımlanmıştır.

Bazal genlik, hava akımının apnenin olduğu epoktan önceki 2 dakikalık süre içinde istikrarlı haldeki ortalama genlik değeri olarak tanımlanır.

Hipopne, uyku esnasında oro-nazal hava akımı sinyali maksimum genliğinde en az 10 sn süreyle %50 azalma, oksijen saturasyonunda bazal değere göre %3 ve üzeri düşüş ile birlikte arousal gerçekleşmesi durumudur. AASM 2007 kurallarında hipopne, nazal kanül sinyal genliğinde bazal genliğe göre %50 ve üzerinde azalma (hava akımı sinyali, göğüs ya da abdominal sinyaller) ve oksijen saturasyonunda bazal değere göre %3 ve üzerinde düşme ile birlikte buna eşlik eden uyanıklık reaksiyonları olarak kabul edilmiştir.

Arousal, uyku esnasında, daha yüzeysel uyku evresine ya da uyanıklık durumuna ani geçişler olarak tanımlanır. Arousal, apne ve hipopnenin sonunda görülür [28].

Apne İndeksi (Aİ), uyku esnasında oluşan apnelerin saatlik ortalamasıdır.

Hipopne İndeksi (Hİ), uyku esnasında oluşan hipopnelerin saatlik ortalamasıdır.

Apne-Hipopne İndeksi (AHİ), uyku esnasında oluşan apne ve hipopnelerin saatlik ortalamasıdır, Solunum Bozukluğu İndeksi (SBI) de denir.

1.5. Uyku Apnesi Esnasında Gözlemlenen ve Kaydedilen Fizyolojik Sinyaller

Uykuda solunum bozukluklarının, özellikle uyku apnesinin teşhisinde PSG altın standart olarak kabul edilmektedir. Gece boyunca kaydedilen PSG ile hastanın uyku esnasındaki sinir sistemi, dolaşım sistemi ve solunum sistemine ait fizyolojik parametreleri elde edilir.

Hastalardan gece boyunca alınan standart PSG parametrelerinden EEG, EOG ve EMG sinyalleri hastanın uyku evrelerinin belirlenmesi ve bu evrelerde oluşabilecek patolojik bulguların değerlendirilmesi, oro-nasal hava akımı ve toraks-abdominal hareket (solunum çabası) sinyalleri uyku apnesinin tespiti, tipinin ve süresinin belirlenmesi, EKG sinyalleri ise uyku apnesi tespiti ve kandaki oksijen saturasyonunu (SpO₂) gösteren pulse oksimetre sinyalleri ise oro-nasal hava akımı ile birlikte hipopnenin tespitinde kullanılmaktadır.

AASM 2007 skorlama kuralları kılavuzuna göre PSG kayıtları için kullanılacak elektrotların empedansının maksimum 5 K Ω , sayısal çözünürlüğünün 12 bit/örnek, örnekleme oranının ise Tablo 1.1’de sunulan biçimde olması önerilmiştir.

Tablo 1.1. PSG örnekleme oranları

Kayıt	Minimum	İstenen
EEG	200 Hz	500 Hz
EOG	200 Hz	500 Hz
EMG	200 Hz	500 Hz
EKG	200 Hz	500 Hz
Hava akımı	25 Hz	100 Hz
Oksijen Satürasyonu	10 Hz	25 Hz
Vücut pozisyonu	1 Hz	1 Hz
Horlama sesi	200 Hz	500 Hz
Toraks ve abdominal hareket	25 Hz	100 Hz


1.5.1. EEG sinyalleri

Kafatası çevresine yerleştirilen elektrotlar kullanılarak, beyin faaliyetleri sırasında kendiliğinden oluşan elektriksel aktivitelerin kaydedilmesine EEG denir [21].

Uyku/uyanıklık, açlık/tokluk, mutluluk/üzüntü, dikkat/dağınıklık vb. farklı fiziksel ve duygusal durumlara bağlı olarak EEG sinyallerinin dalga formları değişiklik göstermektedir [22].


EEG sinyallerinin kaydedilmesinde kullanılacak elektrotların kafatasında hangi bölgelere yerleştirileceği konusunda “10-20” sistemi standart olarak kabul edilmiştir [30]. “10-20” sistemine göre nasion (burun) ile inion (dış oksipal şişlik) arasında mevcut mesafenin yüzde 10, 20, 20, 10 noktalarında kafatasına yerleştirilen elektrot konumlarının soldan ve kafanın üzerinden görünüşü Şekil 1.11’de belirtilmiştir [30].

EEG sinyalleri içerdiği baskın frekans ve genlik bölgelerine göre ayrı adlarla anılan dalgalar Delta, Teta, Alfa, Beta ve Gama olmak üzere beşe ayrılmıştır. Sırasıyla:




Şekil 1.11. EEG'de elektrot yerleşimindeki 10-20 sistemi [30]

Delta dalgaları; 0,5-4 Hz frekans aralığında ve genlikleri 20-400 μ V arasında değişebilen, derin uyku aktiviteleridir [31]. Bir saniyelik delta dalgası örneği Şekil 1.12'de verilmiştir.




Şekil 1.12. Delta dalgası [30]

Teta dalgaları; 4-8 Hz frekans aralığında ve genlikleri 5-100 μ V arasında değişebilen, rüya görülen hafif uyku aktiviteleridir [31]. Bir saniyelik teta dalgası örneği Şekil 1.13'te verilmiştir.




Şekil 1.13. Teta dalgası [30]

Alfa dalgaları; 8-13 Hz frekans aralığında ve genlikleri 2-10 μV arasında değişebilen, gözlerin kapalı olduğu uyanıklık dönemi aktiviteleridir [31]. Bir saniyelik alfa dalgası örneği Şekil 1.14'te verilmiştir.




Şekil 1.14. Alfa dalgası [30]

Beta dalgaları; 13-30 Hz frekans aralığında ve genlikleri 1-5 μV arasında değişebilen, uykunun REM evrelerinde gözlemlenen aktiviteleridir [31]. Bir saniyelik beta dalgası örneği Şekil 1.15'te verilmiştir.



Şekil 1.15. Beta dalgası [30]

Gama dalgaları; 30-100 Hz frekans aralığında olan dalgalarlardır. Bir saniyelik gama dalgası örneği Şekil 1.16'da verilmiştir.




Şekil 1.16. Gama dalgası [30]

1.5.2. EOG sinyalleri

Göz, ışık uyarımından bağımsız olarak kapalı iken veya tamamen karanlıkta belirlenebilen düzgün bir elektriksel potansiyele sahip olup, korneayı pozitif, retinayı negatif kabul eden bir elektriksel dipol modeli ile modellenebilir [21]. Bahsedilen elektrik potansiyelin büyüklüğü 0,4-1 mV aralığında olup retinanın metabolik

hızından elde edilir. Göz hareketlerinin incelenmesinde çok faydalı olan, potansiyel fark ile gözlerin hareketinin bir çift yüzey elektrodu kullanılarak ölçülmesi yöntemine “elektrookülografi”, elde edilen kayda da EOG denir [21, 30]. EEG ve EMG sinyalleri ile beraber uyku evrelerinin belirlenmesinde kullanılır (Şekil 1.1).

Sağ göz kenarına yerleştirilen pozitif ve sol göz kenarlarına yerleştirilen negatif yüzey elektrotları ile gözün her hareketi takip edilerek EOG sinyaline dönüştürülür. Gözün her bir derecelik dönmesine karşılık ölçülen EOG sinyalinin büyüklüğü ise 5-20 $\mu\text{V}/^\circ$ aralığındadır [32]. Gözün sağ tarafa doğru yaptığı dönüş hareketi sonrasında, sağ göz kenarındaki elektrotta pozitif potansiyel fark, ters durumda ise sol göz kenarındaki elektrotta negatif fark ölçülür (Şekil 1.17).



Şekil 1.17. EOG ölçüm yöntemi [30]

1.5.3. EMG sinyalleri

EMG sinyalleri kasların kasılması sonucu oluşan elektriksel aktivitenin iğne tip veya yüzey elektrotlar kullanılarak elde edilen sinyallerdir. EMG sinyalinin 10-5000 Hz aralığında yüksek frekans dağılımına sahip olması nedeniyle ölçümünde kullanılacak cihazların bu aralığa duyarlı olması gerekmektedir [21]. Günümüzde analog-sayısal çeviricilere sahip kayıt sistemleri geçmişte kullanılan optik yöntemlerin yerini almış olup bu sayede kayıtların dijital ortamda saklanabilmesini sağlamıştır [31].

EMG sinyallerinin farklı frekans ve genlik salınımları içermesi nedeniyle hem genlik hem de frekans analizleri yapılabilmektedir [22].

1.5.4. Solunum sinyalleri

Solunum canlıların hayatta kalması için gerekli en önemli öğelerden biridir. İspirasyon (nefes alma) ve ekspirasyon (nefes verme) mekanizmaları solunumu oluşturur. Solunum sisteminin temel görevi havadaki oksijen gazının ispirasyon mekanizması ile alınması ve oluşan karbondioksit gazının ekspirasyon mekanizması ile dışarı atılmasını sağlamaktır.

Solunum karın ile göğüs kafesi altında kalan ve şekli kubbeye benzeyen diyaframın kasılması ile başlar. Diyaframın kasılarak kubbe şeklinden düz bir biçime geçmesi ve bu sayede akciğerin genişlemesi ile ispirasyon gerçekleşir. Bu sırada göğüs kafesi ile abdominal bölgede genişleme olur. İspirasyon mekanizması sayesinde dış ortamda bulunan hava ağız ve burun yoluyla alınır, sırasıyla yutak, gırtlak ve solunum borusundan geçirilir ve akciğere ulaştırılır. Akciğerler içinde bulunan bronş ve bronşçuklardan geçen hava alveollere gelir ve oksijen gazı kana karışır. Kandaki oksijen gazı alyuvarlar sayesinde taşınarak hücrelere iletilir. Hücreler enerji üretimi için oksijen gazını kullanır ve reaksiyon sonucu ortaya çıkan karbondioksit gazı tekrar kandaki alyuvarlara teslim edilir. Bu durumda kirli kan oluşur.

Diyaframın tekrar kubbe biçimini alması ile akciğerlerin hacmi daralır ve içindeki kirli havanın dışarı atılması ile ekspirasyon gerçekleşir. Bu sırada göğüs kafesi ile abdominal bölgede daralma olur. Ekspirasyon mekanizması sayesinde, akciğerlere ulaştırılan kirli kandaki karbondioksit gazı süzülerek vücuttan atılmak üzere soluk borusu, gırtlak ve yutaktan geçirilerek ağız ve burun yoluyla dışarı atılır. Dakikadaki yapılan solunum sayısı yaşla beraber azalma gösterir. Bebeklerde dakikada 30-40 arası solunum gözlenirken çocuklarda dakikada 20-30, yetişkinlerde ise dakikada 15-20 arası solunum gözlenir.

Solunum sinyalleri, ispirasyon ve ekspirasyon esnasında solunum sistemindeki organlarda oluşan ve kaydedilen sinyallerdir. Ağız ve burundan alınan hava akımı buruna takılan nazal kanül veya termistör yoluyla kaydedilir. Termistör, ispirasyon ve ekspirasyon sırasındaki hava akımı sonucunda oluşan ısı farklılığını elektriksel

potansiyele çevirmeye yarar. Termistör ve hava akış algılayıcılarının ağız ve burun bölgesinde kullanılması ile üst solunum yolu sinyalleri elde edilir. Oro-nasal hava akımı sinyali analizi ile uyku apnesinin tespiti yapılır. Şekil 1.18’de termistör örneği verilmiştir.




Şekil 1.18. Termistör [28]

Solunum esnasında toraks ve abdominal bölgenin genişleyip daralma hareketleri üzerinden de solunum sinyalleri elde edilmektedir. Solunum eforunu gösteren bu sinyalleri elde etmek için toraks ve abdominal bölgeye bağlanan, üzerinde uygulanan gerilime paralel olarak elektriksel potansiyel değişimini algılayan sensörler bulunan bantlar kullanılır (Şekil 1.19). Bu sayede toraks ve abdominal solunum sinyalleri elde edilir. Toraks ve abdominal sinyalleri kullanılarak uyku apnesi tipleri belirlenir.




Şekil 1.19. Solunum bantları [28]

Şekil 1.20’de normal solunumlu bir epoktaki solunum sinyalleri sunulmuştur. Solunumun normal olduğu durumda termistörden alınan oro-nasal hava akımı sinyali ile abdominal ve toraks solunum eforlarının da düzenli olduğu gözlemlenmektedir.



Şekil 1.20. Normal durumda solunum sinyalleri

Şekil 1.21’de apne bulunan 200 Hz frekansta örneklenmiş 30 saniyelik bir epoktaki solunum sinyalleri sunulmuştur. Solunumun düzensiz olduğu durumda termistörden alınan oro-nasal hava akımı sinyali ile abdominal ve toraks solunum eforlarının da düzensiz olduğu gözlemlenmektedir.



Şekil 1.21. Apne durumunda solunum sinyalleri

1.5.5. Oksijen satürasyonu

Kandaki oksijen satürasyonu değeri pulse oksimetre cihazı ile ölçülür. Pulse oksimetre cihazı yoğun bakımlarda ve damar cerrahisinde hastaların oksijen satürasyonunun kolay ve ekonomik olarak takibinde tercih edilmektedir [27].

Uyku esnasında tıkanma veya nefes alamama sonucunda kandaki oksijen oranı düşer. Skorlamalarda önemli bir değer olmasına rağmen kandaki oksijen oranının her düşüşü uyku apnesi olarak değerlendirilemez. Hipopne tespiti yapılırken kandaki oksijen oranının en az %4 oranında azalmış olmasına dikkat edilir. Akciğerlerde gaz değişimini ölçmek amacı için oksimetre adı verilen cihazlar kullanılır. Oksimetre cihazı parmak ya da kulak memesine takılarak uygulanır, kullanımı kolay ve güvenilir bir yöntemdir. Şekil 1.22’de pulse oksimetre örneği verilmiştir.




Şekil 1.22. Pulse oksimetreler [28]

1.5.6. EKG sinyalleri

Vücudumuzun doğumdan ölüme kadar hiç durmadan çalışan en çalışkan organı ve dolaşım sisteminin dört bölmeli pompası kalp, kanı akciğerlere ve vücuda kaslarının ritmik kasılması ve gevşemesi yoluyla pompalar. Kalbin kasılma evresi “sistol”, gevşeme evresine de “diyastol” denir. Kanın pompalanması kalp diyastol evresinde karıncıklarının kanla dolması, dolduktan sonra da sistol evresinde kasılması ile gerçekleşir. Kalbin kasının kasılması elektriksel uyarımlarla sağlanır. Kalbin sistol ve diyastol evreleri sırasında ortaya çıkan biyoelektriksel gücün elektrokardiyograf denilen aygıt ile ölçülerek kaydedilmesi yöntemine EKG, özel bir kağıt üzerine kaydedilmesine de elektrokardiyogram denir.


EKG sinyalleri ilk olarak 1903 yılında Willem Einthoven tarafından geliştirilen yay galvanometre ile kaydedilmiştir. EKG sinyalinin ölçülmesi için sağ kol, sol kol ve sol bacağına bağlanan elektrotlar ile ortasında kalbin bulunduğu “Einthoven Üçgeni” adı verilen bir üçgen oluşturulur [21] ve bu elektrotlar ile iki nokta arasındaki potansiyel fark zamana bağlı olarak ölçülür [22]. Şekil 1.23’te insan üzerinde oluşturulan bir Einthoven Üçgeni gösterilmiştir.

Kalbin kasının kasılmasını sağlayan elektriksel uyarımlar tüm kalp kas hücrelerine yayılır. Kalp kası hücrelerinin elektriksel uyarımı ile ilgili üç durum mevcuttur. Depolarizasyon, kalp kası hücrelerinin elektriksel uyarılması durumu iken polarize, kalp hücresinin dinlenme durumudur. Repolarizasyon ise kalp kası hücrelerinin elektriksel uyarılması sonrasında tekrar polarize olmasıdır.



Şekil 1.23. İnsan üzerinde oluşturulan Einthoven Üçgeni [33]

Polarize hücre, dışında pozitif, içinde negatif elektriksel bir yük taşır ve hücre dışındaki pozitif yük ile içindeki negatif yük birbirine eşit olup hücre elektriksel olarak dengededir [34]. Polarize hücrenin elektriksel durumu Şekil 1.24'te gösterilmiştir.




Şekil 1.24. Polarize hücrenin elektriksel durumu

Kalp kası hücresi uyarılmasıyla beraber depolarize olmaya başlar ve öncelikle elektriksel uyarımın gerçekleştiği yerde hücre içi negatiften pozitive geçerken dışı da negatifleşir. Hücre uyarılmış negatif yüklü dış yüzeyi ile uyarılmamış bölümdeki pozitif yüklü dış yüzeyi arasında küçük bir elektriksel akım oluşur. Oluşan akım hücre boyunca yayılarak tüm hücre depolarize oluncaya (dışı negatif, içi pozitif) kadar devam eder [34].

Elektriksel uyarım hücreden hücreye domino etkisi ile geçer ve bir süre sonra tam depolarize olmuş hücre repolarize olur. Hücrenin dışında küçük bir alan yeniden

pozitif'e döner ve repolarizasyon tüm hücre boyunca yayılarak hücreyi tamamen tekrar polarize duruma dönüştürür [34]. Polarize hücrenin uyarılması, depolarize ve repolarize oluşu Şekil 1.25'te gösterilmiştir.




Şekil 1.25. a) Uyarılan hücre, b) Tam depolarize hücre ve c) Repolarize hücre

Normal bir sinüs ritmini gösteren EKG sinyali örneği Şekil 1.26'da verilmiştir. Normal bir EKG sinyali P dalgası, PR aralığı, QRS kompleksi, J noktası, ST segmenti, T dalgası ve U dalgasından oluşur.

P dalgası (atrium depolarizasyonu); sinüs düğümünden çıkan uyarının kalbin sağ ve sol kulakçıklarına (atrium) yayılmasını gösteren, 0,1 saniye kadar süren dalgadır.

PR aralığı; P dalgasından başlayarak QRS kompleksine kadar geçen, normal bir insanda 0,12-0,2 saniye kadar süren, sinüsten çıkan uyarının kalp kulakçıklarından yayılarak kalp karıncıklarına (ventrikül) iletimini diğer bir deyişle kulakçıkların kasılmasından karıncıkların kasılmasına kadar geçen süreyi gösterir.



Şekil 1.26. EKG sinyali [35]

QRS kompleksi (ventrikül depolarizasyonu); depolarizasyonun kalp karıncıklarına yayılması sonucu oluşur, 0,08 saniye kadar sürer ve Q-R-S dalgalarından meydana gelir. QRS kompleksi EKG sinyalinin ortasında bulunur ve sinyalin en belirgin parçasını oluşturan karakteristik dalga setidir. QRS kompleksi içerisinde bulunan R dalgası tepesi, ventrikül depolarizasyonu ile atrium repolarizasyonuna denk gelir. Ardışık iki R tepesi arasında geçen süre RR aralığı olarak tanımlanır ve kalbin atım hızının hesaplanmasında kullanılır.

ST segmenti; QRS kompleksi sonundan T dalgası başlangıcına kadar sürer. QRS ile T dalgasının birleştiği noktaya J noktası denir. Uyarılan kalp karıncıklarının rahatlama haline geçişini gösterir.

T dalgası (ventrikül repolarizasyonu); kalp karıncıklarının repolarizasyonunu gösterir ve 0,2 saniye kadar sürer.

U dalgası; kalp karıncıklarının repolarizasyonunu sonrasında görülebilir, karıncık kasındaki geç repolarizasyonu temsil eder fakat her zaman görülmeyebilir.

Bir dakika içindeki R dalgaları sayısı üzerinden dakikalık kalp atım hızı yani nabız hesaplanabilir. Ardışık iki R tepesi arasında geçen sürenin hesaplanması ile de anlık KAHD elde edilir. KAHD Bölüm 2.4.1’de detaylı olarak açıklanmıştır.

1.6. Apne ve EKG İlişkisi

Özellikle uyku apnesi sendromu bulunan hastalarda gece uyku esnasında oluşan apnelerin sık tekrarlaması kalp atımında değişimlere sebep olur.

Apnenin ilk döneminde kalbin normalden yavaş atması (bradikardi) oluşurken, apne sonrasında ise kalbin normalden hızlı atması (taşikardi) oluşur ve apneden kaynaklı olarak kalp atım hızındaki değişim KAHD sinyali ile gözlemlenebilir [36]. Bu nedenle apne kaynaklı ritim değişikliklerinin EKG kayıtlarından gözlemlenmesinde KAHD analizi kullanılan bir yöntemdir.


KAHD dışında EKG üzerinden gözlemlenebilecek diğer bir olgu ise apne nedeniyle oluşan R dalgalarındaki genlik değişimidir. Vücut yüzeyinden elde edilen EKG sinyali, solunum döngüsü boyunca elektrotun kalbe göre nispi hareketi ve akciğerlerin hava ile dolup boşalmasından kaynaklı göğsün elektrik empedans değişimlerinden etkilenir [16]. Bahse konu etki EKG sinyalinde solunum döngü frekansı ile aynı frekansta genlik modülasyonu oluşturur [23].

Solunumun EKG sinyali genliğine etkisinden yararlanarak EKG sinyali üzerinden çeşitli yöntemlerle [37] elde edilen ve solunumu dolaylı olarak gösteren sinyale EKG'den Türetilmiş Solunum (ETS) sinyali adı verilir. Şekil 1.27'de 200 Hz'de örneklenmiş 20 saniyelik EKG sinyali ve bu sinyalden türetilmiş ETS sinyalinin nazal ve toraks solunum sinyalleri ile ilişkisi sunulmuştur.

1.7. Yumuşak Hesaplama

Yumuşak hesaplama (soft computing) bulanık mantığın kurucusu Lotfi A. Zadeh tarafından önerilmiş olup temeli, insan zekâsının bilişsel yaklaşım modelini oluşturmaktır [38]. Sayısal zekâyâ ve belirli alanlarda bir insan kadar uzmanlığa sahip, analiz çevresini değiştirebilen ve daha iyi sonuç üretmek için öğrenebilen, kararlarını açıklayabilen sistemler tasarlamaya yönelik bir yaklaşımdır [38].

Sonuçları tahmin edilemeyen, 0 ile 1 arasında değişebilen ve kesin olmayan problemlerin analizi ile çözümünde kullanılır. Bulanık mantık, sinirsel programlama ve olasılık teoremlerine dayanan yumuşak hesaplama; sağlamlık, kolay işlenebilirlik ve düşük çözüm maliyetleri elde etmek için belirsizlik ve kararsızlıkların toleransından yararlanan çeşitli yöntemlerin toplamıdır [38, 39].



Şekil 1.27. Hastaya ait 20 saniyelik ETS sinyali ve solunum sinyalleri

Çok parametrelili ve çok değişkenli, geleneksel hesaplama yöntemleri ile hesaplanması güç olan gerçek dünya problemlerinin analizi ile çözümünde yumuşak hesaplama yöntemleri kullanılmaktadır.

Yumuşak hesaplama yöntemleri interpolasyon, regresyon ve kestirme gibi sayısal analiz tekniklerini kullanarak karmaşık problemlere sade çözümler sunabilmektedir.

Geleneksel analitik yöntemler ile karmaşık problemlerin çözümü ve analizi yoğun işlem maliyetine neden olup doğrusal olmayan ilişkilerin modellenmesi ise çok zordur. Yumuşak hesaplama yöntemleri için doğrusal olmayan ilişkilerin modellenmesi daha kolay, işlem maliyeti ise düşüktür.

Günümüze kadar birçok farklı alanda başarıyla uygulanan yumuşak hesaplama yöntemleri, katı hesaplama yöntemlerinin yetersiz veya maliyetli kaldığı problemlerinin çözümü için tercih edilen bir alternatif olmuştur.

Kesin sonuçlar elde etmek için hassas modelleme ve analiz kavramlarına dayanan, basit problemlerde iyi olsa da çözümün kesişim kümesinde sınırlı olduğu [38] katı hesaplama ile yumuşak hesaplama arasındaki karşılaştırma tablosu Tablo 1.2'de sunulmuştur.

Tablo 1.2. Katı hesaplama ile yumuşak hesaplamının karşılaştırılması [38]

Katı Hesaplama	Yumuşak Hesaplama
Geleneksel hesaplama yöntemidir ve kesin olarak tasarlanmış model gerekir.	Kesinlik gerektirmeyen modellemelere karşı toleranslıdır.
Genellikle çok uzun hesaplama süresi gerekir.	Daha kısa sürelerde sonuç üretir.
İdeal model tasarlanamayan gerçek dünya problemleri için uygun değildir.	Uygundur.
Tam doğruluk gerektirir.	Kısmi doğrulukla çalışabilir.
Kesin ve tam doğrudur.	Kesin değildir.
Sonuç için yüksek maliyet gerektirir.	Düşük maliyet.

Yumuşak hesaplama genel olarak sinir ağları, destek vektör makineleri, k en yakın komşu algoritması, evrimsel hesaplama yöntemleri (genetik algoritma, koloni zekâsı vb.), bulanık mantık, bayesiyen ağlar ve makine öğrenme algoritmaları bileşenlerinden oluşur.

1.8. Örüntü Tanıma Sistemi

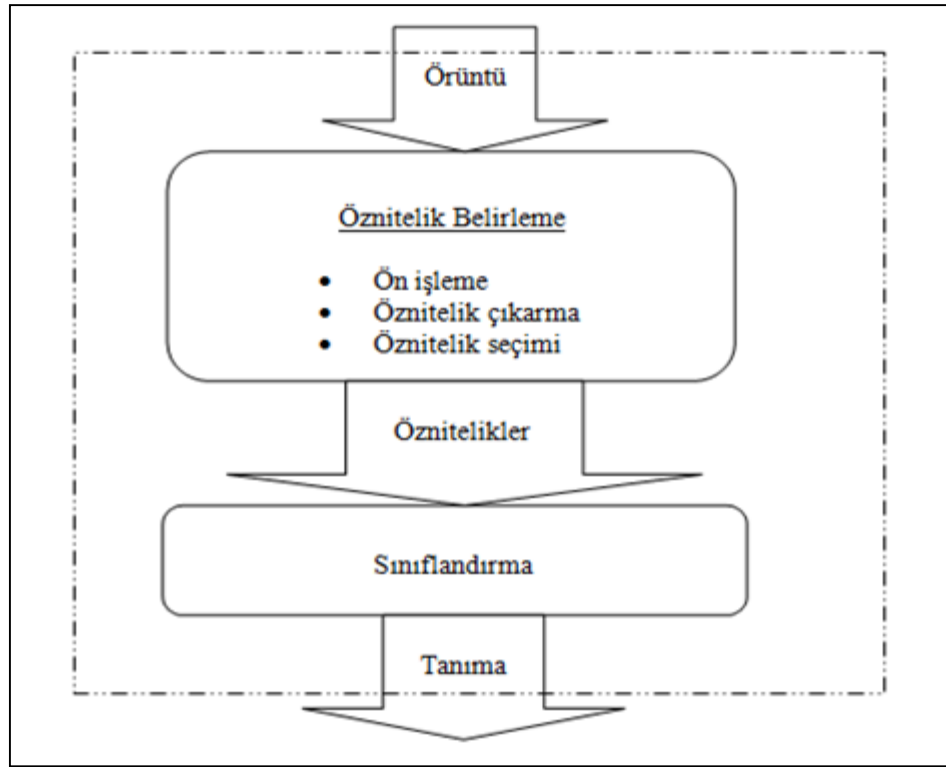
Örüntü, ardışık olarak düzenli bir şekilde gelişen nesnelere ya da olayların oluşturduğu ortak yapısı veya benzerlikleri olan veri kümesidir. Örüntünün ölçülebilir veya gözlemlenebilir olması gerçek dünyada örüntü olarak tanımlanan olayların analizini mümkün kılar. Gerçek dünyada elde edilen örüntülere fizyolojik sinyaller (EEG, EKG, solunum vb.), parmak izi, retina, insan yüzü, ses sinyali ve metin içinde geçen karakterler örnek olarak verilebilir [40].

Örüntü tanıma, bilinen bir sınıfa ait olan örüntüyü teşhis etmek veya bilinmeyen örüntü sınıflarına belirli bir şekil vermek amacıyla aralarında ilişki kurulabilen, ortak

özelliik veya benzerlik bulunan karmaşık verileri veya nesneleri tespit edilmiş karakterler veya özellikler yardımıyla tanımlama veya sınıflandırmadır [41].

Günümüzde birçok farklı alanda kullanılan örüntü tanımlama sistemleri ağırlıklı olarak parmak izi, retina, yüz ve ses tanıma, sismik hareketlerin incelemesi ve deprem tahmini ve fizyolojik sinyallerin analizi alanlarında kullanılmaktadır.

Çeşitli alanlarda uygulanmakta olan örüntü tanıma makine öğrenmesi, ayırım analizi, örüntü sınıflandırma ve nitelik tahmini gibi farklı isimlerle de anılmaktadır [23]. Örüntü tanıma sistemi süreçleri Şekil 1.28’de sunulmuştur.



Şekil 1.28. Örüntü tanıma sistemi

Genel olarak örüntü tanıma sistemleri özellik belirleme ve sınıflandırma olarak iki temel süreçten oluşur. Özellik belirleme sürecinde, analiz edilecek olan veri çeşitli yöntemlerle işlenir ve örüntüyü karakterize edecek özellikler hesaplanarak özellik vektörleri oluşturulur.

Sınıflandırma sürecinde ise, sınıflandırmada kullanılmasına karar verilen özellikler bir karar verme mekanizmasına (sınıflandırıcıya) beslenerek işlenen özellik vektörünün içerdiği örüntünün ait olduğu sınıf tespit edilir.

1.8.1. Öznitelik belirleme

Öznitelik belirleme sürecinin amacı çevreden algılanan yüksek boyutlu ham örüntüyü karakterize edebilen, ölçülebilir, kararlı ve olabildiğince küçük boyutlu bilgi elde etmektir [23]. Söz konusu özellikteki bilginin elde edilebilmesi için çeşitli dönüşüm yöntemleri ile istatistiksel hesaplama, doğrusal olmayan hesaplama gibi çok çeşitli hesaplama yöntemleri kullanılmaktadır. Kullanılan farklı yöntemler sonrasında örüntüyü temsil edecek olan ve ham veriden elde edilen bilgiye öznitelik vektörü denir. Öznitelik belirleme süreci ön işleme, öznitelik çıkarma ve öznitelik seçimi olmak üzere üç aşamadan oluşur.

Ön işleme; işlenecek olan ham verinin özelliğine göre çeşitli ön işlem/işlemlerden geçirildiği aşamadır. Bu aşamada veri gereksinime göre filtrelenebilir, bölütlere ayrılabilir, bileşenlere ayrılabilir veya modellenenebilir [40].

Öznitelik çıkarma; ön işleme aşaması sonrasında örüntünün önemli özniteliklerinin çıkarılarak öznitelik vektörünün elde edilmesi ve bu sayede örüntünün daha küçük boyutta temsil edilmesinin sağlandığı aşamadır. Örüntü tanıma sisteminin en önemli aşamalarından biri olup çıkartılan özelliklerin mümkün olduğunca az sayıda ve ayırt edici olması, daha yüksek hassasiyet ve kısa sürede gerçekleştirilmesini sağlar [23].

Öznitelik seçimi; belirlenen özniteliklerin bazılarının ilgisiz bazılarının da ilintili olduğu özniteliklerin bulunması nedeniyle fazlalık olması durumunda sınıflandırıcının performansı olumsuz biçimde etkilenmektedir. Sınıflandırmada harcanan zamanın uzamasının yanında sınıflandırıcının genelleme ve ayrıştırma özelliğinin azalmasıyla gittikçe artan isabetsizlik oranı ve hatalı sınıflandırma gibi sorunlar oluşabilmektedir. Öznitelik seçiminde amaç öznitelik çıkarma aşamasından sonra oluşturulan öznitelik vektöründen çeşitli yöntemler yardımıyla ilgisiz ve fazlalık özniteliklerin ayıklanarak en belirleyici özniteliklerden oluşan öznitelik alt kümesini seçmek ve öznitelik vektörünün boyutunu indirgemektir.

1.8.2. Sınıflandırma

Örüntü tanıma sistemlerinin son adımı ise sınıflandırmadır. Sınıflandırma, giriş olarak kullanılan öznitelik vektörlerinin hangi sınıfa ait olduğunun bir karar verme mekanizması (sınıflandırıcı) yardımıyla belirlenmesidir. Sınıflandırma süreci

sınıflandırıcının eğitilmesi ve özellik vektörünün hangi sınıfa ait olduğuna karar verilmesi şeklinde iki aşamadan oluşur. Sınıflandırıcılarda öğrenme kullanılan algoritmanın özelliğine göre denetimli öğrenme (supervised learning) ve denetimsiz öğrenme (unsupervised learning) olarak ikiye ayrılır. Denetimli öğrenmede sınıflandırıcıyı eğitme aşamasında işlenen öznitelik vektörünün ait olduğu sınıf bilgisinin sınıflandırıcıya verilmesiyle örüntü sınıfları ile öznitelikler arasında bir model oluşturulması sağlanır. Denetimsiz öğrenmede ise eğitim aşamasında öznitelik vektörünün ait olduğu sınıf bilgisi sınıflandırıcıya verilmez, bunun yerine sadece ilgilenilen örüntülerin belirlenmiş özellikleri gösterilerek bunlar arasındaki uzaklık, benzerlik gibi fonksiyonlar üzerinden bir model oluşturulur [23].

Sınıflandırıcının performansının artırılması amacıyla sınıflandırıcının optimizasyonunun yapılması da önemli bir husustur. Kullanılacak olan sınıflandırıcının varsayılan parametrelerle çalıştırılması yerine optimize parametrelerin hesaplanması ve hesaplanan parametreler ile sınıflandırıcının çalıştırılması örüntü tanıma sisteminin performansını olumlu yönde etkileyebilir.

1.9. Sınıflandırmada Kullanılan Yöntemler

Tez çalışması kapsamında EKG'den elde edilen KAHD ve ETS sinyalleri her bir epok bir dakika olacak biçimde bölütlenmiş, zaman ve frekans uzayında analizleri yapılmış ve sınıflandırmada kullanılacak öznitelikleri belirlenmiştir. Sınıflandırmada denetimli öğrenmeye dayalı 4 farklı sınıflandırıcı kullanılmıştır. Sınıflandırıcılar, eğitim veritabanındaki hasta sinyallerinden elde edilen veri seti ile eğitilmiş, eğitilen modeller daha sonra test veritabanından elde edilen test veri seti ile sınıflandırılarak test edilmiştir. Tez çalışmasında sınıflandırıcı olarak K en yakın komşu algoritması, çok katmanlı almaç, destek vektör makineleri ve C4.5 karar ağacı yöntemleri kullanılmıştır.

1.9.1. K en yakın komşu algoritması (k-nearest neighbor, kNN)

Parametrik olmayan ve denetimli öğrenmeye dayalı bir sınıflandırıcı olan kNN, sınıflandırma becerisinin yüksek olması nedeniyle makine öğrenmesi algoritmaları arasında önemli bir yer tutmakta ve birçok bilim ve mühendislik uygulamasında tercih edilmektedir. Eğitim veri setinin istatistiksel dağılımından bağımsızdır.

Gürültülü veri setlerine karşı dirençli olup eğitim veri setinin sayısının fazlalığı ile etkinliği artar.

Sadece k (karşılaştırılacak komşu sayısı) değerinin parametre olarak belirlenmesinin yeterli olması nedeniyle k NN uygulaması kolay bir sınıflandırıcıdır. Hesaplama tüm komşular yerine sadece k adet yakın komşunun dikkate alınması ve hesaplanmayı sınıflandırmaya kadar bekletmesi sebebiyle ayrıca tembel öğrenme algoritmasıdır. Sınıflandırma basitçe yeni gelen öznitelik vektörünün eğitim veri setindeki k adet en yakın komşusunun ağırlıklı olduğu sınıfa atanmasıyla gerçekleşir.

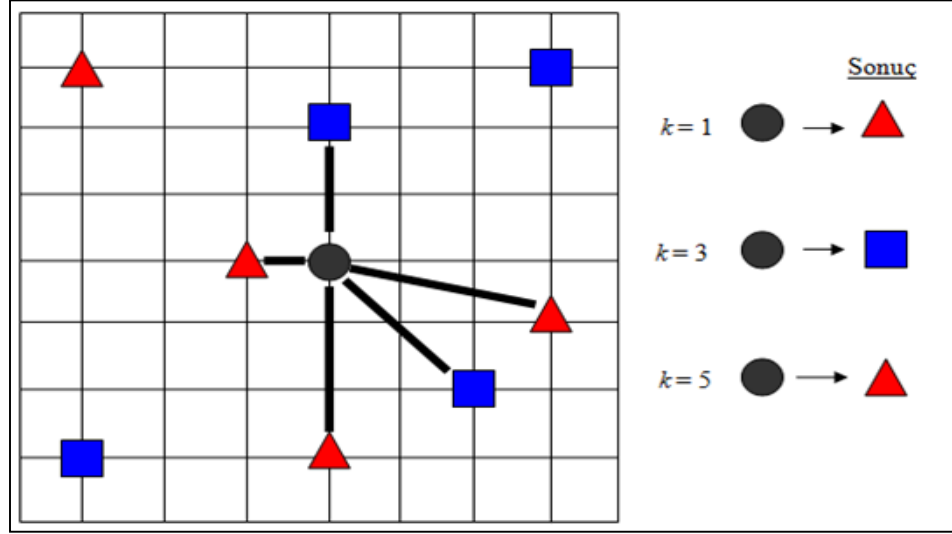
Sınıflandırıcının temel işleyiş adımları; k parametresinin belirlenmesi, eğitim veri setindeki tüm örneklerle olan uzaklığın hesaplanması, en az uzaklıktan itibaren sıralama ve en yakın örneklerin ait olduğu sınıf değerlerine bakılarak ağırlıklı olan sınıfa atanmasıdır.

Algoritmanın başarısı örnekler arasındaki uzaklığının iyi hesaplanmasına bağlı olup Öklid mesafesi (Euclidean distance), Minkowski ve Tanimoto uzaklık ölçüm metotları sıkça kullanılmaktadır. Öklid mesafesi ek sık kullanılan uzaklık ölçüm metodu olup bu tez çalışmasında da tercih edilmiştir. Öklid mesafesi Eşitlik (1.1)'de;

$$d_j(a, b) = \sqrt{\sum_{i=1}^n (a_i - b_{ij})^2} \quad (1.1)$$

sunulmuştur. Eşitlik (1.1)'de $d_j(a, b)$ öznitelik vektörü ile j .inci örnek arasındaki Öklid mesafesi, n öznitelik sayısı, a_i sınıflandırılacak olan öznitelik vektörü, b_{ij} ise j 'inci örneğin öznitelik vektörüdür.

Kullanıcı tarafından belirlenen k parametresi tam sayıdır. İki sınıflı (binary) bir sınıflandırıcı için k parametresinin tek sayı seçilmesi k adet en yakın komşunun çoğunluk oyuna göre sınıfın belirlenmesi aşamasında eşit sayıda iki sınıfla karşılaşılması sorununu engellemesi açısından önemlidir. Tek boyutlu bir özneliğin vektörünün ikili sınıflı bir sınıflandırıcı (birinci sınıf üçgen, ikinci sınıf kare) için k parametresinin 1, 3 ve 5 seçildiği durumlarda (1NN, 3NN ve 5NN) en yakın komşuların çoğunluk oyuna göre atandığı sınıf Şekil 1.29'da gösterilmiştir.



Şekil 1.29. Farklı k parametreleri için kNN davranışı

Birinci durumda $k=1$ seçilerek oluşturulan sınıflandırıcı ile yapılan sınıflandırma sonrasında test edilen öznitelik vektörünün en yakın komşusu üçgen sınıfına ait olduğundan atanma üçgen sınıfına yapılacaktır.

İkinci durumda $k=3$ seçilerek oluşturulan sınıflandırıcı ile yapılan sınıflandırma sonrasında test edilen öznitelik vektörünün en yakın 3 komşusu tarafından yapılacak oylama sonucunda (2'ye karşı 1 oyla) atanma kare sınıfına yapılacaktır.

Üçüncü durumda $k=5$ seçilerek oluşturulan sınıflandırıcı ile yapılan sınıflandırma sonrasında test edilen öznitelik vektörünün en yakın 5 komşusu tarafından yapılacak oylama sonucunda (3'e karşı 2 oyla) atanma üçgen sınıfına yapılacaktır.

Sınıflandırma öncesinde en uygun k parametresinin belirlenmesi amacıyla eğitim veri seti kullanılarak yapılan öznitelik seçimi sonrasında belirlenen öznitelik alt kümesinin en etkin öznitelikleri farklı k değerleri ile çalıştırılmış ve en uygun k değeri tespit edilerek sınıflandırıcıda kullanılması sağlanmıştır.

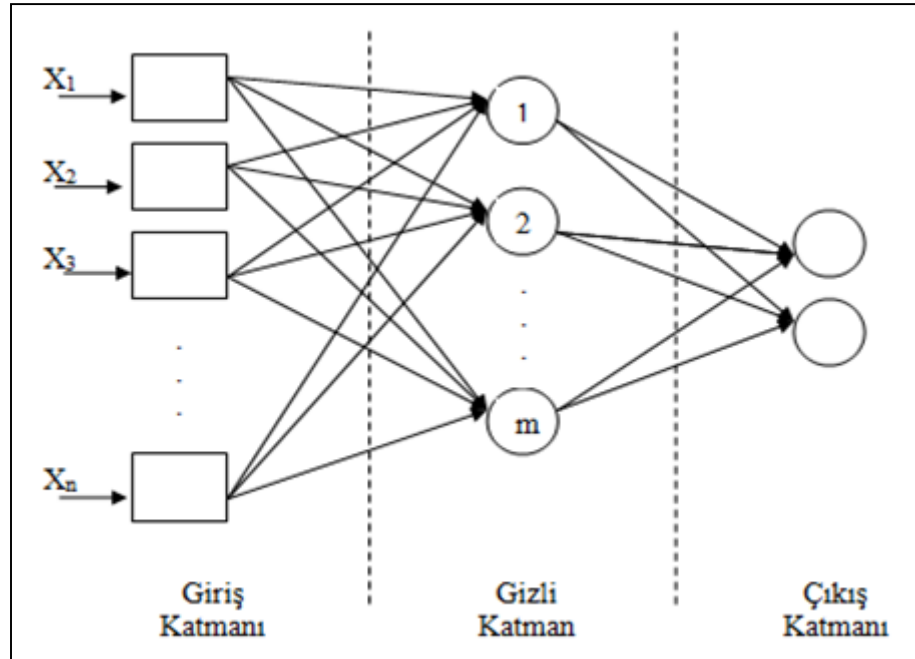
1.9.2. Çok katmanlı almaç (multi layer perceptron, MLP)

MLP yaygın olarak kullanılan denetimli öğrenmeye dayalı ileri beslemeli yapay sinir ağı (Feed Forward Neural Network, FFNN) çeşididir. Doğrusal olarak ayıramayan verileri ayırt edebilir ve karmaşık fonksiyonları modelleyebilir. Ayrıca ilgisiz girişleri ve gürültüyü görmezden gelmede başarılıdır.

MLP ağını eğitmek için farklı denetimli öğrenme teknikleri uygulansa da en çok geri yansıtma (backpropagation) tekniğini kullanmaktadır. Geri yansıtma tekniğinde hesaplanan çıkış değerleri beklenen çıkış değerleri ile karşılaştırılır ve hata değeri hesaplanır. Daha sonra hesaplanan hata değeri katman katman hücrelere iletilerek çıkıştaki hata değerini minimize edecek şekilde ağırlıklarının tekrar hesaplanmasında kullanılır.

MLP sinir hücrelerinden oluşan çok katmanlı bir YSA yapısına sahiptir. Giriş katmanındakiler dışında her sinir hücresine doğrusal olmayan bir aktivasyon fonksiyonuna sahip bir nörondur. MLP'nin en yaygın türünde her biri bir sonraki katmana tam bağlı bir giriş katmanı, bir gizli katman ve bir de çıkış katmanı bulunmaktadır. Veri sadece ileri yönde olmak üzere giriş katmanından gizli katmana, daha sonra gizli katmandan çıkış katmanına iletilir.

Şekil 1.30'da n girişli, gizli katmanında m sinir hücresi olan iki çıkışlı bir MLP örneği sunulmuştur.




Şekil 1.30. n girişli, bir gizli katmanlı ve iki çıkışlı bir MLP örneği

YSA uygulamalarında en çok kullanılan iki aktivasyon fonksiyonu log-sigmoid (lojistik sigmoid fonksiyonu) ve tan-sigmoid (hiperbolik tanjant fonksiyonu) olup tanımlamaları sırasıyla Eşitlik (1.2) ve (1.3)'te;

$$y(v_i) = (1 + e^{-v_i})^{-1} \quad (1.2)$$

$$y(v_i) = \tanh(v_i) \quad (1.3)$$

sunulmuştur. Eşitliklerdeki v_i değeri hücreye gelen net girişi, $y(v_i)$ değeri ise i'inci hücrenin çıkış değerini göstermektedir. Log-sigmoid fonksiyonu 0 ile 1 arasında, tan-sigmoid fonksiyonu -1 ile 1 değer aralığındadır. Şekil 1.31'de log-sigmoid ve tan-sigmoid fonksiyonlarına ait grafikler sunulmuştur.



Şekil 1.31. Aktivasyon fonksiyonları (a) log-sigmoid, (b) tan-sigmoid

MLP optimizasyonu gizli katmandaki hücre sayılarının uygun değerinin hesaplanması ile sağlanmıştır. Bu kapsamda eğitim veri seti kullanılarak yapılan öznetelik seçimi sonrasında belirlenen öznetelik alt kümesinin en etkin öznetelikleri farklı hücre sayıları ile çalıştırılmış ve en uygun değeri tespit edilerek sınıflandırıcıda kullanılması sağlanmıştır.

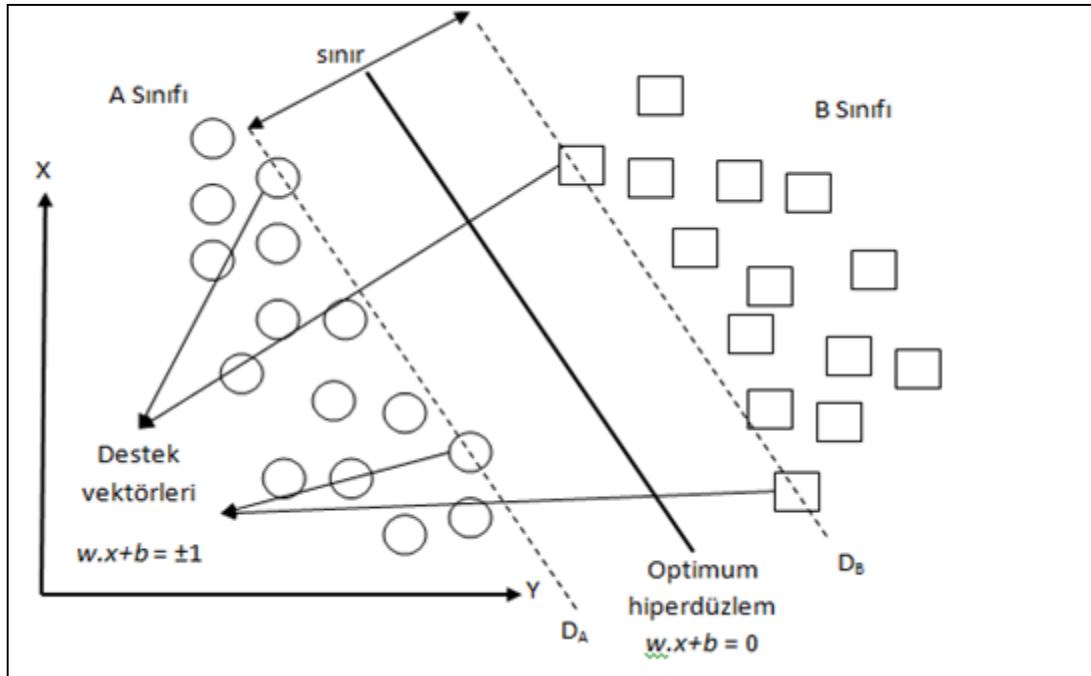
1.9.3. Destek vektör makineleri (support vector machines, SVM)

SVM, Vapnik [42] tarafından 1995'te geliştirilen ve sınıflandırma problemlerinin çözümünde etkili, öğrenmeye dayalı iki sınıflı (binary) doğrusal sınıflandırma metodudur. Temel olarak SVM, N-boyutlu giriş vektörü x 'in, K-boyutlu ($K > N$) öznetelik uzayına, doğrusal olmayan $\phi(x)$ fonksiyonu ile eşleştirilmesiyle elde edilen yüksek boyutlu öznetelik uzayında uygulanan doğrusal makine çalışmasıdır [43]. Tanımlamadan anlaşılacağı gibi SVM, giriş vektörünü daha yüksek boyutlu bir uzaya doğrusal olmayan biçimde taşıyan bir dönüşümdür [23]. Giriş vektörünün daha yüksek boyutlu bir uzaya taşınması sınıflandırma için verinin doğrusal olarak ayrışabilmesini sağlamaktadır. N-boyutlu uzayda iki farklı sınıfı birbirinden ayıran hiperdüzlem (hyperplane) eşitliği Eşitlik (1.4)'te;

$$y(x) = w^T \varphi(x) + b = \sum_{j=1}^K w_j \varphi_j(x) + b \quad (1.4)$$

sunulmuştur. Eşitlikte $\varphi(x) = [\varphi_1(x), \varphi_2(x), \dots, \varphi_K(x)]^T$, w ağırlık vektörü $w = [w_1, w_2, \dots, w_K]^T$ ve b bias değeridir. SVM algoritması olası ayırıcı hiperdüzlemler arasından $y_i \in \{-1, +1\}$ etiketli iki farklı sınıfı birbirinden en iyi ayıran optimal ayırıcı düzlemi belirlemeye çalışır.

Şekil 1.32'de $w^T x_i + b = -1$ eşitliğini sağlayan A sınıfını ayıran D_A düzlemini, $w^T x_i + b = +1$ eşitliği ise B sınıfını ayıran D_B düzlemini gösterir.



Şekil 1.32. SVM sınıflandırıcısı ve destek vektörler

Şekil 1.32'den anlaşılacağı gibi $w^T x_i + b \leq -1$ durumunda giriş vektörü A sınıfına, $w^T x_i + b \geq 1$ durumunda ise B sınıfına atanır.

SVM'de öğrenme ve test süreçlerinde tüm matematiksel işlemler çekirdek (kernel) fonksiyonları $K(x_i, x)$ ile gerçekleştirilir. Çekirdek fonksiyon $\varphi(x)$ vektörünün iç ürünü olarak tanımlanmakta olup Eşitlik (1.5)'te;

$$K(x_i, x) = \varphi(x_i)^T \varphi(x) \quad (1.5)$$

sunulmuştur. Yaygın olarak kullanılan dört çekirdek fonksiyonu Tablo 1.3'te sunulmuştur.

Tablo 1.3. SVM çekirdek fonksiyonları

Çekirdek fonksiyon	Matematiksel Eşitlik
Doğrusal fonksiyon	$K(x_i, x_j) = x_i^T x_j$
Polinom fonksiyonu	$K(x_i, x_j) = (x_i^T x_j + 1)^d$, d polinom derecesidir
Sigmoid fonksiyonu	$K(x_i, x_j) = \tanh(\kappa x_i x_j + c)$, $\kappa > 0$ ve $c < 0$
Radyal tabanlı fonksiyon (RBF)	$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right)$, σ RBF fonksiyonunun genişliğidir. Fonksiyon, $\gamma = \frac{1}{2\sigma^2}$ ifadesiyle parametrik yapılabilir. (γ : gamma)

Bir SVM'deki öğrenme problemi, azami ayırım sınırını (margin) sağlayan ve eğitim veri setindeki öznitelik vektörlerini iki farklı sınıfa ayırma olarak formüle edilir ve α_i Lagrange çarpanlarına bağlı olarak optimize edilebilecek ikincil (dual) optimizasyon problemi ve belirtilen kısıtlamalar paralelinde ikinci dereceden (karesel) fonksiyona Eşitlik (1.6);

$$Q(\alpha) = \sum_{i=1}^p \alpha_i - \frac{1}{2} \sum_{i=1}^p \sum_{j=1}^p \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (1.6)$$

dönüştürülür [23, 43]. Kısıtlamalar Eşitlik (1.7)'deki gibi;

$$\sum_{i=1}^p \alpha_i y_i = 0 \quad \text{ve} \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, p \quad (1.7)$$

biçimindedir. Eşitlik (1.6) ve (1.7)'de belirtilen α_i Lagrange çarpanları, C kullanıcı tarafından tanımlanan düzenleme sabitini, p ise eğitimde kullanılan (x_i, y_i) veri çiftlerinin sayısıdır. Lagrange çarpanları yardımıyla çözülen ikincil optimizasyon problemi ile verilen SVM'in optimal ağırlık vektörü w_{opt} Eşitlik (1.8)'deki gibi;

$$w_{opt} = \sum_{i=1}^{N_{sv}} \alpha_i y_i \phi(x_i) \quad (1.8)$$

hesaplanabilir [43]. Yukarıdaki eşitlikteki N_{sv} değeri destek vektörlerin sayısıdır. Eşitlik (1.7)'de yer değiştirilirse SVM'nin çıkış sinyali $y(x)$ ifadesi kernel fonksiyonları ile Eşitlik (1.9)'de;

$$y(x) = \sum_{i=1}^{N_{sv}} \alpha_i y_i K(x_i, x) + b \quad (1.9)$$

biçiminde ifade edilebilir [43]. SVM'nin çıkış sinyali $y(x)$ fonksiyonun pozitif değerli çıkışı giriş vektörünün +1 olarak etiketlenen sınıfa, negatif çıkış ise -1 olarak etiketlenen diğer sınıfa atanmasını sağlar.

Tez çalışmasında SVM sınıflandırıcıda RBF kernel kullanılmıştır. Bu kapsamda SVM optimizasyonu düzenleme sabiti C ile RBF fonksiyonunun genişliği ile (γ) sağlanmıştır. Bu kapsamda eğitim veri seti kullanılarak yapılan öznelik seçimi sonrasında belirlenen öznelik alt kümesinin en etkin öznelikleri farklı C (0,1, 0,5, 1, 5 ve 10) ve γ (0,1, 0,5 ve 1) değerleri ile çalıştırılmış ve en uygun değerler tespit edilerek sınıflandırıcıda kullanılması sağlanmıştır.

1.9.4. C4.5 karar ağacı (C4.5 decision tree, C4.5)

C4.5 yaygın olarak kullanılan, denetimli öğrenmeye dayalı ve sonucu karar ağacı ile temsil eden bir algoritmadır. C4.5 karar ağacı çok hızlı çalışan ve uygulaması kolay bir sınıflandırıcıdır, verinin normalizasyon gibi ön işlemden geçirilmesine gereksinimi yoktur. C4.5 ayrık değerli fonksiyonları kestirmede ve gürültülü veriyi işlemede başarılı olup sayısal ve kategorik veri ile çalışabilir.

C4.5 karar ağacı ID3 ağacının gelişmiş versiyonudur. ID3 ağacında hesaplama, bilgi kazanımına (information gain) göre yapılarak karar noktaları tespit edilirken C4.5 ağacında bilgi kazanımları birer oran olarak tutulur [44]. Diğer bir fark ise C4.5 karar ağacında budama (prunning) adı verilen daha önce yaratılmış gereksiz dalları keserek yerine yaprak düğümleri oluşturma işleminin kullanılmasıdır.

C4.5 daha önceden hangi sınıfa ait olduğu bilinen eğitim verisi üzerinden bir karar ağacı oluşturmaktadır. Oluşturulan karar ağacı karar düğümleri ile yaprak düğümlerinden oluşur. Karar düğümü öznitelik üzerinde uygulanacak testi belirlerken yaprak düğümü de atanacak sınıfı belirlemektedir. C4.5 normalize edilmiş bilgi kazanımı en yüksek özniteliği seçerek, veriyi alt listelere yinelemeli olarak bölecek şekilde çalışmaktadır.

C4.5 karar ağacının oluşturulmasındaki adımlar; her adımda öznitelik vektöründeki tüm öznitelikler kontrol edilir, her öznitelik için normalize edilmiş bilgi kazanımı hesaplanır, normalize edilmiş bilgi kazanımı en iyi olan öznitelik belirlenir, belirlenen öznitelik için karar düğümü oluşturulur ve karar düğümü ayırımından elde edilen alt listeler için tekrar edilerek oluşturulan karar düğümünün altına çocuk düğümler olarak eklenir şeklinde özetlenebilir.

Eğitim veri setine göre karar ağacı oluşturulduktan sonra test veri seti üzerinden sınıflandırma yapılır. Öznitelik vektörü sınıflandırıcıya gönderildikten sonra kökten başlayıp yaprak düğüme ulaşmaya kadar ulaşılan her karar düğümünde seçilmiş öznitelik ile test edilir ve kullanılacak dala karar verilir. Yaprak düğüme ulaşıncaya kadar ulaşılan her karar düğümünde seçilmiş öznitelik ile test edilir ve kullanılacak dala karar verilir. Yaprak düğüme ulaşıncaya kadar ulaşılan her karar düğümünde seçilmiş öznitelik ile test edilir ve kullanılacak dala karar verilir. Yaprak düğüme ulaşıncaya kadar ulaşılan her karar düğümünde seçilmiş öznitelik ile test edilir ve kullanılacak dala karar verilir.

2. KAPSAM ve YÖNTEM

Bu bölümde, tez çalışmasında kullanılan hasta kayıtları, kayıtların analizi ile kullanılan yöntemler ve EKG sinyalinde elde edilen KAHD ile ETS sinyalleri hakkında detaylı bilgi verilmektedir.

2.1. Tez Çalışmasında Kullanılan Veriler

Tez çalışmasında iki farklı veritabanı kullanılmıştır. Birinci veritabanı MONS Üniversitesi TCTS Laboratuvarı ile Brüksel Üniversitesi CHU de Charleroi Uyku Laboratuvarı tarafından yürütülen DREAMS projesi kapsamında, yetişkinlere ait otomatik sinyal analizi amaçlı gece boyunca kaydedilen PSG kayıtlarından oluşan apne veritabanıdır [45]. İkinci veritabanı ise Kocaeli Üniversitesi Tıp Fakültesi Uyku Laboratuvarından temin edilen, teşhis ve tedavi maksatlı kaydedilmiş PSG kayıtlarından oluşturulmuştur [46]. Eğitim veri seti olarak birinci veritabanından alınan hasta kayıtları, test veri seti olarak da ikinci veritabanından alınan hasta kayıtları kullanılmıştır.

DREAMS apne veritabanı gelecekteki çalışmalarda da kullanılması ve performans karşılaştırması yapılması maksadı ile internet üzerinden araştırmacılara sunulmuştur. Veritabanı gece boyunca uyku laboratuvarında uyutulan ve OUAS teşhisi konmuş 12 hastaya ait PSG kayıtlarından oluşmaktadır. Hasta kayıtlarındaki solunumsal olaylar uzman hekim tarafından incelenmiş ve AASM skorlama kriterlerine göre skorlanmıştır. Görsel skorlama verileri her hasta için ayrı olacak biçimde, tüm solunumsal olayları (obstrüktif apne, santral apne, mikst apne veya hipopne biçiminde), başlangıç zamanı ve süresini de içerecek şekilde ayrı ayrı metin dosyasında kaydedilmiştir. Ayrıca her hasta için uyku evreleri de farklı bir dosyada sunulmuştur. Uyku evrelerine ait kayıtlar Rechtschaffen ve Kales ölçütlerine göre değerlendirilmiş ve her 5 saniye için oluşturulmuştur. PSG kayıtlarının alınmasında 32 kanallı Medatec marka Brainnet model PSG cihazı kullanılmıştır. Örnekleme frekansı 200 Hz olan PSG kayıtları, iki kanal EOG (P8-A1, P18-A1), üç kanal EEG (CZ-A1 veya C3-A1, FP1-A1 ve O1-A1), EKG, oro-nasal solunum, toraks ve abdominal solunum eforu sinyalleri ve kandaki oksijen satürasyonu


değerleri ile diğer standart PSG sinyallerini içerecek şekilde (European Data Format) EDF formatında sunulmuştur.

DREAMS apne veritabanında sunulan ve eğitim veritabanı olarak kullanılan hasta kayıtlarına ait bilgiler Tablo 2.1’de sunulmuştur.

Tablo 2.1. Eğitim veritabanına ait kayıt ve hasta bilgileri

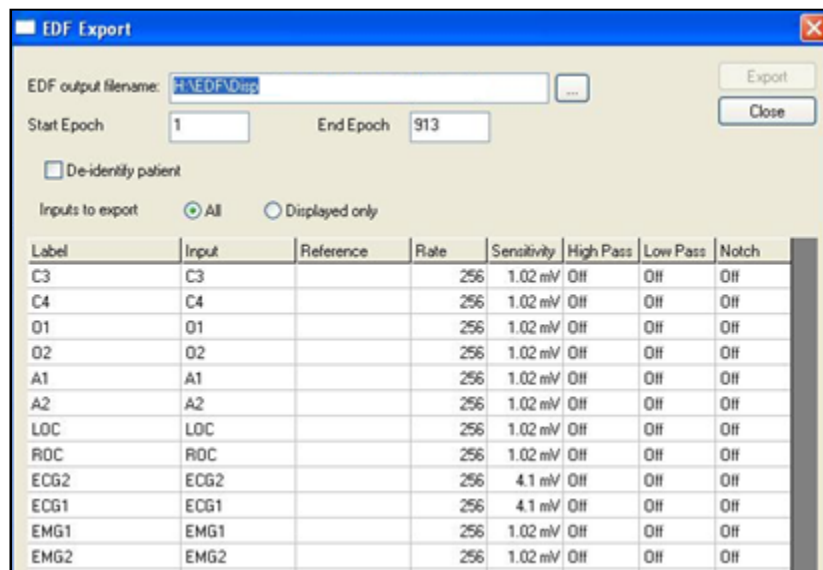
Hasta No	Yaş	AHI	Kayıt Süresi (sa.dk.sn)	Apne Sayısı	Hipopne Sayısı
1	50	7,4	09:05:20	39	12
2	64	16,1	08:27:20	67	47
3	54	21,2	08:35:20	128	37
4	54	25,1	09:12:30	66	151
5	51	46,7	08:02:40	117	172
6	70	49,3	09:33:40	340	38
7	51	50,9	09:32:00	203	249
8	60	51	07:32:00	219	113
9	51	55,5	08:00:00	308	62
10	51	59,1	08:02:00	230	37
11	41	80,9	09:22:40	511	189
12	50	95	08:36:00	390	333
Ortalama	53,93	46,52	08:40:08	218,17	120
Std.Sapma	± 7,6	± 25,9	± 00:40:51	± 146,2	± 100,6

Kocaeli Üniversitesi Tıp Fakültesi Uyku Laboratuvarından [46] temin edilen ve test veri seti olarak kullanılan hasta kayıtları ise tedavi amaçlı olarak gece boyunca uyku laboratuvarında uyutulan 30 hastaya ait PSG kayıtlarından oluşmaktadır. Hasta kayıtlarındaki solunumsal olaylar uzman hekim tarafından incelenmiş ve AASM skorlama ölçütlerine göre skorlanmıştır. PSG kayıtlarının alınmasında 44 kanallı Compumedics E-serisi PSG cihazı kullanılmıştır. PSG kayıtları, iki kanal EOG, dört kanal EEG (C3-A2, C4-A1, O1-A2 ve O2-A1), EKG (örnekleme frekansı 256 Hz), oro-nasal solunum, toraks ve abdominal solunum eforu sinyalleri ve kandaki oksijen saturasyonu değerleri ile diğer standart PSG sinyallerini içerecek şekilde ProFusionPSG2 [48] ticari programı kullanılarak skorlanmıştır. Skorlamada kullanılan ticari programa ait ekran kesiti Şekil 2.1’de sunulmuştur.



Şekil 2.1. ProFusionPSG2 [48] programı ekran kesiti

Anılan ticari program üzerinde işaretlenen solunumsal olaylara ait veriler farklı üçüncü parti dosyalama formatında saklandığı için alınamamıştır. Programın PSG sinyallerini EDF formatında aktarma ara yüzü kullanılarak hastalara ait kayıtlar elde edilmiştir. Bu nedenle tez çalışmasında skorlama sonucunda uzman hekim tarafından her hasta için belirlenen AHI değeri ile teşhis sonucu üzerinden değerlendirme yapılmıştır. EDF formatında dosyaya aktarmada kullanılan ara yüze ait ekran görüntüsü Şekil 2.2’de sunulmuştur. Söz konusu ara yüz üzerinden isteğe göre sinyallerin ham hali (‘All’ seçeneği) veya kullanılan filtre değerleri de uygulanmış, skorlamada kullanılan hali (‘Displayed only’ seçeneği) ile EDF dosyasına aktarma yapılabilmektedir.



Şekil 2.2. ProFusionPSG2 [48] EDF aktarma arayüzü

Kocaeli Üniversitesi Tıp Fakültesi Uyku Laboratuvarından [46] temin edilen ve test veritabanı olarak kullanılan hasta kayıtlarına ait bilgiler Tablo 2.2’de sunulmuştur.

Tablo 2.2. Test veritabanına ait kayıt ve hasta bilgileri

Hasta No	Sınıf	Yaş	Kayıt Süresi (sa:dk:sn)	Epok Sayısı (dk.)	AHI
1	N	59	07:22:00	442	0,3
2	N	60	06:14:00	374	0,6
3	N	58	07:12:00	432	0,7
4	N	44	07:13:00	433	1,4
5	N	34	07:05:00	425	1,7
6	N	44	06:11:00	371	1,8
7	N	63	05:37:00	337	2,5
8	N	44	06:15:00	375	4,5
9	B	59	07:50:00	470	8,3
10	B	40	07:46:00	466	9,5
11	B	63	06:45:00	405	10,2
12	B	47	07:19:00	439	10,4
13	B	50	09:03:00	543	10,5
14	B	31	06:21:00	381	10,5
15	B	34	06:47:00	407	10,9
16	B	43	07:00:00	420	10,9
17	B	34	08:15:00	495	11,6
18	B	44	08:17:00	497	11,7
19	B	53	07:27:00	447	11,8
20	B	50	08:44:00	524	11,8
21	A	32	06:59:00	419	18,1
22	A	54	06:37:00	397	28,2
23	A	37	08:23:00	503	28,7
24	A	43	07:19:00	439	30,2
25	A	27	07:08:00	428	30,6
26	A	57	06:36:00	396	33,4
27	A	63	07:22:00	442	33,4
28	A	49	07:08:00	428	34,6
29	A	78	07:11:00	431	45,5
30	A	38	06:44:00	404	60,1
Ortalama	-	47,73	07:12:20	432,33	16,1
Std.Sapma	-	± 12,01	± 00:47:02	± 47,03	± 15

Test veritabanını oluşturan 30 hastaya ait PSG kaydı, uzman hekim tarafından belirlenen AHI değerleri ile teşhis sonucu dikkate alınarak üç farklı sınıfa ayrılmıştır.

N sınıfı; uyku bozukluğu olmayan ve Normal teşhisi konulmuş 8 hastayı (3 kadın, 5 erkek) içermektedir. Hastaların ortalama yaşı 50,75 ve ortalama AHI 1,69’dur.

B sınıfı; hafif derecede OUA teşhisi konulmuş 12 hastayı (7 kadın, 5 erkek) içermektedir. Hastaların ortalama yaşı 45,67 ve ortalama AHI 10,7'dir.

A sınıfı; orta ve ağır derecede OUA teşhisi konulmuş, $AHI \geq 15$ olan 10 hastayı (2 kadın, 8 erkek) içermektedir. Hastaların ortalama yaşı 47,8 ve ortalama AHI 34,3'tür.

2.2. Tez Çalışmasında İzlenen Süreç

Tez çalışması boyunca izlenen süreç adımları Şekil 2.3'te sunulmuştur. Uygulanan süreç adımlarının özeti bu başlıkta verilmiş olup detayları ise alt başlıklarda sunulmuştur.

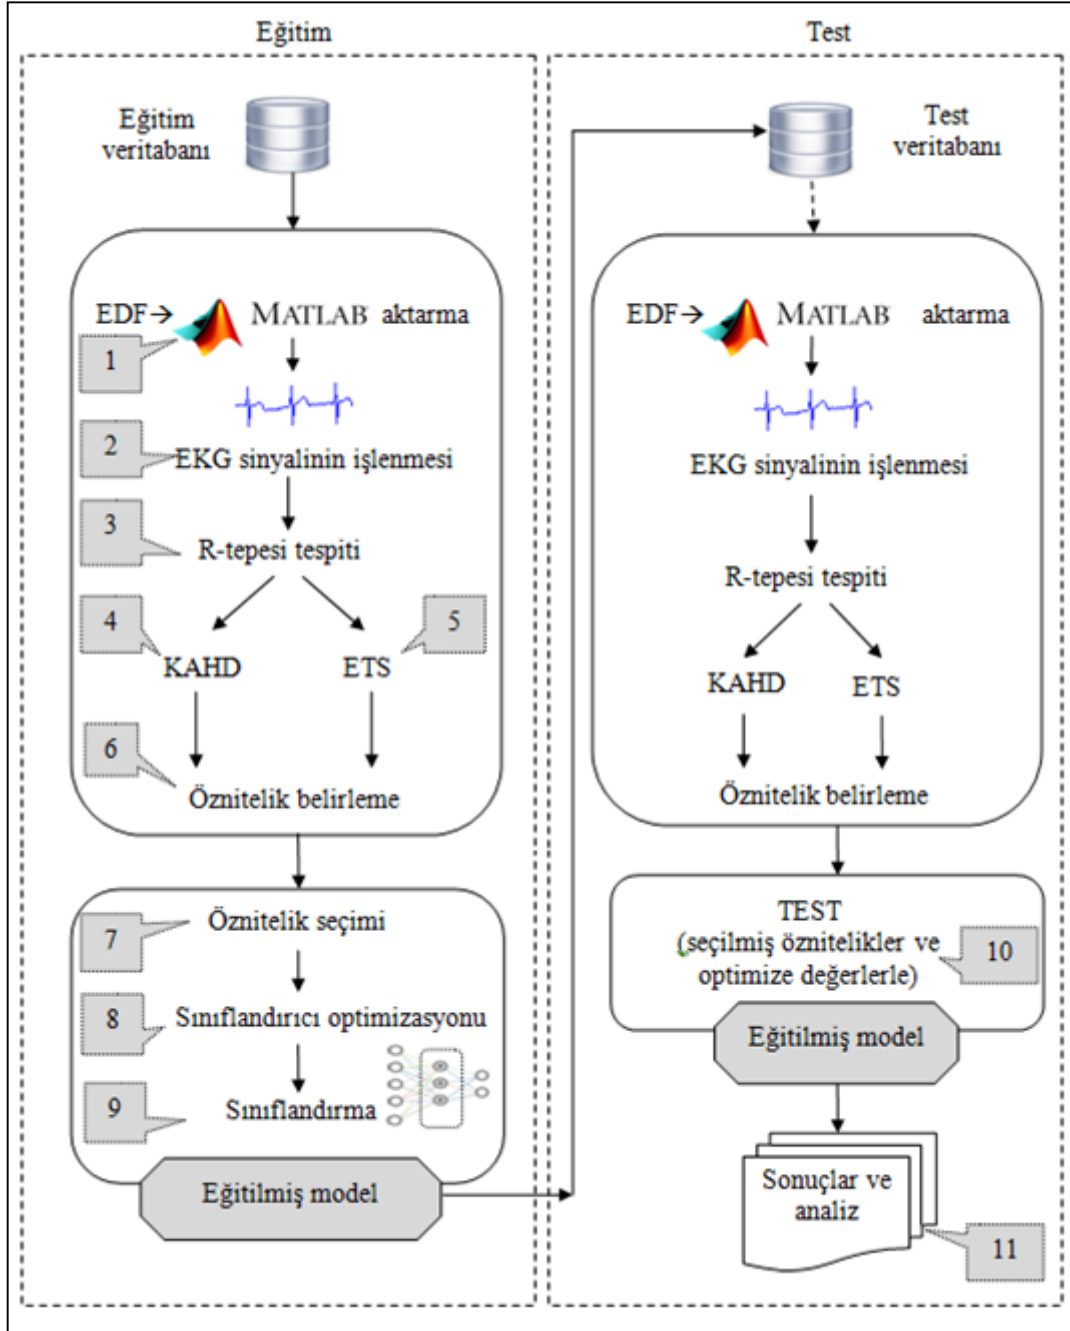
Süreç, eğitim ve test süreci olmak üzere ikiye ayrılmıştır. Her iki süreçte de MATLAB [47] programına aktarma, EKG sinyalinin işlenmesi, R tepelerinin tespiti, KAHD ve ETS sinyallerinin elde edilmesi ve özniteliklerin belirlenmesi adımlarında aynı yöntemler uygulanmıştır.

Eğitim süreci içinde özniteliklerin belirlenmesi adımı sonrasında, belirlenen öznitelikler arasından en belirleyici özniteliklerden oluşan öznitelik alt kümesinin seçilmesi, seçilen öznitelik alt kümesi üzerinden kullanılacak sınıflandırıcıların örüntü tanıma performansını arttırmak üzere optimizasyonu, optimize edilmiş sınıflandırıcıların eğitim veri seti ile eğitilerek eğitilmiş modellerin elde edilmesi sağlanmıştır.

Test sürecinde ise Şekil 2.3'te belirtilen 1-6 arası adımlar test veritabanından elde edilen hasta verilerinin ayrıştırılması ve işlenmesi için tekrarlanmıştır. Özniteliklerin belirlenmesi sonrasında, daha önce eğitilmiş olan modeller test veri seti kullanılarak test edilmiş, elde edilen test sonuçları analiz edilmiş ve oluşturulan modellerin performansları karşılaştırılmıştır.

2.2.1. Eğitim süreci

Eğitim veritabanında bulunan 12 hastaya ait kayıt, her bir hasta için tüm PSG sinyallerini içeren EDF formatında bir dosyada sıkıştırılmış biçimde elde edilmiştir.



Şekil 2.3. Eğitim ve test sürecinde izlenen adımlar

Adım 1; MATLAB'a [47] aktarma adımında, hasta kayıtlarını içeren EDF uzantılı dosyaları MATLAB programına aktarmak için geliştirilmiş bir MATLAB kodu [49] yardımıyla PSG sinyallerini içeren kayıtlar her hasta için ayrı ayrı aktarılmıştır. Aktarılan her EDF dosyası sonrasında MATLAB programında ilgili hasta ile kaydedilen PSG sinyallerine ait gerekli bilgiler ve değerler elde edilmiştir. Bahse konu sinyaller arasından EKG sinyalleri çekilerek her bir hasta için ayrı MAT uzantılı dosyalarlar oluşturulmuştur.

Adım 2; EKG sinyallerinin işlenmesi adımımda, her hasta için elde edilen EKG sinyalleri analizi öncesinde ön işlemden geçirilmiş ve bir dakikalık bölütlere ayrılmıştır. Ön işlem kapsamında, kayıt cihazının şehir şebekesinden etkilenmesi, hastanın uyku esnasındaki solunumu ile hareketleri nedeniyle oluşan taban hattı kayması (baseline drift) gibi gürültülerden arındırılması sağlanmıştır. Sinyalin gürültüden arındırılması için sırasıyla alçak geçiren filtre, yüksek geçiren filtre ve türev bazlı filtre kullanılmıştır.

Adım 3; R tepelerinin tespiti adımımda EKG sinyali üzerinden QRS kompleksi içinde yer alan R dalgalarının tepe noktaları ve konumları tespit edilmiştir. R tepelerinin tespiti ile ilgili detaylı bilgi Bölüm 2.4.1’de sunulmuştur.

Adım 4; KAHD sinyalinin elde edilmesi adımımda ise tespit edilen R tepeleri aralıkları (RR aralıkları) üzerinden türetilen ve kalp atım hızındaki değişimlerin gözlemlenebildiği KAHD sinyali elde edilmiştir. KAHD sinyali ile ilgili detaylı bilgi Bölüm 2.4.2’de sunulmuştur.

Adım 5; ETS sinyalinin elde edilmesi adımımda ise tespit edilen R tepelerini merkezine alacak şekilde QRS kompleksinin 100 ms’lik alanı hesaplanmış ve kübik enterpolasyon kullanılarak ETS sinyali dalga formu elde edilmiştir. ETS sinyali ile ilgili detaylı bilgi Bölüm 2.4.3’te sunulmuştur.

Adım 6; öznitelik belirleme adımımda KAHD ve ETS sinyallerinin zaman ve frekans uzayındaki analizlerinden çeşitli yöntemler ile sınıflandırmada kullanılacak öznitelikler elde edilmiştir.

Adım 7; öznitelik seçimi adımımda belirlenen öznitelikler arasından en belirleyici özniteliklerden oluşan öznitelik alt kümesinin seçimi Weka [50] programı öznitelik seçim ara yüzü üzerinden yapılmıştır.

Adım 8; sınıflandırıcı optimizasyonu adımımda seçilen öznitelik alt kümesi üzerinden kullanılacak sınıflandırıcıların performansını arttırmak üzere kullanılacak parametrelerin optimize değerleri Weka [50] programı sınıflandırma ara yüzü kullanılarak hesaplanmıştır.

Adım 9; sınıflandırma adımında ise seçilen öznitelikleri içeren eğitim veri seti öznitelik vektörleri, optimize edilen sınıflandırıcılara beslenerek kullanılacak olan modellerin eğitilmesi Weka [50] programı sınıflandırma ara yüzü ile sağlanmış ve test sürecince kullanılacak olan eğitilmiş modeller elde edilmiştir.

2.2.2. Test süreci

Kocaeli Üniversitesi Tıp Fakültesi Uyku Laboratuvarından [46] temin edilen ve test veritabanını oluşturan 30 hastaya ait EDF formatındaki kaydın veri ayrıştırması ve EKG sinyalinin işlenerek özniteliklerinin belirlenmesinde Test sürecinde sunulan 1-6 arası adımlar uygulanmıştır.

Elde edilen öznitelikler arasından Adım 7’de seçilen öznitelikler kullanılarak test veri setine ait öznitelik vektörleri elde edilmiştir.

Adım 10; test adımında eğitilmiş olan modellere 30 hastaya ait test veri seti öznitelik vektörleri beslenerek Weka [50] programı sınıflandırma ara yüzü ile sınıflandırılmış ve her hasta için apne tespit edilen dakika sayıları elde edilmiştir.

Adım 11; sonuçlar ve analiz adımında ise elde edilen sonuçlar Oracle 11g XE [51] veritabanına Toad veritabanı arayüzü programı [52] kullanılarak aktarılmıştır. Elde edilen sonuçların analiz ile ilgili çeşitli veritabanı objeleri oluşturulmuş, kullanılan tüm modellerde tespit edilen apne dakika sayıları üzerinden belirlenen eşik değerleri dikkate alınarak apne tespiti ve derecelendirmesi yapılmıştır.

2.3. Verilerin İşlenmesinde Kullanılan Yöntemler

EKG sinyali üzerinden KAHD sinyallerinin elde edilmesi (Bölüm 2.4.2) ve ETS sinyallerinin çıkartılması (Bölüm 2.4.3) sonrasında bu sinyallerin zaman ve frekans uzayında ayrı ayrı analizleri yapılmıştır.

Frekans uzayı analizi kapsamında KAHD ve ETS sinyallerinin her bölütün güç spektrum yoğunluğu (GSY) hızlı fourier dönüşümü (HFD) ile hesaplanmış, değişik frekans bölgelerindeki sinyal enerjilerinin hesaplanması ile frekans bölgesi öznitelikleri elde edilmiştir.

Zaman uzayı analizinde sinyallerin KAHD ve ETS sinyallerinin her bölütledeki ortalama mutlak sapması, ortanca değeri ve çeyrek değerler genişliği değeri ile KAHD sinyalinin kısa süreli zaman uzayı analizinde kullanılması önerilen istatistiksel değerler hesaplanmıştır.

KAHD ve ETS sinyallerinin frekans ve zaman uzayı analizlerinde kullanılan yöntemler aşağıdaki başlıklarda sunulmuştur.

2.3.1. Fourier dönüşümü

Fourier dönüşümü (FD), bir sinyalin zaman uzayından frekans uzayına dönüştürülmesi olarak tanımlanır ve frekans uzayındaki özelliklerinin tanımlanmasında en çok kullanılan yöntemlerden biridir. Sürekli zamanlı yapıdaki bir $X(t)$ sinyalinin fourier dönüşümü $X(w)$ Eşitlik (2.1)'de;

$$X(w) = \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt \quad (2.1)$$

şeklinde ifade edilir [21, 22]. Yukarıdaki eşitlikte w açısal frekans olup $w=2\pi f$ (rad/sn)'dir. Söz konusu dönüşümün $X(f)$ cinsinden ifadesi Eşitlik (2.2)'deki gibi;

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt \quad (2.2)$$

biçimindedir [21, 22].

2.3.2. Ayrık fourier dönüşümü

FD sürekli ve sonsuz sinyallerde etkin olduğundan fizyolojik sinyaller gibi sonlu sayıda örnek içeren sinyaller için uygun bir yöntem değildir. FD yerine bu tür sonlu uzunlukta, ayrık zamanlı sinyalin Fourier katsayılarını veren Ayrık Fourier Dönüşümü (AFD) kullanılmaktadır. Sonsuz uzunluktaki $x[n]$ dizisinin ayrık zamandaki FD Eşitlik (2.3)'teki gibi;

$$X(w) = \sum_{n=-\infty}^{\infty} x[n] e^{-j\omega n} \quad (2.3)$$

biçimindedir [21]. Ayrık Zamanlı Fourier Dönüşümü (AZDF), bir sinyalin sonlu sayıdaki ayrık zaman örneklerinden hesaplanır. N uzunluktaki sonlu bir $x[n]$ dizisi için AFD eşitliği Eşitlik (2.4)'te;

$$X(k) = \sum_{n=0}^{N-1} x[n] e^{-j2\pi 2\pi k} ; k = 0, 1, \dots, N - 1 \quad (2.4)$$

sunulduğu şekildedir [21, 22].

2.3.3. Hızlı fourier dönüşümü

HFD, FD'nin hızlı biçimde yapılmasını sağlayan, sinyalin bölütlere ayrılarak FD'lerinin alınması temeline dayanan bir yöntem olup sinyal içindeki frekans bileşenlerinin güç yoğunluğunu belirlemek için kullanılır.

$X_k(w)$ spektrum dizisi ($k=1,2,3,..,K$ için) sinyalin zamanla değişen spektral özelliklerini içerir. Bir $x[n]$ dizisinin zaman bölgesinde $x_k(n)$ şeklinde bölütlenmesi ile her bölüt için hesaplanan HFD Eşitlik (2.5)'te sunulduğu gibi;

$$X_k(w) = \sum_{n=0}^{N-1} x_k(n) e^{-jwn} \quad (2.5)$$

şeklindedir [21, 27].

2.3.4. Güç spektrumu ve periodogram

Bir sinyalin özilinti fonksiyonuna FD yapılması ile sinyale ait güç spektrumu elde edilir. Aşağıda sürekli zaman ve ayrık zamandaki sinyallerin güç spektrumları ise Eşitlik (2.6) ve (2.7) deki gibi;

$$PS(f) = \int_0^{\tau} r_{xx}(t) e^{-j2\pi ft} dt ; P = 1, 2, 3 \dots \quad (2.6)$$

$$PS(f) = \sum_{n=0}^{N-1} r_{xx}[n] e^{-j2\pi n f T_s} ; P = 1, 2, 3 \dots \quad (2.7)$$

biçimindedir [27]. Eşitlik (2.7)'deki $r_{xx}[n]$ ifadesi sinyalin özilinti fonksiyonudur.

Buna ek olarak bir sinyale ait enerjinin denklemi Eşitlik (2.8)'de;

$$E = \int_{-\infty}^{\infty} |x(t)|^2 dt \quad (2.8)$$

olarak verilmiştir [21, 27]. Yukarıdaki eşitlik Parseval teoremine göre Eşitlik (2.9)'daki gibi;

$$E = \int_{-\infty}^{\infty} |x(t)|^2 dt = \int_{-\infty}^{\infty} |X(f)|^2 df \quad (2.9)$$

şeklinde yazılabilir [21, 27]. Eşitlikte belirtilen $|X(f)|^2$ ifadesine Periodogram denir. Periodogram frekansa karşı enerjinin yoğunluğunu ifade eder ve Fourier dönüşümü uygulanmış sinyalin genliğinin karesi ile hesaplanır [27]. Ayrıca enerji spektral yoğunluğu, güç spektrumu veya güç spektral yoğunluğu olarak da isimlendirilebilir. Sinyalin tamamı yerine tüm sinyal üzerinden bölütlerine HFD uygulanması ve daha sonra her bölütün dönüşümünün ortalamasının alınması ile hesaplanan Periodogram, ile sinyalin güç spektrumu daha iyi ifade edilebilmektedir [27].

2.3.5. Sinyal enerjisi

Sürekli zamanlı bir $x(t)$ sinyalinin t_1 ve t_2 arasında toplam enerjisi Eşitlik (2.10)'da belirtilen;

$$E = \int_{t_1}^{t_2} |x(t)|^2 dt \quad (2.10)$$

biçimde sinyalin genliğinin karesinin zamana karşı toplamı ile hesaplanır [27, 22]. Benzer olarak ayrık zamanlı sonlu bir $x[n]$ dizisi için n_1 ve n_2 örnekleri arasındaki toplam enerji Eşitlik (2.11)'de sunulmuştur [22].

$$E = \sum_{n=n_1}^{n_2} |x(n)|^2 \quad (2.11)$$

2.3.6. Ortalama değer

Ortalama değer veri dizisindeki değerlerin toplamının sinyalin uzunluğuna oranıdır. Sürekli zamanlı bir $x(t)$ sinyalinin ortalama değeri Eşitlik (2.12)'deki gibi;

$$\bar{x} = \frac{1}{T} \int_0^T x(t) dt \quad (2.12)$$

hesaplanır [27]. Benzer olarak ayrık zamanlı sonlu bir $x[n]$ dizisinin ortalama değeri Eşitlik (2.13)'te;

$$\bar{x} = \frac{1}{N} \sum_{n=1}^N x_n \quad (2.13)$$

sunulduğu gibidir [27].

2.3.7. Etkin değer

Karesel ortalama değer (root mean square, RMS) olarak da adlandırılır. Değişen miktarların büyüklüğünün ölçülmesinde kullanılan bir ölçüttür.

Değişimin artı ve eksi yönde olduğu sinyallerde özellikle çok faydalıdır. Sürekli zamanlı bir $x(t)$ sinyalinin etkin değeri Eşitlik (2.14)'deki gibi;

$$x(t)_{\text{rms}} = \sqrt{\frac{1}{T} \int_0^T x(t)^2 dt} \quad (2.14)$$

biçiminde hesaplanır [27]. Benzer olarak ayrık zamanlı sonlu bir $x[n]$ dizisinin etkin değerini veren denklem Eşitlik (2.15)'teki gibidir [27].

$$x_{\text{rms}} = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (2.15)$$

2.3.8. Varyans

Varyans, bir olasılık dağılımı için istatistiksel yayılımın, mümkün bütün değerlerinin aritmetik ortalamadan olan uzaklığının karesini alarak hesaplanır. Sürekli zamanlı bir $x(t)$ sinyalinin varyansı Eşitlik (2.16)'daki biçimde;

$$\sigma^2 = \frac{1}{T} \int_0^T (x(t) - \bar{x})^2 dt \quad (2.16)$$

hesaplanır [22]. Burada (\bar{x} ortalama deęerdir). Benzer olarak ayırık zamanlı sonlu bir $x[n]$ dizisinin varyansını Eşitlik (2.17)'de;

$$\sigma^2 = \frac{1}{N-1} \sum_{n=1}^N (x_n - \bar{x})^2 \quad (2.17)$$

sunulmuştur [22].

2.3.9. Standart sapma

Standart sapma, sinyal deęerlerinin ortalamadan sapmalarının karesel ortalamasının kareköküdür. Varyansın karekökünün alınması ile hesaplanır. Sürekli zamanlı bir $x(t)$ sinyalinin standart sapması Eşitlik (2.18)'deki gibi;

$$\sigma = \sqrt{\frac{1}{T} \int_0^T (x(t) - \bar{x})^2 dt} \quad (2.18)$$

biçimindedir (\bar{x} ortalama deęerdir) [27]. Benzer olarak ayırık zamanlı sonlu bir $x[n]$ dizisinin standart sapması Eşitlik (2.19)'daki gibi;

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x_n - \bar{x})^2} \quad (2.19)$$

verilebilir [27].

2.3.10. Ortalama mutlak sapma (mean absolute deviation, MAD)

Bir veri setinin aritmetik ortalamasının mutlak sapmalarının aritmetik ortalamasıdır. MAD, veri setindeki her bir deęerin ilgili veri setinin ortalaması ile farkının mutlak deęerlerinin ortalaması olarak hesaplanır [18].

MAD Eşitlik (2.20)'deki gibi;

$$\text{MAD} = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n} \quad (2.20)$$

biçiminde hesaplanır.

2.3.11. Ortanca değer (median)

Büyükliğe göre sıralanmış veri setlerinde dağılımı iki eşit parçaya bölen değerdir. Ortanca değer, veri sayısı tek ise en ortadaki değer, çift ise en ortadaki iki değer aritmetik ortalaması alınarak hesaplanır. Veri setinin alt ve üst limitlerinin net olarak bilinmediği durumlarda yararlıdır.

2.3.12. Çeyrek değerler genişliği (interquartile range, IQR)

Yayıklık ölçüleri yöntemi olan çeyrek değerler genişliği, büyüklüğe göre sıralanmış dağılımın dört eşit parçaya (çeyrek) ayrılması sonrasında üçüncü çeyrek (%75) ile birinci çeyrek (%25) değerinin farkının bulunması ile elde edilir [18]. Çeyrek değerler genişliği, en alttaki %25'lik kısım ile en üstteki %25'lik kısmın ihmal edilmesini ve uç değerlerin dağılıma etkisini azaltmayı sağlar. İncelenen epok aralığındaki KAHD çeyrek değerler genişliği değeri özniteliklerden biri olarak belirlenmiştir.

2.3.13. Teager Enerji Operatörü (TEO)

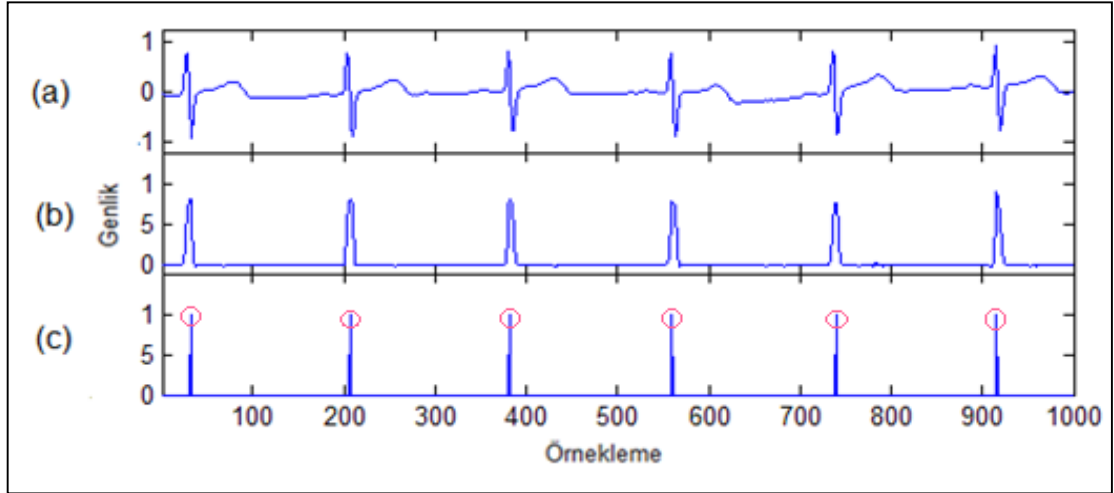
Tek boyutlu sinyaller ile görüntü işleme üzerinde yapılan çalışmalarda kullanılan TEO, doğrusal olmayan ve enerjisi bulunan sinyallerde kullanılan bir sinyal operatörü olarak tanımlanmaktadır [22] ve Eşitlik (2.21) ile;

$$\psi_c[x(t)] = \dot{x}^2(t) - x(t)\ddot{x}(t) \quad (2.21)$$

hesaplanır [21, 22]. TEO, bir sinyalin kendisi ile ilk iki türevine bağımlı yapıdadır. Bir sinyale TEO uygulayarak sinyaldeki ani değişikliklerin kuvvetlendirilmesi ve yumuşak geçişlerin bastırılması sağlanabilir [21]. N örneklili ayırık bir sinyal olan $w_s(n)$ için n'inci değerine TEO uygulanmış yapıya ait denklem Eşitlik (2.22)'de;

$$\psi_{Ts}(n) = \psi_s^2(n) - \psi_s(n-1)\psi_s(n+1) \quad (2.22)$$

sunulmuştur [21, 22]. Şekil 2.4'te TEO yöntemi kullanılarak EKG sinyali üzerinde hesaplanan R tepeleri gösterilmiştir. Şekil 2.4 (a)'da sunulan EKG sinyaline TEO yöntemi uygulanarak belirgin hale getirilen QRS alanı Şekil 2.4 (b)'de gösterilmiştir. TEO yöntemi uygulanmış sinyal üzerinde bir tepe bulucu (peak finder) fonksiyon kullanılarak R dalgası tepe noktaları tespit edilmiştir (Şekil 2.4 (c)).



Şekil 2.4. (a) EKG sinyali, (b) TEO uygulanmış EKG sinyali, (c) R tepeleri

2.4. EKG Sinyali Analizi

Zaman ve frekans uzayında yapılabilen EKG sinyalleri analizi ile çeşitli hastalıkların tespitinde yararlanılmaktadır. EKG sinyallerinin çok değerli bilgiler taşıması, analizinin nispeten basit ve etkili olması sayesinde kalp hastalıkları dışında uyku apnesi gibi solunumsal olayların tespitinde de kullanılmasını sağlamaktadır [13, 18].

Bölüm 1.4'te de belirtildiği gibi özellikle uyku apnesi sendromu bulunan hastalarda gece uyku esnasında oluşan apnelerin sık tekrarlaması kalp atımında değişimlere sebep olmakta ve bu değişim KAHD sinyali ile gözlemlenebilmektedir [36]. Benzer şekilde, solunumun EKG sinyali genliğine etkisinden yararlanarak elde edilen ETS sinyali ile uyku apnesi tespiti yapılabilmektedir [16, 23].

EKG sinyali üzerinden KAHD ve ETS sinyallerinin elde edilmesi sürecinde öncelikle eğitim ve test veritabanından elde edilen EKG sinyalleri önışlemden geçirilmiştir. Daha sonra önışlemden geçirilen sinyal bir dakikalık bölütlere ayrılmıştır. Her bölüt içinde R dalgalarının tepe noktalarının konumu ve genlikleri tespit edilmiştir.

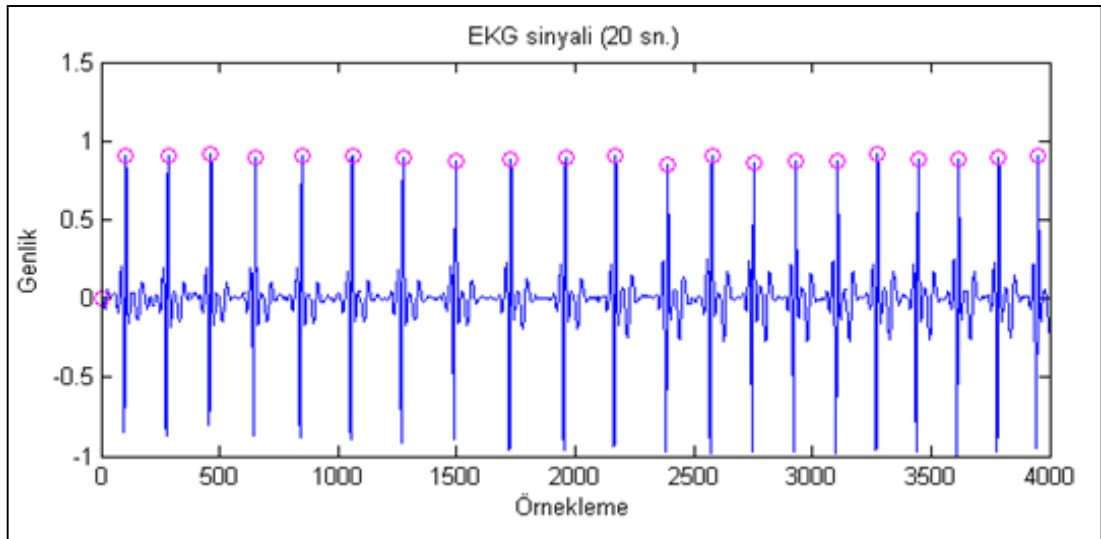
Literatürde R dalgalarının tespitinde dalgacık dönüşümü, TEO ve Pan-Tomkins algoritması gibi yöntemler kullanılmaktadır [7]. Tez çalışmasında söz konusu yöntemler arasından türev bazlı çalışan TEO yöntemi kullanılmıştır. R tepelerinin TEO yöntemi ile tespitinde detaylı bilgi Bölüm 2.3.13'te sunulmuştur.

R dalgalarının tepe noktaları ile konumlarının bulunması sonrasında KAHD sinyalinin elde edilmesi adımına geçilmiştir. KAHD sinyalinin elde edilmesi ile ilgili detaylı bilgi Bölüm 2.4.2’de sunulmuştur.

KAHD sinyalinin elde edilmesi sonrasında ETS sinyalinin elde edilmesi adımına geçilmiştir. R tepelerini merkezine alacak şekilde QRS kompleksinin 100 ms’lik alanı hesaplanmış ve kübik enterpolasyon kullanılarak ETS sinyali dalga formu elde edilmiştir. ETS sinyalinin elde edilmesi ile ilgili detaylı bilgi Bölüm 2.4.3’te sunulmuştur.

2.4.1. R tepelerinin belirlenmesi

R tepelerinin belirlenmesi amacıyla eğitim ve test veri tabanlarındaki hasta kayıtlarında bulunan gece boyunca uykuda kaydedilmiş EKG sinyalleri önışlemeden geçirilerek bir dakikalık bölütlere ayrılmıştır. Her bölüt üzerinde TEO yöntemi uygulanarak R dalgalarının daha belirgin olması sağlanmıştır. Bölüt üzerinden 0,6 saniye genişlik içindeki en yüksek genlik değerini tarayarak tespit eden bir tepe bulucu fonksiyon kullanılarak R dalgası tepe noktaları ve konumları belirlenmiştir. Şekil 2.5’te 20 saniye uzunluğunda önışlemeden geçirilmiş bir EKG sinyali üzerinde belirlenen R tepeleri sunulmuştur.



Şekil 2.5. EKG sinyali üzerinde belirlenen R tepeleri

R tepelerinin doğru biçimde belirlenmesi KAHD ve ETS sinyallerinin sağlıklı olarak oluşturulması için önemlidir. R tepelerinin tespitinde yapılacak hatalar KAHD ve

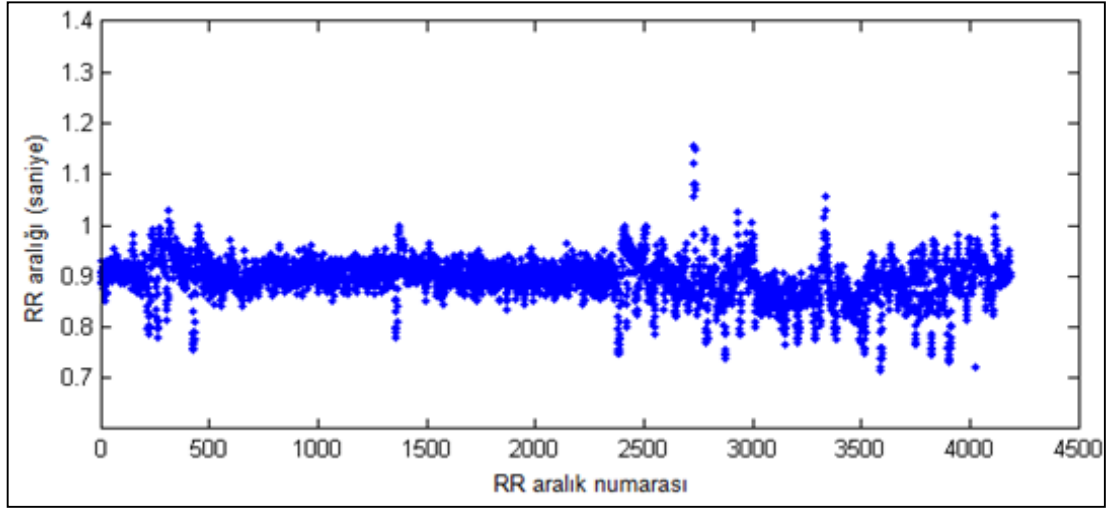
ETS sinyallerinin hatalı biçimde elde edilmesi dolayısıyla hatalı sonuçlara neden olabilir.

R tespiti adımında karşılaşılan iki temel hata R tepesinin ıskalanması ile fazladan R tepesi tespitidir. Söz konusu sorunların giderilmesi için bir çeşit düzeltme algoritmasının uygulanması gerekmektedir. İskalan R tepeleri ile fazladan tespit edilmiş R tepelerinin düzeltilmesinde genel yaklaşım RR aralıklarının 0,5 saniyeden küçük olduğu durumda ikinci R tepe değerinin çıkarılması, 1,5 saniyeden büyük olduğu değerlerde ise her iki R dalgasının tepe değerleri ile konumlarının ortalaması hesaplanarak bulunan konum ve değerlerde bir R tepesi eklenmesidir.

R tepelerinin düzeltilmesi kapsamında öncelikle tüm epoklardaki RR aralık değerlerinin minimum, maksimum ve ortalama değerleri tespit edilmiş, 0,5-1,5 saniye (minimum-maksimum) aralığı dışındaki epoklarda geliştirilen düzeltme algoritması uygulanmıştır. Öncelikle belirlenen epokta fazladan belirlenmiş R tepelerinin tespiti ve ayıklanması için 0,5 saniyeden küçük RR aralığı olup olmadığı kontrol edilmiştir.

Eğitim ve test verilerinde bu koşula uyan bir değer tespit edilmemiştir. Daha sonra belirlenen epokta ıskalanan R tepelerinin tespiti amacıyla 1,5 saniyeden büyük değerli RR aralıkları taranmıştır. Epoklardaki maksimum RR aralık değerlerinin gözle incelemesi sonucunda 1,5 saniyeye yakın küçük değerli, ıskalanmış R tepesinden kaynaklı RR aralıklarının bulunduğu tespit edilmiştir. Daha sonra algoritma epoktaki ortalama değerlerin %180 üzerindeki maksimum RR aralığını tespit edecek şekilde güncellenmiş ve bu koşula uyan eğitim veri setinde 58, test veri setinde ise 70 epokta RR aralıkları üzerinden ıskalan R tepeleri tespit edilmiş ve düzeltilmesi sağlanmıştır.

İki kalp atımı arasındaki geçen süre RR aralığının hesaplanmasıyla elde edilir. RR aralığı ise iki R tepe noktası arasında geçen süre ile bulunabilir. Şekil 2.6'da bir hastaya ait bir saatlik EKG sinyali üzerinden hesaplanmış olan RR aralıkları gösterilmektedir.



Şekil 2.6. Bir saatlik EKG sinyalinde belirlenen RR aralıkları

2.4.2. Kalp atım hızı değişimi (KAHD) sinyalinin elde edilmesi


KAHD ardışık iki R tepesi arasındaki zaman farkı olarak ölçülen RR aralıklarındaki değişimdir [53, 54]. Özellikle solunumsal olayların kalp üzerindeki etkilerini gözlemlemede KAHD sinyali değerli bilgiler içermektedir. Kalp atımı sayısı sempatik aktiviteyle artarken, parasempatik aktiviteyle azalmaktadır. Kalp atım hızındaki bu tür değişikliklerin hesaplanması EKG sinyali analizini uyku apnesinin tespiti açısından alternatif bir yöntem yapmaktadır.

KAHD sinyali EKG sinyali üzerinden türetilmiş bir sinyaldir. KAHD sinyali, bölüt içinde hesaplanan RR aralıklarından elde edilen zaman serisinin kalp atım sayısına göre çizdirilmesi ile elde edilmiştir. İki dakikalık EKG kaydı üzerinden türetilmiş KAHD sinyali örneği Şekil 2.7’de sunulmuştur.

Sayısal sinyaller üzerinde zaman bölgesi analizinde geometrik ve istatistiksel yöntemler kullanılırken, frekans bölgesi analizlerinde kullanılan yöntemler uzun süreli (24 saatlik) kayıtlar ile kısa süreli (1-5 dakikalık) kayıtlar için farklılaşmaktadır. KAHD analizinde genellikle zaman uzayı ve frekans uzayı (spektral) analizleri kullanılmaktadır.

KAHD zaman uzayı analizi uygulamaya bağlı olarak kısa süreli veya uzun süreli zaman uzayı analizleri ile gerçekleştirilmektedir. Avrupa Kardiyoloji Derneği (the Task Force of the European Society of Cardiology) ile Kuzey Amerika Pacing ve Elektrofizyoloji Derneği (the North American Society of Pacing and

Electrophysiology) tarafından KAHD sinyalinin zaman uzayı analizinde kullanılması önerilen istatistiksel öznitelikler Tablo 2.3'te sunulmuştur.

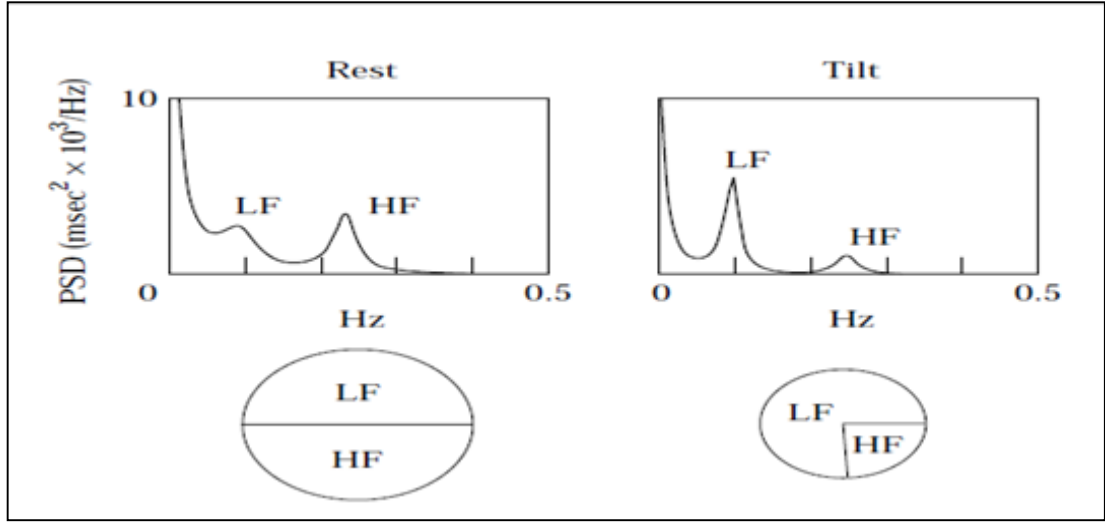


Şekil 2.7. İki dakikalık EKG kaydı üzerinden türetilmiş KAHD sinyali örneği

Tablo 2.3. KAHD'nin zaman uzayı analizi için önerilen istatistiksel öznitelikler

Öznitelik	Ölçü Birimi	Tanımlama
SDNN	ms	RR aralıklarının standart sapması
SDANN	ms	Tüm kaydın 5 dakikalık bölütlerindeki RR aralık ortalamalarının standart sapması
RMMSD	ms	Ardışık RR aralıkları farkının karekök ortalaması
SDNN indeksi	ms	Tüm kaydın 5 dakikalık bölütlerindeki RR aralıklarının standart sapmalarının ortalaması
SDSD	ms	Ardışık RR aralıkları farkının standart sapması
NN50 sayısı	ms	Ardışık RR aralıkları farkının 50 ms'den farklı olduğu çiftlerinin (üç farklı tipte) sayısı
pNN50	%	NN50 sayısının toplam RR aralığına bölümü

KAHD frekans uzayı analizinde kullanılan yöntem GSY hesaplanmasına dayanmaktadır. Bu sayede, temel olarak gücün frekanslara dağılımı bulunabilir. Diğer bir deyişle sinyaldeki değişkenliğin frekansa bağlı olarak gözlemlenebilmesine olanak sağlanır. GSY analizinde incelenen üç temel frekans bölgesi bulunmaktadır (Şekil 2.8) [53].



Şekil 2.8. LF ve HF frekans bölgeleri ile istirahat (rest) ve aktiviteye (tilt) göre değişimleri [53]

Bu bölgeler; çok düşük frekans (VLF) 0,015-0,04 Hz, düşük frekans (LF) 0,04-0,15 Hz ve yüksek frekans (HF) 0,15-0,4 Hz aralığındadır.

Merkezi sinir sisteminin kalp üzerindeki etkisinin belirlenmesi söz konusu spektral bölgelerin analizi ile sağlanabilir. HF bölgesi solunum esnasındaki parasempatik aktivitenin, LF bölgesi ise hem sempatik hem de parasempatik aktivitenin belirleyicisidir [21, 53]. Ayrıca LF/HF oranı da sempatik sistemin etkilerinin belirlenebilmesi bakımında ayırt edicidir [21]. Birçok çalışmada, uyku apnesi içeren sinyallerden elde edilen güç yoğunluğunun LF bileşeninin normal solunum içeren sinyallere göre daha yüksek oranda olduğu gözlemlenmiştir [7].

Analiz edilen kayıtların farklı kişilere ait olması ve analiz edilen bölütlerdeki kalp atışlarının hız farkı nedeniyle KAHD sinyalinin elde edilmesinde kullanılan her epoktaki RR aralık sayılarında farklılıklar oluşmaktadır. Bu farkı gidermek için öncelikle her bölüt için hesaplanan KAHD verileri doğrusal aradeğerleme ile dört kez artırılmış, daha sonra örnekleme frekansı 2 Hz'e indirgenerek tüm epoklarda

veri sayısının aynı olması sağlanmıştır. Daha sonra DC bileşeninden arındırmak amacıyla incelenen epoktaki sinyalin ortalaması kendinden çıkarılmıştır. GSY hesaplamasında 2048 örnekleme HFD kullanılmıştır.


İncelenen epok aralığında hesaplanan GSY üzerinden LF ve HF frekans bölgelerine denk gelen kısımların integrali ile LF ve HF bölgeleri güç değerleri hesaplanmış, LF ve HF bölgelerine ait güç değerleri oranlanarak LF/HF değeri elde edilmiştir.

2.4.3. EKG'den türetilmiş solunum (ETS) sinyalinin elde edilmesi

ETS sinyali, vücut yüzeyinden elde edilen EKG sinyalinin solunum döngüsü boyunca elektrotun kalbe göre nispi hareketinden faydalanarak çeşitli yöntemlerle elde edilen ve solunumu dolaylı olarak gösteren türetilmiş sinyaldir [37]. İspirasyon ve ekspirasyon mekanizmalarının EKG sinyalinde solunum döngü frekansı ile aynı frekansta genlik modülasyonu oluşmasına neden olması çeşitli sinyal işleme yöntemlerini kullanarak EKG sinyali üzerinden solunum sinyalinin türetilmesine olanak sağlamaktadır [23].

ETS sinyalinin elde edilmesinde QRS komplekslerinin genlikleri üzerinden hesaplama yapılacağı için sinyalin gürültüden arındırılması ve taban hattı kaymasının düzeltilmesi önemlidir. Şekil 2.9'da taban hattı kayması düzeltilmesinin öncesindeki ve sonrasındaki EKG sinyali örneği verilmiştir.

EKG sinyalinin gürültüden arındırılması ve taban hattı kaymasının düzeltilmesi amacıyla bölütlere ayrılan EKG sinyali ön işlemeden geçirilir. Ön işlemeden geçirilen bölütlere belirlenen aralıkta tepe bulucu fonksiyon kullanılarak QRS kompleksinin merkezi olan R dalgasının tepe noktası genlik değeri ile zamandaki konumu belirlenir. Belirlenen R dalgasının tepe noktasını merkezine alacak şekilde 100 ms genişlikte (200 Hz ile örneklenmiş sinyal için R tepe konumu öncesi 10 ve R tepe konumu sonrası 10 olmak üzere 20 örnek) QRS alanı hesaplanır. Hesaplanan QRS alan değerleri üzerinden daha önce belirlenen R tepelerinin konumlarından zaman serisi elde edilir.




Şekil 2.9. (a) Orijinal EKG, (b) Taban hattı kayması düzeltilmiş EKG

Elde edilen zaman serisinin örnekleme frekansı dikkate alınarak (200 Hz ile örneklenmiş sinyal için 12000 örnek) kübik enterpolasyon yardımıyla genişletilir. 0,4 Hz kesim frekanslı 5. dereceden Butterworth alçak geçiren filtreden geçirilerek düzgün ETS dalga formu elde edilir. Şekil 2.10'da 200 Hz'de örneklenmiş 20 saniyelik EKG sinyali ve bu sinyalden türetilmiş ETS sinyalinin grafikleri sunulmuştur.

2.4.4. KAHD ve ETS sinyallerinden elde edilen öznelikler

KAHD ve ETS sinyallerinin elde edilmesi amacıyla eğitim ve test veri tabanlarındaki gece boyunca uykuda kaydedilmiş EKG sinyalleri ön işlemeden geçirilerek bir dakikalık bölütlere ayrılmış, her bölüt üzerinde TEO yöntemi ile R dalgası tepe değerleri ve konumları belirlenmiştir. Belirlenmiş olan R dalgası tepe konumlarının zaman lokalizasyonu yapılarak iki R tepesi arasında geçen süre üzerinden RR aralıkları bulunmuştur. Bulunan RR aralıklarından elde edilen zaman serisinin kalp atım sayısına göre çizdirilmesi ile KAHD elde edilmiştir. KAHD sinyalinin zaman ve frekans uzayında ayrı ayrı analizleri yapılmıştır.



Şekil 2.10. EKG ve ETS sinyali (20 saniyelik)

Zaman uzayı analizinde her bölüt için Bölüm 2.3'te açıklanan istatistiksel yöntemler ile Tablo 2.3'teki KAHD'nin zaman uzayı analizi için önerilen (5 dakikalık bölütler için hesaplanan SDANN ve SDNN indeksi hariç) öznitelikler kullanılarak Tablo 2.4'te sunulan 14 öznitelik elde edilmiştir.

Tablo 2.4. KAHD sinyali zaman uzayı analizinden elde edilen öznitelikler

Öznitelik	Öznitelik	
	Numarası	Tanımlama
IQR	1	KAHD verisinin çeyrek değerler genişliği
MEDIAN	2	KAHD verisinin ortanca değeri
MAD	3	KAHD verisinin ortalama mutlak sapması
SDNN	4	RR aralıklarının standart sapması
RMSSD	5	Ardışık RR aralıkları farkının karekök ortalaması
NN50 v1	6	Ardışık RR aralıkları farkının 50 ms'den farklı olduğu çiftlerinin sayısı
NN50 v2	7	Ardışık RR aralıkları farkının 50 ms'den farklı ve birinci RR aralığının büyük olduğu çift sayısı
NN50 v3	8	Ardışık RR aralıkları farkının 50 ms'den farklı ve ikinci RR aralığının büyük olduğu çift sayısı
pNN50 v1	9	NN50 v1 değerinin toplam RR aralığına bölümü
pNN50 v2	10	NN50 v2 değerinin toplam RR aralığına bölümü
pNN50 v3	11	NN50 v3 değerinin toplam RR aralığına bölümü
SDSD	12	Ardışık RR aralıkları farkının standart sapması
MEAN	13	KAHD verisinin ortalama değeri
HR	14	Kalp atım hızı

KAHD sinyalinin frekans uzayı analizi kapsamında Bölüm 2.4.2’de açıklandığı yöntemle GSY hesaplaması sonrasında toplam güç (TP), VLF, LF ve HF bileşenlerinin güç değerleri ile LF/HF oranı hesaplanmış ve Tablo 2.5’te sunulan öznitelikler elde edilmiştir.

Tablo 2.5. KAHD sinyali frekans uzayı analizinden elde edilen öznitelikler

Öznitelik	Öznitelik Numarası	Tanımlama
TP	15	Bölüt içindeki toplam güç değeri
VLF	16	VLF bileşeni güç değeri
LF	17	LF bileşeni güç değeri
HF	18	HF bileşeni güç değeri
LF/HF	19	LF/HF bileşenlerinin oranı

ETS sinyalinin elde edilmesi kapsamında taban hattı kayması giderilmiş, EKG sinyali üzerinde belirlenmiş QRS kompleksi merkezi R tepeleri üzerinden tepe noktası merkezde olacak şekilde QRS kompleksinin 100 ms süre içinde kalan alanı üzerinden hesaplanmıştır.

ETS sinyalinin zaman ve frekans uzayında ayrı ayrı analizleri yapılmıştır. ETS sinyalinin frekans uzayı analizi kapsamında her bölüt için hesaplanan ETS GSY sonrasında TP, VLF, LF ve HF bileşenlerinin güç değerleri ile LF/HF oranı hesaplanmış ve Tablo 2.6’da sunulan öznitelikler elde edilmiştir.

Tablo 2.6. ETS sinyalinin frekans uzayı analizinden elde edilen öznitelikler

Öznitelik	Öznitelik Numarası	Tanımlama
EDR_TP	20	Bölüt içindeki toplam güç değeri
EDR_VLF	21	VLF bileşeni güç değeri
EDR_LF	22	LF bileşeni güç değeri
EDR_HF	23	HF bileşeni güç değeri
EDR_LF/HF	24	LF/HF bileşenlerinin oranı

ETS sinyalinin zaman uzayı analizinde Bölüm 2.3’te açıklanan istatistiksel yöntemlerden her bölüt için ETS sinyalinin çeyrek değerler genişliği, ortanca değeri ve ortalama mutlak sapma değerleri kullanılarak Tablo 2.7’de sunulan öznitelikler elde edilmiştir.

Tablo 2.7. ETS sinyalinin zaman uzayı analizinden elde edilen öznitelikler

Öznitelik	Öznitelik	
	Numarası	Tanımlama
EDR_IQR	25	ETS verisinin çeyrek değerler genişliği
EDR_MEDIAN	26	ETS verisinin ortanca değeri
EDR_MAD	27	ETS verisinin ortalama mutlak sapması

3. BULGULAR ve TARTIŞMA

Bu tez çalışması kapsamında EKG sinyalinin elde edilen KAHD ve ETS sinyallerinin zaman ve frekans uzaylarındaki analizleri ile elde edilen öznitelikler aşağıda belirtilen şekilde dört grup altında incelenmiştir:

KAHD zaman (Grup 1); KAHD sinyalinin zaman uzayı analizinden elde edilen öznitelikler üzerinden sınıflandırmadır. KAHD zaman ve frekans (Grup 2); KAHD sinyalinin zaman ve frekans uzayı analizinden elde edilen öznitelikler üzerinden sınıflandırmadır. KAHD-ETS zaman (Grup 3); KAHD ve ETS sinyallerinin zaman uzayı analizinden elde edilen öznitelikler üzerinden sınıflandırmadır. KAHD-ETS zaman ve frekans (Grup 4); KAHD ve ETS sinyallerinin zaman ve frekans uzayı analizinden elde edilen öznitelikler üzerinden sınıflandırmadır.

Yukarıda belirtilen dört grup için belirlenen özniteliklerin sınıflandırılmasında, her grup için kNN, MLP, SVM ve C4.5 sınıflandırıcılarının kullanılması ile tez çalışması kapsamında incelenecek toplam 16 örüntü tanıma modeli oluşturulmuştur. EKG sinyali üzerinden OUAS tespit ve derecesinin sınıflandırılması amacıyla KAHD ve ETS sinyallerinin analizi ile hangi modelin daha etkin olduğunun belirlenebilmesi hedeflenmiştir.

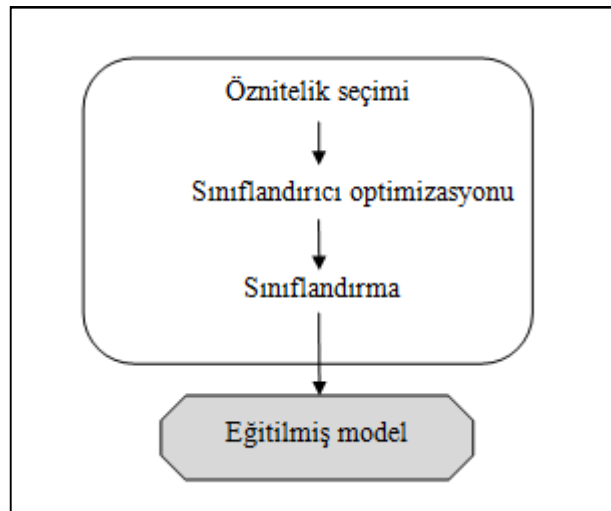
Tez çalışması kapsamında oluşturulan modellerle ilgili olarak kullanılan sınıflandırıcılar, analiz edilen sinyaller ve uzay bilgileri Tablo 3.1’de sunulmuştur.

Eğitim veritabanında bulunan hasta kayıtlarındaki solunumsal olaylara ait uzman hekim tarafından incelenmiş görsel skorlama verileri tüm solunumsal olaylara ait (obstrüktif apne, santral apne, mikst apne ve hipopne biçiminde) başlangıç zamanı ve oluşum süresini içerecek şekilde mevcuttur. Oluşum süresi 10 saniye ile 114 saniye arasında değişen, 2818 apne ve 1140 hipopne olmak üzere toplam 4058 adet apne/hipopne kaydı üzerinden bir dakikalık bölütlere ayrılan sinyallerde 3005 bölütte apne/hipopne olduğu belirlenmiş ve ‘apne/hipopneli bölüt’ olarak işaretlenmiştir.

Tablo 3.1. Oluşturulan örüntü tanıma modelleri

Grup No	Model No	Kullanılan Sınıflandırıcı	Analiz Edilen Sinyal	Analiz Edilen Uzay
1	1	kNN	KAHD	Zaman
	2	MLP		
	3	SVM		
	4	C4.5		
2	5	kNN	KAHD	Zaman ve Frekans
	6	MLP		
	7	SVM		
	8	C4.5		
3	9	kNN	KAHD ve ETS	Zaman
	10	MLP		
	11	SVM		
	12	C4.5		
4	13	kNN	KAHD ve ETS	Zaman ve Frekans
	14	MLP		
	15	SVM		
	16	C4.5		

Geriye kalan 3233 bölüt ise ‘normal bölüt’ yani ‘apne yok’ olarak işaretlenmiştir. Bu sayede eğitimde kullanılan 6238 öznitelik vektörünün ait olduğu bölütlerin normal solunum mu yoksa apne/hipopne mi içerdiği bilgisi elde edilmiştir. Apne/hipopne içeren bölütlerin 1, diğerleri ise 0 olacak biçimde iki sınıfa ayrılmaları sağlanmıştır. Modellerin eğitim süreci ile ilgili bilgi Bölüm 2.2.1’de sunulmuş olup Şekil 3.1’de temel hatları gösterilmiştir.



Şekil 3.1. Modellerin eğitimi

Belirlenen özniteliklerden her model için kullanılacak sınıflandırıcıya uygun en etkin alt grup özniteliğinin belirlenmesi amacıyla 10-katlı çapraz doğrulama yöntemi ile Wrapper tabanlı öznitelik seçim metotları kullanılmıştır. Wrapper tabanlı öznitelik seçim metodu, öznitelik seçimini sınıflandırmada kullanılacak olan sınıflandırıcının kendisi üzerinden yapmaktadır. Bu sayede sınıflandırmada daha iyi performans sağlayacak özniteliklerin seçilmesi sağlanmış olmaktadır. Öznitelik seçimi sonucunda elde edilen ve modellerde kullanılan öznitelikler Tablo 3.2’de sunulmuştur.

Tablo 3.2. Modellerde kullanılan seçilmiş öznitelikler

Grup No	Model No	Sınıflandırıcı	Kullanılan Öznitelikler Numaraları
1	1	kNN	1, 2, 3, 4, 5, 6, 9, 10, 11, 12, 13, 14
	2	MLP	1, 3, 6, 7, 8, 9, 10, 11, 12, 13, 14
	3	SVM	6, 9, 12, 14
	4	C4.5	2, 3, 6, 8, 10, 11, 12, 14
2	5	kNN	1, 2, 3, 5, 8, 9, 10, 12, 14, 15, 16
	6	MLP	1, 2, 3, 4, 6, 7, 8, 9, 10, 11, 12, 13, 14, 16, 18, 19
	7	SVM	1, 3, 6, 9, 11, 12, 14, 19
	8	C4.5	2, 3, 6, 8, 9, 12, 16
3	9	kNN	1, 2, 3, 6, 8, 10, 12, 13, 14, 25
	10	MLP	1, 2, 3, 4, 6, 8, 10, 11, 12, 13, 14, 26
	11	SVM	1, 4, 6, 9, 13, 14, 25, 26, 27
	12	C4.5	2, 8, 9, 11, 12, 14, 26, 27
4	13	kNN	1, 2, 3, 4, 5, 6, 10, 12, 14, 15, 19, 25
	14	MLP	1, 2, 3, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 16, 17, 18, 19, 20, 21, 22
	15	SVM	1, 9, 10, 13, 14, 15, 16, 19, 25, 26, 27
	16	C4.5	2, 4, 6, 9, 12, 15, 17, 26, 27

Seçilen öznitelikler arasından en belirleyici ilk iki öznitelik kullanılarak sınıflandırıcılarda kullanılacak parametrelerin belirlenmesi amacıyla optimizasyon yapılmıştır. Böylece sınıflandırıcılarda kullanılacak olan kNN için kaç tane en yakın komşunun (çoğunluk oyuna göre) belirlenmesini sağlayacak olan k parametresi, MLP için gizli katmandaki hücre sayısı (n), SVM için düzenleme sabiti (C) ile RBF fonksiyonunun genişliği (γ), C4.5 için güven faktörü (CF) ve yaprak başına düşen minimum bölünme durumu (MS) sayısının değerleri, hesaplanmıştır.

Modellerin eğitimi öncesinde Tablo 3.2’de sunulan seçilmiş öznitelikler ile Tablo 3.3’te verilen ve her model için tespit edilmiş parametre değerlerinin etkinliğinin gözlemlenmesi amacıyla eğitim veritabanındaki hasta kayıtları (Tablo 2.1) üzerinden OUAS teşhisi ve sınıflandırması yapılmıştır. Bu amaçla hasta kayıtlarının ilk 8 tanesi eğitim, geri kalan 4 hasta ise test amaçlı olarak kullanılmıştır. Test edilen 4 hastaya ait apne/hipopne içeren dakika sayılları belirlenmiş ve her model için belirlenen eşik seviyelerine göre OUAS teşhisi ve sınıflandırması yapılmıştır. Modellerin tamamında 4 hasta için OUAS teşhisi ve sınıflandırmasında %100 doğrulukta başarımlar sağlandığı görülmüştür.

Optimize edilen sınıflandırıcılar her model için seçilen öznitelikler ile ilgili bölütün apne/hipopne içerip içermediğini tespit edecek biçimde 10-katlı çapraz doğrulama yöntemi ile eğitilmiştir. Her model için hesaplanan parametreler ve elde edilen eğitim başarımları Tablo 3.3’te sunulmuştur.

Tablo 3.3. Modellere ait parametreler ve eğitim başarımları

Grup No	Model No	Sınıflandırıcı	Parametreler	Doğruluk	Duyarlılık	Kesinlik
1	1	kNN	k = 17	0,77444	0,77767	0,77118
	2	MLP	n= 15	0,74719	0,73586	0,76221
	3	SVM	C=5, $\gamma=0,1$	0,73210	0,73040	0,73420
	4	C4.5	CF=0,1,MS=1	0,76900	0,75878	0,78208
2	5	kNN	k = 5	0,77172	0,77494	0,768041
	6	MLP	n= 21	0,75537	0,74013	0,77614
	7	SVM	C=10, $\gamma=0,1$	0,74110	0,74124	0,74094
	8	C4.5	CF=0,1,MS=1	0,76771	0,75430	0,78542
3	9	kNN	k =15	0,76258	0,76691	0,757781
	10	MLP	n= 21	0,75104	0,73516	0,77232
	11	SVM	C=5, $\gamma=0,1$	0,76980	0,77071	0,76876
	12	C4.5	CF=0,1,MS=1	0,77861	0,77774	0,77961
4	13	kNN	k = 15	0,76402	0,76027	0,76847
	14	MLP	n= 17	0,74030	0,73451	0,74741
	15	SVM	C=10, $\gamma=0,1$	0,77541	0,77360	0,77751
	16	C4.5	CF=0,1,MS=1	0,78871	0,78370	0,79462

Eğitilen modeller daha sonra test veritabanındaki kayıtlardan elde edilen 12.790 adet bir dakikalık bölütlerden oluşturulmuş öznitelikler kullanılarak 10-katlı çapraz doğrulama yöntemi ile test edilmiştir. Bu sayede DREAMS apne veritabanından elde edilen veriler ile eğitilen modeller Kocaeli Üniversitesi Tıp Fakültesi Uyku

Laboratuvarından [46] temin edilen veriler ile test edilmiştir. Testlerde modelin etkinliğinin belirlenmesi için 10-katlı çapraz doğrulama yöntemi kullanılmıştır.

Test sonucunda kullanılan model tarafından apne/hipopne tespit edilen bölütler 1, diğerleri ise 0 olarak sınıflandırılmıştır. Böylece her hasta için apne/hipopne içeren dakika sayıları elde edilmiştir.

Test veritabanındaki hastalara ait apne/hipopne içeren dakika sayıları, her model için belirlenen iki eşik seviyesine göre değerlendirilmiştir.

Eşik 1, hastanın OUAS'lı olup olmadığını teşhisini sağlayan eşik değeridir ve bu değer altında kalanlar OUAS'lı olmayan yani normal gruptaki (N sınıfı) hastalar olarak sınıflandırılmıştır.

Eşik 2, OUAS tespit edilen hastaların derecelendirilmesi için kullanılan eşik değeridir. Bu değer üzerinde kalan hastalar orta/ağır derecede OUAS'lı (A sınıfı) olarak sınıflandırılmıştır. Eşik 1 ile Eşik 2 arasında kalan hastalar ise hafif derecede OUAS'lı (B sınıfı) olarak sınıflandırılmıştır.

Eşik değerlerine göre sınıflandırma sonrasında hastaların uzman hekim tarafından konulan teşhisleri ile test sonucunda elde edilen sınıflandırma bilgileri üzerinden kullanılan örüntü tanıma modellerinin başarımları karşılaştırılmıştır.

Oluşturulan modellerin başarımları ikili sınıflandırma (binary classification) performanslarının hesaplanması için kullanılan doğruluk, duyarlılık ve kesinlik istatistiksel ölçütleri üzerinden değerlendirilmiştir. Söz konusu istatistiksel ölçütler aşağıda açıklanmıştır.

Doğruluk (accuracy); modelin doğru tespit etme performansıdır. Aşağıda sunulduğu gibi gerçek pozitif ve gerçek negatif değerlerin toplam örnek sayısına bölünmesi ile elde edilir ve yüzde olarak Eşitlik (3.1)'deki şekilde;

$$\text{Doğruluk} = \frac{GP + GN}{GP + GN + YP + YN} \times 100\% \quad (3.1)$$

ifade edilebilir.

Duyarlılık (sensitivity); modelin gerçekte pozitif olan olguları doğru tespit etme yeteneğidir. Aşağıda sunulduğu gibi gerçek pozitiflerin gerçek pozitif ve yanlış negatif olguların toplam sayısına bölünmesiyle Eşitlik (3.2)'deki şekilde;

$$\text{Duyarlılık} = \frac{GP}{GP + YN} \times 100\% \quad (3.2)$$

hesaplanır.

Kesinlik (specificity); hassasiyet veya belirleyicilik olarak da adlandırılır. Modelin gerçekte negatif olan olguları doğru olarak tespit etme yeteneğini gösterir. Gerçek negatif değerlerin gerçek negatif ve yanlış pozitif olguların toplam sayısına bölünmesi ile Eşitlik (3.3)'teki şekilde;

$$\text{Kesinlik} = \frac{GN}{GN + YP} \times 100\% \quad (3.3)$$

elde edilir.

Gerçek pozitif (GP) sayısı; gerçekte pozitif olan ve modelin de pozitif sonucunu verdiği toplam olgu sayısıdır.

Gerçek negatif (GN) sayısı; gerçekte negatif olan ve modelin de negatif sonucunu verdiği toplam olgu sayısıdır.

Yanlış pozitif (YP) sayısı; gerçekte negatif olan fakat modelin pozitif sonucunu verdiği toplam olgu sayısıdır.

Yanlış negatif (YN) sayısı; gerçekte pozitif olan fakat modelin negatif sonucunu verdiği toplam olgu sayısıdır.

3.1. KAHD Zaman Analizinden Elde Edilen Bulgular

KAHD sinyalinin zaman uzayı analizinden 14 adet öznitelik (Grup 1) elde edilmiştir. Grup 1 özniteliklerinin kullanıldığı Model 1-4'e ait bulgular alt başlıklarda verilmiştir.

3.1.1. Model 1

KAHD sinyalinin zaman uzayı analizi ile kNN sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir. Wrapper tabanlı öznelik seçimi metodu k parametresi 5 seçilerek çalıştırılmış ve Tablo 3.2’de sunulan 12 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir.

Söz konusu seçilmiş özneliklerden IQR ve RMSSD öznelikleri kullanılarak farklı k değerleri (1,3,5,...,23) için sınıflandırıcı başarımları incelenmiş, sonuçları Tablo 3.4 ve Şekil 3.2.(a)’da verilmiştir.

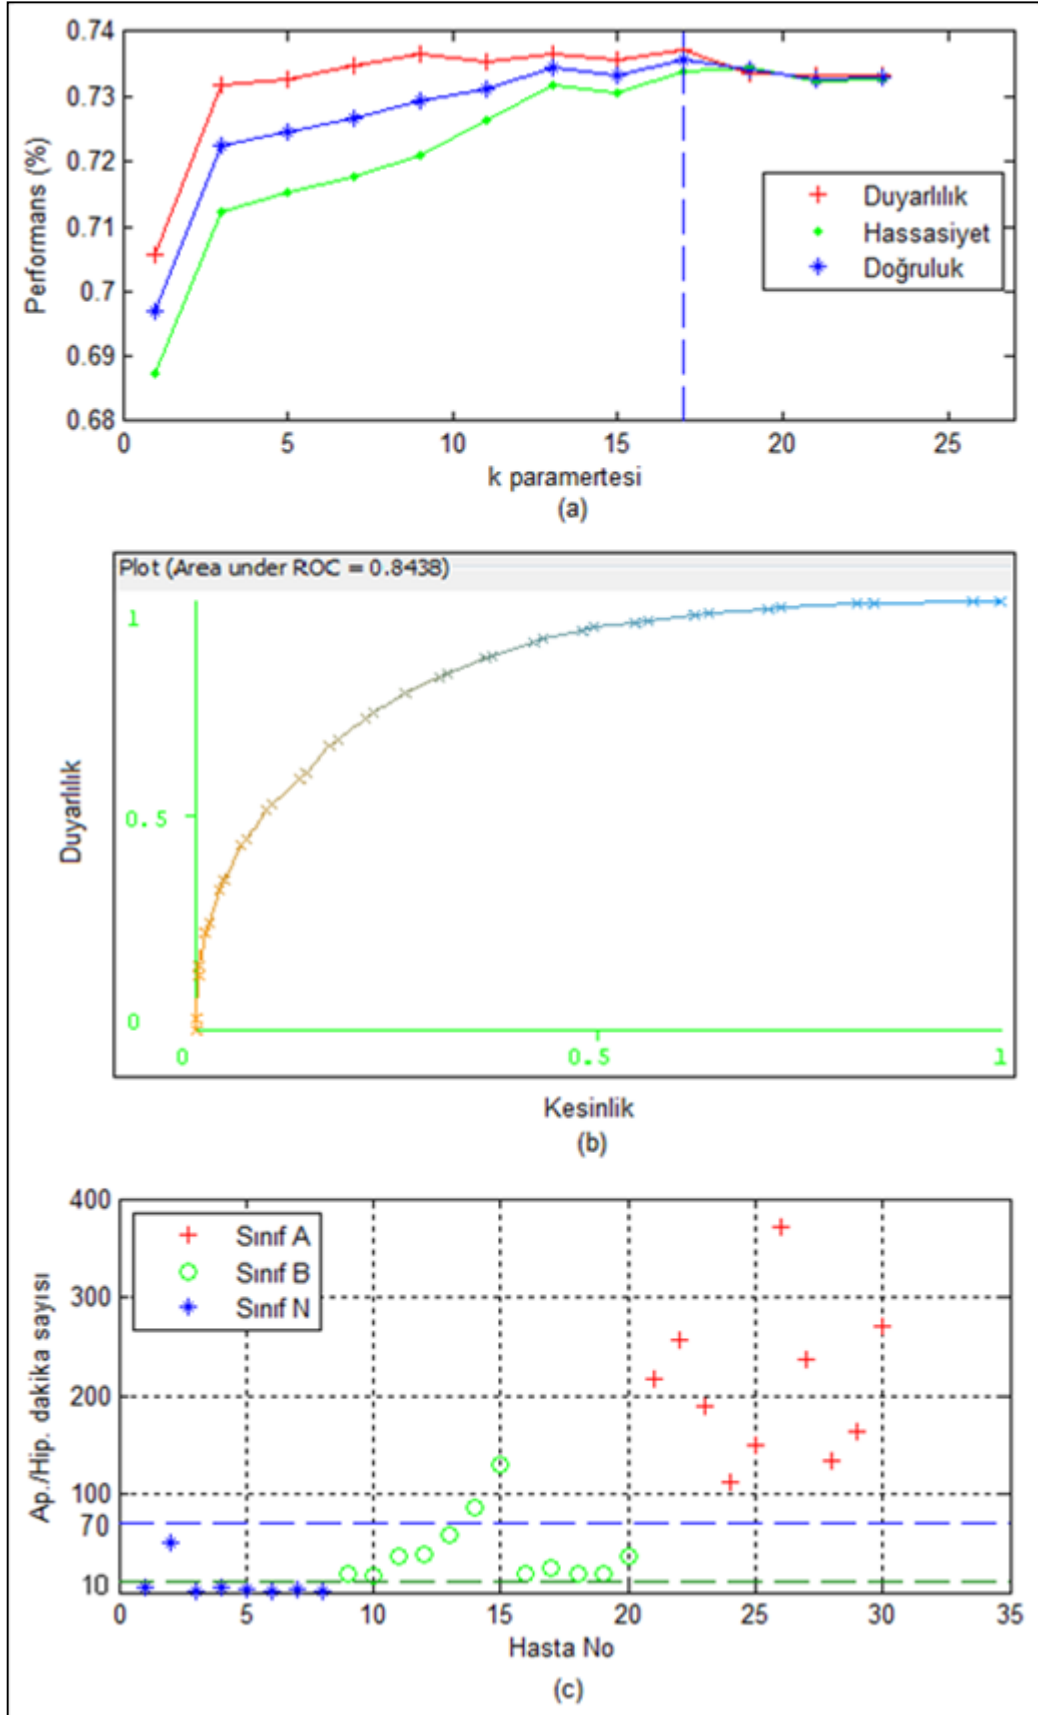
Optimum k =17 olarak belirlenmiştir.

Tablo 3.4. Model 1, kNN için k parametresi belirleme

Deneme No	k parametresi	Doğruluk	Duyarlılık	Kesinlik
1	1	0,6970	0,7057	0,6872
2	3	0,7225	0,7318	0,7122
3	5	0,7244	0,7325	0,7154
4	7	0,7267	0,7347	0,7177
5	9	0,7292	0,7365	0,7211
6	11	0,7312	0,7353	0,7264
7	13	0,7344	0,7366	0,7317
8	15	0,7332	0,7356	0,7304
9	17	0,7357	0,7372	0,7338
10	19	0,7340	0,7337	0,7345
11	21	0,7328	0,7332	0,7323
12	23	0,7329	0,7333	0,7325

Belirlenen optimum k değeri üzerinden eğitilen model başarımları Tablo 3.3’te sunulmuş olup, eğitilen modelin istatistiksel ölçütlerinden duyarlılığın kesinliğe oranını gösteren ROC (Receiver Operating Characteristic) eğrisi Şekil 3.2.(b)’de verilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=10 ve Eşik 2=70 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.2.(c)’de çizdirilmiştir.



Şekil 3.2. Model 1 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.1.2. Model 2

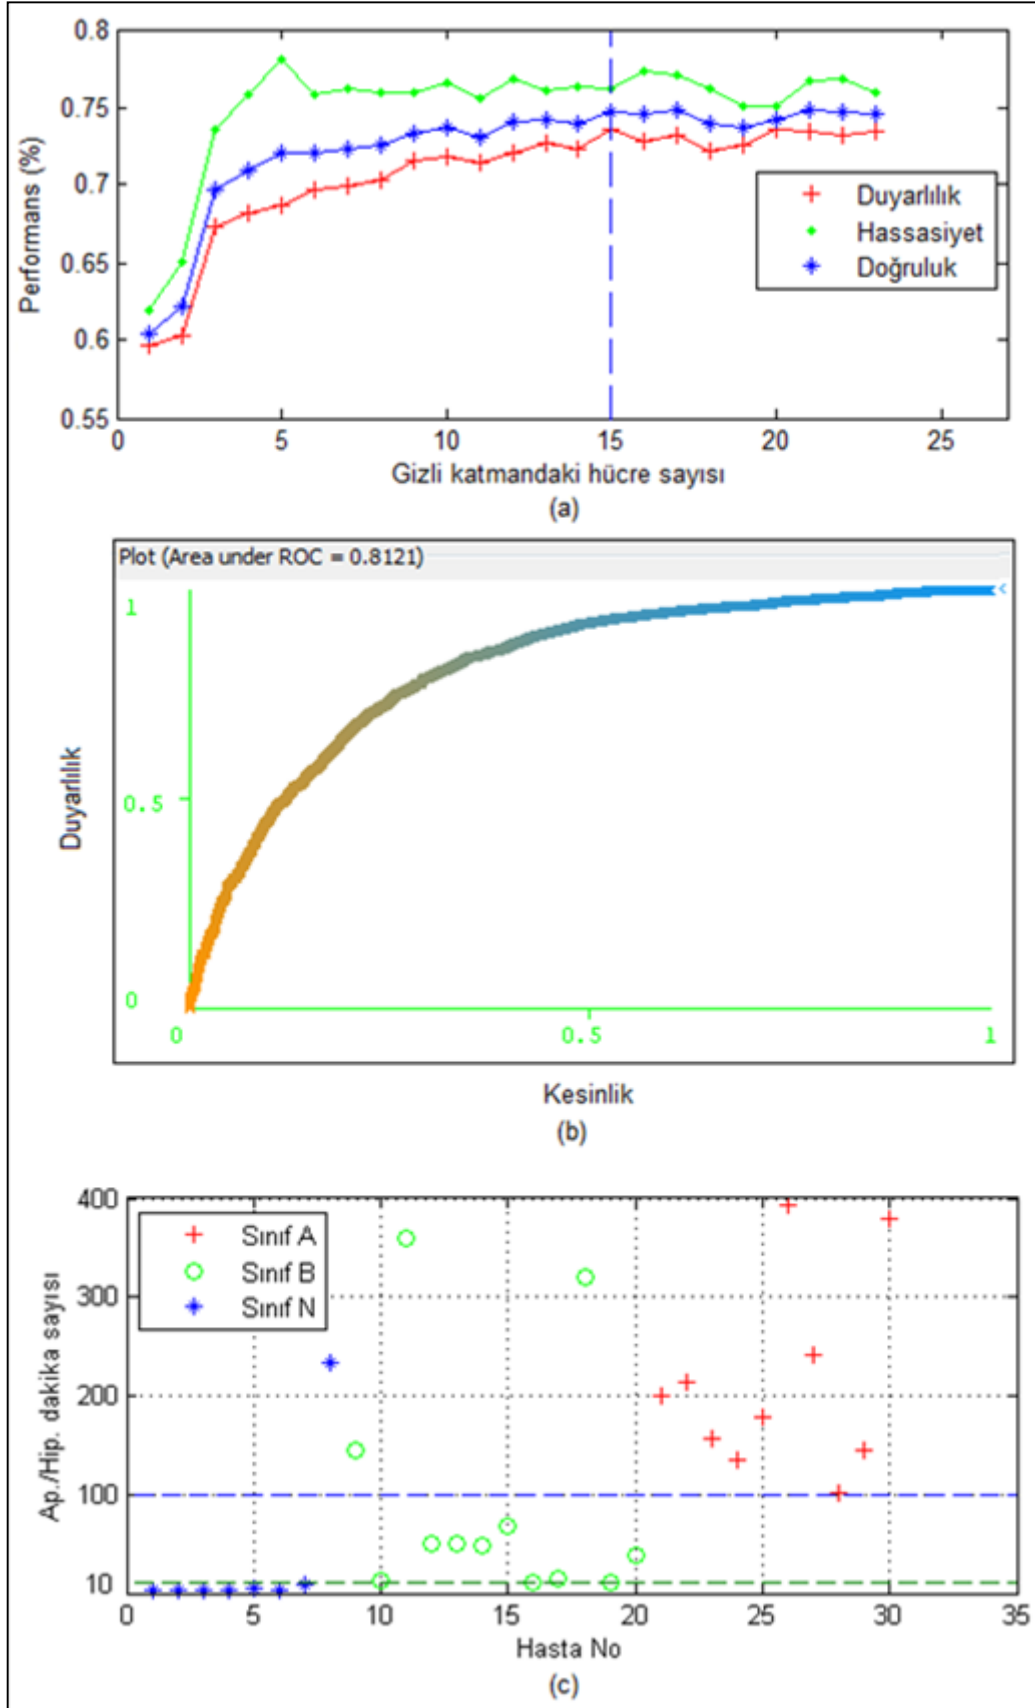
KAHD sinyalinin zaman uzayı analizi ile MLP sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir. Wrapper tabanlı öznelik seçimi metodu kullanılmış ve Tablo 3.2’de sunulan 11 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir. Farklı hücre sayısı değerleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.5 ve Şekil 3.3.(a)’da verilmiştir. Gizli katmandaki hücre sayısının optimum değeri 15 olarak belirlenmiştir.

Tablo 3.5. Model 2, MLP için hücre sayısı belirleme

Hücre sayısı	Doğruluk	Duyarlılık	Kesinlik
1	0,60484	0,59695	0,61964
2	0,62140	0,60339	0,65017
3	0,69654	0,67355	0,73543
4	0,70968	0,68169	0,75871
5	0,72042	0,68744	0,78054
6	0,72010	0,69635	0,75813
7	0,72363	0,69932	0,76250
8	0,72543	0,70313	0,75979
9	0,73293	0,71506	0,75884
10	0,73693	0,71756	0,76531
11	0,73100	0,71425	0,75508
12	0,74014	0,72097	0,76799
13	0,74126	0,72727	0,76046
14	0,73966	0,72341	0,76255
15	0,74719	0,73586	0,76221
16	0,74607	0,72752	0,77259
17	0,74848	0,73229	0,77097
18	0,73917	0,72205	0,76183
19	0,73629	0,72567	0,75047
20	0,74206	0,73574	0,75009
21	0,74864	0,73495	0,76717
22	0,74687	0,73167	0,76782
23	0,74559	0,73485	0,75976

Belirlenen gizli katmandaki optimum hücre sayısı değeri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.3.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=10 ve Eşik 2=100 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.3.(c)’de çizdirilmiştir.



Şekil 3.3. Model 2 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.1.3. Model 3

KAHD sinyalinin zaman uzayı analizi ile SVM sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Wrapper tabanlı öznelik seçimi metodu ile Tablo 3.2’de sunulan 4 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir.

Söz konusu seçilmiş öznelikler kullanılarak farklı değerlerdeki C ve γ parametreleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.6 ve Şekil 3.4.(a)’da verilmiştir.

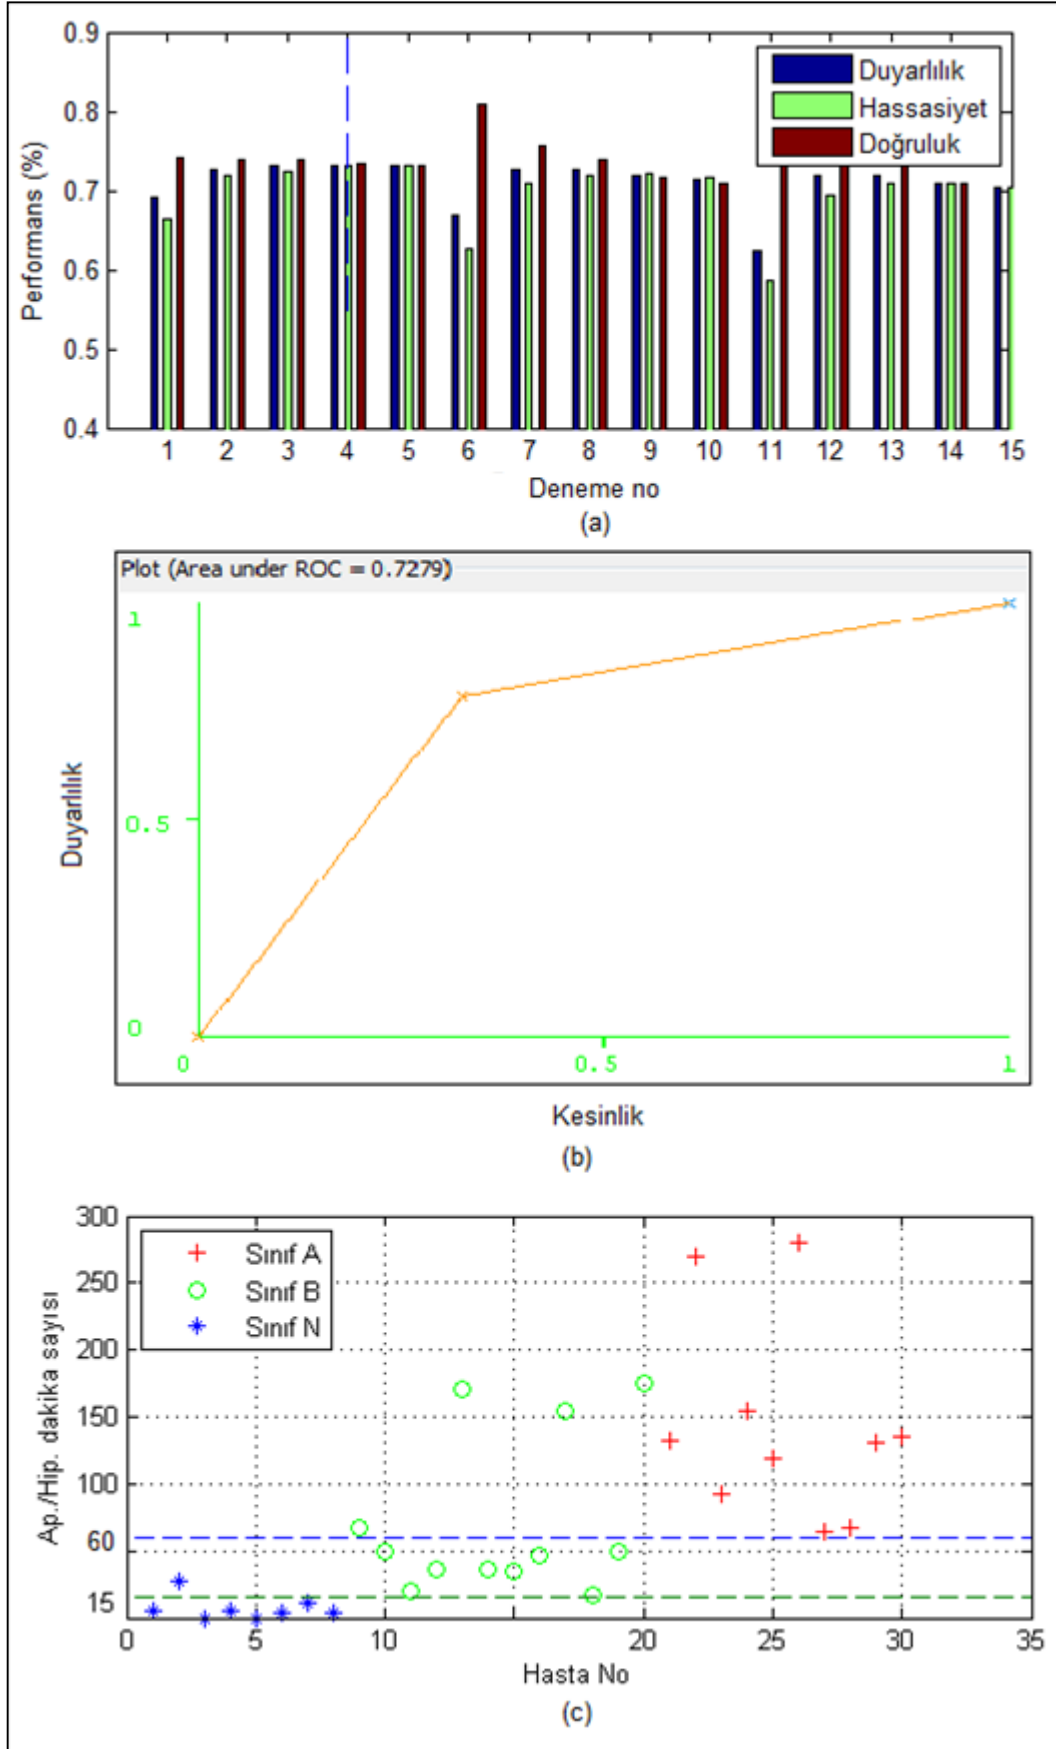
C ve γ parametreleri optimum değerleri sırasıyla 5 ve 0,1 olarak belirlenmiştir.

Tablo 3.6. Model 3, SVM için C ve γ parametreleri belirleme

Deneme No	C	γ	Doğruluk	Duyarlılık	Kesinlik
1	0,1	0,1	0,6914	0,6644	0,7410
2	0,5	0,1	0,7268	0,7177	0,7390
3	1	0,1	0,7302	0,7235	0,7389
4	5	0,1	0,7321	0,7304	0,7342
5	10	0,1	0,7313	0,7306	0,7322
6	0,1	0,5	0,6691	0,6253	0,8087
7	0,5	0,5	0,7272	0,7082	0,7554
8	1	0,5	0,7275	0,7191	0,7385
9	5	0,5	0,7182	0,7204	0,7155
10	10	0,5	0,7126	0,7167	0,7077
11	0,1	1	0,6238	0,5865	0,8201
12	0,5	1	0,7175	0,6947	0,7539
13	1	1	0,7185	0,7096	0,7305
14	5	1	0,7092	0,7087	0,7098
15	10	1	0,7041	0,7049	0,7031

Belirlenen parametre değerleri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.4.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=15 ve Eşik 2=60 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.4.(c)’de çizdirilmiştir.



Şekil 3.4. Model 3 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.1.4. Model 4

KAHD sinyalinin zaman uzayı analizi ile C4.5 sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Wrapper tabanlı öznelik seçimi metodu ile Tablo 3.2’de sunulan 8 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir. Söz konusu seçilmiş öznelikler kullanılarak farklı değerlerdeki CF ve MS parametreleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.7 ve Şekil 3.5.(a)’da verilmiştir.

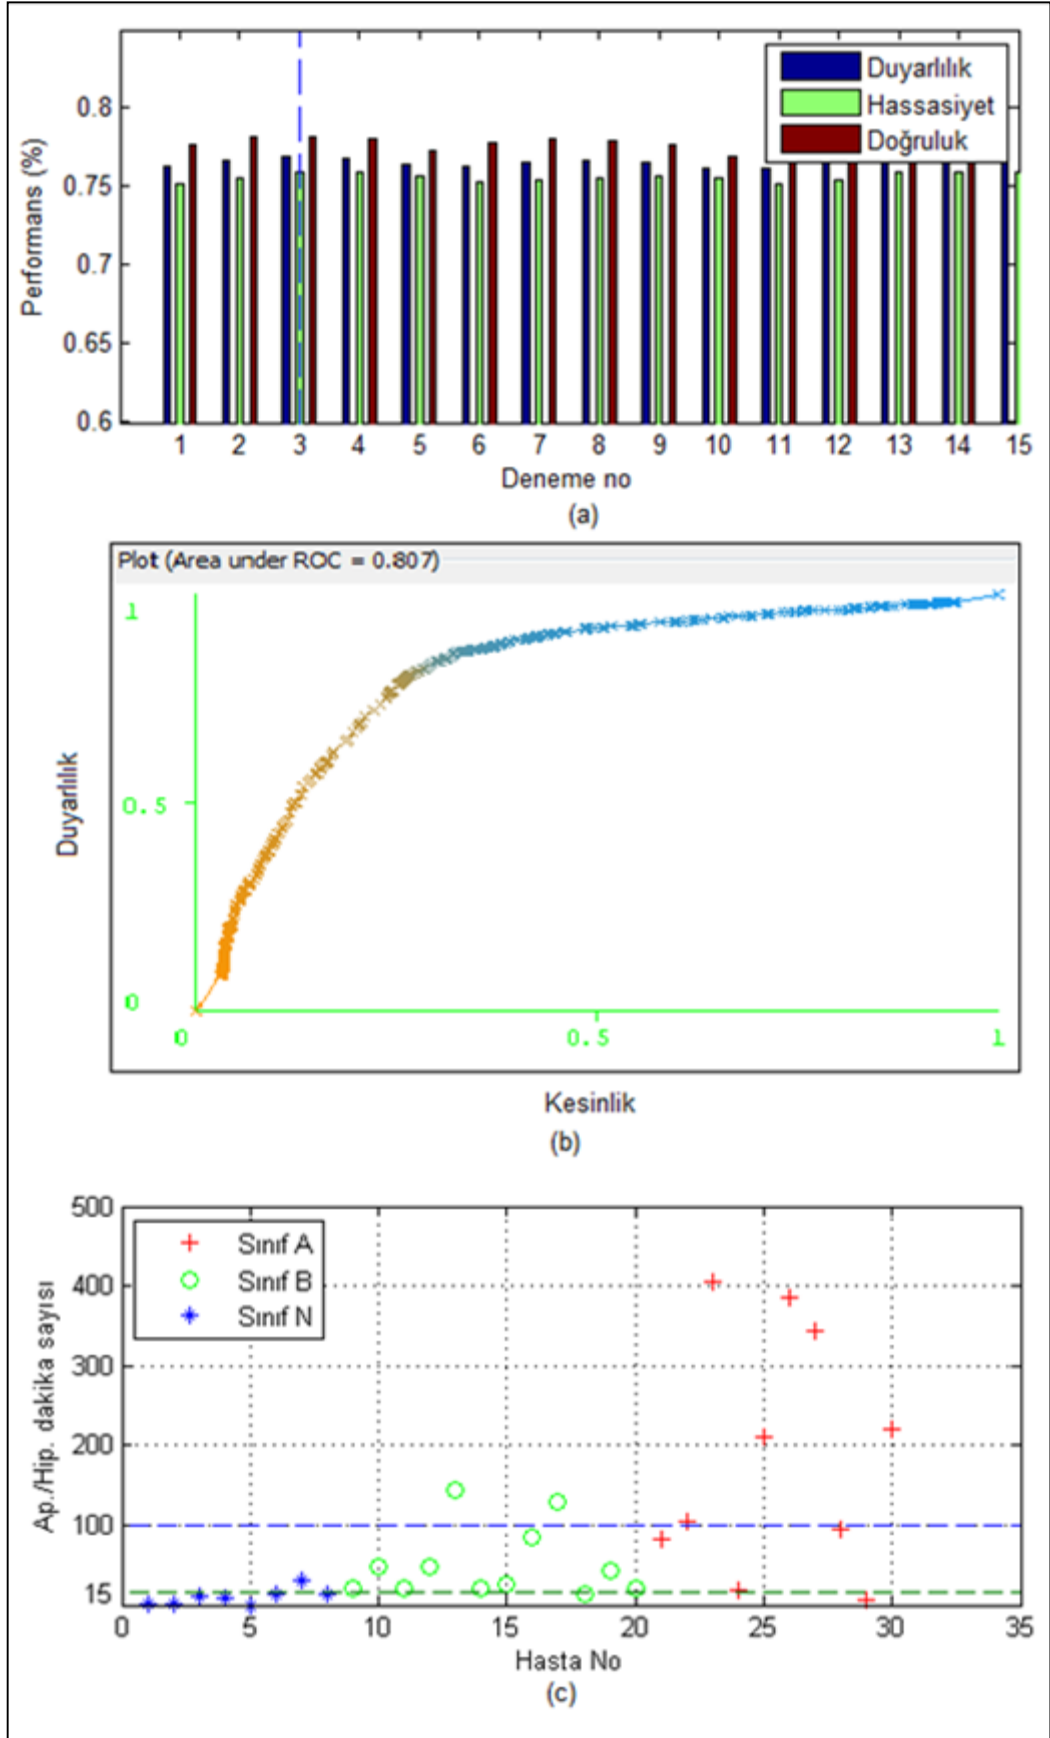
CF ve MS parametrelerinin optimum değerleri sırasıyla 0,1 ve 1 olarak belirlenmiştir.

Tablo 3.7. Model 4, C4.5 için CF ve MS parametreleri belirleme

Deneme No	CF	MS	Doğruluk	Duyarlılık	Kesinlik
1	0,01	1	0,76258	0,75149	0,77700
2	0,05	1	0,76707	0,75532	0,78237
3	0,1	1	0,76900	0,75878	0,78208
4	0,25	1	0,76852	0,75916	0,78041
5	0,5	1	0,76419	0,75729	0,77281
6	0,01	2	0,76355	0,75263	0,77770
7	0,05	2	0,76611	0,75461	0,78105
8	0,1	2	0,76643	0,75620	0,77957
9	0,25	2	0,76563	0,75673	0,77693
10	0,5	2	0,76194	0,75571	0,76970
11	0,01	3	0,76194	0,75135	0,77565
12	0,05	3	0,76547	0,75433	0,77990
13	0,1	3	0,76787	0,75948	0,77846
14	0,25	3	0,76836	0,75999	0,77891
15	0,5	3	0,76563	0,75881	0,77414

Belirlenen parametre değerleri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.5.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=15 ve Eşik 2=100 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.5.(c)’de çizdirilmiştir.



Şekil 3.5. Model 4 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.2. KAHD Zaman ve Frekans Analizinden Elde Edilen Bulgular

KAHD sinyalinin zaman ve frekans uzayı analizinden 19 adet öznitelik (Grup 2) elde edilmiştir. Grup 2 özniteliklerinin kullanıldığı Model 5-8'e ait bulgular alt başlıklarda verilmiştir.

3.2.1. Model 5

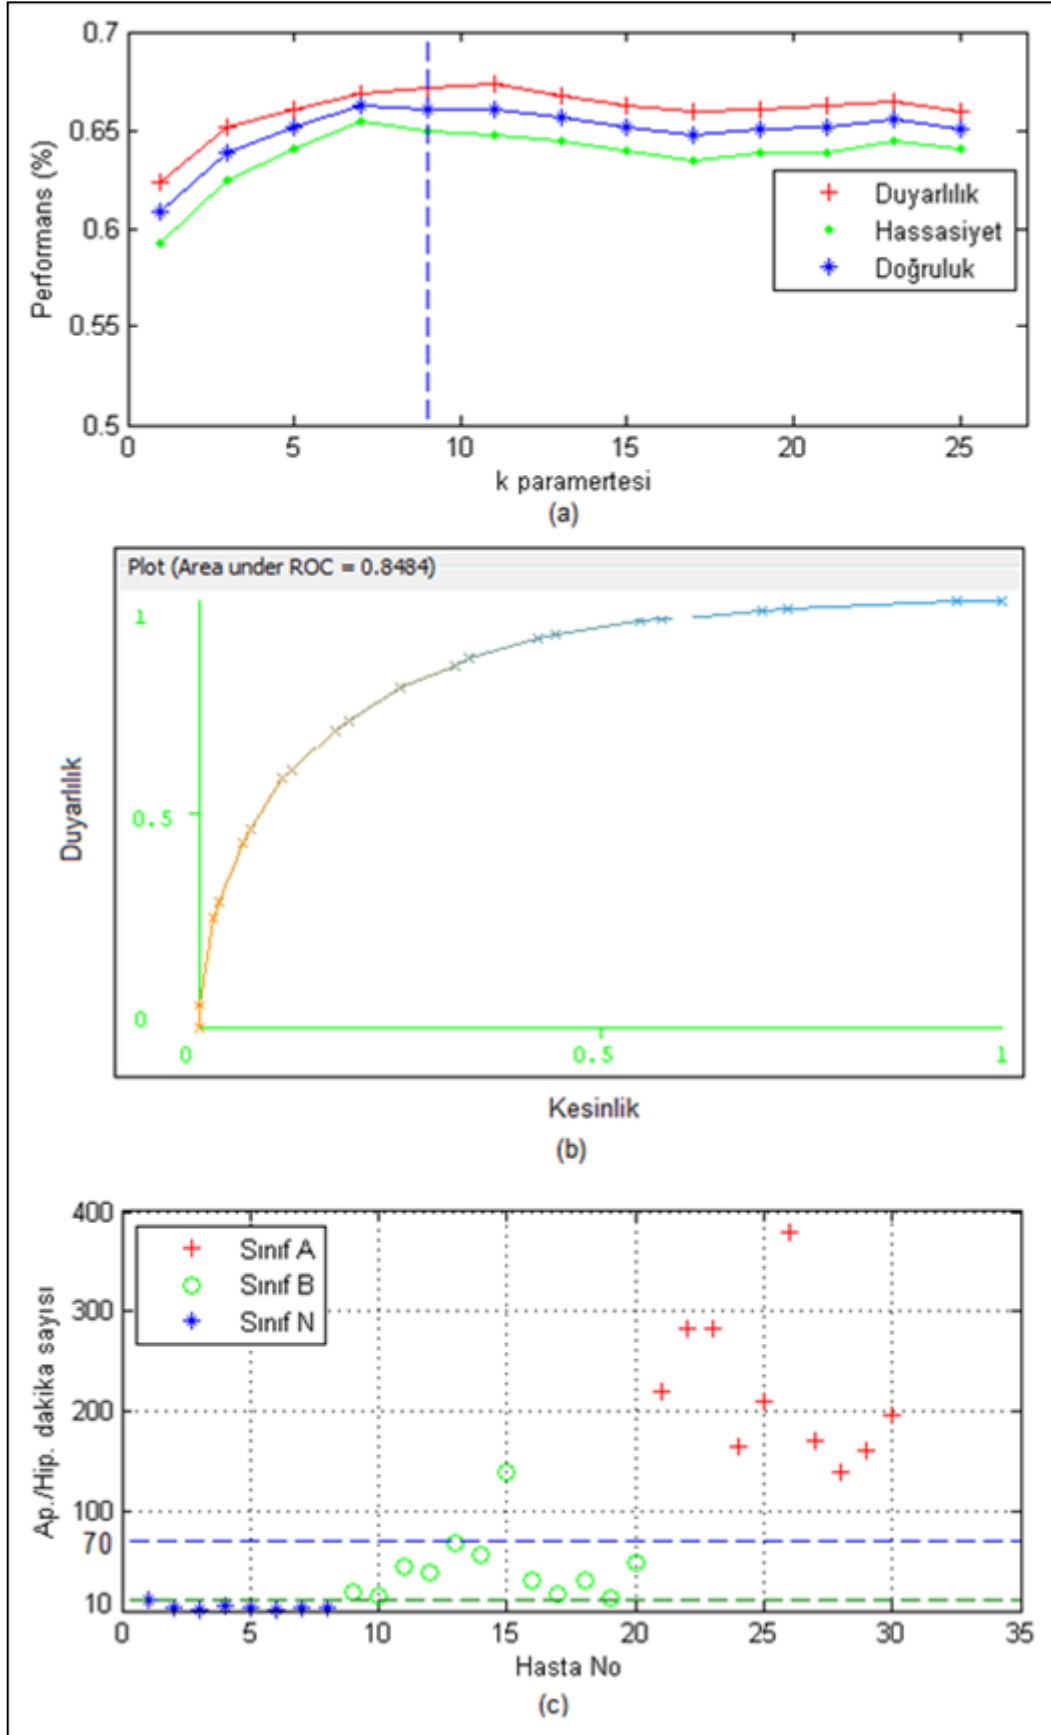
KAHD sinyalinin zaman ve frekans uzayı analizi ile kNN sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir. Wrapper tabanlı öznitelik seçimi metodu k parametresi 5 seçilerek çalıştırılmış ve Tablo 3.2'de sunulan 11 öznitelikten oluşan en belirleyici öznitelik alt kümesi elde edilmiştir. Farklı k değerleri (1,3,5,...25) için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.8 ve Şekil 3.6.(a)'da verilmiştir. Optimum k=9 olarak belirlenmiştir.

Tablo 3.8. Model 5, kNN için k parametresi belirleme

Deneme No	k parametresi	Doğruluk	Duyarlılık	Kesinlik
1	1	0,60869	0,62352	0,59213
2	3	0,63851	0,65113	0,62428
3	5	0,65117	0,66061	0,64018
4	7	0,66255	0,66892	0,65492
5	9	0,66095	0,67107	0,64936
6	11	0,66095	0,67336	0,64714
7	13	0,65678	0,66757	0,64450
8	15	0,65197	0,66266	0,63974
9	17	0,64748	0,65922	0,63419
10	19	0,65021	0,66077	0,63809
11	21	0,65117	0,66225	0,63855
12	23	0,65534	0,66478	0,64439
13	25	0,65053	0,65906	0,64046

Belirlenen optimum k değeri üzerinden eğitilen model performansı Tablo 3.3'te sunulmuş olup, Şekil 3.6.(b)'deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=10 ve Eşik 2=70 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.6.(c)'de çizdirilmiştir.



Şekil 3.6. Model 5 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

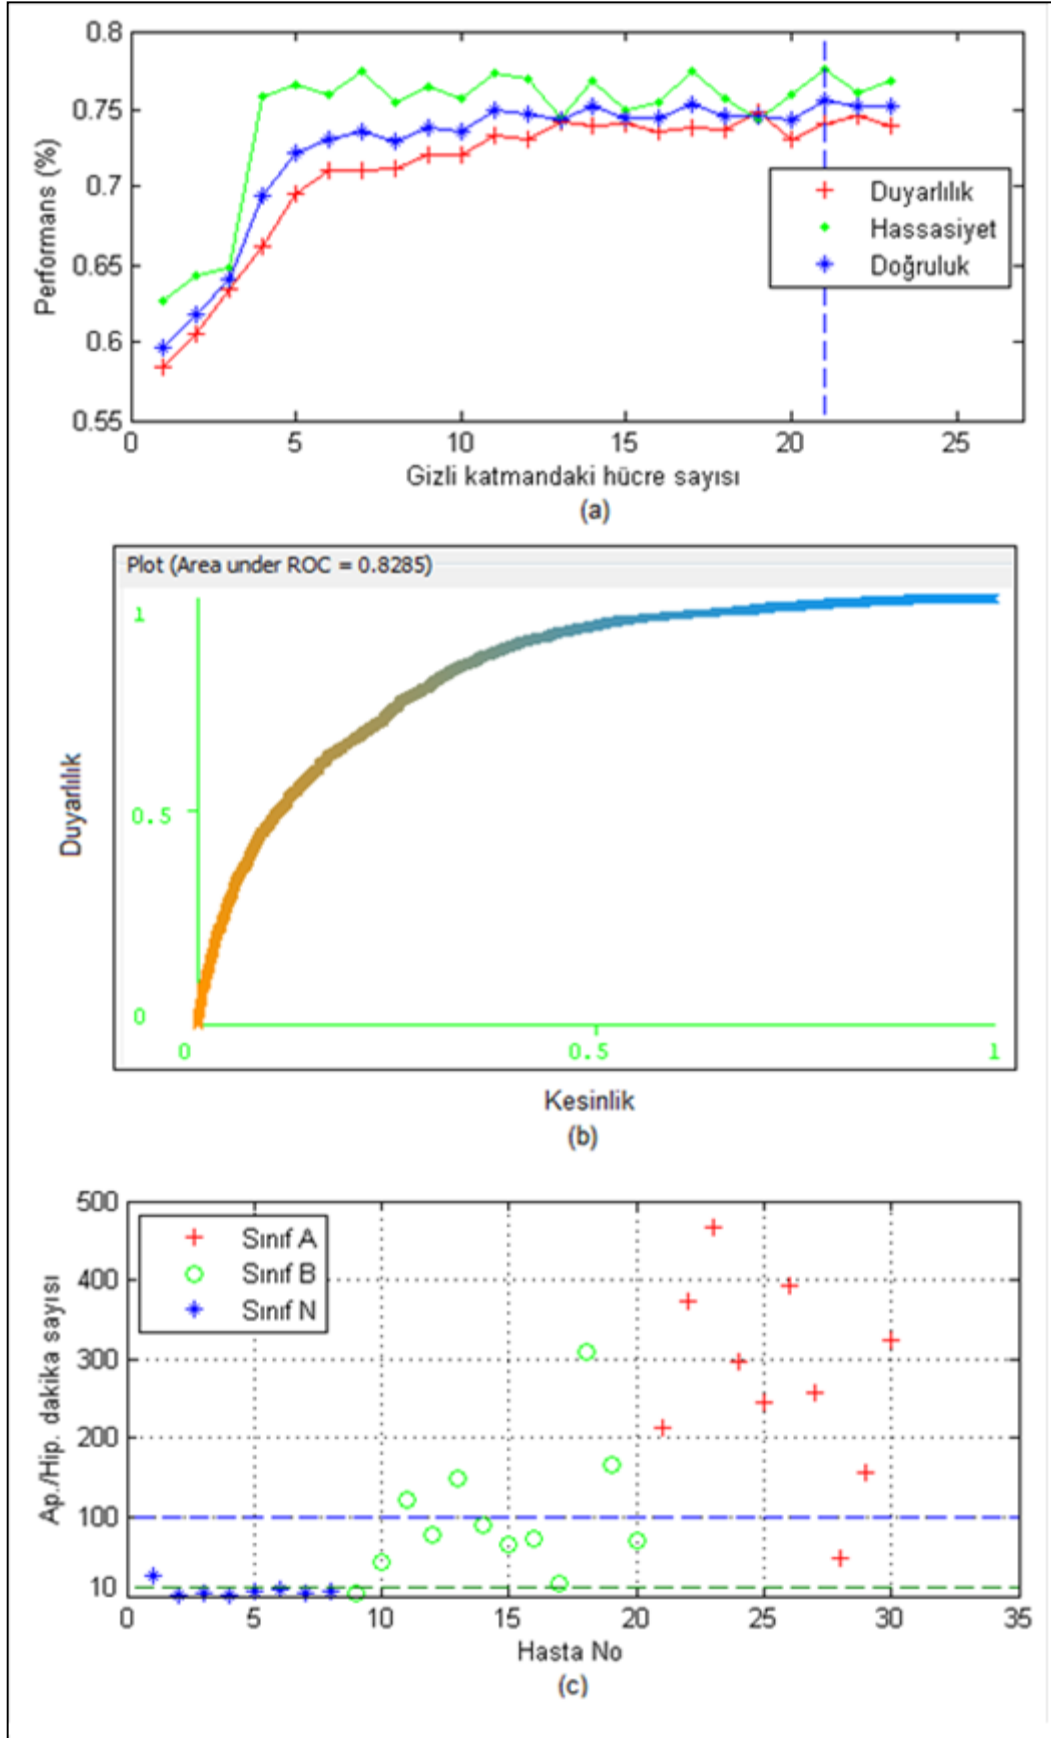
3.2.2. Model 6

KAHD sinyalinin zaman ve frekans uzayı analizi ile MLP sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir. Wrapper tabanlı öznelik seçimi metodu ile Tablo 3.2’de sunulan 16 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir. Farklı hücre sayısı değeri (1,2,3,...23) için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.9 ve Şekil 3.7.(a)’da verilmiştir. Gizli katmandaki hücre sayısının optimum değeri 21 olarak belirlenmiştir.

Tablo 3.9. Model 6, MLP için hücre sayısı belirleme

Hücre sayısı	Doğruluk	Duyarlılık	Keskinlik
1	0,59699	0,58421	0,62744
2	0,61847	0,60571	0,64354
3	0,64011	0,63457	0,64845
4	0,69445	0,66249	0,75789
5	0,72219	0,69575	0,76583
6	0,73036	0,71061	0,75978
7	0,73549	0,71061	0,77449
8	0,72892	0,71162	0,75403
9	0,73854	0,72034	0,76477
10	0,73581	0,72097	0,75653
11	0,74992	0,73320	0,77322
12	0,74703	0,73085	0,76956
13	0,74287	0,74137	0,74468
14	0,75184	0,73934	0,76851
15	0,74463	0,74052	0,74973
16	0,74383	0,73563	0,75441
17	0,75329	0,73813	0,77399
18	0,74591	0,73728	0,75707
19	0,74591	0,74814	0,74330
20	0,74287	0,73058	0,75940
21	0,75537	0,74013	0,77614
22	0,75232	0,74590	0,76041
23	0,75216	0,73975	0,76868

Belirlenen gizli katmandaki optimum hücre sayısı değeri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.7.(b)’deki ROC eğrisi elde edilmiştir. Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=10 ve Eşik 2=100 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.7.(c)’de çizdirilmiştir.



Şekil 3.7. Model 6 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.2.3. Model 7

KAHD sinyalinin zaman ve frekans uzayı analizi ile SVM sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Wrapper tabanlı öznelik seçimi metodu ile Tablo 3.2’de sunulan 8 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir.

Söz konusu seçilmiş öznelikler kullanılarak farklı değerlerdeki C ve γ parametreleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.10 ve Şekil 3.8.(a)’da verilmiştir.

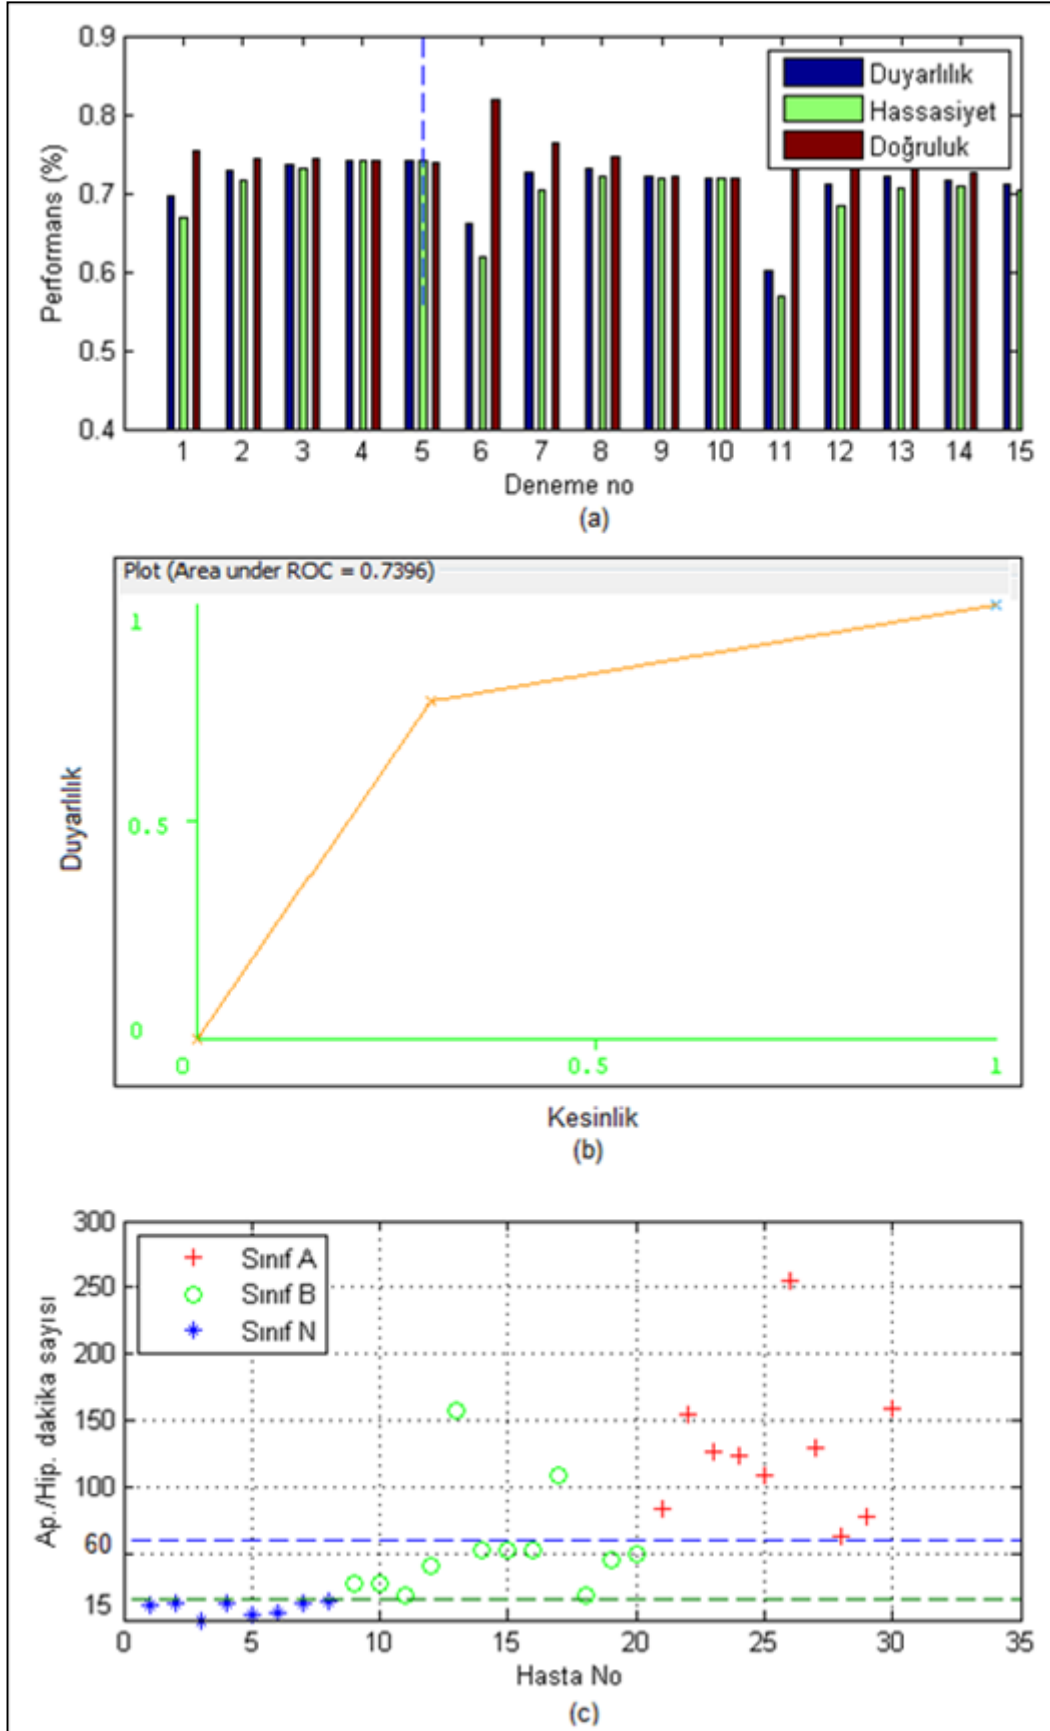
C ve γ parametreleri optimum değerleri sırasıyla 10 ve 0,1 olarak belirlenmiştir.

Tablo 3.10. Model 7, SVM için C ve γ parametreleri belirleme

Deneme No	C	γ	Doğruluk	Duyarlılık	Kesinlik
1	0,1	0,1	0,69750	0,66757	0,75405
2	0,5	0,1	0,72796	0,71667	0,74329
3	1	0,1	0,73661	0,73034	0,74462
4	5	0,1	0,74062	0,74230	0,73864
5	10	0,1	0,74110	0,74124	0,74094
6	0,1	0,5	0,66223	0,61793	0,81891
7	0,5	0,5	0,72716	0,70367	0,76400
8	1	0,5	0,73245	0,72230	0,74598
9	5	0,5	0,72042	0,71986	0,72111
10	10	0,5	0,71914	0,71933	0,71891
11	0,1	1	0,60035	0,56950	0,82176
12	0,5	1	0,71241	0,68434	0,76119
13	1	1	0,72058	0,70524	0,74267
14	5	1	0,71561	0,70822	0,72541
15	10	1	0,71032	0,70283	0,72033

Belirlenen parametre değerleri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.8.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=15 ve Eşik 2=60 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.8.(c)’de çizdirilmiştir.



Şekil 3.8. Model 7 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.2.4. Model 8

KAHD sinyalinin zaman ve frekans uzayı analizi ile C4.5 sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Wrapper tabanlı öznitelik seçimi metodu ile Tablo 3.2’de sunulan 7 öznitelikten oluşan en belirleyici öznitelik alt kümesi elde edilmiştir.

Söz konusu seçilmiş öznitelikler kullanılarak farklı değerlerdeki CF ve MS parametreleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.11 ve Şekil 3.9.(a)’da verilmiştir.

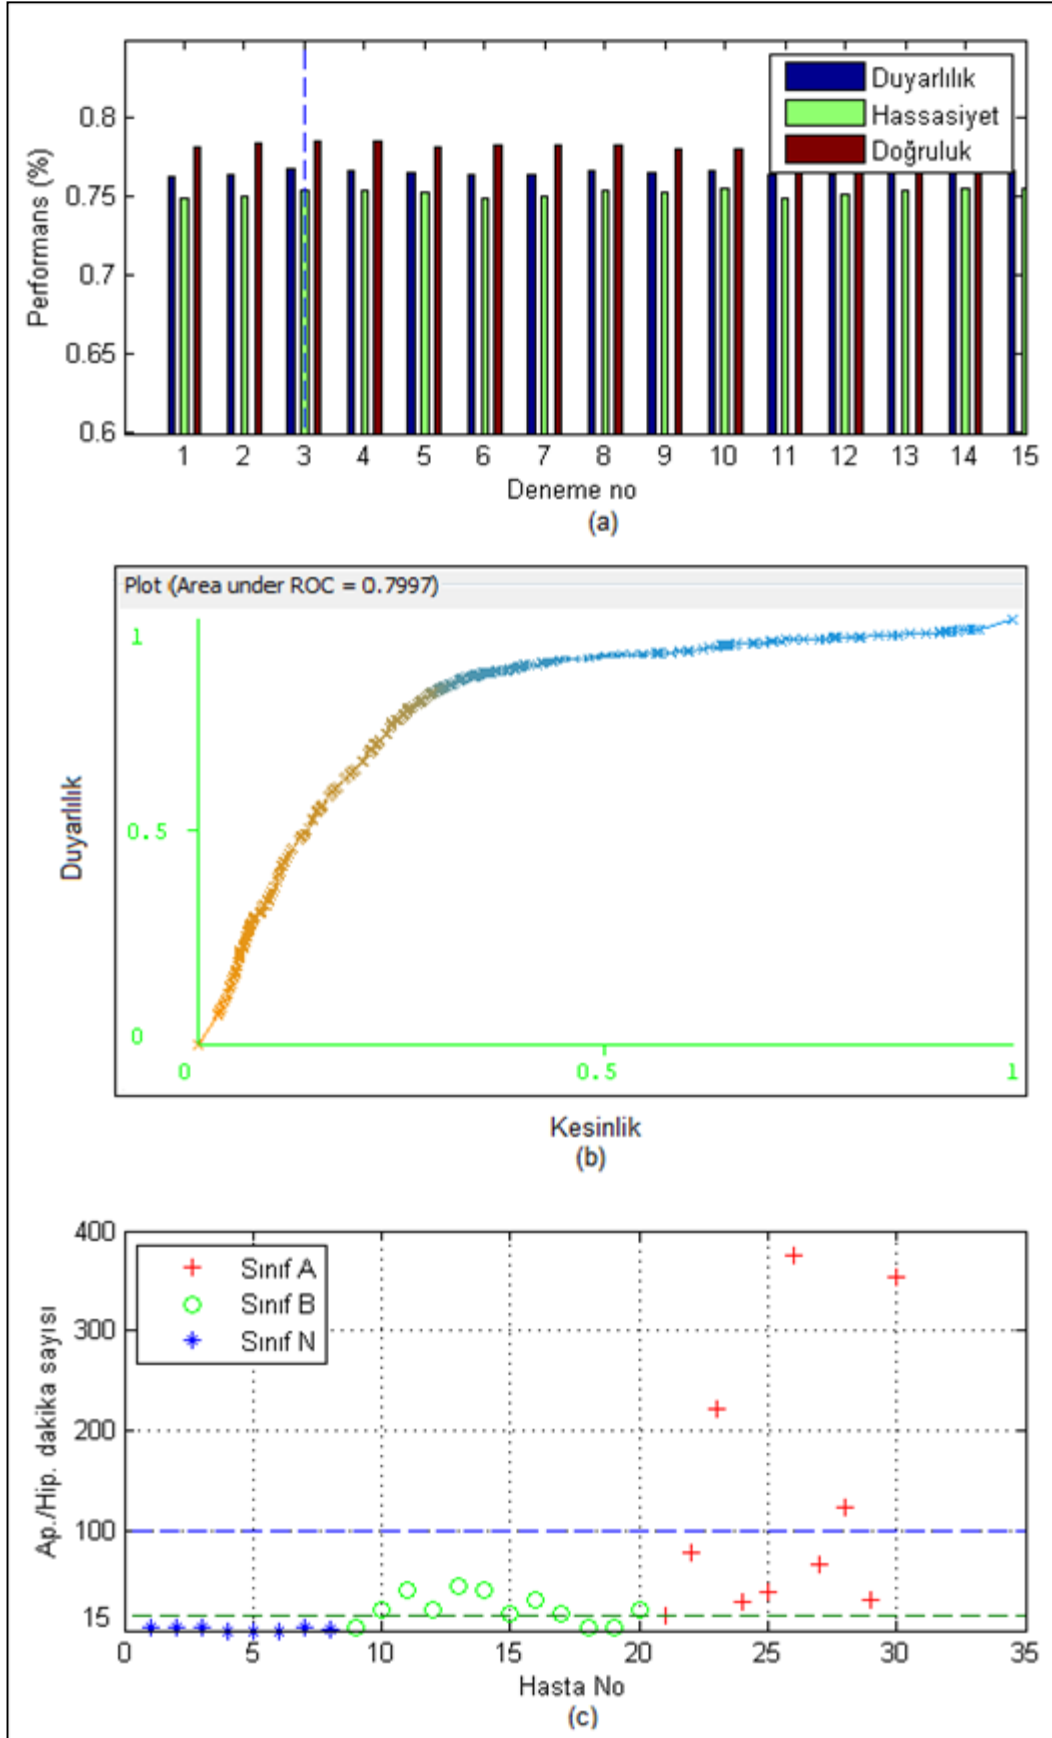
CF ve MS parametrelerinin optimum değerleri sırasıyla 0,1 ve 1 olarak belirlenmiştir.

Tablo 3.11. Model 8, C4.5 için CF ve MS parametreleri belirleme

Deneme No	CF	MS	Doğruluk	Duyarlılık	Kesinlik
1	0,01	1	0,76323	0,74923	0,78189
2	0,05	1	0,76499	0,75014	0,78491
3	0,1	1	0,76771	0,75430	0,78542
4	0,25	1	0,76739	0,75402	0,78505
5	0,5	1	0,76531	0,75297	0,78148
6	0,01	2	0,76403	0,74986	0,78293
7	0,05	2	0,76467	0,75070	0,78326
8	0,1	2	0,76659	0,75395	0,78317
9	0,25	2	0,76515	0,75333	0,78057
10	0,5	2	0,76643	0,75533	0,78080
11	0,01	3	0,76403	0,74986	0,78293
12	0,05	3	0,76435	0,75141	0,78141
13	0,1	3	0,76675	0,75431	0,78304
14	0,25	3	0,76707	0,75604	0,78133
15	0,5	3	0,76707	0,75604	0,78133

Belirlenen parametre değerleri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.9.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=15 ve Eşik 2=100 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.9.(c)’de çizdirilmiştir.



Şekil 3.9. Model 8 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.3. KAHD ve ETS Zaman Analizinden Elde Edilen Bulgular

KAHD ve ETS sinyallerinin zaman uzayı analizinden 17 adet öznitelik (Grup 3) elde edilmiştir. Grup 3 özniteliklerinin kullanıldığı Model 9-12'ye ait bulgular alt başlıklarda verilmiştir.

3.3.1. Model 9

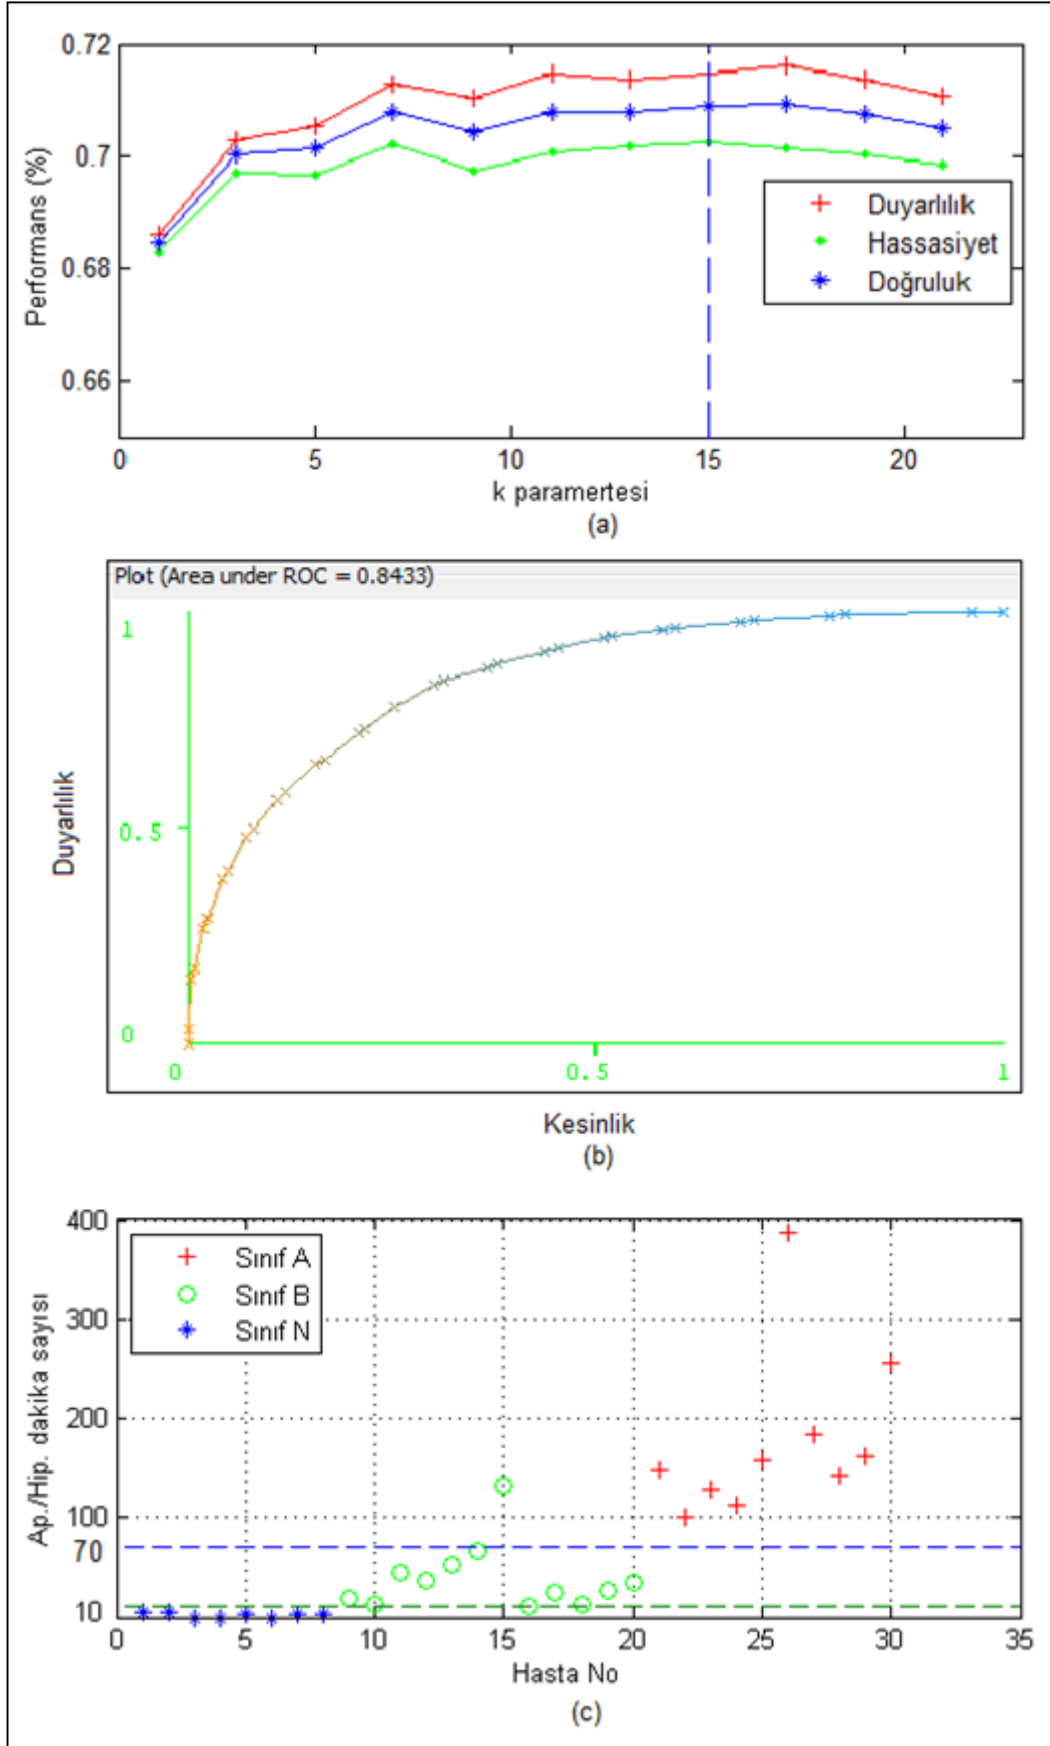
KAHD ve ETS sinyallerinin zaman uzayı analizi ile kNN sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir. Wrapper tabanlı öznitelik seçimi metodu k parametresi 5 seçilerek çalıştırılmış ve Tablo 3.2'de sunulan 10 öznitelikten oluşan en belirleyici öznitelik alt kümesi elde edilmiştir. Söz konusu seçilmiş özniteliklerden IQR ve RMSSD öznitelikleri kullanılarak farklı k değerleri (1,3,5,...,21) için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.12 ve Şekil 3.10.(a)'da verilmiştir.

Optimum k =15 olarak belirlenmiştir.

Tablo 3.12. Model 9, kNN için k parametresi belirleme

Deneme No	k parametresi	Doğruluk	Duyarlılık	Kesinlik
1	1	0,68451	0,68587	0,68289
2	3	0,70022	0,70301	0,69698
3	5	0,70135	0,70534	0,69676
4	7	0,70792	0,71308	0,70208
5	9	0,70423	0,71043	0,69728
6	11	0,70808	0,71459	0,70081
7	13	0,70808	0,71355	0,70191
8	15	0,70904	0,71485	0,70252
9	17	0,70920	0,71625	0,70139
10	19	0,70744	0,71385	0,70027
11	21	0,70519	0,71096	0,69870

Belirlenen optimum k değeri üzerinden eğitilen model performansı Tablo 3.3'te sunulmuş olup, Şekil 3.10.(b)'deki ROC eğrisi elde edilmiştir. Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=10 ve Eşik 2=70 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.10.(c)'de çizdirilmiştir.



Şekil 3.10. Model 9 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.3.2. Model 10

KAHD ve ETS sinyallerinin zaman uzayı analizi ile MLP sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Wrapper tabanlı öznitelik seçimi metodu ile Tablo 3.2’de sunulan 12 öznitelikten oluşan en belirleyici öznitelik alt kümesi elde edilmiştir.

Söz konusu seçilmiş öznitelikler kullanılarak farklı hücre sayısı değeri (1,3,5...23) için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.13 ve Şekil 3.11.(a)’da verilmiştir.

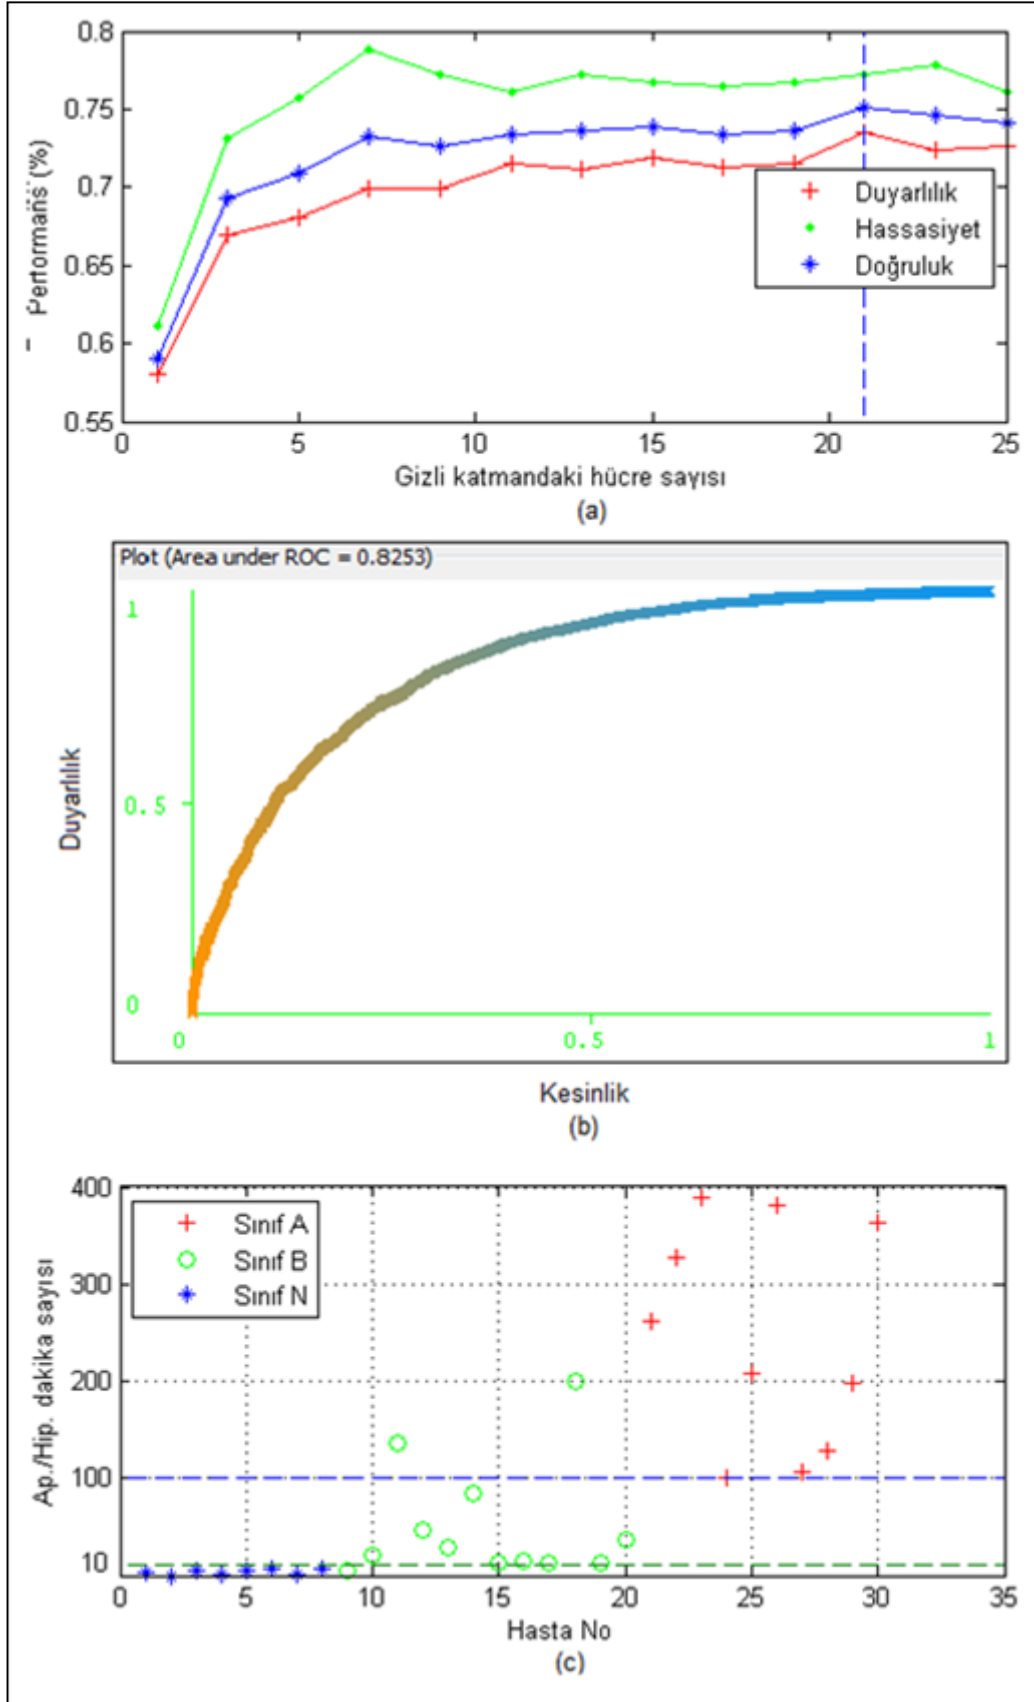
Gizli katmandaki hücre sayısının optimum değeri 21 olarak belirlenmiştir.

Tablo 3.13. Model 10, MLP için hücre sayısı belirleme

Hücre sayısı	Doğruluk	Duyarlılık	Kesinlik
1	0,59073	0,58080	0,61133
3	0,69253	0,66933	0,73079
5	0,70936	0,68103	0,75734
7	0,73261	0,69946	0,78877
9	0,72684	0,69873	0,77206
11	0,73421	0,71546	0,76074
13	0,73565	0,71154	0,77185
15	0,73886	0,71901	0,76708
17	0,73357	0,71224	0,76468
19	0,73661	0,71521	0,76769
21	0,75104	0,73516	0,77232
23	0,74591	0,72343	0,77843
25	0,74142	0,72651	0,76146

Belirlenen gizli katmandaki optimum hücre sayısı değeri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.11.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş Eşik 1=10 ve Eşik 2=100 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.11.(c)’de çizdirilmiştir.



Şekil 3.11. Model 10 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.3.3. Model 11

KAHD ve ETS sinyallerinin zaman uzayı analizi ile SVM sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Wrapper tabanlı öznelik seçimi metodu ile Tablo 3.2’de sunulan 4 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir.

Söz konusu seçilmiş öznelikler kullanılarak farklı değerlerdeki C ve γ parametreleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.14 ve Şekil 3.12.(a)’da verilmiştir.

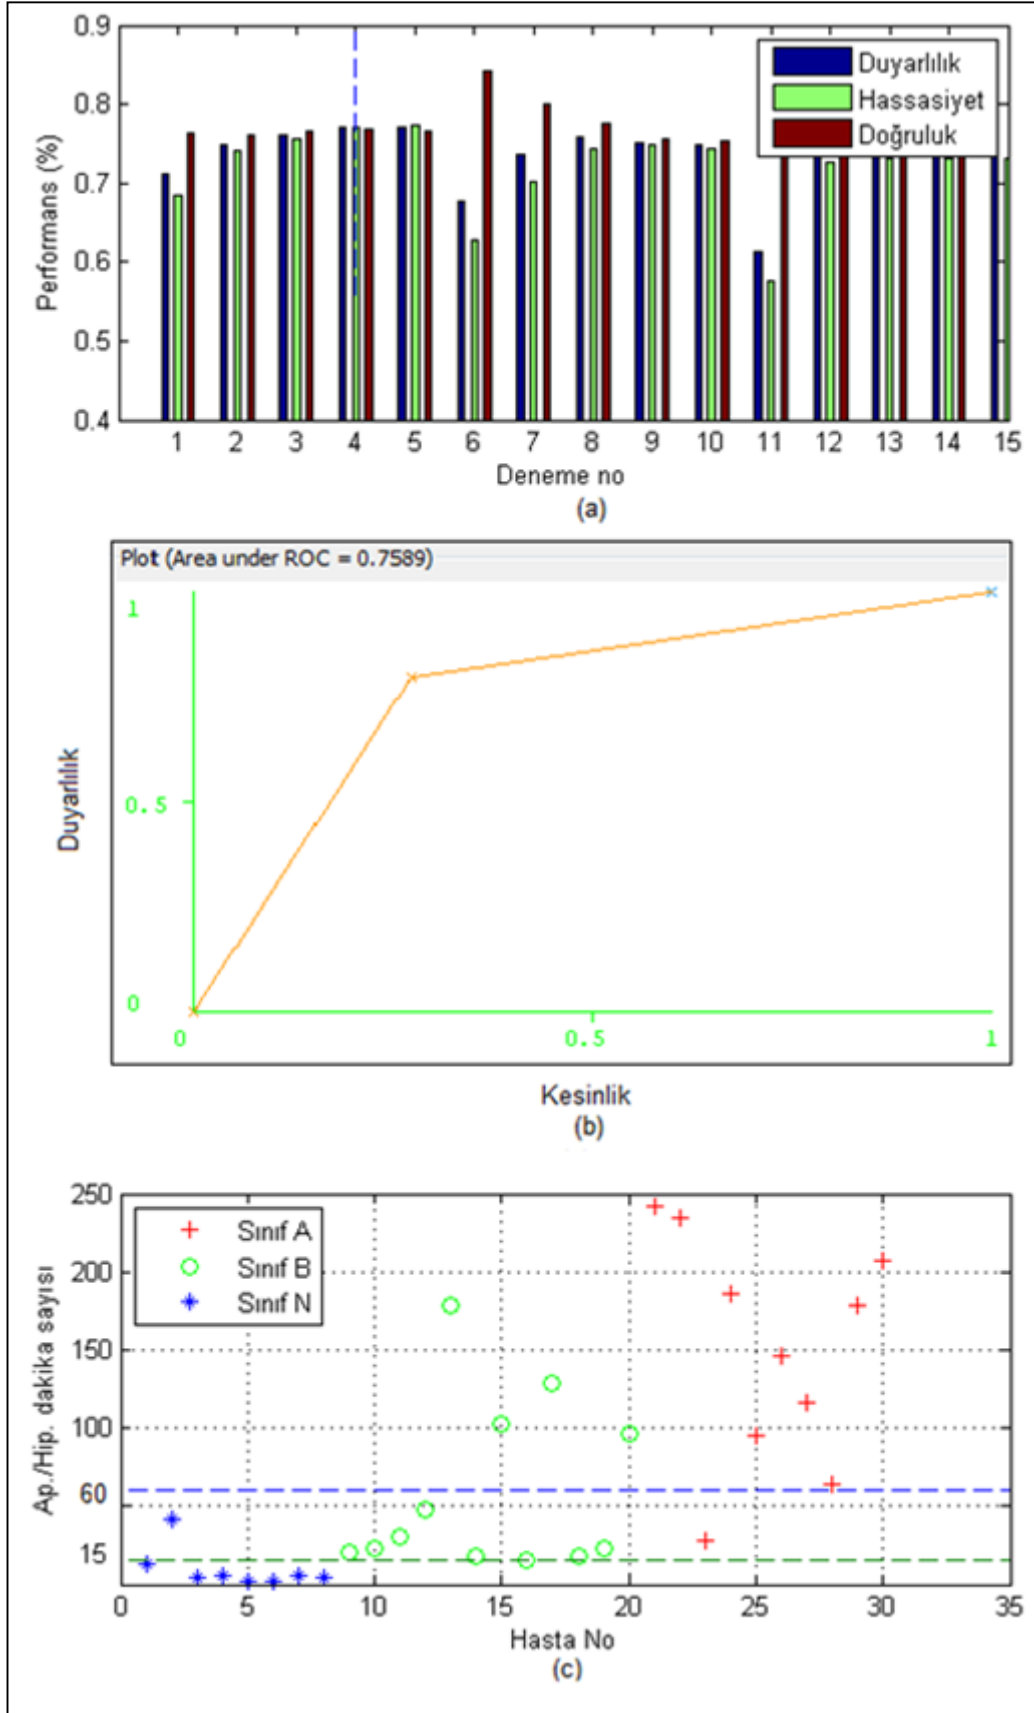
C ve γ parametreleri optimum değerleri sırasıyla 5 ve 0,1 olarak belirlenmiştir.

Tablo 3.14. Model 11, SVM için C ve γ parametreleri belirleme

Deneme No	C	γ	Doğruluk	Duyarlılık	Kesinlik
1	0,1	0,1	0,71257	0,68330	0,76234
2	0,5	0,1	0,74944	0,73994	0,76142
3	1	0,1	0,76018	0,75627	0,76483
4	5	0,1	0,76980	0,77071	0,76876
5	10	0,1	0,77012	0,77365	0,76618
6	0,1	0,5	0,67666	0,62688	0,84163
7	0,5	0,5	0,73742	0,70103	0,80097
8	1	0,5	0,75729	0,74383	0,77479
9	5	0,5	0,75200	0,74809	0,75669
10	10	0,5	0,74816	0,74412	0,75300
11	0,1	1	0,61189	0,57507	0,85181
12	0,5	1	0,75569	0,72708	0,79919
13	1	1	0,75152	0,73048	0,78121
14	5	1	0,74479	0,73171	0,76196
15	10	1	0,74239	0,73136	0,75661

Belirlenen parametre değerleri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.12.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=15 ve Eşik 2=60 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.12.(c)’de çizdirilmiştir.



Şekil 3.12. Model 11 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.3.4. Model 12

KAHD ve ETS sinyallerinin zaman uzayı analizi ile C4.5 sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Wrapper tabanlı öznelik seçimi metodu ile Tablo 3.2’de sunulan 8 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir.

Söz konusu seçilmiş öznelikler kullanılarak farklı değerlerdeki CF ve MS parametreleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.15 ve Şekil 3.13.(a)’da verilmiştir.

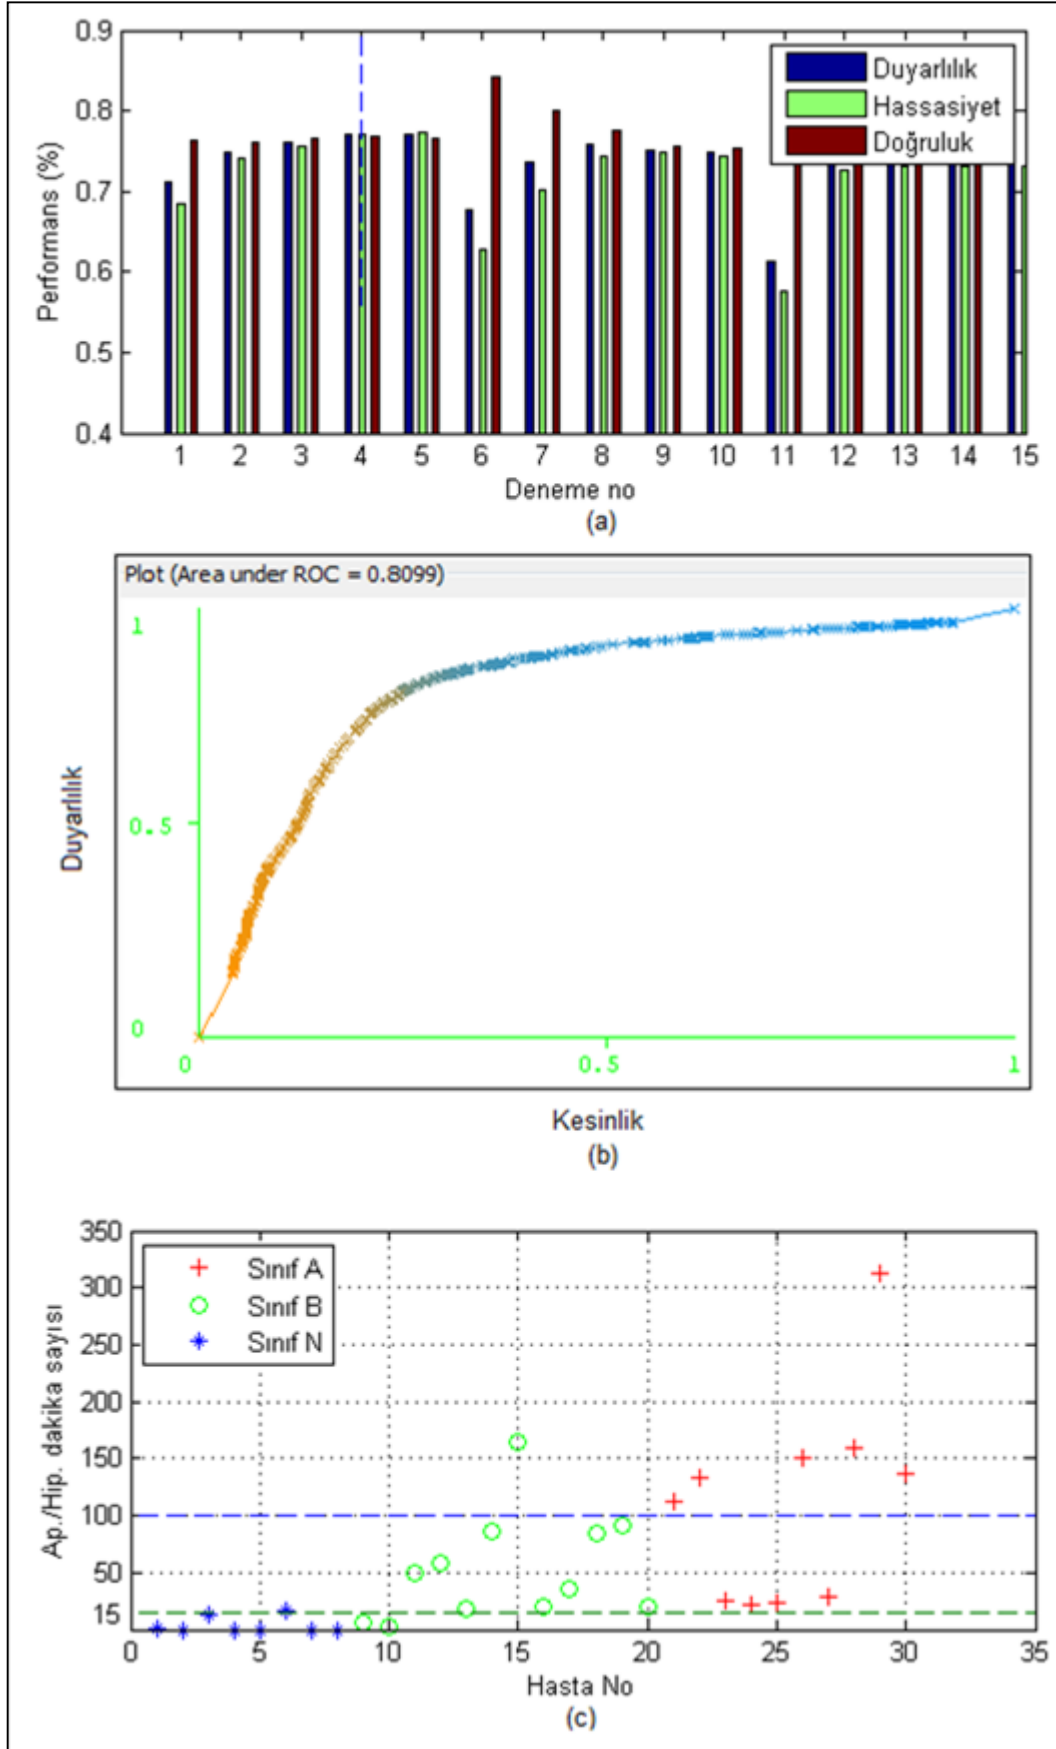
CF ve MS parametrelerinin optimum değerleri sırasıyla 0,1 ve 1 olarak belirlenmiştir.

Tablo 3.15. Model 12, C4.5 için CF ve MS parametreleri belirleme

Deneme No	CF	MS	Doğruluk	Duyarlılık	Kesinlik
1	0,01	1	0,77060	0,76131	0,78208
2	0,05	1	0,77749	0,77513	0,78024
3	0,1	1	0,77861	0,77774	0,77961
4	0,25	1	0,77685	0,77437	0,77974
5	0,5	1	0,77461	0,77196	0,77770
6	0,01	2	0,77060	0,76101	0,78248
7	0,05	2	0,77701	0,77460	0,77982
8	0,1	2	0,77797	0,77615	0,78008
9	0,25	2	0,77445	0,77189	0,77743
10	0,5	2	0,77156	0,76985	0,77355
11	0,01	3	0,77124	0,76098	0,78402
12	0,05	3	0,77637	0,77433	0,77874
13	0,1	3	0,77733	0,77572	0,77920
14	0,25	3	0,77493	0,77274	0,77747
15	0,5	3	0,77316	0,77151	0,77509

Belirlenen parametre değerleri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.13.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=10 ve Eşik 2=100 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.13.(c)’de çizdirilmiştir.



Şekil 3.13. Model 12 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.4. KAHD ve ETS Zaman ve Frekans Analizinden Elde Edilen Bulgular

KAHD ve ETS sinyallerinin zaman ve frekans uzayı analizinden 27 adet öznelik (Grup 4) elde edilmiştir. Grup 4 özneliklerinin kullanıldığı Model 13-16'ya ait bulgular alt başlıklarda verilmiştir.

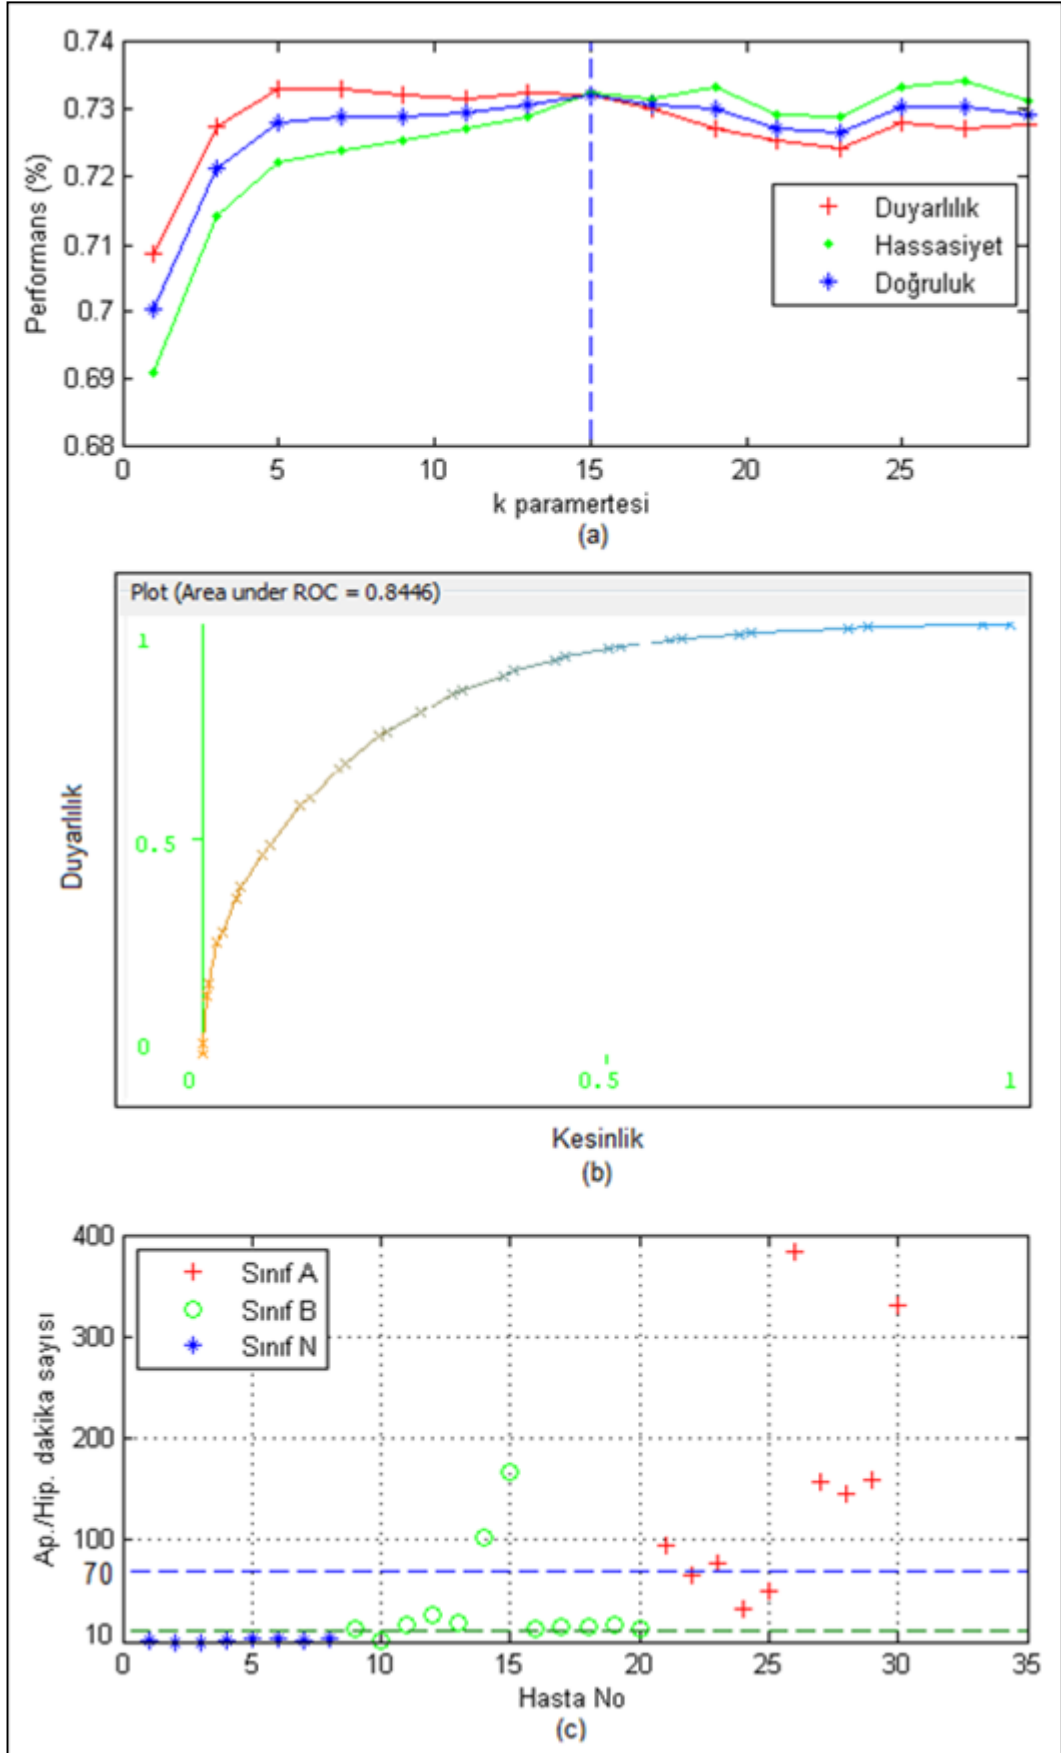
3.4.1. Model 13

KAHD ve ETS sinyallerinin zaman ve frekans uzayı analizi ile kNN sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir. Wrapper tabanlı öznelik seçimi metodu k parametresi 5 seçilerek çalıştırılmış ve Tablo 3.2'de sunulan 12 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir. Farklı k değerleri (1,3,5,...,25) için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.16 ve Şekil 3.14.(a)'da verilmiştir.

Tablo 3.16. Model 13, kNN için k parametresi belirleme

Deneme No	k parametresi	Doğruluk	Duyarlılık	Kesinlik
1	1	0,70038	0,70882	0,69112
2	3	0,72122	0,72761	0,71414
3	5	0,72796	0,73315	0,72215
4	7	0,72892	0,73321	0,72408
5	9	0,72908	0,73217	0,72556
6	11	0,72956	0,73158	0,72724
7	13	0,73084	0,73236	0,72909
8	15	0,73229	0,73211	0,73250
9	17	0,73084	0,73029	0,73149
10	19	0,73004	0,72719	0,73347
11	21	0,72716	0,72548	0,72916
12	23	0,72651	0,72436	0,72910
13	25	0,73052	0,72810	0,73343
14	27	0,73036	0,72709	0,73433
15	29	0,72940	0,72781	0,73130

Belirlenen optimum k değeri üzerinden eğitilen model performansı Tablo 3.3'te sunulmuş olup, Şekil 3.14.(b)'deki ROC eğrisi elde edilmiştir. Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=10 ve Eşik 2=70 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.14.(c)'de çizdirilmiştir.



Şekil 3.14. Model 13 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.4.2. Model 14

KAHD ve ETS sinyallerinin zaman ve frekans uzayı analizi ile MLP sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir. Wrapper tabanlı öznitelik seçimi metodu ile Tablo 3.2’de sunulan 20 öznitelikten oluşan en belirleyici öznitelik alt kümesi elde edilmiştir.

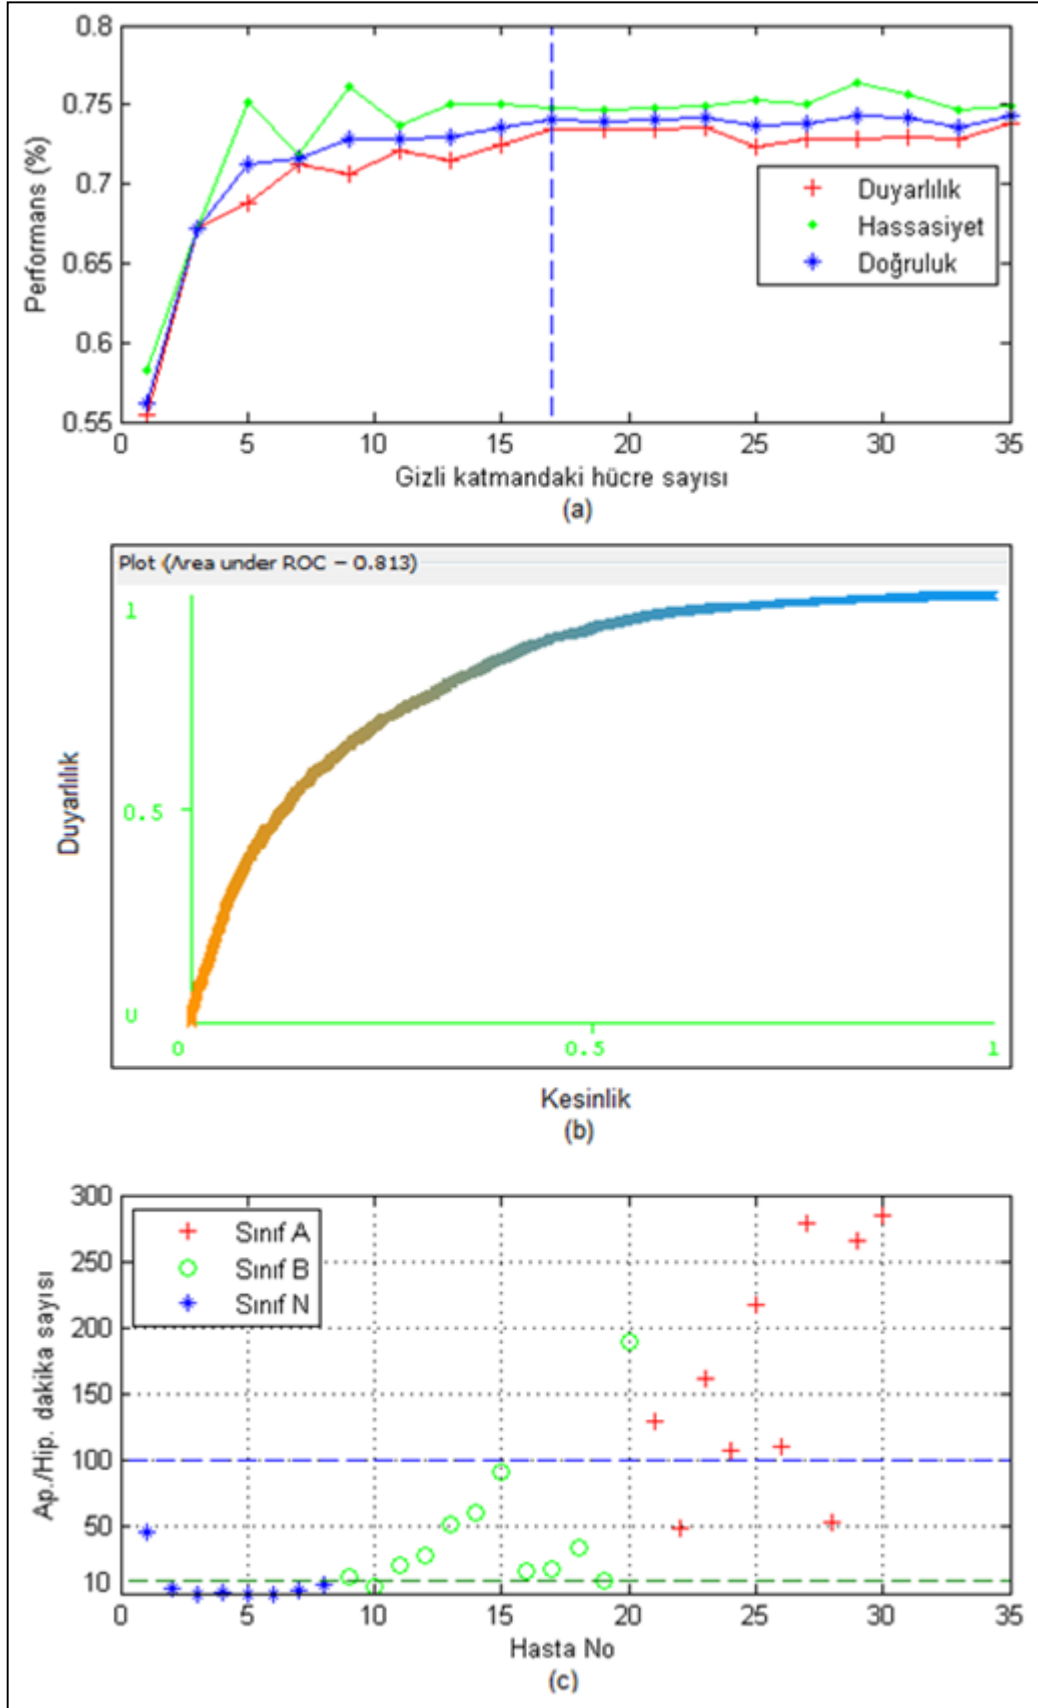
Söz konusu seçilmiş öznitelikler kullanılarak farklı hücre sayısı değeri (1,3,...,35) için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.17 ve Şekil 3.15.(a)’da verilmiştir. Gizli katmandaki hücre sayısının optimum değeri 17 olarak belirlenmiştir.

Tablo 3.17. Model 14, MLP için hücre sayısı belirleme

Hücre sayısı	Doğruluk	Duyarlılık	Kesinlik
1	0,562039115	0,554635	0,582577
3	0,671689644	0,671491	0,671937
5	0,712888746	0,688447	0,751658
7	0,715613979	0,712744	0,719117
9	0,728278294	0,706166	0,761164
11	0,728117987	0,721278	0,736709
13	0,729881372	0,714881	0,750379
15	0,736133376	0,725234	0,750276
17	0,740301379	0,734516	0,74741
19	0,739820455	0,734012	0,746962
21	0,740301379	0,734516	0,74741
23	0,741744149	0,735345	0,749642
25	0,736293684	0,72341	0,753353
27	0,738377685	0,72891	0,750456
29	0,742866303	0,727705	0,763247
31	0,741583841	0,73006	0,756538
33	0,735973068	0,727874	0,746193
35	0,743186919	0,738102	0,749378

Belirlenen gizli katmandaki optimum hücre sayısı değeri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.15.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=10 ve Eşik 2=100 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.15.(c)’de çizdirilmiştir.



Şekil 3.15. Model 14 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.4.3. Model 15

KAHD ve ETS sinyallerinin zaman ve frekans uzayı analizi ile SVM sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Bu kapsamda Wrapper tabanlı öznelik seçimi metodu ile Tablo 3.2’de sunulan 11 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir.

Farklı değerlerdeki C ve γ parametreleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.18 ve Şekil 3.16.(a)’da verilmiştir.

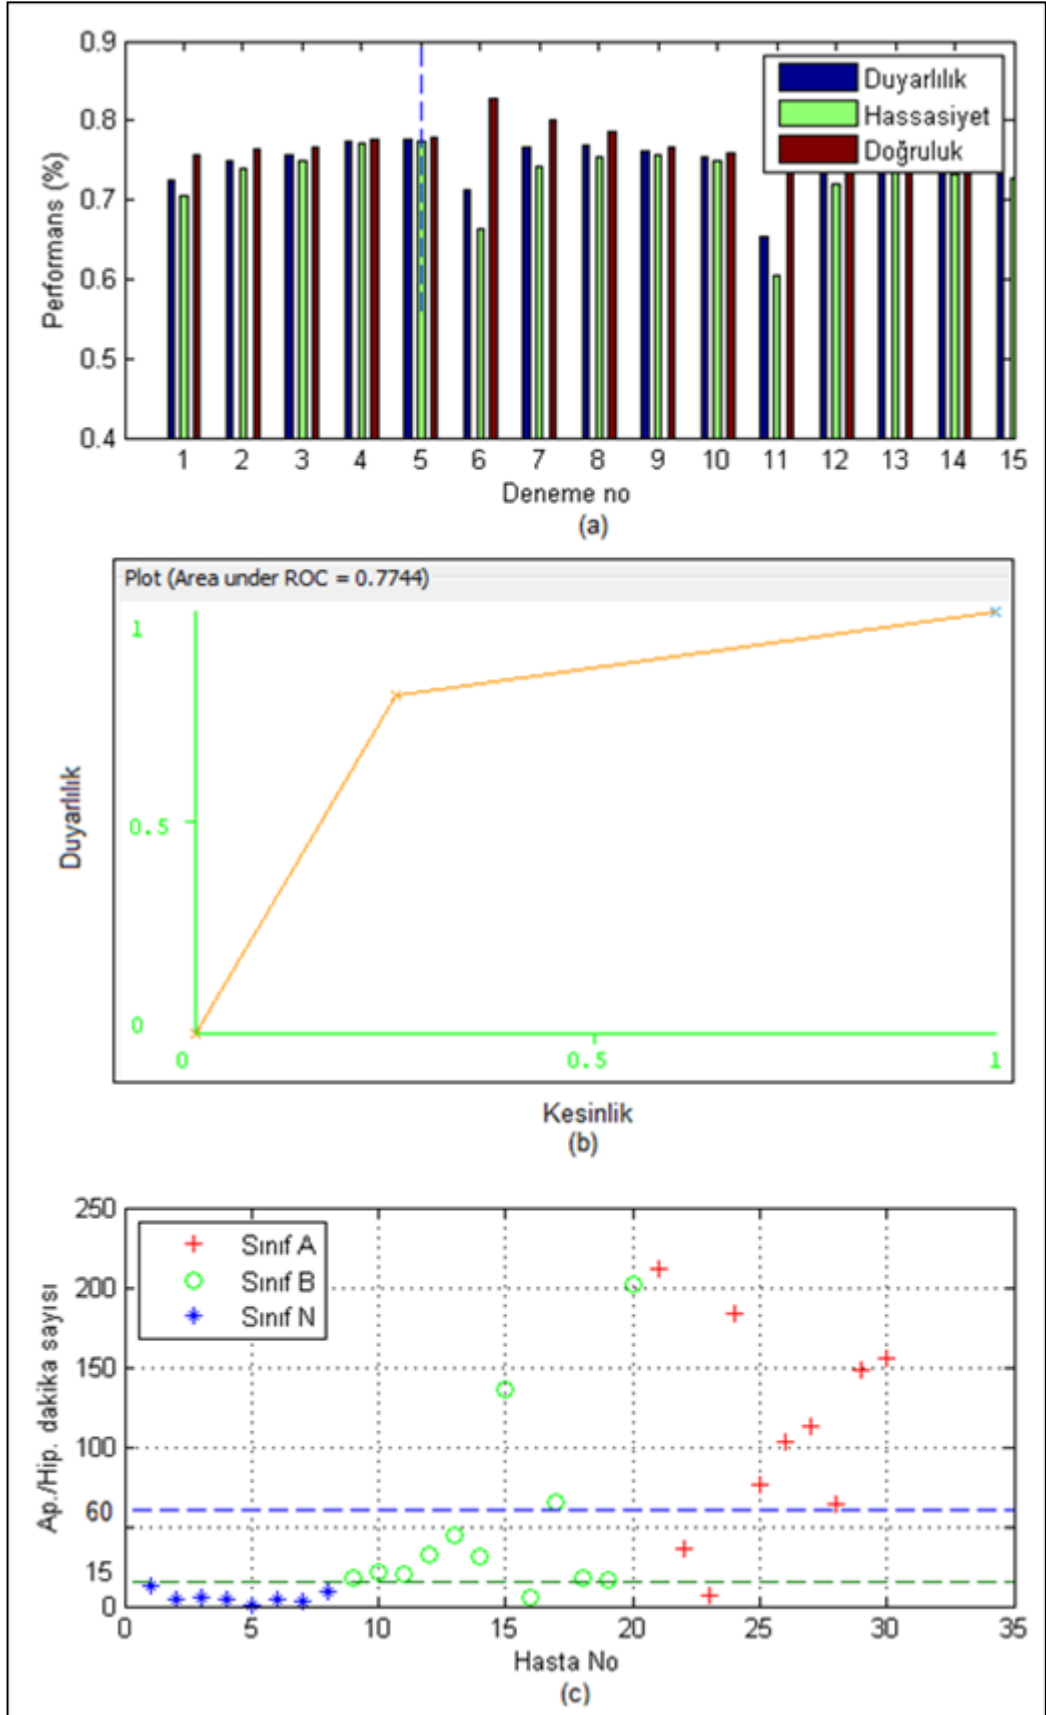
C ve γ parametreleri optimum değerleri sırasıyla 10 ve 0,1 olarak belirlenmiştir.

Tablo 3.18. Model 15, SVM için C ve γ parametreleri belirleme

Deneme No	C	γ	Doğruluk	Duyarlılık	Kesinlik
1	0,1	0,1	0,72539	0,70463	0,75594
2	0,5	0,1	0,75024	0,74032	0,76280
3	1	0,1	0,75729	0,75007	0,76615
4	5	0,1	0,77445	0,77189	0,77743
5	10	0,1	0,77541	0,77360	0,77751
6	0,1	0,5	0,71161	0,66295	0,82807
7	0,5	0,5	0,76643	0,74183	0,80164
8	1	0,5	0,76884	0,75520	0,78637
9	5	0,5	0,76130	0,75647	0,76709
10	10	0,5	0,75409	0,74978	0,75925
11	0,1	1	0,65325	0,60586	0,85557
12	0,5	1	0,75329	0,71864	0,81007
13	1	1	0,76339	0,74181	0,79347
14	5	1	0,74655	0,73333	0,76390
15	10	1	0,73998	0,72825	0,75526

Belirlenen parametre değerleri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.16.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=15 ve Eşik 2=60 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.16.(c)’de çizdirilmiştir.



Şekil 3.16. Model 15 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.4.4. Model 16

KAHD ve ETS sinyallerinin zaman ve frekans uzayı analizi ile C4.5 sınıflandırıcısının kullanılması üzerine oluşturulmuş bir örüntü tanıma sistemidir.

Wrapper tabanlı öznelik seçimi metodu ile 3.2’de sunulan 10 öznelikten oluşan en belirleyici öznelik alt kümesi elde edilmiştir.

Söz konusu seçilmiş öznelikler kullanılarak farklı değerlerdeki CF ve MS parametreleri için sınıflandırıcı performansları incelenmiş, sonuçları Tablo 3.17 ve Şekil 3.17.(a)’da verilmiştir.

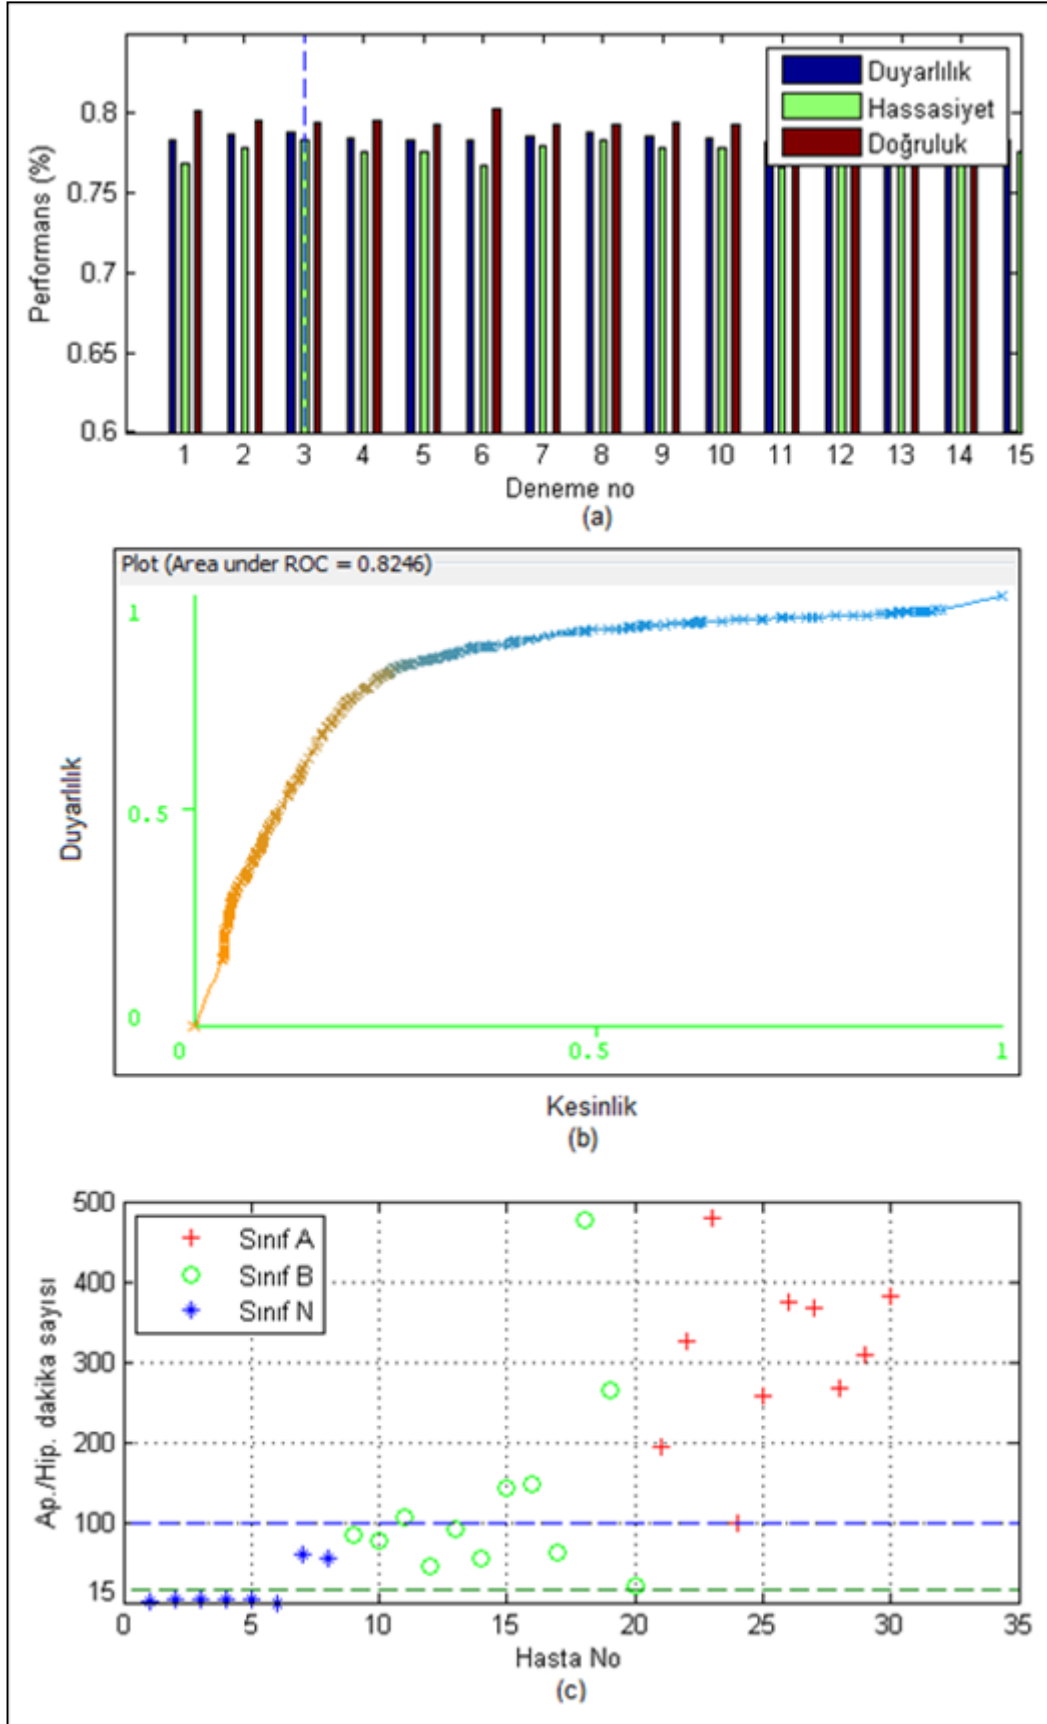
CF ve MS parametrelerinin optimum değerleri sırasıyla 0,1 ve 1 olarak belirlenmiştir.

Tablo 3.19. Model 16, C4.5 için CF ve MS parametreleri belirleme

Deneme No	CF	MS	Doğruluk	Duyarlılık	Kesinlik
1	0,01	1	0,78310	0,76842	0,80190
2	0,05	1	0,78631	0,77843	0,79582
3	0,1	1	0,78871	0,78370	0,79462
4	0,25	1	0,78455	0,77593	0,79503
5	0,5	1	0,78342	0,77547	0,79305
6	0,01	2	0,78278	0,76706	0,80309
7	0,05	2	0,78551	0,77892	0,79338
8	0,1	2	0,78759	0,78292	0,79309
9	0,25	2	0,78599	0,77863	0,79484
10	0,5	2	0,78503	0,77840	0,79296
11	0,01	3	0,78230	0,76551	0,80421
12	0,05	3	0,78615	0,77610	0,79850
13	0,1	3	0,78695	0,78266	0,79199
14	0,25	3	0,78358	0,77634	0,79230
15	0,5	3	0,78358	0,77537	0,79354

Belirlenen parametre değerleri üzerinden eğitilen model performansı Tablo 3.3’te sunulmuş olup, Şekil 3.17.(b)’deki ROC eğrisi elde edilmiştir.

Eğitim veri seti ile eğitilen modele test veri seti beslenerek her hasta için apne/hipopne tespit edilen dakika sayıları elde edilmiş ve Eşik 1=15 ve Eşik 2=100 değerlerine göre yapılan sınıflandırma sonucu Şekil 3.17.(c)’de çizdirilmiştir.



Şekil 3.17. Model 16 (a) Optimizasyon, (b) Eğitim ve (c) Sınıflandırma

3.5. Test Sonuçları

Test veritabanını oluşturan 30 hastaya ait kayıtlar uzman hekim tarafından belirlenen AHI değerleri ile teşhis sonucu dikkate alınarak üç farklı sınıfa ayrılmıştır. N sınıfı, uyku bozukluğu olmayan ve normal teşhisi konulmuş 8 hasta; B sınıfı, hafif derecede OUAS teşhisi konulmuş 12 hasta; A sınıfı, orta ve ağır derecede OUAS teşhisi konulmuş 10 hastadan oluşmaktadır.

Test veritabanındaki hastalara ait kayıtların oluşturulan modellerle test edilmesi sonrasında tespit edilen apne/hipopne içeren dakika sayıları, her model için belirlenen eşik seviyeleri üzerinden sınıflandırılmıştır.

Eşik 1, hastanın OUAS'lı olup olmadığının teşhisini sağlamaktadır. Uyku bozukluğu olmayan normal hastalar ile OUAS'lı olan hastaların ayırt edilmesi için kullanılan eşik değeridir. Eşik 1 değerinin üzerinde kalan hastalarda OUAS teşhisi pozitif, altında kalanlarda ise OUAS teşhisi negatif olarak kabul edilmiş olup bu gruptaki hastalar N sınıfı olarak sınıflandırılmıştır.

Eşik 2, OUAS'lı olarak tespit edilen hastaların derecelendirilmesi için kullanılan eşik değeridir. Eşik 2 üzerinde kalan hastalar orta/ağır derecede OUAS'lı (A sınıfı), Eşik 1 ile Eşik 2 arasında kalanlarda ise hafif derecede OUAS'lı (B sınıfı) olarak sınıflandırılmıştır.

Literatürdeki çalışmalar [12, 13, 16, 20] ve sınıflandırıcı performansları paralelinde Eşik 1 değeri kNN için 10, MLP için 10, SVM için 15 ve C4.5 için 15, Eşik 2 değeri ise kNN için 70, MLP için 100, SVM için 60 ve C4.5 için 100 olarak belirlenmiştir.

Oluşturulan 16 farklı örüntü tanıma modeli üzerinden yapılan çalışma ile elde edilen test sonuçları; OUAS teşhisi, OUAS derecelerinin belirlenmesi ve OUAS sınıflandırma bakımından incelenmiş olup kullanılan sinyal/sinyallerden elde edilen öznelik gurubu, sınıflandırıcılar ve hasta sınıfları bazındaki başarımların bakış açılarıyla ele alınarak alt başlıklarda sunulmuştur.

3.5.1. OUAS teşhisi sonuçları

Modellerden elde edilen test sonuçları test veritabanındaki 30 hastanın (22 OUAS'lı ve 8 Normal) OUAS teşhisi amacıyla Eşik 1 değerlerine göre ayrıştırılmıştır. Eşik

1'in altında kalan hastalar OUAS negatif, üzerinden kalan hastalar ise OUAS pozitif olarak belirlenmiştir. Tablo 3.20'de testlerden elde edilen teşhis sonuçlarına göre oluşturulan karmaşıklık matrisi (confusion matrix) sunulmuştur.

Tablo 3.20. OUAS teşhisi karmaşıklık matrisi

Test Sonucu	Gerçek Teşhis	
	OUAS	Normal
OUAS	GP	YP
Normal	YN	GN

Teşhis sonuçlarına göre oluşturulan karmaşıklık matrisine ait değerler sırasıyla; GP, gerçekte OUAS'lı olan ve modelin de OUAS pozitif sonucunu verdiği toplam olgu sayısı; GN, gerçekte OUAS'lı olmayan normal hastaları ve modelin de OUAS negatif sonucunu verdiği toplam olgu sayısı; YP, gerçekte OUAS'lı olmayan fakat modelin OUAS pozitif sonucunu verdiği toplam olgu sayısı ve YN gerçekte OUAS'lı olan fakat modelin OUAS negatif sonucunu verdiği toplam olgu sayısıdır.

OUAS teşhisi ile ilgili sonuçlar modellerde kullanılan öznitelik grupları ile kullanılan sınıflandırıcılar bazında olmak üzere iki başlıkta ele alınmıştır. EKG sinyalinden türetilen KAHD ve ETS sinyallerinin zaman ve frekans uzaylarındaki analizleri ile elde edilen ve modellerde giriş verisi olarak kullanılan öznitelikler Bölüm 3'te açıklanan dört grup altında toplanmıştır.

Grup bazlı OUAS teşhis sonuçlarının analizi ile hangi grup özniteliğinin OUAS teşhisinde daha etkin olduğunun belirlenmesi hedeflenmiştir. Testler sonucunda elde edilen grup bazlı OUAS teşhis sonuçları Tablo 3.21'de sunulmuştur.

OUAS teşhis sonuçlarının grup bazlı olarak incelenmesinin yanı sıra sınıflandırıcı bazında da analiz edilmesiyle hangi sınıflandırıcının OUAS teşhisinde daha etkin olduğunun belirlenmesi hedeflenmiştir. Bu kapsamda Bölüm 1.9'da detaylı olarak sunulan ve modellerde kullanılan 4 farklı sınıflandırıcının testler sonucunda elde edilen OUAS teşhis sonuçları Tablo 3.22'de sunulmuştur.

Tablo 3.21. Grup bazlı OUAS teşhis sonuçları

Grup	Model	Sınıfl.	Test Sonucu	Gerçek Teşhis		Doğruluk	Duyarlılık	Kesinlik
				OUAS	Normal			
1	1	kNN	OUAS	22	0	%96,7	%95,7	%100
			Normal	1	7			
	2	MLP	OUAS	22	0	%96,7	%95,7	%100
			Normal	1	7			
3	SVM	OUAS	22	0	%96,7	%95,7	%100	
		Normal	1	7				
4	C4.5	OUAS	20	2	%90,0	%95,2	%77,8	
		Normal	1	7				
Ortalama						%95,0	%95,5	%94,4
2	5	kNN	OUAS	22	0	%96,7	%95,7	%100
			Normal	1	7			
	6	MLP	OUAS	21	1	%93,3	%95,5	%87,5
			Normal	1	7			
7	SVM	OUAS	22	0	%100	%100	%100	
		Normal	0	8				
8	C4.5	OUAS	18	4	%86,7	%100	%66,7	
		Normal	0	8				
Ortalama						%94,2	%97,8	%88,5
3	9	kNN	OUAS	22	0	%100	%100	%100
			Normal	0	8			
	10	MLP	OUAS	21	1	%96,7	%100	%88,9
			Normal	0	8			
11	SVM	OUAS	22	0	%96,7	%95,7	%100	
		Normal	1	7				
12	C4.5	OUAS	20	2	%90,0	%95,2	%77,8	
		Normal	1	7				
Ortalama						%95,8	%97,7	%91,7
4	13	kNN	OUAS	21	1	%96,7	%100	%88,9
			Normal	0	8			
	14	MLP	OUAS	20	2	%90,0	%95,2	%77,8
			Normal	1	7			
15	SVM	OUAS	20	2	%93,3	%100	%80,0	
		Normal	0	8				
16	C4.5	OUAS	22	0	%93,3	%91,7	%100	
		Normal	2	6				
Ortalama						%93,3%	%96,7	%86,7

Tablo 3.22. Sınıflandırıcı bazlı OUAS teşhis sonuçları

Sınıflandırıcı	Model	Test Sonucu	Gerçek Teşhis		Doğruluk	Duyarlılık	Kesinlik	
			OUAS	Normal				
kNN	1	OUAS	22	0	%96,7	%95,7	%100	
		Normal	1	7				
	5	OUAS	22	0	%96,7	%95,7	%100	
		Normal	1	7				
	9	OUAS	22	0	%100	%100	%100	
		Normal	0	8				
	13	OUAS	21	1	%96,7	%100	%88,9	
		Normal	0	8				
				Ortalama		%97,5	%97,8	%97,2
	MLP	2	OUAS	22	0	%96,7	%95,7	%100
			Normal	1	7			
		6	OUAS	21	1	%93,3	%95,5	%87,5
Normal			1	7				
10		OUAS	21	1	%96,7	%100	%88,9	
		Normal	0	8				
14		OUAS	20	2	%90,0	%95,2	%77,8	
		Normal	1	7				
			Ortalama		%94,2	%96,6	%88,5	
SVM		3	OUAS	22	0	%96,7	%95,7	%100
			Normal	1	7			
		7	OUAS	22	0	%100	%100	%100
	Normal		0	8				
	11	OUAS	22	0	%96,7	%95,7	%100	
		Normal	1	7				
	15	OUAS	20	2	%93,3	%100	%80,0	
		Normal	0	8				
				Ortalama		%96,7	%97,8	%95,0
	C4.5	4	OUAS	20	2	%90,0	%95,2	%77,8
			Normal	1	7			
		8	OUAS	18	4	%86,7	%100	%66,7
Normal			0	8				
12		OUAS	20	2	%90,0	%95,2	%77,8	
		Normal	1	7				
16		OUAS	22	0	%93,3	%91,7	%100	
			2	6				
			Ortalama		%90,0	%95,5	%80,6	

3.5.2. OUAS derecelerinin belirlenmesi sonuçları

Test veritabanındaki hastaların OUAS derecelerinin belirlenmesi amacıyla modellerden elde edilen test sonuçları Eşik 2 değerlerine göre ayrıştırılmıştır. Test veritabanında 10 orta/ağır derecede OUAS'lı (A sınıfı), 12 hafif derecede OUAS'lı (B sınıfı) ve 8 OUAS bulunmayan normal hasta (N sınıfı) olmak üzere 30 hasta bulunmaktadır. Test sonucunda sınıflandırıcıların Eşik 2 değeri üzerinde kalan hastalar A sınıfı, Eşik 1 ile Eşik 2 arasında kalan hastalar B sınıfı, Eşik 1 değeri altında kalan hastalar ise N sınıfı olarak belirlenmiştir. OUAS derecelerinin belirlenmesi sonuçlarının analizi, A sınıf hastalar ile B sınıfı hastaların tespitindeki grup bazlı ve sınıflandırıcı bazlı başarımların ayrı ayrı incelenmesiyle yapılmıştır. A sınıfı hastaların tespitindeki başarımın belirlenmesi amacıyla testlerden elde edilen sonuçlara göre oluşturulan karmaşıklık matrisi Tablo 3.23'te sunulmuştur.

Tablo 3.23. A sınıfı hastaların karmaşıklık matrisi

Test Sonucu	Gerçek Teşhis	
	A sınıfı	Diğer
A sınıfı	GP	YP
Diğer	YN	GN

A sınıfı hastaların tespit sonuçlarına göre oluşturulan karmaşıklık matrisine ait değerler sırasıyla; GP, gerçekte A sınıfı olan (10 tane) ve modelin de A sınıfı sonucunu verdiği toplam olgu sayısı; GN, gerçekte A sınıfı olmayan (20 tane) ve modelin de A sınıfı değildir (Diğer) sonucunu verdiği toplam olgu sayısı; YP, gerçekte A sınıfı olmayan fakat modelin A sınıfı sonucunu verdiği toplam olgu sayısı ve YN, gerçekte A sınıfı olan fakat modelin A sınıfı değildir sonucunu verdiği toplam olgu sayısıdır.

OUAS derecelerinin sınıflandırması kapsamında A sınıfı hastaların tespiti ile ilgili sonuçlar modellerde kullanılan öznitelik grupları ile kullanılan sınıflandırıcılar bazında olmak üzere iki başlıkta ele alınmıştır. A sınıfı hastaların grup bazlı tespit sonuçları Tablo 3.24'te, sınıflandırıcı bazlı sonuçları ise Tablo 3.25'te sunulmuştur.

Tablo 3.24. Grup bazlı orta/ağır derecede OUAS'lı (A sınıfı) tespit sonuçları

Grup	Model	Sınıflr.	Test Sonucu	Gerçek Teşhis		Doğruluk	Duyarlılık	Kesinlik
				A sınıfı	Diğer			
1	1	kNN	A sınıfı	10	2	%93,3	%100	%90,0
			Diğer	0	18			
	2	MLP	A sınıfı	10	4	%86,7	%100	%80,0
			Diğer	0	16			
	3	SVM	A sınıfı	10	4	%86,7	%100	%80,0
			Diğer	0	16			
	4	C4.5	A sınıfı	6	2	%80,0	%60,0	%90,0
			Diğer	4	18			
Ortalama						%86,7	%90,0	%85,0
2	5	kNN	A sınıfı	10	1	%96,7	%100	%95,0
			Diğer	0	19			
	6	MLP	A sınıfı	9	4	%83,3	%90,0	%80,0
			Diğer	1	16			
	7	SVM	A sınıfı	10	2	%93,3	%100	%90,0
			Diğer	0	18			
	8	C4.5	A sınıfı	4	0	%80,0	%40,0	%100
			Diğer	6	20			
Ortalama						%88,3	%82,5	%91,3
3	9	kNN	A sınıfı	10	1	%96,7	%100	%95,0
			Diğer	0	19			
	10	MLP	A sınıfı	10	2	%93,3	%100	%90,0
			Diğer	0	18			
	11	SVM	A sınıfı	9	4	%83,3	%90,0	%80,0
			Diğer	1	16			
	12	C4.5	A sınıfı	6	1	%83,3	%60,0	%95,0
			Diğer	4	19			
Ortalama						%89,2	%87,5	%90,0
4	13	kNN	A sınıfı	7	2	%83,3	%70,0	%90,0
			Diğer	3	18			
	14	MLP	A sınıfı	8	1	%90,0	%80,0	%95,0
			Diğer	2	19			
	15	SVM	A sınıfı	8	3	%83,3	%80,0	%85,0
			Diğer	2	17			
	16	C4.5	A sınıfı	9	5	%80,0	%90,0	%75,0
			Diğer	1	15			
Ortalama						%84,2	%80,0	%86,3

Tablo 3.25. Sınıflandırıcı bazlı orta/ağır OUAS (A sınıfı) tespit sonuçları

Sınıflandırıcı	Model	Test Sonucu	Gerçek Teşhis		Doğruluk	Duyarlılık	Kesinlik	
			OUAS	Normal				
kNN	1	A sınıfı	10	2	%93,3	%100	%90,0	
		Diğer	0	18				
	5	A sınıfı	10	1	%96,7	%100	%95,0	
		Diğer	0	19				
	9	A sınıfı	10	1	%96,7	%100	%95,0	
		Diğer	0	19				
	13	A sınıfı	7	2	%83,3	%70,0	%90,0	
		Diğer	3	18				
	Ortalama					%92,5	%92,5	%92,5
	MLP	2	A sınıfı	10	4	%86,7	%100	%80,0
Diğer			0	16				
6		A sınıfı	9	4	%83,3	%90,0	%80,0	
		Diğer	1	16				
10		A sınıfı	10	2	%93,3	%100	%90,0	
		Diğer	0	18				
14		A sınıfı	8	1	%90,0	%80,0	%95,0	
		Diğer	2	19				
Ortalama					%88,3	%92,5	%86,3	
SVM		3	A sınıfı	10	4	%86,7	%100	%80,0
	Diğer		0	16				
	7	A sınıfı	10	2	%93,3	%100	%90,0	
		Diğer	0	18				
	11	A sınıfı	9	4	%83,3	%90,0	%80,0	
		Diğer	1	16				
	15	A sınıfı	8	3	%83,3	%80,0	%85,0	
		Diğer	2	17				
	Ortalama					%86,7	%92,5	%83,8
	C4.5	4	A sınıfı	6	2	%80,0	%60,0	%90,0
Diğer			4	18				
8		A sınıfı	4	0	%80,0	%40,0	%100	
		Diğer	6	20				
12		A sınıfı	6	1	%83,3	%60,0	%95,0	
		Diğer	4	19				
16		A sınıfı	9	5	%80,0	%90,0	%75,0	
		Diğer	1	15				
Ortalama					%85,0	%86,3	%84,4	

Grup 2 özniteliklerinin kNN ile sınıflandırılmasını sağlayan Model 5 ve Grup 3 özniteliklerinin kNN ile sınıflandırılmasını sağlayan Model 9, A sınıfını yaklaşık %97 doğrulukta belirleme başarısı sağlamıştır.

OUAS derecelerinin sınıflandırması kapsamında B sınıfı (hafif derecede OUAS'lı) hastaların tespiti ile ilgili sonuçlar modellerde kullanılan öznitelik grupları ile kullanılan sınıflandırıcılar bazında olmak üzere iki başlıkta ele alınmıştır.

B sınıfı hastaların tespitindeki başarımın belirlenmesi amacıyla testlerden elde edilen sonuçlara göre oluşturulan karmaşıklık matrisi Tablo 3.26'da sunulmuştur.

Tablo 3.26. B sınıfı hastaların karmaşıklık matrisi

Test Sonucu	Gerçek Teşhis	
	B sınıfı	Diğer
B sınıfı	GP	YP
Diğer	YN	GN

B sınıfı hastaların tespit sonuçlarına göre oluşturulan karmaşıklık matrisine ait değerler sırasıyla; GP, gerçekte B sınıfı olan (12 tane) ve modelin de B sınıfı sonucunu verdiği toplam olgu sayısı; GN, gerçekte B sınıfı olmayan (18 tane) ve modelin de B sınıfı değildir (Diğer) sonucunu verdiği toplam olgu sayısı; YP, gerçekte B sınıfı olmayan fakat modelin B sınıfı sonucunu verdiği toplam olgu sayısı ve YN, gerçekte B sınıfı olan fakat modelin B sınıfı değildir sonucunu verdiği toplam olgu sayısıdır.

OUAS derecelerinin sınıflandırması kapsamında B sınıfı hastaların tespiti ile ilgili sonuçlar modellerde kullanılan öznitelik grupları ile kullanılan sınıflandırıcılar bazında olmak üzere iki başlıkta ele alınmıştır.

B sınıfı hastaların grup bazlı tespit sonuçları Tablo 3.27'de, sınıflandırıcı bazlı sonuçları ise Tablo 3.28'de sunulmuştur.

Grup 3 özniteliklerinin kNN ile sınıflandırılmasını sağlayan Model 9 ise B sınıfını yaklaşık %97 doğrulukta belirleme başarısı sağlamıştır.

Tablo 3.27. Grup bazlı hafif derecede OUAS'lı (B sınıfı) tespit sonuçları

Grup	Model	Sınıflandırıcı	Test Sonucu	Gerçek Teşhis		Doğruluk	Duyarlılık	Kesinlik
				B sınıfı	Diğer			
1	1	kNN	B sınıfı	10	1	%90,0	%83,3	%94,4
			Diğer	2	17			
	2	MLP	B sınıfı	9	0	%90,0	%75,0	%100
			Diğer	3	18			
3	SVM	B sınıfı	8	1	%83,3	%66,7	%94,4	
		Diğer	4	17				
4	C4.5	B sınıfı	9	4	%76,7	%75,0	%77,8	
		Diğer	3	14				
Ortalama						%85,0	%75,0	%91,7
2	5	kNN	B sınıfı	11	1	%93,3	%91,7	%94,4
			Diğer	1	17			
	6	MLP	B sınıfı	7	2	%76,7	%58,3	%88,9
			Diğer	5	16			
7	SVM	B sınıfı	10	0	%93,3	%83,3	%100	
		Diğer	2	18				
8	C4.5	B sınıfı	9	5	%73,3	%75,0	%72,2	
		Diğer	3	13				
Ortalama						%84,2	%77,1	%88,9
3	9	kNN	B sınıfı	11	0	%96,7	%91,7	%100
			Diğer	1	18			
	10	MLP	B sınıfı	9	0	%90,0	%75,0	%100
			Diğer	3	18			
11	SVM	B sınıfı	8	2	%80,0	%66,7	%88,9	
		Diğer	4	16				
12	C4.5	B sınıfı	9	5	%73,3	%75,0	%72,2	
		Diğer	3	13				
Ortalama						%85,0	%77,1	%90,3
4	13	kNN	B sınıfı	9	3	%80,0	%75,0	%83,3
			Diğer	3	15			
	14	MLP	B sınıfı	9	3	%80,0	%75,0	%83,3
			Diğer	3	15			
15	SVM	B sınıfı	8	1	%83,3	%66,7	%94,4	
		Diğer	4	17				
16	C4.5	B sınıfı	7	3	%73,3	%58,3	%83,3	
		Diğer	5	15				
Ortalama						%79,2	%68,8	%86,1

Tablo 3.28. Sınıflandırıcı bazlı hafif OUAS (B sınıfı) tespit sonuçları

Sınıflandırıcı	Model	Test Sonucu	Gerçek Teşhis		Doğruluk	Duyarlılık	Kesinlik	
			B sınıfı	Diğer				
kNN	1	B sınıfı	10	1	%90,0	%83,3	%94,4	
		Diğer	2	17				
	5	B sınıfı	11	1	%93,3	%91,7	%94,4	
		Diğer	1	17				
	9	B sınıfı	11	0	%96,7	%91,7	%100	
		Diğer	1	18				
	13	B sınıfı	9	3	%80,0	%75,0	%83,3	
		Diğer	3	15				
				Ortalama		%90,0	%85,4	%93,1
	MLP	2	B sınıfı	9	0	%90,0	%75,0	%100
Diğer			3	18				
6		B sınıfı	7	2	%76,7	%58,3	%88,9	
		Diğer	5	16				
10		B sınıfı	9	0	%90,0	%75,0	%100	
		Diğer	3	18				
14		B sınıfı	9	3	%80,0	%75,0	%83,3	
		Diğer	3	15				
			Ortalama		%84,2	%70,8	%93,1	
SVM		3	B sınıfı	8	1	%83,3	%66,7	%94,4
	Diğer		4	17				
	7	B sınıfı	10	0	%93,3	%83,3	%100	
		Diğer	2	18				
	11	B sınıfı	8	2	%80,0	%66,7	%88,9	
		Diğer	4	16				
	15	B sınıfı	8	1	%83,3	%66,7	%94,4	
		Diğer	4	17				
				Ortalama		%85,0	%70,8	%94,4
	C4.5	4	B sınıfı	9	4	%76,7	%75,0	%77,8
Diğer			3	14				
8		B sınıfı	9	5	%73,3	%75,0	%72,2	
		Diğer	3	13				
12		B sınıfı	9	5	%73,3	%75,0	%72,2	
		Diğer	3	13				
16		B sınıfı	7	3	%73,3	%58,3	%83,3	
		Diğer	5	15				
			Ortalama		%74,2	%70,8	%76,4	

3.5.3. OUAS sınıflandırma sonuçları

Test veritabanındaki hastaların OUAS derecelerinin belirlenmesi amacıyla oluşturulan modellerden elde edilen test sonuçları Eşik 1 ve Eşik 2 değerlerine göre ayrıştırılmıştır. Test sonucunda sınıflandırıcıların Eşik 1 değeri altında kalan hastalar N sınıfı, Eşik 1 ile Eşik 2 arasında kalan hastalar B sınıfı ve Eşik 2 değeri üzerinde kalan hastalar A sınıfı olarak sınıflandırılmıştır. Test sonucunda N, B ve A sınıfı biçiminde sınıflandırılan hastalar uzman hekim tarafından belirlenen teşhis sonuçları dikkate alınarak karşılaştırılmıştır.

Kullanılan örüntü tanımlama modellerinin başarımı hastaların ait olduğu sınıfların doğru tespit edilme oranına göre yapılmıştır. 30 hasta üzerinden yapılan testlerde elde edilen grup bazlı OUAS sınıflandırma sonuçları Tablo 3.29’da, sınıflandırıcı bazlı OUAS sınıflandırma sonuçları ise Tablo 3.30’da sunulmuştur. C4.5 sınıflandırıcının kullanıldığı modeller ile sınıflandırmada elde edilen başarımlar %70 civarında olup diğer modellere kıyaslandığında çok düşük kalmıştır. Bu nedenle OUAS sınıflandırmada C4.5 sınıflandırıcının kullanıldığı modellere ait sonuçlar tablolara konulmamıştır.

Tablo 3.29. Grup bazlı OUAS sınıflandırma sonuçları

Grup	Model	Sınıflandırıcı	Doğru Tespit (Sınıf)			Toplam		Doğruluk
			N	B	A	Doğru	Hatalı	
1	1	kNN	7	10	10	27	3	%90,0
	2	MLP	7	9	10	26	4	%86,7
	3	SVM	7	8	10	25	5	%83,3
Ortalama								%86,7
2	5	kNN	7	11	10	28	2	%93,3
	6	MLP	7	7	9	23	7	%76,7
	7	SVM	8	10	10	28	2	%93,3
Ortalama								%85,6
3	9	kNN	8	11	10	29	1	%96,7
	10	MLP	8	9	10	27	3	%90,0
	11	SVM	7	8	9	24	6	%80,0
Ortalama								%90,7
4	13	kNN	8	9	7	24	6	%80,0
	14	MLP	7	9	8	24	6	%80,0
	15	SVM	8	8	8	24	6	%80,0
Ortalama								%80,0

Tablo 3.30. Sınıflandırıcı bazlı OUAS sınıflandırma sonuçları

Sınıflandırıcı	Model	Doğru Tespit (Sınıf)			Toplam		Doğruluk
		N	B	A	Doğru	Hatalı	
kNN	1	7	10	10	27	3	%90,0
	5	7	11	10	28	2	%93,3
	9	8	11	10	29	1	%96,7
	13	8	9	7	24	6	%80,0
Ortalama							%90,0
MLP	2	7	9	10	26	4	%86,7
	6	7	7	9	23	7	%76,7
	10	8	9	10	27	3	%90,0
	14	7	9	8	24	6	%80,0
Ortalama							%83,3
SVM	3	7	8	10	25	5	%83,3
	7	8	10	10	28	2	%93,3
	11	7	8	9	24	6	%80,0
	15	8	8	8	24	6	%80,0
Ortalama							%84,2

3.5.4. Literatürdeki başarımlar

Literatürde OUAS teşhisi ile ilgili yapılan çalışmalar Tablo 3.31, OUAS sınıflandırma ile ilgili çalışmalar ise Tablo 3.32’de verilmiş olup Bölüm 4’te detayları sunulmuştur.

Tablo 3.31. Literatürde OUAS teşhisi ile ilgili yapılan çalışmalar

Kaynak	Analiz Edilen Sinyal	Analiz Edilen Uzay	Kullanılan Sınıflandırıcı	Doğruluk
[15]	KAHD	Zaman-Frekans	Klasik	%93,3
[16]	KAHD+ETS	Zaman-Frekans	LDA, QDA	%100
[12]	KAHD+ETS	Frekans	kNN	%85
[13]	KAHD+ETS	Frekans	kNN, MLP	%100
[19]	KAHD	Zaman	SVM, Naive Bayes	%99
[19]	KAHD	Zaman	kNN	%88
[23]	KAHD	Frekans	YSA, Ekk-SVM	%98
[23]	KAHD+ETS	Frekans	YSA, Ekk-SVM	%96,7
[20]	KAHD	Zaman	MLP	%85
[20]	KAHD	Frekans	MLP	%93
[20]	KAHD	Zaman-Frekans-Doğrusal olmayan ölçütler	MLP	%96

Tablo 3.32. Literatürde OUAS sınıflandırma ile ilgili yapılan çalışmalar

Kaynak	Analiz Edilen Sinyal	Analiz Edilen Uzay	Kullanılan Sınıflandırıcı	Doğruluk
[13]	KAHD+ETS	Frekans	kNN	%88
[13]	KAHD+ETS	Frekans	MLP	%88
[19]	KAHD	Zaman	SVM	%85
[19]	KAHD	Zaman	Naive Bayes	%85
[19]	KAHD	Zaman	kNN	%74
[20]	KAHD	Zaman	MLP	%63
[20]	KAHD	Frekans	MLP	%78
[20]	KAHD	Zaman-Frekans-Doğrusal olmayan ölçütler	MLP	%82

4. SONUÇLAR VE ÖNERİLER

Uyku hastalıkları arasında en sık karşılaşılan ve toplumun %1-5'ini etkileyen OUAS her yaşta ve etnik grupta görülebilen bir hastalıktır. Uyku apnesi sendromunun teşhisinde altın standart olarak kabul edilen ve genellikle uyku laboratuvarlarında kullanılan, uyku sırasındaki fizyolojik sinyalleri ölçen ve kaydeden polisomnograftan elde edilen PSG sinyallerinin analizi uzun zaman alan ve masraflı bir yöntemdir. Bunun yanında ev ortamından uzak, gece boyunca birçok algılayıcı bağlanarak uyutulması da hastalar için rahatsız edici bir durum oluşturmaktadır. Halen kullanılmakta olan ticari PSG analiz programlarının katı hesaplama yöntemlerine dayalı olarak yaptığı otomatik olarak uyku apne teşhisi ve sınıflandırmasındaki doğruluk oranlarının tatmin edici olmaması nedeniyle bu programların apne tespit sonuçları uzmanlar tarafından güvenilir olarak kabul edilmemektedir. Uykuda solunum bozukluklarının görülme sıklığı ve uyku laboratuvarlarının sayısının yetersizliği de göz önüne alınca daha pratik ve güvenilir çözümler üzerindeki çalışmalar önem kazanmaktadır.

Tez çalışmasının önemi, uykuda solunum bozuklukları arasında en sık karşılaşılan rahatsızlık olan OUAS'ın teşhisi ve derecesinin belirlenmesinin sadece EKG sinyalleri üzerinden yumuşak hesaplama yöntemleri ile iki farklı veritabanından elde edilen kayıtlarla gerçekleştirilmesidir. Tez çalışmasında, birçok farklı cihaz ve karmaşık sistemler yerine sadece holter gibi pratik ve taşınabilir bir EKG kayıt cihazı kullanılarak, başka bir donanım gerektirmeden, EKG sinyalleri üzerinden OUAS teşhisi ve derecesinin belirlenmesinin gerçekleştirebileceği çeşitli örüntü tanıma modelleri oluşturulmuştur.

Literatürdeki çalışmaların hemen hemen hepsinde tek veritabanı kullanılırken bu tez çalışmasında iki farklı veritabanından elde edilen kayıtlar kullanılmıştır. Bu sayede oluşturulan modellerin hasta ve kullanılan ölçüm cihazlarından bağımsız olarak değerlendirilebileceği düşünülmüştür. DREAMS projesi [45] apne veritabanındaki 12 hastaya ait toplam 6238 kayıt eğitim veri seti olarak, Kocaeli Üniversitesi Tıp

Fakültesi Uyku Laboratuvarından [46] temin edilen 30 hastaya ait toplam 12790 dakikalık kayıt ise test veri seti olarak kullanılmıştır.

Literatürdeki benzer çalışmalar genellikle OUAS teşhisi ağırlıklı olup bir veya iki farklı öznitelik grubu üzerinden daha az sayıda sınıflandırıcı kullanılarak yapılmıştır [10, 12, 13, 15-23]. Bu tez çalışmasında ise dört farklı grup, belirlenen özniteliklerin sınıflandırılmasında da dört farklı sınıflandırıcının kullanıldığı 16 örüntü tanıma modeli oluşturulmuştur. Bu sayede tez çalışması daha geniş kapsamlı yapılmıştır. Sınıflandırıcıların seçiminde yumuşak hesaplama yöntemlerinde etkin, fizyolojik sinyal yapılarının değişikliğine paralel ve doğrusal olarak ayrılamayan verileri ayırt edebilecek yapıda olmasına dikkat edilmiştir. Ayrıca karmaşık fonksiyonları modelleyebilecek, denetimli öğrenmeye dayalı ve literatürdeki çalışmalarla kıyaslanabilecek sınıflandırıcılar olması tercih edilmiştir. Söz konusu sınıflandırıcıların başarımlarının daha iyi gözlemlenebilmesi ve karşılaştırılabilmesi amacıyla diğerlerinden nispeten daha basit yapıda olan C4.5 sınıflandırıcısı da çalışmada kullanılmıştır. Öznitelik seçimlerinde 10-katlı çapraz doğrulama yöntemi ile Wrapper tabanlı öznitelik seçim metotları, sınıflandırmalarda da 10-katlı çapraz doğrulama yöntemi kullanılmıştır.

Oluşturulan modeller doğruluk, duyarlılık ve kesinlik istatistiksel ölçütleri üzerinden değerlendirilmiş, analiz edilen öznitelik grubu ve kullanılan sınıflandırıcı bakış açılarına göre karşılaştırılmış, OUAS teşhisi ile sınıflandırılması ayrı başlık altında incelenerek elde edilen sonuçlar aşağıdaki başlıklarda sunulmuştur.

4.1. OUAS Teşhisi

OUAS teşhisi ile ilgili olarak, Grup 2 (KAHD sinyalinin zaman ve frekans uzayı) özniteliklerinin SVM ile sınıflandırılmasını sağlayan Model 7 ile Grup 3 (KAHD ve ETS sinyallerinin zaman uzayı) özniteliklerinin kNN ile sınıflandırılmasını sağlayan Model 9 OUAS'lı hastaları normal hastalardan %100 doğruluk, duyarlılık ve kesinlikte sınıflandırma başarısı sağlamıştır. Modellerin grup bazlı OUAS teşhis sonucu ortalamalarının karşılaştırılmasında başarımlar birbirine yakın olsa da Grup 3 öznitelikler ile daha iyi sınıflandırma başarısı sağlamıştır. Modellerin sınıflandırıcı bazlı OUAS teşhis sonucu ortalamalarına bakıldığında en iyi başarımlar kNN ve SVM sınıflandırıcıları ile sağlanmıştır.

Literatürde OUAS teşhisi ile ilgili yapılan çalışmaların bir kısmı KAHD sinyalinin 5 dakikalık bölütler üzerinden klasik hesaplama yöntemleri analizi ile yapılmış olup en iyi başarımlarda %93,3 doğruluk, %94,2 duyarlılık ve %96,5 kesinlik ile elde edilmiştir [10, 14, 15]. Genel olarak analizler 1 dakikalık bölütler üzerinden farklı sınıflandırıcılar kullanılarak yapılmıştır. Grup 1 (KAHD sinyalinin zaman uzayı) öznelikleri ile Sani ve diğ. [19] SVM ve Naive Bayes kullanarak %99, kNN ile %88 doğrulukta OUAS teşhisi, Mendez ve diğ. [12] KAHD ve ETS sinyallerinin frekans uzayı öznelikleri ile kNN kullanarak %85 doğrulukta OUAS teşhisi yapmıştır. Yıldız [23] ise uzun dönem sinyal analizinde YSA ve en küçük kareler-SVM ile KAHD sinyallerinin frekans uzayı özneliklerini kullanarak %98,3, Grup 3 özneliklerini kullanarak da %96,7 doğrulukta OUAS teşhisini başarmıştır. Grup 4 (KAHD ve ETS sinyallerinin zaman ve frekans uzayı) öznelikleri ile Chazal ve diğ. [16] LDA ve QDA kullanarak %100 doğrulukta, Gürüler ve diğ. [20] ise MLP kullanarak Grup 1 öznelikleri ile %85, KAHD sinyalinin frekans uzayı öznelikleri %93, Grup 3 özneliklerine ek olarak doğrusal olmayan ölçütleri (entropi değerleri gibi) kullanarak %96 doğrulukta OUAS teşhisini başarmıştır.

Tez çalışması kapsamında OUAS teşhisi ile ilgili alınan sonuçların literatürdeki benzer çalışmaları destekler yapıda olduğu, %100 doğruluk, duyarlılık ve kesinlikte başarımlar sağlayan Model 7'nin (Grup 2 öznelikleri üzerinden SVM) ile Model 9'un (Grup 3 öznelikleri üzerinden kNN) OUAS teşhis kabiliyetinin de oldukça yüksek olduğu görülmektedir. Ayrıca, Grup 4 öznelikleri ile kNN, SVM, MLP ve C4.5 sınıflandırıcıların kullanıldığı EKG üzerinden OUAS teşhisi ilk bu çalışmada uygulanmıştır.

4.2. OUAS Sınıflandırma

OUAS derecesinin sınıflandırılması kapsamında oluşturulan modellerin, uzman hekim tarafından belirlenen teşhis sonuçları dikkate alınarak A sınıfı (orta/ağır derecede OUAS'lı), B sınıfı (hafif derecede OUAS'lı) ve N sınıfı (normal) olarak üç sınıfa ayrılan hastaların doğru olarak sınıflandırılmasındaki başarımlar sonuçları incelenmiştir. En iyi başarımlar, yaklaşık %97 doğruluk (30 hastadan 29'unu doğru sınıflandırma) ile Grup 3 özneliklerinin kNN ile sınıflandırılmasını sağlayan Model 9 ile elde edilmiştir. Ortalama başarımlar göz önüne alındığında OUAS sınıflandırmada kullanılan öznelik grubu bakımından Grup 3 (%90,7), sınıflandırıcı

bakımından da kNN'nin (%90) diğerlerine göre daha başarılı sonuçlar sağladığı gözlemlenmiştir.

Literatürde OUAS derecesinin sınıflandırılması ile ilgili yapılan çalışmalar ağırlıklı 1 dakikalık bölütler üzerinden farklı sınıflandırıcılar kullanılarak gerçekleştirilmiştir. Mendez ve diğ. [13] KAHD ve ETS sinyallerinin frekans uzayı öznelikleri ile kNN ve MLP kullanarak %88, Sani ve diğ. [19] Grup 1 öznelikleri ile SVM ve Naive Bayes kullanarak %85, kNN ile %74 doğrulukta, Gürüler ve diğ. [20] ise MLP kullanarak Grup 1 öznelikleri ile %63, KAHD sinyalinin frekans uzayı öznelikleri %78, Grup 3 özneliklerine ek olarak doğrusal olmayan ölçütleri (entropi değerleri gibi) kullanarak %82 doğrulukta OUAS derecesinin sınıflandırılmasını başarmıştır.

Tez çalışması kapsamında OUAS derecesinin sınıflandırılması ile ilgili alınan sonuçların da literatürdeki benzer çalışmaları destekler yapıda olduğu, yaklaşık %97 doğrulukta başarımları sağlayan Model 9'un (Grup 3 öznelikleri üzerinden kNN) ile sınıflandırma kabiliyetinin yüksek olduğu görülmektedir. Sınıflandırıcıların işlem süreleri dikkate alındığında kNN sınıflandırıcısının işlem süresi SVM ve MLP sınıflandırıcılarından çok daha kısadır. Bu nedenle elde edilen doğruluk başarısının yanında işlem süresi de dikkate alındığında kNN ile elde edilen başarı dikkate değerdir. Ayrıca, Grup 3 ve Grup 4 öznelikleri ile kNN, SVM, MLP ve C4.5 sınıflandırıcıların kullanıldığı EKG üzerinden OUAS derecesinin sınıflandırılması ilk bu çalışmada uygulanmıştır.

4.3. Sonuçlar

Uyku apnesi sendromunun teşhisinde altın standart olarak kabul edilen ve genellikle uyku laboratuvarlarında kullanılan polisomnografiye elde edilen PSG sinyallerinin analizi uzun zaman alan ve masraflı bir yöntemdir. OUAS hastalığının görülme sıklığının fazla olması ve uyku laboratuvarlarının sayısının yetersizliği de göz önüne alınca tez çalışması sonucunda elde edilen bulgularda; EEG, EMG, EOG, EKG, solunum sinyalleri, solunum eforu sinyalleri, SpO2 ve vücut pozisyonlarına ait 15'ten fazla PSG sinyali yerine sadece EKG sinyali (KAHD ve ETS türetilerek) analizi ile güvenilir seviyede uyku apnesi teşhisi ve sınıflandırılmasının yapılabileceği ve holter gibi pratik ve taşınabilir bir EKG kayıt cihazının bu amaçla kullanılabileceği, böylece hastanın laboratuvar gibi farklı, maliyetli ve rahatsız edici

bir ortam yerine kendi ev ortamında kayıtlarının alınabileceği, bu sayede uyku apnesi teşhis maliyetinde önemli ölçüde düşüş sağlanabileceği, ayrıca uzman hekimlere OUAS teşhislerinde destek verilebilecek bir karar destek sisteminin oluşturulabileceği ve klinik olarak OUAS şüphesi olan hastaların ön teşhis ve sınıflandırılmasının yapılarak uzman hekimlerin öncelik gerektiren daha riskli hastalara odaklanmasına yardımcı olunabileceği sonuçlarına ulaşılmıştır.

4.4. Öneriler

EKG sinyali üzerinden OUAS teşhisi ve sınıflandırılması amacıyla yapılacak çalışmalarda katı hesaplama yöntemleri yerine yumuşak hesaplama yöntemlerinin daha uygun olacağı, bu kapsamda analiz edilecek uzayın iyi belirlenmesinin gerektiği ve zaman uzayında yapılacak analizlerde sadece KAHD sinyaline ait özniteliklerin kullanılması yerine ETS sinyaline ait özniteliklerinin de kullanılmasının faydalı olacağı değerlendirilmelidir.

Ayrıca, zaman ve frekans uzayında yapılacak analizlerde ise KAHD sinyalinin yeterli olacağı ve oluşturulacak modellerde öznitelik seçimi ve sınıflandırıcı optimizasyonunun mutlaka uygulanması gerektiği değerlendirilmelidir.

KAHD ve ETS sinyallerinin zaman uzayı analizinden seçilmiş özniteliklerin kullanıldığı, optimize edilmiş kNN sınıflandırıcısına dayalı Model 9, OUAS teşhisi ve sınıflandırılması için etkin ve güvenilir bir model olarak önerilmektedir.

KAYNAKLAR

- [1] Köktürk O., Uykuda solunum bozuklukları tarihçe, tanımlar, hastalık spektrumu ve boyutu, *Tüberküloz ve Toraks Dergisi*, 1998, **46**, 187-192.
- [2] Santillo E., Migale M., Fallavollita L., Marini L., Balestrini F., Electrocardiographic analysis of heart rate variability in aging heart, Editor: Millis R, *Advances in electrocardiograms - methods and analysis*, InTech, Rijeka, 253-271, 2012.
- [3] Dingli K., Assimakopulos T., Wraith P. K., Fietze I., Witt C., Douglas N. J., Spectral Oscillations of RR Intervals in Sleep Apnae/Hypopnea Syndrome Patients, *European Respiratory Journal*, 2003, **22**, 943-950.
- [4] Chazal P., Heneghan C., Sheridan E., Reilly R. P. N., O'Malley M., Automatic classification of sleep apnea epochs using the electrocardiogram, *Computers in Cardiology*, 2000, **27**, 745-748.
- [5] Schrader M., Zywiets C., Von Einem V., Widiger B., Joseph G., Dedection of sleep apnea in single channel ecgs from the physionet data base, *Computers in Cardiology*, 2000, **27**, 263-266.
- [6] Yachuan P., Patterson R., Bornemann M. C., Detecting pediatric obstructive sleep apnea using ecg, *25th Annual International Conferance of the IEE EMBS*, Cancun, Meksika, 17-21 September 2003.
- [7] Koçak O., Bayrak B., Erdamar A., Özparlak B., Telatar Z., Eroğlu O., Automated detection and classification of sleep apnea types using electrocardiogram (ecg) and electroencephalogram (eeg) features, Editor: Millis R, *Advances in electrocardiograms - methods and analysis*, InTech, Rijeka, 212-230, 2012.
- [8] Drinnan M., Allen J., Langley P., Murray A., Dedection of sleep apnea from frequency analysis of heart rate variability, *Computers in Cardiology*, 2000, **27**, 259-262.
- [9] Roche F., Duverney D., Court-Fortune I., Pichot V., Costes F., Lacour J. R., Antoniadis A., Gaspoz J. M., Barthelemy J.C., Cardiac interbeat interval increment for the identification of obstructive sleep apnea, *Pace-Pacing and Clinical Electrophysiology*, 2002, **25**(8), 1192-1199.
- [10] Roche F., Pichot V., Sforza E., Court-Fortune I., Duverney D., Costes F., Garet M., Barthelemy J.C., predicting sleep apnea syndrome from heart period: a time-frequency wavelet analysis, *European Respiratory Journal*, 2003, **22**, 937-942.

- [11] Goldberger A. L., Amaral L. A. N., Glass L., Hausdorff J. M., Ivanov P. C., Mark R. G., Mietus J. E., Moody G. B., Peng C. K., Stanley H. E., PhysioBank, physiobank, and physionet: components of a new research resource for complex physiologic signals, *Circulation*, 2000, **101**, 215-220.
- [12] Mendez M. O., Ruini D. D., Villantrieri O. P., Matteucci M., Penzel T., Cerutti S., Bianchi A. M., Detection of sleep apnea from surface ecg based on features extracted by an autoregressive model, *Proceedings of the 29th Annual International Conference of the IEEE EMBS Cite Internationale*, Lyon, Fransa, 22-26 August 2007.
- [13] Mendez M. O., Bianchi A. M., Matteucci M., Cerutti S., Penzel T., Sleep apnea screening by autoregressive models from a single ecg lead, *IEEE Transactions Biomedical Engineering*, 2009, **56**, 2838-2849.
- [14] Roche F., Gaspoz J. M., Court-Fortune I., Minini P., Pichot V., Duverney D., Costes F., Lacour J. R., Barthelemy J.C., Screening of obstructive sleep apnea syndrome by heart rate variability analysis, *American Heart Association Circulation*, 1999, **100**, 1411-1415.
- [15] Mietus J., Peng C., Ivanov P., Goldberger A., Detection of obstructive sleep apnea from cardiac interbeat interval time series, *Computers in Cardiology*, 2000, **27**, 753-756.
- [16] Chazal P., Heneghan C., Sheridan E., Reilly R. B., Nolan P., O'Malley M., Automated processing of the single lead electrocardiogram for the detection of obstructive sleep apnea, *IEEE Transactions Biomedical Engineering*, 2003, **50**, 686-696.
- [17] Chazal P., Penzel T., Heneghan C., Automated detection of obstructive sleep apnea at different time scales using the electrocardiogram, *Physiological Measurement*, 2004, **25**, 967-983.
- [18] Yılmaz B., Asyalı M. H., Arıkan E., Yetkin S., Özgen F., Sleep stage and obstructive apneic epoch classification using single-lead ECG, *Biomedical Engineering Online*, 2010, **9**, 1-14.
- [19] Sani I. M., Fanany M., Jatmiko M., Murini A., Feature and model selection on automatic sleep apnea detection using ecg, *International Conference on Computer Science and Information Systems ICACISIS 2010*, Depok, Endonezya, 20-23 November 2010.
- [20] Gürüler H., Şahin M., Ferikoğlu A., Feature selection on single-lead ECG for obstructive sleep apnea diagnosis, *Turkish Journal of Electrical Engineering & Computer Sciences*, 2014, **22**, 465-478.
- [21] Erdamar A., Uyku apnesinin öngörülmesi ve dil uyarılması için model geliştirilmesi, Doktora Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2007, 216376.

- [22] Akşahin M.F., Uyku apnesi türlerinin sınıflandırılması, Doktora Tezi, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2010, 266434.
- [23] Yıldız A., EEG ve ekg işaretlerinden örüntü tanıma uygulamaları ve karşılaştırılması, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2011, 287069.
- [24] Korpinen L., Frey H., Sleep-expert : an intelligent medical decision support system for sleep disorders, *Informatics for Health and Social Care*, 1993, **18**, 163-170.
- [25] Korpinen L., Partinen M., Telakivi T., Martikainen K., Pietila T., Peltola J., Falck B., Frey H., Evaluation of sleep-expert : a computer aided decision support system for sleep disorders, *Informatics for Health and Social Care*, 1994, **19**, 247-252.
- [26] Çavuşoğlu M., Kamasak M., Eroğul. O., Çiloğlu T., Serinağaoğlu Y., Akçam T., An efficient method for snore/nonsnore classification of sleep sound, *Physiological Measurement*, 2007, **28**, 841-853.
- [27] Demirgüneş D. D., Basit horlayan ve tıkayıcı uyku apne sendromlu hastalardan toplanacak fizyolojik sinyallerin analizi ve karşılaştırılması, Yüksek Lisans Tezi. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2009, 258723.
- [28] Aydın H., Özgen F., Yetkin S., Sütçigil L., *Uyku ve uykuda solunum bozuklukları*, GATA Basımevi, Ankara, 2005.
- [29] Rechtschaffen A., Kales A., *A manual of standardized terminology techniques and scoring system for sleep stages of human subjects*, United States Government Printing Office, D.C., 1968.
- [30] Malmivuo J., Plonsey R., *Bioelectromagnetism-principles and applications of bioelectric and biomagnetic fields*, Oxford University Press, New York, 1995.
- [31] Pehlivan F., *Biyofizik*, Hacettepe-TAS Kitapçılık, Ankara, 1997.
- [32] <http://en.wikipedia.org/wiki/Electroencephalography>, (Ziyaret Tarihi: 10 Ekim 2014)
- [33] <http://noodle.med.yale.edu/~staib/bme355/ecg/prep.htm>, (Ziyaret Tarihi: 20 Ekim 2014)
- [34] Milli Eğitim Bakanlığı, *Acil sağlık hizmetleri: ekg (elektrokardiyografi) 723H00048*, Milli Eğitim Bakanlığı, Ankara, 2011.
- [35] http://anesteziseminerleri.com/ecg_dosyalar/ec14.jpg (Ziyaret Tarihi: 22 Ekim 2014)

- [36] Guilleminault C., Connolly S. J., Winkle R., Melvin K., Tilkian A., Cyclical variation of the heart rate in sleep apnoea syndrome. Mechanisms and usefulness of 24h electrocardiography as a screening technique, *Lancet*, 1984, **1**, 126–131.
- [37] O'Brien C., Heneghan C., A comparison of algorithms for estimation of a respiratory signal from the surface electrocardiogram, *Computers in Biology and Medicine*, 2007, **37**, 305-314.
- [38] Kabalcı E., Esnek Hesaplamaya Giriş, WordPress, <https://ekblc.files.wordpress.com/2013/09/esnek-hesaplamaya-giris59f.pdf> (Ziyaret Tarihi: 10 Aralık 2014)
- [39] Zadeh L. A., Fuzzy logic, neural Networks, and soft computing, *Communication of the ACM*, 1994, **37**, 77-84.
- [40] Türkoğlu İ., Durağan olmayan işaretler için zaman-frekans entropilerine dayalı akıllı örüntü tanıma, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2002, 116574.
- [41] Türkoğlu İ., Örüntü Tanıma Ders Notları-1, Blogcu, http://perweb.firat.edu.tr/personel/yayinlar/fua_69/69_22586.pdf (Ziyaret Tarihi: 15 Aralık 2014)
- [42] Cortes C., Vapnik. V., Support vector Networks, Editor: Saitta L., *Machine learning*, 20, Kluwer Academic Publishers, Boston, 273-297, 1995.
- [43] Osowski S., Hoai L. T., Markiewicz T., Supervised learning methods for ecg classification/neural networks and svm approaches, Editors: Gari D. Clifford G.D., Azuaje F., McSharry P. E., *Advanced methods and tools for ecg data analysis*, Artech House Inc., Norwood, ABD, 319-336, 2006.
- [44] Şeker S. E., C4.5 Ağacı (C4.5 Tree), Bilgisayar Kavramları, <http://bilgisayarkavramlari.sadievrenseker.com/2012/11/13/c4-5-agaci-c4-5-tree/> (Ziyaret Tarihi: 15 Aralık 2014)
- [45] Devuyst S., Dutoit D., Kerkhofs M., DREAMS apne veritabanı, MONS Üniversitesi TCTS Laboratuvarı ve Brüksel Üniversitesi CHU de Charleroi Uyku Laboratuvarı, <http://www.tcts.fpms.ac.be/~devuyst/Databases/DatabaseApnea/> (Ziyaret Tarihi: 10 Aralık 2014)
- [46] Kocaeli Üniversitesi Tıp Fakültesi, *Uyku Laboratuvarı Hasta Kayıtları*, Kocaeli Üniversitesi, Kocaeli, 2014.
- [47] MathWorks, *MATLAB and Statistics Toolbox Versiyon 2013b*, The MathWorks Inc., Massachusetts, 2013.
- [48] Compumedics, *ProfusionPSG Viewer Versiyon 2.1*, Compumedics Limited, Abbotsford, 2005.

- [49] Shoelson B., A simple file reader for european data formatted (edf) files, Mathworks, <http://www.mathworks.com/matlabcentral/fileexchange/31900-edfread/content/edfreadm>. (Ziyaret Tarihi: 10 Aralık 2013)
- [50] Waikato University, *Waikato Environment for Knowledge Analysis (Weka) Versiyon 3.7.11*, Waikato University, Hamilton, 2014.
- [51] Oracle Corporation, *Oracle Database 11g XE, Version 11.2.0*, Oracle Corporation, Redwood City, 2013.
- [52] Dell Software, *Toad for Oracle Version 9.7.2*, Dell Software Inc., Aliso Viejo, 2013.
- [53] Camm A., J. Malik M., Bigger J. T., Breithardt G., Cerutti S., Cohen R. J., Coumel P., Fallen E. L., Kennedy H. L., Kleiger R. E., Lombardi F., Malliani A., Moss A. J., Rottman J. N., Schmidt G., Schwartz P. J., Singer D. H., Heart rate variability-standards of measurement. Physiological interpretation. and clinical use, *European Heart Journal*, 1996, **17**, 354-381.
- [54] Yakut O., Solak S., Bolat E. D., Measuring ecg signal using e-health sensor platform, *International Conference on Chemistry, Biomedical and Environment Engineering, ICCBEE'14*, Antalya, Turkey, 7-8 October 2014.

KİŞİSEL YAYIN VE ESERLER

- [1] Kıyak E., Özkan G., **Timuş O.**, Envanter yönetiminde genetik algoritmaların kullanılması. *Yöneylem Araştırması ve Endüstri Mühendisliği 31. Ulusal Kongresi*, Sakarya Üniversitesi, Sakarya, 05-07 Temmuz 2011.

ÖZGEÇMİŞ

1976 yılında İstanbul'da doğdu. İlk ve orta öğrenimini İstanbul'da tamamladı. Lise öğrenimini İstanbul Deniz Lisesi'nde ve üniversite öğrenimini Deniz Harp Okulu Kontrol ve Bilgisayar Mühendisliği bölümünde tamamlayarak 1998 yılında subay olarak mezun oldu. 2002 yılında Naval Post Graduate School Monterey/Kaliforniya, ABD'de Bilgisayar Mühendisliği bölümünde Yüksek Lisans öğrenimini tamamladı. 1998 yılından bugüne Deniz Kuvvetleri Komutanlığı'nda muhabere, hareket ve bilgisayar yazılımları ile ilgili görevlerde bulunmuştur. Evli ve 2 çocuk babasıdır. İngilizce bilmektedir.