

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĐİ ANABİLİM DALI

**UYKU APNESİ TANISI İÇİN BİLGİSAYAR DESTEKLİ TESPİT SİSTEMİNİN
TASARIMI VE GERÇEKLEMESİ**

YÜKSEK LİSANS TEZİ

BETÜL NUREFŐAN YAMAN

TEZ DANIŐMANI
DR. ÖĐR. ÜYESİ İDİL İŐIKLI ESENER

BİLECİK, 2021

10399144

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĐİ ANABİLİM DALI

**UYKU APNESİ TANISI İÇİN BİLGİSAYAR DESTEKLİ TESPİT SİSTEMİNİN
TASARIMI VE GERÇEKLEMESİ**

YÜKSEK LİSANS TEZİ

BETÜL NUREFŐAN YAMAN

TEZ DANIŐMANI
DR. ÖĐR. ÜYESİ İDİL İŐIKLI ESENER

BİLECİK, 2021

10399144

BEYAN

Uyku Apnesi Tanısı için Bilgisayar Destekli Tespit Sisteminin Tasarımı ve Gerçekleşmesi adlı yüksek lisans tezi hazırlık ve yazımı sırasında bilimsel ahlak kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını beyan ederim.

Bu çalışmamın, Bilimsel Araştırmalar Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte beyan edilmelidir.	
DESTEK ALINMIŞTIR	DESTEK ALINMAMIŞTIR
Destek alındı ise;	
Destekleyen Kurum:	
Desteğin Türü	Proje Numarası
1- BAP (Bilimsel Araştırma Projesi)	
2- TÜBİTAK	
Diğer;	

Öğrenci Adı ve Soyadı

Betül Nurefşan YAMAN

Tarih

.../.../2021

İmza

ÖN SÖZ

Bu tez çalışmasının yazılmasında, çalışmamı sahiplenerek takip eden, değerli bilgileri ile beni destekleyip yönlendiren ve manevi desteğiyle bana destek olan danışmanım Sayın Dr. Öğr. Üyesi İdil IŞIKLI ESENER'a değerli katkı ve emekleri için teşekkürlerimi ve saygılarımı sunarım.

Tez çalışmam sırasında ve hayatımın her anında yardımlarını ve anlayışını esirgemeyerek bana sabırla destek veren annem Sema YAMAN'a, bu günlere gelmemi borçlu olduğum babam Hüseyin YAMAN'a ve eğitim hayatım boyunca beni destekleyen dedem Hasan Hüseyin KAYA'a anneannem Hayriye KAYA'a ve değerli emekleri adına aileme teşekkür ederim.

Öğrenci Adı ve Soyadı

Betül Nurefşan YAMAN

Tarih

.../.../2021

ÖZET

UYKU APNESİ TANISI İÇİN BİLGİSAYAR DESTEKLİ TESPİT SİSTEMİNİN TASARIMI VE GERÇEKLEMESİ

Tez çalışmasında, uyku apnesi teşhisi gerçekleştirebilen bir bilgisayar destekli teşhis sistemi önerilmiş ve PhysioNet Apnea-ECG veri tabanı üzerinde doğrulanmıştır. Önerilen sistemin ön işleme aşamasında, veritabanında yer alan elektrokardiyogram sinyalleri z-skor normalizasyonuna tabi tutulmuş, bant geçiren filtreden geçirilmiş ve bir-dakikalık bölütlere ayrılmıştır. Sonrasında, öznitelik çıkarımı aşamasında, bir-dakikalık bölütler gerek uzamsal düzlemde gerekse frekans düzleminde yedi farklı öznitelik grubu ile betimlenmiştir. Ayrıca, her bir öznitelik grubuna temel bileşen analizi, ortak vektör yaklaşımı ve ayırt edici ortak vektör yaklaşımı yöntemleri uygulanarak öznitelik seçimi gerçekleştirilmiştir. Sınıflandırma aşamasında ise lojistik doğrusal sınıflandırıcı, doğrusal ayırtaç sınıflandırıcı, fisher doğrusal ayırıcı analizi, bayes sınıflandırıcı, k-en yakın komşu sınıflandırıcısı kullanılarak, 2- ve 3-sınıflı teşhis çalışmaları gerçekleştirilmiştir. Sonuç olarak, bir-dakikalık bölütlerin apneli/apnesiz olarak sınıflandırıldığı 2-sınıflı teşhis çalışmasında kalp atım hızı değişkenliği öznitelikleri kullanılarak maksimum %72,29, kalp atım hızı değişkenliği özniteliklerinin temel bileşen analizi yöntemi ile boyut indirilmesi yapıldıktan sonra %67,00 doğruluk sağlandığı tespit edilmiştir. Hasta/sınırdı/sağlıklı olarak sınıflandırıldığı 3-sınıflı teşhis çalışmasında da kalp atım hızı değişkenliği öznitelikleri kullanılarak maksimum %68,67, hibrit özniteliklerinin temel bileşen analizi ile boyut indirilmesi yapıldıktan sonra %68,67 doğruluk sağlandığı tespit edilmiştir.

Anahtar Kelimeler: Uyku apnesi, bilgisayar destekli teşhis, 1-boyutlu yerel konfigürasyon örüntüsü, öznitelik çıkarımı, öznitelik seçimi

ABSTRACT

DESIGN AND IMPLEMENTATION OF A COMPUTER AIDED DETECTION SYSTEM FOR DIAGNOSIS OF SLEEP APNEA

In the thesis study, a computer aided diagnostic system capable of diagnosing sleep apnea is proposed and validated on the PhysioNet Apnea-ECG database. In the preprocessing phase of the proposed system, electrocardiogram signals in the database is subjected to z-score normalization, bandpass filtered and divided into one-minute segments. Then, in the feature extraction stage, one-minute segments are described with seven different feature groups in both the spatial plane and the frequency plane. In addition, feature selection is performed by applying principal component analysis, common vector approach and distinguished common vector approach methods to each feature group. In the classification stage, 2- and 3-class diagnostic studies are performed using the logistic linear classifier, linear differential classifier, fisher linear differential analysis, bayes classifier, k-neighbor classifier. As a result, In the 2-class diagnostic study, it is determined that maximum 72.29% accuracy is achieved by using heart rate variability features, and 67.00% accuracy is achieved after size reduction of heart rate variability features by principal component analysis method. In the 3-class diagnostic study, in which the patient is classified as borderline/healthy, it is determined that the maximum accuracy is 68.67% using heart rate variability features, and 68.67% accuracy is achieved after size reduction with principal component analysis of hybrid features.

Keywords: Sleep apnea, computer aided diagnosis, 1-dimensional local configuration pattern, feature extraction, feature selection

İÇİNDEKİLER

	Sayfa No
ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT.....	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	viii
KISALTMALAR VE SİMGELER LİSTESİ.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR ÇALIŞMASI.....	6
2.1. Apne/Hipopne Teşhisi Yapılan Çalışmalar.....	7
2.1.1. Nabız Oksimetresi Kullanılan Çalışmalar.....	7
2.1.2. ECG Kullanılan Çalışmalar.....	8
2.1.3. RESP Kullanılan Çalışmalar.....	9
2.1.4. Ses Sinyali Kullanılan Çalışmalar.....	10
2.1.5. EEG Kullanılan Çalışmalar.....	11
2.1.6. Birleşik Yaklaşımlar Kullanılan Çalışmalar.....	11
2.2. OSA Teşhisi Yapılan Çalışmalar.....	13
2.2.1. Nabız Oksimetresi Kullanılan Çalışmalar.....	13
2.2.2. ECG Kullanılan Çalışmalar.....	14
2.2.3. RESP Kullanılan Çalışmalar.....	18
2.2.4. Ses Sinyali Kullanılan Çalışmalar.....	19
2.2.5. EEG Kullanılan Çalışmalar.....	20
2.2.6. Birleşik Yaklaşımlar Kullanılan Çalışmalar.....	20
2.3. OSA/ CSA/MSA Teşhisi Yapılan Çalışmalar.....	21
3. MATERYAL ve YÖNTEM.....	23
3.1. Apne-ECG Veri Tabanı.....	23
3.2. Ön İşleme.....	25
3.2.1. Z-skor Normalizasyonu.....	25
3.2.2. Butterworth Bant Geçiren Filtreleme.....	26
3.3. Öznitelik Çıkarımı.....	27
3.3.1. Yerel Konfigürasyon Örüntüsü.....	27
3.3.2. İstatistiksel öznitelik çıkarımı.....	30

3.4. Öznitelik Seçimi	31
3.4.1. Temel Bileşen Analizi	31
3.4.2. Ortak Vektör Yaklaşımı	33
3.4.3. Ayırt Edici Ortak Vektör Yaklaşımı	34
3.5. Sınıflandırma	34
3.5.1. Lojistik Doğrusal Sınıflandırıcı	34
3.5.2. Doğrusal Ayırtaç Sınıflandırıcı	35
3.5.3. Fisher Doğrusal Ayırtaç Analizi Sınıflandırıcısı	35
3.5.4. Bayes Sınıflandırıcısı	36
3.5.5. k-En Yakın Komşu Sınıflandırıcısı	36
4. DENEYSEL ÇALIŞMALAR	37
4.1. Eğitim ve Test Kümelerinin Belirlenmesi	38
4.2. Ön İşleme	39
4.2.1. RR Aralıklarının Elde Edilmesi	39
4.2.2. RR Aralıklarının Filtrelenmesi	40
4.3. Öznitelik Çıkarımı	41
4.3.1. Dalgacık Düzlemi Öznitelikleri	41
4.3.2. HRV Öznitelikleri	44
4.3.3. Yerel Konfigürasyon Örüntüsü Öznitelikleri	46
4.3.4. Hibrit yöntem öznitelikleri	46
4.4. Öznitelik Seçimi	48
4.5. Sınıflandırma	48
4.6. Performans Değerlendirme Metrikleri	49
5. BULGULAR ve TARTIŞMA	51
6. SONUÇ	80
KAYNAKÇA	83

TABLULAR LİSTESİ

Sayfa No

Tablo 3.1. PhysioBank Apnea-ECG veritabanındaki kayıt ve hastaların ortalama özellikleri	24
Tablo 4.1. Dalgacık düzlemi öznitelikleri ve matamatiksel gösterimleri.....	42
Tablo 4.2. HRV öznitelikleri ve matamatiksel gösterimleri.....	44
Tablo 4.3. LCP katsayısı ve kodu.....	46
Tablo 4.4. 60-boyutlu hibrit öznitelik vektörlerinin oluşturulması	47
Tablo 4.5. Performans değerlendirme metrikleri.....	50
Tablo 5.1. BP-Norm, dalgacık düzlemi öznitelikleri kullanılan BC sınıflandırıcısı karmaşıklık matrisleri.....	52
Tablo 5.2. BP-Norm, HRV öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri	54
Tablo 5.3. Ham veri, LCP öznitelikleri kullanılan LDC sınıflandırıcısı karmaşıklık matrisleri	56
Tablo 5.4. Norm, LCP vektör öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri.....	58
Tablo 5.5. Ham veri, LCP istatistiksel öznitelikleri kullanılan BC sınıflandırıcısı karmaşıklık matrisleri.....	60
Tablo 5.6. BP-Norm, LCP dalgacık düzlemi öznitelikleri kullanılan BC sınıflandırıcısı karmaşıklık matrisleri.....	62
Tablo 5.7. Norm, Hibrit öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri	64
Tablo 5.8. BP-Norm, Dalgacık düzlemi öznitelikleri kullanılan LDC sınıflandırıcısı karmaşıklık matrisleri.....	67
Tablo 5.9. Norm, HRV öznitelikleri kullanılan LDC sınıflandırıcısı karmaşıklık matrisleri .	69
Tablo 5.10. BP-Norm, LCP öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri.....	71

TABLÖLAR LİSTESİ (devam)

Tablo 5.11. BP-Norm, LCP vektör öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri..... 73

Tablo 5.12. BP, LCP istatistiksel öznitelikleri kullanılan BC sınıflandırıcısı karmaşıklık matrisleri..... 75

Tablo 5.13. BP, LCP dalgacık düzlemi öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri..... 77

Tablo 5.14. Norm, hibrit öznitelikleri kullanılan LLC sınıflandırıcısı karmaşıklık matrisleri 79



ŞEKİLLER LİSTESİ

	Sayfa No
Şekil 3.1. Eğitim setinde bulunan hastanın EKG sinyali kaydı	23
Şekil 3.2. Bant Geçiren filtre özellikleri ve frekans yanıtı.....	26
Şekil 3.3. LCP öznitelik çıkarımı yönteminin yapısı	27
Şekil 3.4. Dairesel şekilde gc ve gi'lerin gösterimi	29
Şekil 3.5. Vektör formatında gc ve gi'lerin gösterimi	30
Şekil 3.6. PCA uygulanmış bir veritabanı gösterimi	33
Şekil 4.1. Tez çalışması basamakları	38
Şekil 4.2. EKG sinyalinde QRS kompleksleri ve RR aralığı gösterimi.....	39
Şekil 4.3. 1 dk'lık bölütlere bölünmüş normal ve apnesi EKG sinyali	40
Şekil 4.4. Öznitelik seçimi için uygulanan aşamalar	48
Şekil 4.5. Sınıflandırma çalışma aşamaları.....	49
Şekil 5.1. Dalgacık düzlemi öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları	51
Şekil 5.2. BP-Norm, dalgacık düzlemi öznitelikleri kullanılan BC sınıflandırıcısı performans değerlendirme kriterleri.....	52
Şekil 5.3. BP-Norm, dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri ve kullanılarak BC sınıflandırıcısı ortalama doğruluk oranları.....	53
Şekil 5.4. HRV öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları	53
Şekil 5.5. BP-Norm, HRV öznitelikleri kullanılan FLDA sınıflandırıcısı performans değerlendirme kriterleri.....	54
Şekil 5.6. BP-Norm, HRV öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları	55
Şekil 5.7. LCP öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları	55
Şekil 5.8. Ham veri, LCP öznitelikleri kullanılan LDC sınıflandırıcısı performans değerlendirme kriterleri.....	56

ŞEKİLLER LİSTESİ (devam)

Şekil 5.9. LCP öznitelikleri boyut indirgeme yöntemleri kullanılarak LDC sınıflandırıcısı ortalama doğruluk oranları	57
Şekil 5.10. LCP vektör öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları	57
Şekil 5.11. Norm, LCP vektör öznitelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri	58
Şekil 5.12. Norm, LCP vektör öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları	59
Şekil 5.13. LCP istatistiksel öznitelikler kullanılarak elde edilen ortalama doğruluk oranları	59
Şekil 5.14. Ham veri, LCP istatistiksel öznitelikleri BC sınıflandırıcısı performans değerlendirme kriterleri.....	60
Şekil 5. 15. LCP istatistiksel öznitelikleri boyut indirgeme yöntemleri kullanılarak BC sınıflandırıcısı ortalama doğruluk oranları	61
Şekil 5.16. LCP dalgacık düzlemi öznitelikleri kullanarak elde edilen ortalama doğruluk oranları	61
Şekil 5.17. BP-Norm, LCP dalgacık düzlemi öznitelikleri BC sınıflandırıcısı performans değerlendirme kriterleri.....	62
Şekil 5.18. BP-Norm, LCP dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri kullanılarak BC sınıflandırıcısı ortalama doğruluk oranları	63
Şekil 5.19. Hibrit öznitelik çıkarımı yöntemi öznitelikleri kullanarak elde edilen ortalama doğruluk oranı	63
Şekil 5.20. Norm, Hibrit öznitelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri.....	64
Şekil 5.21. Norm, hibrit öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları	65
Şekil 5.22. Dalgacık düzlemi öznitelikleri kullanarak elde edilen ortalama doğruluk oranları	66
Şekil 5.23. BP-Norm, Dalgacık düzlemi öznitelikleri LDC sınıflandırıcısı performans değerlendirme kriterleri.....	66

ŞEKİLLER LİSTESİ (devam)

Şekil 5.24. BP-Norm, Dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri kullanılarak LDC sınıflandırıcısı ortalama doğruluk oranları	67
Şekil 5.25. HRV öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları	68
Şekil 5.26. Norm, HRV öznitelikleri LDC sınıflandırıcısı performans değerlendirme kriterleri	68
Şekil 5.27. Norm, HRV öznitelikleri boyut indirgeme yöntemleri kullanılarak LDC sınıflandırıcısı ortalama doğruluk oranları	69
Şekil 5.28. LCP öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları	70
Şekil 5.29. BP-Norm, LCP öznitelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri	70
Şekil 5.30. BP-Norm, LCP öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları	71
Şekil 5.31. LCP vektör öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları	72
Şekil 5.32. BP-Norm, LCP vektör öznitelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri	72
Şekil 5.33. BP-Norm, LCP vektör öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları	73
Şekil 5.34. LCP istatistiksel öznitelikler kullanılarak elde edilen ortalama doğruluk oranları	74
Şekil 5.35. BP, LCP istatistiksel öznitelikleri BC sınıflandırıcısı performans değerlendirme kriterleri	74
Şekil 5.36. BP, LCP istatistiksel öznitelikleri boyut indirgeme yöntemleri kullanılarak BC sınıflandırıcısı ortalama doğruluk oranları	75
Şekil 5.37. LCP dalgacık düzlemi öznitelikleri kullanılarak elde edilen ortalama doğruluk oranı	76
Şekil 5.38. BP, LCP dalgacık düzlemi öznitelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri	76
Şekil 5.39. BP, LCP dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları	77

ŞEKİLLER LİSTESİ (devam)

- Şekil 5.40. Hibrit öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları 78
- Şekil 5.41. Norm, hibrit öznitelikleri LLC sınıflandırıcısı performans değerlendirme kriterleri 78
- Şekil 5.42. Norm, hibrit öznitelikleri boyut indirgeme yöntemleri kullanılarak LLC sınıflandırıcısı ortalama doğruluk oranları 79



KISALTMALAR VE SİMGELER LİSTESİ

ACC: Doğruluk (Accuracy)

AdaBoost: Uyarlamalı Güçlendirme (Adaptive Boosting)

AI: Yapay Zeka (Artificial Intelligence)

AHI: Apne ve Hipopne İndeksi (Apnea and Hypopnea Index)

AI: Apne İndeksi (Apnea Index)

ANN: Yapay Sinir Ağları (Artificial Neural Networks)

ApEn: Yaklaşık Entropi (Approximate Entropy)

AUC: ROC Eğrisi Altında Kalan Alan (Area Under Curve)

BC: Bayes Sınıflandırıcısı (Bayes Classifier)

CAD: Bilgisayar Destekli Teşhis (Computer Assisted Diagnosis)

BGF: Bant Geçiren Filtre (Band Pass Filter)

BHC: İkili Hiyerarşik Sınıflandırma (Binary Hierarchical Classification)

BMF: Butterworth medyan filtreleme (Butterworth Median Filtering)

CSA: Merkezi Uyku Apnesi (Central Sleep Apnea)

CTM: Merkezi Eğilim Ölçüsü (Central Tendency Measure)

CVA: Ortak vektör yaklaşımı (Common Vector Approach)

DCVM: Ayırt edici Ortak Vektör Yöntemi (Distinguished Common Vector Method)

DCVA: Ayırt Edici Ortak Vektör Yaklaşımı (Distinguishing Common Vector Approach)

DFA: Sabit Dalgalanma Analizi (Detrended Fluctuation Analysis)

DT: Karar Ağacı (Decision Tree)

EDR: EKG'den türetilmiş solunum (ECG-Derived Respiration)

ECG: Elektrokardiyogram (Electrocardiogram)

EEG: Elektroensefalogram (Electroencephalogram)

EMG: Elektromiyogram (Electromyogram)

EOG: Elektrookülograf (Electrooculograph)

FF: İleri Beslemeli (Feed Forward)

FFNN: İleri Beslemeli Sinir Ağları (Feed Forward Neural Networks)

FFT: Hızlı Fourier Dönüşümü (Fast Fourier Transform)

FLDA: Fisher Doğrusal Ayırıcı Analizi (Fisher Linear Differential Analysis)

GLRT: Genelleştirilmiş Olabilirlik Oranı Testi (Generalized Likelihood Ratio Test)

HF: Yüksek Frekans Bileşeni (High Frequency Component)

HI: Hipopne İndeksi (Hypopnea Index)

HPF: Yüksek Geçiren Filtre (High Pass Filter)

HR: Kalp Atış Hızı (Heart Rate)

HRV: Kalp Atım Hızı Değişkenliği (Heart rate variability)

HRV: Kalp Atış Hızı Değişkenliği (Heart Rate Variability)

K: Basıklık (Kurtosis)

k-NN: k-En Yakın Komşu Sınıflandırıcısı (k-Nearest Neighbor Classifier)

LBP: Yerel Bölge Bilgisi (Local Binary Pattern)

LCP: Yerel Konfigürasyon Örüntüsü (Local Configuration Pattern)

LDA: Doğrusal Ayırtaç Analizi (Linear Discriminator Analysis)

LDC: Doğrusal Ayırtaç Sınıflandırıcısı (Linear Discriminator Classifier)

LF: Düşük Frekans Bileşeni (Low Frequency Component)

LLC: Lojistik Doğrusal Sınıflandırıcısı (Logistic Linear Classifier)

LLDA: Lojistik Doğrusal Ayırtaç Analizi (Logistic Linear Discriminator Analysis)

LOGR: Lojistik Regresyon (Logistic Regression)

LPF: Alçak Geçiren Filtre ((Low Pass Filter)

LR: Doğrusal Regresyon (Linear Regression)

LS-SVM: En Küçük Kareler-Destek Vektör Makineler (Least Squares-Support Vector Machines)

LZC: Lempel-Ziv Karmaşıklığı (Lempel-Ziv Complexity)

MİC: Mikroskopik Konfigürasyon (Microscopic Configuration)

MLPNN: Çok Katmanlı Yapay Sinir Ağları (Multilayer Artificial Neural Networks)

MSA: Birleşik Uyku Apnesi (Mixed Sleep Apnea)

NPV: Negatif Tahmin Değeri (Negative Predictive Value)

NREM: Hızlı olmayan göz hareketi (Non-Rapid Eye Movement)

O: Yerel Öznitelikler

OSA: Obstrüktif Uyku Apnesi (Obstructive Sleep Apnea)

PCA: Temel Bileşen Analizi (Principal Component Analysis)

PNN: Olasılıksal Sinir Ağları (Probabilistic Neural Networks)

PPV: Pozitif Tahmin Değeri (Positive Predictive Value)

PSD: Güç Spektral Yoğunluğu (Power Spectral Density)

PSG: Polisomnografi (Polysomnography)

QDA: Kuadratik Diskriminant Analizi (Quadratic Discriminant Analysis)

RBF çekirdeği: Gauss Radyal Temel Fonksiyonu Çekirdeği(Gauss Radial Basic Function Core)

RBM: Sınırlı Boltzman Makinesi (Restricted Boltzman Machine)

RDI: Solunum Bozukluk İndeksi (Respiratory Disorder Index)

REM: Hızlı Göz Hareketi (Rapid Eye Movement)

RESP: Solunum (Respirasyon)

RF: Rastgele Orman (Random Forest)

RFE: Özyinelemeli Özellik Eliminasyonu (Recursive Feature Elimination)

ROC: Çalışma Karakteristiği Eğrisi (Receiver Operating Characteristics)

RR: Ardışık R Tepe Noktası (Consecutive R Peak)

RVM: Alaka Düzeyi Vektör Makineleri (Relevancy Vector Machines)

S: Çarpıklık (Skewness)

SAS: Uyku Apnesi Sendromu (Sleep Apnea Syndrome)

SAS-CAD: SAS tespit ve teşhisi yapan CAD sistemleri

SFI: İstatiksel Öznitelik Çıkarımı (Statistical Feature Inference)

SHHS: Uyku Kalp Sağlığı Çalışması (Sleep Heart Health Study)

SNS: Hassaslık (Sensitivity)

SPC: Özgüllük (Specificity)

SpO₂: Oksijen Satürasyonu (Oxygen Saturation)

SVM: Destek Vektör Makineleri (Support Vector Machines)

UCD Veritabanı: St. Vincent Üniversitesi Hastanesi / University College Dublin Uyku Apnesi Veritabanı

VAR: Yerel Varyans

VLF: Çok Düşük Frekans Bileşeni (Very Low Frequency Component)

WFDB: Dalga Biçimi Veritabanları (WaveForm Databases)

WT: Dalgacık Dönüşümü (Wavelet Transform)

1. GİRİŞ

Uyku, bilincin dış dünyaya çeşitli uyaranlara geri dönülebilir şekilde, kısmen veya tamamen yitirildiği, tepkinin azaldığı bünyenin dinlenme hali olarak tanımlanmaktadır (Boostani vd., 2017: 79). İnsan yaşamının yaklaşık üçte biri uykuda geçmektedir. Bu neden ile uyku, insan yaşamının önemli bir kısmını kapsamaktadır. Kişi sağlığı ve günlük yaşam kalitesi üzerindeki etkileri nedeniyle uykunun yaşam için önemli bir etken olduğu görülmektedir. İnsan zihinsel ve bedensel sağlığını korumak için uykuya ihtiyaç duymaktadır. Uykunun, insan fizyolojisine etkileri hakkında yapılan çalışmalar sonucunda, uyku davranışsal ve fizyolojik belirleyiciler yardımıyla tanımlanmakta ve iki ana evreye ayrılarak incelenmektedir (Le Bon, 2020: 7). İlki Hızlı Göz Hareketi (Rapid Eye Movement - REM) evresidir. REM’de uyku ve uyanıklık halleri birlikte gözlemlenmektedir. İkinci ana evre ise Hızlı Olmayan Göz Hareketi (Non-Rapid Eye Movement - NREM) evresidir. Günümüzde, geçmişte anlaşılamayan hastalıklar uyku sırasında yapılan incelemelerde anlaşılabilir hale gelmektedir. Bu durum keşfedildikten sonra uyku tıbbi adı altında farklı bir disiplin olarak incelenmeye başlanmıştır (Bailey ve Attanasio, 2012: 319). Uyku sırasında hastalıkların incelenmeye başlanmasıyla, daha önce nedeni bulunamayan, bebek ve yaşlılarda uykuda görülen ani ölüm olayları vb. hastalıkların teşhis edilmesinde gelişmeler yaşanmıştır. Uyku ile ilgili hastalıklar, gündüz uykululuk hali, yorgunluk, horlama, okul çağındaki çocukların düşük performansının, yanı sıra; kardiyovasküler (hipertansiyon, kardiyak aritmi, miyokard enfarktüs, inme vs.), nörolojik, psikiyatrik ve metabolik hastalıkların ortaya çıkma riskini arttırmaktadır (Dai vd., 2019: 26). Dikkat eksikliği nedeniyle mesleki kazalara veya trafik kazalarına sebep olabilmektedir. Uyku hastalıklarının içerisinde en önemlilerinden biri, uykuda solunum bozukluklarıdır. Tedavi edilmezse kişide uykuda ölümlere kadar varan ağır sonuçlar gözlemlenmektedir. Bu nedenle, uyku ile ilgili problemlerinin araştırılması, doğru teşhis ve tedavi hayati önem taşımaktadır.

Amerika Uyku Tıbbi Akademisi’nin 2014 yılında yayınladığı verilerine göre 80’nin üzerinde uyku hastalığı bulunmaktadır (Sateia, 2014: 1388). Dünya nüfusunun %1,5’inin ve Türkiye’de ise yaklaşık 1,5 milyon insanın uyku hastalığı yaşadığı tahmin edilmektedir (Demir vd., 2015: 300). İnsan sağlığı açısından taşıdığı riskler nedeniyle bu hastalıklar arasındaki en önemlilerinden biri de Uyku Apnesi Sendromu (SAS)’dur. Dünyadaki uyku apnesi hastalarının %80-90’ına henüz tanı konulamadığı hesaplanmıştır. Bu oranın Türkiye’de %95-98 olduğu sanılmaktadır. SAS, genel olarak, uyku sırasında üst solunum yolunun geçici ve/veya tamamen tıkanması böylelikle havanın akciğerlere gitmesinin engellenmesi olarak tanımlanmaktadır (Young vd., 1993:1231). Uyku sırasında solunumun tamamen durması apne, kısmi olarak

durması da hipopne olarak adlandırılmaktadır (Nieto vd., 2000: 1831). SAS durumunda, uyku esnasında yumuşak dokuların gevşemeye başlaması ve nefes alma sırasında oluşan negatif basınç ile birlikte üst solunum yolunun tıkanarak akciğerlere yeterli hava akışı engellenmektedir. Bunun sonucunda kandaki oksijen miktarı azalır, karbondioksit miktarı artar ayrıca ECG dalgalarının süresinde ve genliğinde değişiklikler meydana gelmektedir. SAS, hava akışının durması esnasında, hastanın solunum çabası gösterip göstermediğine göre incelenmektedir. Bunlar; Obstrüktif Uyku Apnesi (Obstructive Sleep Apnea - OSA), Merkezi Uyku Apnesi (Central Sleep Apnea - CSA) ve Birleşik Uyku Apnesi (Mixed Sleep Apnea - MSA) olarak adlandırılır. Hastanın solunumun devam edebilmesi için bir abdominal ve torasik çabının görüldüğü OSA, %80 oranıyla en yaygın görülen SAS tipidir ve apneler 20 saniye ile 1-2 dakika süresince gerçekleşmektedir (Bixler vd., 2001: 610). Apnelerin %2'sini oluşturan CSA, solunumu kontrol eden kaslara beyinden yeterli sinyal gönderilmemesi sonucu oluşmaktadır (Flemons ve McNicholas, 1997: 20). CSA'da solunum hareketleri ve hava akımı en az 10 saniye boyunca tamamen kesilmektedir. Hastalarda OSA ve CSA'nın birlikte görülmesi hali MSA olarak adlandırılmaktadır. MSA, SAS'nin yaklaşık %18'ini oluşturmaktadır. Uyku apnesi, kardiyovasküler sistemi etkileyerek hipertansiyon düzeyinin artması, koroner arter hastalığı ve aritmiye sebep olabilmektedir (Partinen, 2011: 286). Ek olarak, SAS, aşırı gündüz uykululuk durumu, uykululuk nedeniyle artan motorlu taşıt ve iş yeri kaza seviyeleri, zayıf gündüz bilişsel performansı, depresyon, azalmış cinsel fonksiyon gibi yaşam kalitesi sorunları ile de ilişkilendirilmiştir. Uyku apnesi yetişkin erkeklerde, menopoz sonrası kadınlarda ve prematüre bebeklerde daha yoğun görülmektedir (Troxel vd., 2010: 1634). Ayrıca obez, üst solunum yolları dar olan ve horlayan kişilerde uyku apnesi sendromu olma olasılığının daha fazla olduğu gözlemlenmiştir. Apneik olaylar her iki uyku evresinde ortaya çıkmasına rağmen daha çok NREM evrelerinde görülmektedir. Uyku apnesi hastalığının yaygınlaşması, hastaların yaşam kalitelerinin düşmesi ve ölümcül risklere sahip olması sebebiyle tanı ve tedavi yöntemlerine olan gereksinimi artırmaktadır.

SAS, tanısı için uyku laboratuvarlarında Polisomnografi (Polysomnography - PSG) kullanılmaktadır (Bixler vd., 2001: 610). Ayrıca PSG'den fizyolojik uyku evrelerini inceleyerek uyku kalitesini değerlendirmek ve uyku bozukluklarını (OSA, huzursuz bacak sendromu ve periyodik bacak hareket bozukluğu vb.) teşhis etmede de yararlanılmaktadır. PSG ile hastadan tüm gece boyunca horlama, burun hava akımı, orta çene hareketi, Solunum (Respirasyon - RESP), Elektrokardiyogram (Electrocardiogram – ECG), Elektroensefalogram (Electroencephalogram - EEG), solunum çabası, sağ ve sol Elektrokülograf

(Electrooculograph - EOG). Elektromiyogram (Electromyogram - EMG), Oksijen Satürasyonu (Oxygen Saturation - SpO₂), göğüs hareketi ve karın hareketi dâhil olmak üzere yaklaşık 16 sinyal kaydı toplanmaktadır. Gece boyunca alınan bu kayıtlardan solunumun kaç defa durduğu, ne kadar süre ile durduğu, durduğu andaki oksijen satürasyonu ile apne tipi belirlenmektedir (Flemons ve McNicholas, 1997: 20). PSG'den edinilen bilgiler doğrultusunda, apne/hipopne gerçekleşme sayılarına göre SAS derecesi de belirlenebilmektedir. SAS derecelendirmesi için, apne/hipopne sayımlarının saat başına ortalamalarının alınmasıyla ölçülen, Apne İndeksi (Apnea Index - AI), Hipopne İndeksi (Hypopnea Index - HI), Apne ve Hipopne İndeksi (Apnea and Hypopnea Index - AHI) veya Solunum Bozukluk İndeksi (Respiratory Disorder Index - RDI) gibi standart kriterler değerlendirilmektedir. Yaygın olarak kullanılan AHI kriterine göre, kayıtlarda apne içeren kısım 100 dakika ve üzeri ise uyku apnesi hastası, 5 ila 99 dakika arası sınırdadır ve 5 dakikadan az ise sağlıklı olarak sınıflandırılmaktadır (Nieto vd., 2000: 1831). Kriterler uyku teknisyenleri ve hekimler tarafından değerlendirilerek hasta için gerekli tedavi yöntemi seçilmektedir. Fakat PSG yöntemin birçok dezavantajı bulunmaktadır (Chokroverty, vd., 2005: 2). PSG kaydının yapılabilmesi için uyku laboratuvarlarına ve yetişmiş teknik elemanlara ihtiyaç duyulmaktadır. Dünyada uyku laboratuvarlarının az olması nedeniyle uzun bekleme listeleri oluşmaktadır. PSG kayıtların gece boyunca ve en az 7 saat süreyle yapılması, personelin ve cihazların tüm gece boyunca çalışmasından dolayı uyku testleri pahalı olmaktadır. Bunun yanı sıra, hastanın farklı bir yerde uyumasının gerekmesi, test için birçok parametreye bakılması gerektiğinden hastaya birçok sensörün takılması, hastanın rahat uyuyamamasına neden olmaktadır. Bu yüzden test tekrarlanabilmektedir. Testin bu dezavantajlarından dolayı, SAS tanısında PSG dışında başka yöntemler araştırılmaktadır.

Bu araştırmalar sonucunda tanı ve tedavide sağlık çalışanlarına yardımcı olmak için sinyal işleme, veri madenciliği gibi bilgisayar destekli tespit sistemleri geliştirilmektedir (Hassan ve Haque, 2016: 258). Hastalığa neden olan sebepleri bulmak için elektrofizyolojik işaretlerden de yararlanılmaktadır (Liguori vd., 2016: 19). Uzman personel, incelemeler sonucunda elde edilen vücuttaki elektrofizyolojik işaretleri, sağlıklı bir insandaki sinyallerle karşılaştırarak farklılıkları bulunmaktadır. Farklılıklardan yararlanılarak hastalıkların kendi içinde ve birbirleriyle etkileşimleri incelenmektedir. Çok çeşitli işaretlerin aynı anda incelenmesi insan gözüyle mümkün olmadığından, Bilgisayar Destekli Tanı (Computer Assisted Diagnosis - CAD) sistemlerinin, hızı ve gücünden faydalanmak üzere modeller tasarlanmaktadır. Elektrofizyolojik işaretlerin, hastalıkların teşhisinde işaret işleme,

matematiksel yöntemler, modelleme yöntemleri ve sınıflandırma algoritmalarıyla kullanımıyla başarılı sonuçlar elde edildiği gözlemlenmektedir.

ECG bu sinyallerden biri olarak karşımıza çıkmaktadır. ECG sinyali ile kalbin aktivitelerini elektriksel olarak temsil edilir (Sharma ve Sharma, 2016: 118). Anormal anların tespitinde Kalp Atım Hızı Değişkenliği (Heart rate variability - HRV)'in oluşturduğu desenlerdeki farklılıklar hastaların sağlık durumu ve hastalık tipi hakkında önemli verileri içerdiği ortaya çıkmıştır. Sürekli değişim içinde olan ECG periyodu, P-QRS-T dalga parçacıklarından oluşmaktadır. Ardışık R Tepe Noktası (Consecutive R Peak - RR) arasındaki boyut ve şekilce değişiklikler göstermektedir. Bu bilgiler ışığında ECG sinyalindeki değişimler kullanılarak hastaların sağlık durumları, hastalığın tanısı hakkında bilgi edinmede kullanışlı olabileceği düşünülmektedir.

Tez çalışması kapsamında, PhysioNet Apnea-ECG veri tabanından alınan ECG sinyallerinden ön işleme, öznitelik çıkarımı, öznitelik seçimi işlemleri ile elde edilen öznitelikler kullanılarak apneli/apnesiz ayrımının yapıldığı 2-sınıflı teşhis ve hasta/sınırdı/sağlıklı ayrımının yapıldığı 3-sınıflı teşhis çalışması yapılması amaçlanmıştır.

Bu tez çalışması, belirtilen amaca uygun olarak altı bölümden oluşmaktadır. Bölüm 1'de çalışma hakkında genel bilgi verilmekte ve çalışmanın amacı anlatılmaktadır. Bölüm 2'de apne tanı ve/veya teşhisi konusunda yapılan çalışmalar son teknolojilerin belirlenmesi için literatür incelemesi yapılmaktadır. Bölüm 3'de ECG sinyalinin elde edildiği veri tabanı hakkında bilgi verilmektedir. CAD sistemi ve bu sistemi oluşturan temel bileşenler tanıtılmaktadır. Ön işleme aşamasında; ECG sinyalinden elde edilen RR aralıklarının belirlenmesinde kullanılan z-skor normalizasyonu ve butterworth bant geçiren filtreleme yöntemleri anlatılmaktadır. Daha sonra öznitelik çıkarım ve seçimi süreçlerinde kullanılan Yerel Konfigürasyon Örüntüsü (Local Configuration Pattern - LCP), istatistiksel öznitelik çıkarım yöntemleri, Temel Bileşen Analizi (Principal Component Analysis - PCA), Ortak Vektör Yaklaşımı (Common Vector Approach - CVA) ve Ayırt Edici Ortak Vektör Yaklaşımı (Distinguished Common Vector Approach - DCVA) yöntemleri hakkında teorik bilgiler verilmektedir. Ayrıca bu bölümde sınıflandırma sürecinde kullanılan Lojistik Doğrusal Sınıflandırıcı (Logistic Linear Classifier - LLC), Doğrusal Ayırtaç Sınıflandırıcı (Linear Discriminator Classifier - LDC), Fisher Doğrusal Ayırıcı Analizi (Fisher Linear Differential Analysis - FLDA), Bayes Sınıflandırıcı (Bayes Classifier - BC), k-En Yakın Komşu Sınıflandırıcısı (k-Nearest Neighbor Classifier - k-NN) sınıflandırıcıları tanıtılmaktadır. Bölüm 4'de Bölüm 3'de anlatılan tekniklere dayalı olarak geliştirilen CAD sistemin deneysel çalışmalarından bahsedilmektedir. Bölüm 5 de ise deneysel

alıřma sonucu elde edilen bulgular paylařılmıř ve yorumlanmaktadır. Son olarak Blm 6'da elde edilen sonulardan bahsedilmektedir.



2. LİTERATÜR ÇALIŞMASI

Literatür çalışmasında, apne tespit ve/veya teşhisi konusunda son teknolojilerin belirlenmesi için 1993-2021 yılları arasında önerilen sistemler incelenmiştir. Bu sistemler veri seçimi, ön işleme öznitelik çıkarımı/seçimi, sınıflandırma süreci ve performanslarına göre detaylandırılmıştır.

SAS tespit ve teşhisi yapan CAD sistemleri (SAS-CAD), tüm CAD sistemlerinde olduğu gibi, verilerin temini, bu verilerin ön işlenmesi, ön işlenmiş verilerden öznitelik çıkarımı/seçimi ve özniteliklerin sınıflandırma aşamalarını gerçeklemektedir. SAS tespiti için veri temini PSG testi ile elde edilmektedir (Chokroverty, vd., 2005: 2).

Literatürde, SAS-CAD sistemlerinde, hastanın kardiyak değişimleri ve solunumu değerlendirmek amacı ile sırasıyla ECG, RESP sinyalleri, nabız oksimetresinden edinilen ve apne/hipopne ayırımında önem arz eden SpO₂ sinyali ve horlama takibi için ses sinyali kullanılmaktadır. Bu sinyaller, genel olarak Physionet Apne-ECG Veri Tabanı (Penzel vd., 2000: 255), St. Vincent Üniversitesi Hastanesi / University College Dublin Uyku Apnesi Veri tabanı (UCD Veri tabanı) (Goldberger vd., 2000: 215), Negrín Üniversitesi Hastanesi (Las Palmas) tarafından sağlanan HuGCDN2014 veri tabanı (Ravelo-García, 2018), Uyku Kalp Sağlığı Çalışması (Sleep Heart Health Study - SHHS) (Zhang vd., 2018: 1351) veri tabanlarından temin edilmektedir.

Ön işleme aşamasında analiz edilecek verilerin gürültüden arındırılması, standartlaştırılması ve verilerden ilgi alanlarının tespiti amaçlanmaktadır. Öznitelik çıkarımı aşamasında PSG testi ile temin edilen verilerden apneli/apnesiz anların karakteristik özellikleri tanımlanmaktadır. Veriler bu karakteristik özelliklere göre sınıflandırılacağından, öznitelik çıkarımı SAS-CAD sistemlerinin verimliliğini etkileyen en önemli aşamadır. Eş-zamanlı uygulamalarda verinin temsili kadar o verinin değerlendirme süresi de önemli olduğundan gerekirse öznitelik seçimi de uygulanabilmektedir. Son olarak, sınıflandırma aşamasında, öznitelikler apneli/apnesiz olarak sınıflandırılmaktadır Ayrıca, apneli verinin apne/hipopne ve OSA/CSA/MSA ayırımının yapıldığı çalışmalar da literatürde mevcuttur. Bu durum göz önüne alındığında literatür çalışması üç ana başlıkta incelenmektedir.

2.1. Apne/Hipopne Teşhisi Yapılan Çalışmalar

2.1.1. Nabız Oksimetresi Kullanılan Çalışmalar

Rolón vd. apne/hipopne teşhisi için ayırt edici aktivasyon seçimi ve ayırt edici sütün seçimi olarak adlandırdıkları iki yaklaşım önermişlerdir (Rolón vd., 2017: 358). Yazarlar bu yaklaşımları, tamamlanmış, tamamlanmamış ve FULL (seyrek temsil) koşullarında incelemişler ve SHHS veri tabanını kullanarak doğrulamışlardır. Çok Katmanlı Yapay Sinir Ağları (Multilayer Artificial Neural Networks - MLPNN) kullanılarak gerçekleştirilen teşhis çalışmasında, %90,6 Doğruluk (Accuracy – ACC), %81,4 SNS: Hassaslık (Sensitivity – SNS), %79,31 SPC: Özgüllük (Specificity – SPC) ve %80,35 ROC Eğrisi Altında Kalan Alan (Area Under Curve - AUC)ile MDCS-OD'nin diğer yaklaşımlara göre daha iyi performans gösterdiği gözlemlenmiştir.

Jung vd. apneik olay ve oksijen desatürasyonu arasındaki kanıtlanmış ilişkiye dayanarak, apne olaylarının saptanması ve apne/hipopne ataklarının bulması için bir algoritma geliştirmeyi amaçlamışlardır (Jung vd., 2018: 706). AHI değerleri 0 ila 86,5 olay/saat arasında değişen 230 PSG kayıttan sırasıyla 138 (% 60) kayıt eğitim seti, 92 (% 40) kayıt test seti olarak ayırmışlardır. Yazarlar eğitim setini, bir apneik olayın neden olduğu SpO₂ değerlerinin dalgalanmasındaki morfometrik karakteristikleri çıkarmak ve daha sonra apneik olay tespiti için kuralları oluşturan sayısal değerleri belirlemek için kullanmışlardır. AHI'nin doğrudan tahmini için eğitim seti ile AHI tahminleri yapabilen bir regresyon modeli % 95'lik anlamlı bir olasılık seviyesine sahip bir Hill fonksiyonuna dayanarak geliştirilmişlerdir. PSG sonucunda elde edilen apne/apnesiz karşılaştırmasında eğitim seti için ortalama % 83,5 ± 11,8 % SNS , % 89,1 ± 10,5 SPC, % 84,8 ± 13,0 Pozitif Tahmin Değeri (Positive Predictive Value – PPV), % 89,3 ± 12,5 Negatif Tahmin Değeri (Negative Predictive Value – NPV), % 91,3 ± 5,6 ACC ve Cohen'in kappa katsayısı 0,71 ± 0,09 olarak bulunmuştur. Test seti için % 82,8 ± 11,7 SNS, % 88,6 ± 10,5 SPC, % 83,8 ± 12,4 PPV, % 89,9 ± 11,0 NPV, % 91,0 ± 5,7 ACC ve Cohen'in kappa katsayısı 0,71 ± 0,08 elde edilmiştir.

Morales vd. uyku apnesi hastaların AHI derecesinin 5'ten yüksek olduğundan, AHI derecesini tanımlayacak özneliklerin kullanımını önermişlerdir (Morales vd., 2017: 43). Bu amaçla, SpO₂ sinyallerinden ölçülen oksijen doygunluğuna bağlı özneliklerin çıkarılması için Dalgacık Dönüşümü (Wavelet Transform - WT) ve faz alanına dayanan bir yöntem kullanmışlardır. Önerilen öznelikler, dışbükey gövde algoritması kullanılarak hesaplanan faz uzayındaki her bir dalgacık seviyesinin kapsadığı alana göre çıkartılmıştır. Daha sonra,

çıkartılan özniteliklerin k-NN ve En Küçük Kareler-Destek Vektör Makineler (Least Squares-Support Vector Machines - LS-SVM) algoritmaları kullanılarak sınıflandırılması sonucu sırasıyla %93,0 ve % 88,61 ACC oranı ile hastaların AHI derecesi belirlenmiştir.

Sánchez-Morillo vd. SpO₂ sinyalinden elde edilen öznitelikleri kullanarak dört sınıflı (SAS olmayan, hafif SAS, orta SAS, şiddetli SAS) SAS teşhisi yapmayı çalışmışlardır (Sánchez-Morillo vd., 2014: 1854). Zaman ve frekans alanı analizi, doğrusal olmayan analiz teknikleri kullanılarak azaltılmış bir öznitelik seti oluşturmuşlardır. Öznitelik seçimi için, çok sınıflı sınıflandırıcının her bir düğümünde, sıralı geriye doğru seçim kullanılmıştır. Hesaplama ve kavramsal sadeliği nedeniyle çok dereceli problem içinde farklı sınıflandırıcıları kullanan İkili Hiyerarşik Sınıflandırma (Binary Hierarchical Classification - BHC) yapısı seçmişlerdir. BHC'nin bir parçası olarak üç sınıflandırıcı eğitilmiştir. Bu çalışmada, DT, Doğrusal Diskriminant Analiz (Linear Discriminant Analysis - LDA), Doğrusal Regresyon (Linear Regression - LR), k-NN, Genelleştirilmiş Olabilirlik Oranı Testi (Generalized Likelihood Ratio Test - GLRT), SVM, Alaka Düzeyi Vektör Makineleri (Relevancy Vector Machines - RVM) ve Olasılıksal Sinir Ağları (Probabilistic Neural Networks - PNN) sınıflandırıcılar her bir düğüm için aday olarak değerlendirilmiştir. Sonuç olarak DT, SVM ve PNN seçilerek ve % 82,6 ACC bulunmuştur.

2.1.2. ECG Kullanılan Çalışmalar

Sharma ve Sharma apne/hipopne ve SAS'nın tespiti için hastanın ECG sinyaline dayalı bir yöntem önermişlerdir (Sharma ve Sharma, 2016: 116). ECG sinyalinden çıkarılan; RR aralıklarının ortalaması, RR aralıklarının standart sapması ve QRS yaklaşımı hatası enerjisine dayanan öznitelikler apne ve normal segmentleri ayırt etmek için kullanılmıştır. Apne/hipopne teşhisi için PhysioNet Apnea-ECG veritabanında belirlenen performans kriterlerine göre k-NN; ACC %73,3 SNS %72,5 SPC %73,8 AUC 73,8, MLPNN; ACC % 81,2 SNS %77,5 SPC %83,4 AUC 80,7, SVM RBF: Gauss Radyal Temel Fonksiyonu Çekirdeği(Gauss Radial Basic Function Core-RBF çekirdeği) ACC % SNS % 82,6 SPC %76,7 88,2 AUC 82,0, LS-SVM (RBF çekirdeği); ACC % 83,8 SNS % 79,5 SPC %88,4 AUC 83,4 sonuçları elde edilmiştir. Apne/hipopne sınıflandırmasında RBF çekirdeğine sahip LS-SVM algoritması kullanılarak yaklaşık % 84'lük bir SNS elde edilmiştir.

González vd. apne/hipopne teşhisi için HRV öznitelik seçim sürecine dayanan bir uyku apnesi karakterizasyonu ve sınıflandırma yaklaşımı üzerinde çalışmışlardır (Martín-González vd., 2017: 47). Çalışmada doğrusal/doğrusal olmayan değişkenler, RR serisinden elde edilen;

Cepstrum Katsayıları, Filterbanks, Sabit Dalgalanma Analizi (Detrended Fluctuation Analysis-DFA) ve bu özniteliklerin ikili kombinasyonlarından oluşan öznitelikler kullanılmıştır. Lojistik Regresyon (Logistic Regression - LOGR) , LDA ve Kuadratik Diskriminant Analizi (Quadratic Discriminant Analysis - QDA) sınıflandırıcıları ile Negrín Üniversite Hastanesi (Las Palmas de Gran Canaria, İspanya) tarafından sağlanan HuGCDN2014 veri tabanındaki veriler sınıflandırılmıştır. Segment başına en iyi sonuçlar; ACC% 81.96, SNS % 70.95, SPC % 85.47 AUC 0.92 ile LDA sınıflandırıcı kullanılarak bulunmuştur. Physionet Apne-ECG veritabanında ise segment başına ACC % 84,76, SNS % 81,45, SPC % 86,82 AUC 0.92 olarak QDA ile en iyi performans sonuçları elde edilmiştir.

Alvarez-Estevez ve Moret-Bonillo, uyku apnesi teşhisinde HRV kullanımı üzerine araştırma yapmışlardır (Alvarez-Estevez ve Moret-Bonillo, 2016: 14). Teorik olarak HRV integral nabız frekansı modülasyonu model varsayımı altında optimum olma avantajına sahip olduğunu belirlemişlerdir. Yöntem için sadece HRV çalışmalarında standart olarak tanımlanan spektral bantlar göz önünde bulundurularak, LF/HF (Low Frequency Component - Düşük Frekans Bileşeni/ High Frequency Component - Yüksek Frekans Bileşeni) oranı ve VLF (Çok Düşük Frekans Bileşeni - Very Low Frequency Component) öznitelikleri türetmişlerdir. Elde edilen farklı öznitelik kombinasyonları arasında karşılaştırmalı bir istatistiksel analiz ve BC ile incelenmiştir. LF/HF oranını öznitelik olarak kullanılan algoritmada %88 AUC ile en iyi performans hesaplanmıştır.

2.1.3. RESP Kullanılan Çalışmalar

Huang vd. apne/hipopne teşhisi için hava akımı sinyalinin kullanıldığı bir algoritma önermişlerdir (Huang vd., 2017: 32). RESP sinyalindeki gürültünün giderilmesi için sürgülü pencere ve sabit kısa süre dilimlerini kullanmışlardır. Önerilen algoritma iki aşamadan oluşturmuşlardır: İlk aşamada solunum olaylarını daha doğru şekilde tanımlamak için kısa zaman dilim olay durumu tespit edilmektedir. Kısa zaman dilim olay durumundan, durum akışları oluşturulmuştur. İkinci aşamada kısa zaman dilimi durumunun durum akışından farklı solunum sinyalleri türetilerek öznitelikler seçilmiştir. Sichuan Üniversitesi'nin Huaxi Uyku Merkezi'nden (Huaxi Sleep Center of Sichuan University - HSCSU) ve Chengdu Geleneksel Çin Tıbbı Üniversitesi Eğitim Hastanesinden (Chengdu Traditional Chinese Medicine University Training Hospital - CTCMUTH) 30 kişinin uyku verileri BC analiz edilmiştir. SNS ve PPV sırasıyla % 92,3 ve % 92,3 olarak belirlenmiştir.

Koley ve Dey, tek kanallı oronazal hava akışı sinyalinin kaydedilmesinden elde edilen ortalama olay süresini ve kişisel bilgisayar tabanlı veri toplama sistemini SAS şiddetinin değerlendirilmesi için kullanmışlardır (Koley ve Dey, 2013: 2082). AHI, AI, HI ve apne/hipopne tespiti yapmayı amaçlamışlardır. Veri toplama sisteminde önceden güçlendirilen solunum sinyalleri; ilk olarak 50 Hz'lik çentik filtresinden, ardından 0.01-15 Hz'lik geçiş bandına sahip bir altıncı dereceden aktif bant geçiren filtreden geçirilmekte ve normal solunum sinyali genliğine bölünerek normalize edilmektedir. Solunum genliği ve solunum hızı apne/hipopne olaylarında değişkenlik gösterdiğinden, normalleştirilmiş solunum sinyalinden elde edilen ani solunum genliğini ve anlık solunum aralığını incelenmişlerdir. Güç Spektral Yoğunluğu (Power Spectral Density - PSD) tahmininden frekans etki alanına dayalı öznitelikler çıkarmışlardır. Öznitelik seçimi için SVM tabanlı bir Özyinelemeli Özellik Eliminasyonu (Recursive Feature Elimination - RFE) tekniği kullanılmaktadır. SVM sınıflandırıcı ile HI, AI ve AHI için sırasıyla 0.970, 0.986 ve 0.982 bulunmuştur.

Koley ve Dey oronasal hava akışı sinyalinin tek kanallı kaydından uyku sırasında meydana gelen apne/hipopne olaylarının tespiti için otomatik bir yöntem önermişlerdir (Koley ve Dey, 2012: 85). Apne/hipopne olaylarının tanımlanması için, örtüşen kısa solunum pencerelerinin her birinden üç zaman alanı ölçüsü çıkarılmıştır. Normal ve anormal solunum olaylarını ayırmak için hava akışı sinyali alanı 90'dan büyükse apne olayı meydana gelir bulgusundan faydalanılmıştır. Sınıflandırıcı modeli kurulurken sıralı ardışık örtüşen pencereler üzerinde ardışık kararlar, normal nefeslerden anormal solunum olaylarını tanımlamak için sezgisel kurallarla birleştirilmiş, üç ikili SVM tabanlı sınıflandırıcıdan oluşan grup kullanılmıştır. Apne anının tespitinde çapraz doğrulama ve bağımsız test ACC'sı sırasıyla % 93,3 ve % 92,8 olarak, hipopne olayı için bu iki metrik % 90,1 ve % 89,6 olarak elde edilmiştir.

2.1.4. Ses Sinyali Kullanılan Çalışmalar

Karunajeewa vd. horlama ile ilgili seslerin SAS teşhisinde kullanılabilecek öznitelikler taşıdığını gözlemlemişlerdir (Karunajeewa vd., 2011: 83). Daha yüksek dereceli istatistikler tabanlı algoritma kullanılarak perde tahmini ve toplam hava yolu yanıtı özniteliklerinden türetilen horlama parametreleriyle beslenen LR modeli kullanılarak algoritma oluşturulmuşlardır. Perde tahmini ile hava yolu titreşimlerinin karakteristik bir zaman alanını ve toplam hava yolu yanıtı ile çökmekte olan üst hava yollarının neden olduğu akustik değişiklikler temsil edilmektedir. Önerilen algoritmanın performansı, 41 kişinin gece boyunca horlama seslerinden oluşan bir klinik veri tabanı üzerinde k-katlama çapraz doğrulama tekniği kullanılarak sırasıyla %92,3, %89,3 ve %0,96 SPC, SNS ve AUC elde edilmiştir.

Tabak, uyku apne sendromu tanısı için, kalp ve solunum seslerinden elde edilen zaman ve frekans düzlemi parametrelerinin çeşitli kombinasyonları ile yapılan sınıflandırma yöntemini kullanmıştır. En başarılı sonuca kalp ve solunum sesi zaman ve frekans düzlemi parametrelerinin birlikte özellik vektörü olarak kullanıldığı, K en yakın komşuluk algoritması kullanılan sınıflandırıcı ile elde edilmiştir.

2.1.5. EEG Kullanılan Çalışmalar

Übeyli vd. apne/hipopne teşhisinde insan EEG aktivitelerindeki değişikliklerin otomatik tespiti için LS-SVM ile sınıflandırma yöntemini önermişlerdir (Übeyli vd., 2010: 4463). Çalışmada C3, C4, O2 elektrotlarından hipopne öncesi ve sırasında kaydedilen EEG sinyallerinin otoregressif i PSD tahminiyle bulunmaktadır. PSD'ler ile gücün frekansla dağılımı tanımlanmıştır. EEG sinyallerini tanımlayan öznitelikler Burg otoregressif yöntemi ile hesaplanmaktadır. Çıkarılan Burg otoregressif katsayıları LS-SVM'nin girişi olarak kullanılmış ve ACC % 95,00 olarak bulunmuştur.

Yörük, çalışmada, uyku apnesi anındaki EEG sinyalleri incelenerek spektral analizini yapılması amaçlanmaktadır (Yörük 2019: 5). PSG kayıtları kullanılarak EEG sinyallerine sinyal işleme teknikleri uygulanarak spektral entropi değişimleri gözlenmiştir. Sinyallerin ilk olarak hızlı fourier dönüşümü ile spektral güç yoğunlukları elde edilmiş ve daha sonra spektral entropileri hesaplanmıştır. Karşılaştırma sonucu olarak entropinin minimum seviyelere düştüğü zamanların apne başlangıcına denk geldiği bulunmuştur.

2.1.6. Birleşik Yaklaşımlar Kullanılan Çalışmalar

Álvarez-Estévez ve Moret-Bonillo bulanık mantık tabanlı sistem ile SAS teşhisi yapmayı amaçlamışlardır (Álvarez-Estévez ve Moret-Bonillo, 2009: 7778). Yazarlar normal solunum esnasındaki genliğe göre apne/hipopne esnasındaki sinyallerin genliğinde belirgin bir azalmanın, hipopneyi tespit etmek için yeterli olabileceğini düşünmüşlerdir. Bulanık mantık girişleri; torasik ve abdominal solunum hareket sinyalleri ve SpO₂ sinyalinden oluşturmuşlardır. Bulanık mantık tabanlı sistem üç aşamadan modellenmektedir. İlk aşamada; SpO₂ sinyalinde meydana gelen düşmelerin desatürasyonlar olarak kabul edilip edilemeyeceklerini belirlemek için muhakeme birimleri oluşturularak soyutlama işlemi yapılmaktadır. İkinci aşamada muhakeme birimlerindeki düşüşler incelenmektedir. Son aşamada bu birimlerdeki apne çıktıkları birinci ve ikinci aşama ile ilişkilendirilmektedir. Olayların apne/hipopne olarak sınıflandırılma performansı sonuçları sırasıyla %87,0 ve %89,0 SNS ve SPC bulunmuştur.

Cohen ve Chazal, ECG ve SpO₂ sinyallerini kullanarak bebeklerde apne/hipopne teşhisi yapmayı amaçlamışlardır (Cohen ve Chazal, 2015: 118) . Tek kanallı 100 Hz olarak elde edilen ECG sinyallerinin RR aralıklarını oluşturmak için Pon Tompkins algoritmasına dayalı QRS algılama algoritması kullanılmış ve filtrelenmiş RR aralıkları SpO₂ sinyali içinde kullanılan 30 saniyelik zaman aralıklarına bölünmüştür. Daha sonra sınıflandırma aşamasında kullanılmak üzere; ortalama RR aralığı, aralıkların standart sapması, komşu RR aralıklarının ortalamasının karekökü, öznitelikleri RR aralıklarından PSD yöntemi ile elde edilmiştir. RR aralıklarına Hızlı Fourier Dönüşümü (Fast Fourier Transform - FFT) uygulanmıştır. 1 Hz'lik SpO₂ sinyalleri elde edilen oksimetre değerlerinin doygunluğu %65'i geçiyorsa ve doygunluktaki her bir değişiklik saniyede %4'ü geçiyorsa öznitelik setinden çıkartılmıştır. Oksimetre sensörlerinde zamana dayalı istatistiksel yöntemler kullanılarak öznitelikler elde edilmiştir. Ulusal işbirlikçi eve bebek izleme ve değerlendirme tarafından sağlanan veri tabanından elde edilen 396 veri kümesi kullanılmıştır. Çalışmada LDA sınıflandırıcısı, girişi olarak SpO₂ den elde edilen özniteliğinin kullanıldığında SPC %66,7, SNS %58,9, ACC %66,0; 35; ECG'den elde edilen öznitelikler kullanıldığında SPC %76,4, SNS %39,6, ACC %74,7 ve iki sinyalden elde edilen özniteliklerin birlikte kullanılmasıyla SPC %67,0, SNS %58,1, ACC %66,7 olarak hesaplanılmıştır.

Maali ve Al-Jumaily Elman, RBF ve İleri Beslemeli (Feed Forward - FF) sinir ağları, hava akımı, abdominal ve torasik kas hareket sinyallerini kullanarak apne/hipopne teşhisi yapmayı amaçlamışlardır (Maali ve Al-Jumaily, 2013: 97) . Çalışmadaki veri setini Sidney'deki Concord hastanesindeki 5 hastadan oluşturmuşlardır. Burun hava akımı, abdominal ve torasik hareket sinyallerinin her biri ortalama değerine bölünerek normalleştirilen sinyaller, 3 seviyeli Haar dalgacık paketi ile dalgacık katsayılarından farklı istatistiksel öznitelikler çıkarılmaktadır. Öznitelikler ANN algoritmasının girişlerine uygulanmaktadır. Girdi özellikleri değerleri [-1,1] aralığında ölçeklendirilerek her segment penceresi için 60 öznitelik üretilmektedir. ANN giriş katmanındaki düğüm sayısı, öznitelik sayısına eşitlenmiştir. Elman, FF ve RBF için AUC'nin ortalaması sırasıyla 0,8279, 0,8332 ve 0,7851 elde edilmiştir.

Cabrero-Canosa vd. PSG temelli hastanın bireysel SAS teşhisini sağlayan Yapay Zeka (Artificial Intelligence - AI) tekniklerine dayalı modüler bir sistem önermişlerdir (Cabrero-Canosa vd., 2003: 335). Tasarlanan sistem polisomnografik reçete, RESP fonksiyonları karakterizasyonu, hipnogramın yapısı ve SAS teşhisi bölümlerinden oluşmaktadır. Polisomnografik reçete; PSG uygunluğunu araştırmak için uyanma koşulu, duygusal durum, fiziksel durum, uyku sırasındaki davranış, başlıkları altında 25 sorudan oluşan Johnson ve Halberstadt protokolünde yer alan anket kullanılmaktadır. RESP fonksiyonunun

karakterizasyonu ile apneik bir yapının olası solunumsal düzensizliklerini tespit etmeyi amaçlamışlardır. Bunun için hastanın çevrimdışı RESP fonksiyonunu üç modül (apneik olayın tanınması, oksijen saturasyonunun karakterizasyonu ve solunum çabasının karakterizasyonu) göz önünde bulundurularak karakterize edilmektedir. EEG, EOG ve EMG'den elde edilen bilgiler ile hipnogramı oluşturulmuştur. Hipnogramı; hastanın solunum fonksiyonunun karakterizasyonu yoluyla tespit edilen solunum anormalliklerinin yorumlanması için kullanılmışlardır. Bu sinyaller 30 saniyelik bölümlere ayrılarak, her bölüm için serebral aktivitenin karakterizasyonu, göz hareketlerinin tespiti, baskın kas tonusunun karakterizasyonu, sınıflandırılması, her döneme bir uyku evresinin atanması adımları yapılmaktadır. Sınıflandırma sonucu %92,31 ACC olarak bulunmuştur.

2.2. OSA Teşhisi Yapılan Çalışmalar

2.2.1. Nabız Oksimetresi Kullanılan Çalışmalar

Alvarez vd. OSA+ ve OSA- hastalar arasında ayırım yapmak için SpO₂ sinyalinin doğrusal olmayan analizini değerlendirmişlerdir (Álvarez vd., 2006: 399). Klinik olarak OSA olduğundan şüphelenilen 187 referanslı poliklinik örneğinden, (111 hastada pozitif OSA geri kalan 76 hastada OSA negatif) PSG ile eşzamanlı olarak çıkarılan SpO₂ kullanılarak çalışmışlardır. Bununla birlikte çalışma sırasında yazarlar kesin bir tanı için standart olan PSG'ye alternatif olarak SpO₂'yi tek başına kullanmak için ek analiz gerçekleştirmişlerdir. SpO₂ sinyalinde Merkezi Eğilim Ölçüsü (Central Tendency Measure - CTM) ve Lempel-Ziv Karmaşıklığı (Lempel-Ziv Complexity - LZC) analizi ile spektral ve doğrusal olmayan öznitelikler çıkarılmıştır. Üç zaman alanı istatistiği, bir frekans alanı istatistiği, bir geleneksel spektral öznitelik ve 1 doğrusal olmayan öznitelik genetik algoritma ile seçilmektedir. Seçilen öznitelikler azaltılmış tamamlayıcı özelliğe sahip LR sınıflandırıcı ile ACC % 87,5, SNS % 90,6 ve SPC % 81,3 olarak hesaplanmıştır.

Marcos vd. OSA tanısında SpO₂ kayıtlarından elde edilen doğrusal olmayan öznitelikleri MLPNN ile değerlendirmişlerdir (Marcos vd., 2008: 79). Üç aşamadan oluşan algorithmada ilk olarak, doğrusal olmayan öznitelikleri SpO₂ kayıtlarından çıkarmak için LZC, CTM ve Yaklaşık Entropi (Approximate Entropy - ApEn) kullanılmıştır. İkinci aşamada, özniteliklerin kapladığı boyutsal uzayda bir ortonormal temeli tanımlamak için PCA kullanan ön işleme aşaması gerçekleştirilmektedir. Son olarak, sinir ağına dayalı sınıflandırma algoritması üçüncü aşamada uygulanmaktadır. MLPNN sınıflandırıcı ile ACC %85,5, SNS %89,8, SPC %79,4, AUC % 90,0 performans sonuçları elde edilmiştir.

Marcos vd. OSA tanısında geleneksel istatistiksel örüntü tanıma tekniklerinin kullanımını değerlendirmişlerdir (Marcos vd., 2009: 971). SpO₂ sinyalinden elde edilen spektral ve doğrusal olmayan öznitelikleri değerlendirmek için QDA, LDA, k-NN ve LR sınıflandırıcılarında girdi olarak kullanılmıştır. SpO₂ sinyalinden PSD tahmini için Welch yöntemi kullanılmıştır. S_T; PSD altındaki toplam alan, S_B; ilgili bandın etrafındaki alan, PA: PSD tepe genliği öznitelikleri çıkartılmıştır. Doğrusal olmayan öznitelikler, ApEn CTM, LZC yöntemleriyle çıkarılmaktadır. QDA, LDA, k-NN ve LR'ye spektral öznitelikler, doğrusal olmayan öznitelikler ve her iki grubun kombinasyonundan oluşan özniteliklerin uygulanmasıyla on iki farklı sınıflandırma algoritması geliştirilmektedir. En iyi sınıflandırma performans ACC % 87,61 SNS % 91,05 SPC % 82,61 AUC 0,925 ile LDA'ya sınıflandırıcısına aittir olduğu gözlemlenmiştir.

Álvarez vd. SpO₂ kayıtlarından gelen bilgileri kullanarak OSA tespit etmeyi amaçlayan bir NN tasarımı ve değerlendirilmesine odaklanmışlardır (Álvarez vd., 2016: 1). Zaman alanındaki istatistiksel momentler, frekans alanındaki istatistikler, geleneksel spektral ölçümler, doğrusal olmayan ölçümler yoluyla SpO₂ sinyalinden toplam on altı öznitelik çıkarmışlardır. Hızlı korelasyon bazlı filtreyle öznitelik seçimi yapılmaktadır. Seçilen özniteliklerle OSA hastalarını teşhis etmek için MLPNN önerilmişlerdir. 320 gözetimsiz SpO₂ kaydının %60'i eğitim %40'i test olarak ayrılmıştır. Sınıflandırma sonucunda test setinde sırasıyla %94,2, %69,6 ve % 89,8 SNS, SPC ve ACC sağlamıştır.

2.2.2. ECG Kullanılan Çalışmalar

Bozkurt vd. ECG sinyali ile makine öğrenimi tabanlı yeni bir hibrid uyku/uyanıklık algılama yöntemi geliştirmeyi amaçlamışlardır (Bozkurt vd. , 2020: 241). 10 OSA hastasının ECG sinyalinden elde edilen HRV ve dijital filtreleme yöntemi ile elde edilen QRS bileşenlerinin her birinden 25 öznitelikten oluşan 9 sinyal çıkarılmıştır. Öznitelik seçimi için FLDA ve PCA kullanmışlardır. Öznitelikler DT, SVM, k-NN ve Ensemble sınıflandırıcıları ile sınıflandırılmakta ve dışarıda bırakma yöntemi ile kontrol edilmektedir. 3 öznitelik ile %82,11 ACC, diğerleriyle %85,12 ACC gözlemlenmiştir.

Faust vd. OSA tanısı için CAD sistemlerinden yararlanarak RR aralıklarını sınıflandıran bir derin öğrenme modeli tasarlamayı amaçlamışlardır (Faust vd. , 2021: 992). RR aralıkları Ornstein – Uhlenbeck üçüncü derece gauss süreci ile bant geçiren filtreyle standartlaştırılmıştır. 10 kat çapraz doğrulama ile uzun kısa süreli bellek ağının % 99,80 ACC, % 99,85 SNS ve %

99,73 SPC, Uzatma doğrulaması ile aynı ağ % 81,30 ACC, % 59,90 SNS ve % 91,75 SPC performans sonuçları elde edilmiştir.

Mostafa vd. öznelik çıkarımı için bir derin inanç ağının ve uyku apnesinin sınıflandırılmasında derin sinir ağının kullanıldığı bir metot önermişlerdir (Mostafa vd. , 2017: 91). PhysioNet Apne-ECG ve UCD veritabanından elde edilen veriler önışleme aşamasında 1 Hz ile örneklendirilmiştir. Kan oksijen seviyesi %50'den az olan dakikalar hata olarak kabul edilir ve bu dakikalar veri kümelerinden çıkarılmaktadır. Derin inanç ağı Sınırlı Boltzman Makinesi (Restricted Boltzman Machine - RBM) kullanılarak modellenmiştir. İlk iki katman otomatik kodlayıcı tipinde, son katman soft-max tipinde oluşturulmuştur. Kullanılan ilk ağırlıklar denetimsiz öğrenme kullanılarak hesaplanmış, son aşamada ağırlıkların denetimli bir ayarlaması yapılmıştır. Toplam 33 veriye sahip veri tabanları 10 kat çapraz doğrulama ile test edilmiştir. UCD veri tabanında ACC % 85,26 ve Apnea-ECG veri tabanında ACC % 97,64 olarak bulunmuştur.

Gürüler, OSA hastalarına ait tek-kanal ECG işaretlerindeki HRV sinyallerinin zaman, frekans ve doğrusal olmayan yöntemleri kullanarak analiz edilmesini amaçlamıştır (Gürüler, 2013: 15). HRV'den elde edilen bu öznelikleri kullanarak sınıflandırma önermiştir. Korelasyon matrislerine dayalı yeni bir özellik seçim metodu kullanmıştır. Elde edilen sonuçlar, Korelasyon matrislerinin hastalık sınıflandırma işlemlerinde özellik kümelerinin seçim ve sınırlandırılmasında yapay sinir ağı sınıflandırma başarımını artırması bakımından önemli bulunmuştur.

Hassan, ECG sinyalini kullanarak CAD sistemiyle OSA tanısı yapmayı amaçlamıştır (Hassan, 2016: 22). Yazar ilk olarak ECG sinyalini Q faktörü dalgacık dönüşümünü kullanarak alt tabanlarına ayırmışlardır. Elde edilen alt bantlar simetrik normal ters gauss pdf modellemesiyle ECG sinyallerinin her biri modellenmektedir. TQWT ile seçilen özneliklerin performansı çeşitli sınıflandırıcılar için değerlendirilmektedir. Physionet'in Apne-ECG veri tabanı üzerinde BC, LDA, ANN, k-NN, RF, RBM, Önyükleme Toplaması, SVM ve Uyarlamalı Güçlendirme (Adaptive Boosting - AdaBoost) sınıflandırıcıları kullanılmaktadır. RBM ile en düşük ACC %38.79 performansı elde edilmiştir. SVM %59,22, BC %62,15, ANN %81,37, RF %82,70, k-NN %83,32, Önyükleme Toplaması %83,33, LDA %83,72, AdaBoost %87,33 ACC bulunmuştur.

Sharma vd. optimal, biorthogonal antisimetrik dalgacık filtre bankası kullanarak ECG tabanlı OSA-CAD sistemiyle OSA tanısı yapmayı amaçlamışlardır (Sharma vd. , 2018: 100).

Filtre bankası tasarımı; problemi kısıtlı bir optimizasyon problemine dönüştürmüşlerdir. Burada yazarların amacı, verilen zaman dağılımı için frekans yayılımını veya verilen frekans aralığı için zaman yayılımını en aza indirmektir. Optimizasyon problemi yarı tanımlı programlama problemi olarak formüle edilir ve iç nokta algoritması kullanılarak elde edilmektedir. ECG sinyali 1 dakikalık dalgacık alt bantlarına ayrılmakta ve bulanık entropi ve log-enerji öznitelikleri çıkarılmaktadır. FE ve LE özellikleri LS-SVM ile sınıflandırılmaktadır. PPV %92,93, AUC %95,0, F1-skor %92,0 sonuçları bulunmuştur.

Jafari ECG sinyalinin yeniden yapılandırılmış faz alanında OSA teşhisi için faydalı bilgiler olduğunu gözlemlemiştir (Jafari, 2013: 551). ECG sinyali yeniden yapılandırılmış faz alanından çıkarılan doğrusal olmayan öznitelikler ve frekans tabanlı öznitelikler, son öznitelik kümesini yeniden oluşturmak için birleştirilmiştir. Bu öznitelik seti; DFA, korelasyon boyutları, büyük lyapunov üstü, spektral entropi ve spektral özelliklerden elde edilen çok düşük frekans bandı, düşük frekans bandı, yüksek frekans bandından oluşturulmuştur. Öznitelik seti ile bir çekirdek bazlı SVM sınıflandırıcı kullanılarak Physionet Apnea-ECG veri kümesi üzerinde yaklaşık % 94,8 ACC bulunmuştur.

Tripathy HRV ve EDR sinyallerinden çıkarılan özniteliklere dayanarak uyku apnesinin otomatik tespiti için yeni bir yöntem önermişlerdir (Tripathy, 2018: 136). Ön işleme aşamasında ECG verileri çerçeve bazlı bölümlendirilip her bir ECG çerçevesinden EDR ve HRV sinyalleri elde edilmiştir. HRV ve EDR sinyallerinin gerçek bant fonksiyonları, fourier ayrıştırma yöntemi kullanılarak değerlendirilmiştir. Enerji ve FE öznitelikleri bu gerçek bant fonksiyonlarından elde edilmektedir. Doğrusal, polinom, RBF ve kosinüs dalgacık çekirdeği gibi dört çekirdek işlevli çekirdek aşırı öğrenme makinesi sınıflandırıcısı, uyku apnesinin otomatik algılanması için kullanılmıştır. Önerilen teknik, kamuya açık veri tabanı kullanılarak sırasıyla %78,02 ve %74,64 SNS ve SPC sağlamaktadır.

Li vd. ECG sinyaline dayalı OSA'yı teşhis etmek için bir yöntem önermişlerdir (Li vd., 2018: 94). Pan-Tompkins algoritması ile ECG sinyalinden RR noktaları bulunmuştur. Fizyolojik olarak yorumlanamayan noktalar, medyan filtresi ile ortadan kaldırılmıştır. RR aralık serisini hesaplamak ve 100 noktaya enterpolasyon yapmak için doğrulanmış RR pozisyonunu kullanmışlardır. Yazarlar çalışmada; etiketlenmemiş ECG sinyalleri gerektiren denetimsiz öğrenmeye ait olan öznitelikleri belirlemek için seyrek otomatik kodlayıcı kullanmışlardır. Seyrek otomatik kodlayıcıdan elde edilen öznitelikleri sınıflandırmak için SVM ve ANN sınıflandırıcıları kullanılmıştır. Sınıflandırıcıların doğruluğunu geliştirmek için gizli markov modelleri ve sınıflandırma performansını iyileştirmek için bir karar füzyon

yöntemi kullanmışlardır. Segment başına OSA tespitinde yaklaşık % 85 ACC, % 88,9 SNS elde edilmiştir. Segment başına OSA algılama sonuçlarına dayanarak, OSA kaydını %100 ACC elde edilmiştir.

Yıldız vd. ECG kayıtlarının otomatik olarak tanınması için ayrık dalgacık dönüşümü, FFT ve LS-SVM'ye dayalı bir sistem ile SAS teşhisi yapmayı amaçlamışlardır (Yıldız vd. , 2011: 12880). ECG sinyallerinden RR aralıkları QRS ile hesaplanmıştır. HRV ve EDR değişikliklerinin tespiti için ECG kayıtlarının analizinde ayrık dalgacık dönüşümüne dayalı bir algoritma kullanılmaktadır. HRV ve EDR değişikliklerinden öznitelik çıkarımı FFT bazlı bir PSD ile yapılmaktadır. Sınıflandırma performansını artıran en iyi öznitelikleri tanımlamak için tepe tırmanma özniteliği seçme algoritması kullanılmıştır. Elde edilen özellikler LS-SVM sınıflandırıcısının giriş parametreleri olarak kullanılmıştır. LS-SVM'nin lineer, polinom ve RBF çekirdeği ile sınıflandırma performansı değerlendirilmiştir. Sırasıyla ACC ; %83,3, %70, %76,7 olarak bulunmuştur.

Khandoker vd. ECG kayıtlarından çıkarılan öznitelikleri kullanılarak OSA+ ve OSA- hastaların otomatik tanınması için SVM'lerin kullanımını performansını diğer sınıflandırıcılarla karşılaştırmışlardır (Khandoker vd. , 2009: 88). WT ile HRV ve EDR sinyallerinden elde edilen öznitelikler, SVM sınıflandırıcısını eğitmek için girdi olarak kullanılmıştır. 14 HRV ve 14 EDR özniteliğinin tümü, sınıflandırıcılara uygulanmadan önce sonuçları karşılaştırmak için normalleştirilmiştir. Veri kümesi, test için kullanılan ve SVM karar yüzeyini eğitmek, yapılandırmak ve diğer sınıflandırıcıların parametrelerini ayarlamak için kullanılan 29 kayıt, aynı şekilde 30 alt gruba bölünmüş ve tüm alt kümeler test örneği olarak kullanılmıştır. SVM %100 ACC ile en iyi sonucu vermiştir. k-NN %83, PNN %70 ACC ile sınıflandırıcıların test verileri üzerindeki sınıflandırma performanslarının daha düşük olduğu görülmüştür.

Al-ani vd. uyku apnesi olaylarını sınıflandırmak için ECG sinyallerinden gizli markov modeli ile öznitelik çıkarımına dayalı noninvaziv otomatik yaklaşım önermişlerdir (Al-ani vd., 2008: 285). ECG sinyallerinin R-R aralıkları cinsinden tanımlanan HRV ve EDR sinyallerinin frekans analiziyle öznitelikler çıkartılmıştır. HMM modeli; stokastik süreç modellerinin kapsamlı bir gözlem topluluğuyla tahmin edildiği eğitim aşaması ve modelin, her model tarafından değerlendirilen test dizisinin olasılığını elde etmek için çevrimdışı / çevrimiçi kullanılabilirdiği test veya tespit aşamasından oluşturulmuştur. HMM zaman serilerinin sınıflandırılmasında doğrusal olmayan teknikler kullanılmıştır. Baum-Welch algoritmasına ve bayes çıkarım kriterine dayanan eğitim modeli ile, her bir eğitim özniteliği kümesine karşılık

gelen en uygun durum sayısı seçilmiştir. Tüm bu alt kümeler kullanılarak yapılan çevrim içi test sonuçlarına göre % 70'lik genel bir tanınma oranı elde edilmiştir.

Mendez vd. RR aralık zaman serileri ile apne olayları sırasında gözlemlenen osilatör bradik taşikardi desenlerini kullanarak OSA teşhisi yapmayı amaçlamışlardır (Mendez vd. , 2009: 2838) . Desenlerin RR aralıkları spektrumunda düşük frekans bandına (yaklaşık 0.02 Hz) karşılık geldiği bulunmuştur. Elde edilen seriler, hatalı tespit edilen kısımların manuel düzeltilmesi için ilgili ECG PC ekranında çizilmiş ve RR zaman serileri hesaplanmıştır. RR ortalama değeri, on vuruş hareketli bir ortalama filtre kullanılarak hesaplanmıştır. Her atımdaki ortalama göre %30 daha yüksek ve %20 daha düşük tüm RR aralıkları için bir arama yapılmaktadır. Sinyallerin frekans analizi zamanla değişen otoregressif model ile yapılmıştır. Bu çalışmada yazarlar k-NN ve NN denetimli sınıflandırıcıları karşılaştırmışlardır. k-NN algoritması %88 SNS ve %90 SPC, NN algoritması, %89'a SNS ve %86'ya SPC elde edilmiştir.

Martínez-Vargas vd. HRV zaman serisinin spektrogramından elde edilen dinamik filtre bankasına ait özneliklerine dayanan OSA tespit metodu önermişlerdir (Martínez-Vargas vd. , 2012: 9118). Physionet Apne-ECG veri tabanındaki ECG sinyallerinden elde edilen HRV'den özneliklerin çıkarılması için frekans cepstral katsayıları kümesi oluşturulmuştur. Yazarlar LF HF bantlarıyla ilgili dinamik filtre bankasına ait özneliklerinin oluşturması için spektrogram bölme adımını sezgisel yaklaşım ve stokastik değişkenliğe dayalı spektral yarıma aşamalarıyla yapmışlardır. Doğrulama amacıyla, Physionet veritabanı kaydından 1 dakikalık HRV segmentlerinde test edilmiştir. Çıkarılan öznelikler k-NN ile sınıflandırılmış ACC %80,61, SNS %76,22, SPC % 82,27 elde edilmiştir.

2.2.3. RESP Kullanılan Çalışmalar

Caseiro vd. uyanıklık dönemine ait PSG kayıtlarından elde edilen 5 dakikalık oronazal hava yolu basıncı sinyallerini kullanarak OSA tespiti yapmayı amaçlamışlardır (Caseiro vd. , 2010: 561). Sinyallerin içsel salınım modlarını çıkarmak için Hilbert-Huang dönüşümüne dayanan bir sinyal analiz tekniği kullanılmıştır. Yazarlar; birinci modun, ikinci modun ve bunların toplamının frekans dağılımının OSA- bireyler ile OSA+ bireyler arasında önemli ölçüde farklılık gösterdiği gözlemlenmişlerdir. 20 OSA- birey ve 21 OSA+ bireyden oluşan veri seti kullanılarak; salınım modlarının dağılım frekanslarına dayanan bir indeks ölçümü, OSA'nın saptanması için % 81,0'lik (% 95 SPC için) ACC elde edilmiştir. Alan ve frekans histogramının 1. ve 2. yarılarının maksimumu arasındaki ilişkiye dayanan diğer iki indeks ölçüsünün her ikisi de % 76,2'lik (% 95 SPC için) ACC elde edilmiştir.

Özdemir vd. OSA dönemlerinin zaman serisi öznitelikleri, düzenli solunum sinyalleri ve burun hava akımı sinyaliyle apne saptama algoritması geliştirmeyi amaçlamışlardır (Özdemir vd., 2016: 117). 32 Hz'de örneklenen 6 hastanın 8 saatlik solunum, burun hava akımı sinyalleri içeren veri seti: ilk olarak 40 saniyelik bölümlere ayrılmıştır. Teager enerji operatörü ile bağımsız olarak enerji açısından değerlendirilmiştir. Potansiyel apne içeren dönemler, enerji seviyesindeki değişikliklerle belirlenmiştir. Daha önce potansiyel apne adayı olarak etiketlenen burun hava akımı sinyal bölümlerine birinci derece türev uygulanarak, sınıflandırma için ön apne ve düzenli solunum şeklinde iki farklı girdi sınıfı kullanılmıştır. Apne segmentlerinin başlangıcı, otomatik olarak apne saptama algoritması ile işaretlenip, apne öncesi aralığı çıkarmak için kullanılmıştır. Bu çalışmada sadece zaman serisi özniteliklerinin k-NN, SVM, LR sınıflandırıcıları ile performansları değerlendirilmiştir. Sırasıyla ACC %71,1 SNS %72,4 SPC % 68,7, ACC % 87,6 SNS %91,3 SPC % 77,2, ACC %58,7 SNS %79,8 SPC %49,5, elde edilmiştir.

2.2.4. Ses Sinyali Kullanılan Çalışmalar

Montero-Benavides vd. konuşma analizi kullanan bir sistem ile OSA teşhisi önermişlerdir (Montero-Benavides vd ., 2014: 434). Konuşma materyali, İspanya Malaga'daki Clínico Universitario hastanesi solunum departmanında kaydedilen sinyallerden iki farklı veritabanı (bir eğitim veritabanı ve bir test veritabanı) oluşturulmuştur: Eğitim veri seti 82 erkek deneğin okumalarını içermektedir; 42'si şiddetli uyku apnesine sahip kişilerden, geri kalanı sağlıklı kişiler ve hafif OSA'ya sahip kişilerden oluşturulmuştur. Test veri seti, 20'si ağır uyku apnesine sahip kişilerden ve 20'si sağlıklı ve hafif OSA'ya sahip kişilerden oluşturulmuştur. İlk olarak bireysel özniteliklerin analizine odaklanmışlardır. Ses sinyalleri üzerinde; ikinci ve üçüncü fomantlar arasındaki mesafeden artikülasyon ve rezonans öznitelikleri, genizden okuma (nazality), sessizlik süreleri çıkarılmıştır. OSA+ bireyler ile ilgili fonasyon anormalliklerini tespit etmek için sesin akustik özellikleri incelenerek; harmonik/gürültü oranı, segmental sinyal/disperiyodisite oranı, bozulma, parıltı öznitelikleri çıkarılmıştır. Korelasyon analizi, çoklu doğrusal regresyon, LDA ile öznitelik seçimi yapılmış ve yine LDA ile sınıflandırılmıştır. Bu model 20 sağlıklı ve 20 apne deneyi içeren ayrı bir veri seti üzerinde test edilmiştir ve % 85'lik SNS % 75'lik SPC, % 81'lik bir F1-skoru bulunmuştur.

Praydas vd. OSA (OSA olmayan, hafif OSA, orta OSA ve şiddetli OSA olmak üzere) şiddetinin horlamanın ses spektrumlarını kullanılarak ayırt edilmesini amaçlamışlardır (Praydas vd. , 2016: 142) . Solunum sesleri, Uyku Bozuklukları Servis ve Araştırma Merkezi Songklanagarind Hastanesi ve Tayland Songkla Prensi Üniversitesi'ndeki 33 hastadan (18

kadın, 44.7 ± 11.6 yıl) kaydedilmiştir. Kaydedilen tüm solunum sesleri yüksek frekanslı gürültünün etkilerini ortadan kaldırmak için 1.500 Hz kesme frekansına sahip düşük geçiş filtresinden geçirilmiştir. Solunum ses sinyallerinin ses spektrumlarını hesaplamak için FFT kullanılmıştır. Tüm deneklerin ses spektrumları toplanıp, en baskın ses spektrumu özniteliklerin % 90'nı tutulmuştur. Ses spektrumunu kümelemek ve öznitelikleri yeniden yapılandırmak için K-ortalamları kümeleme kullanılmıştır. SVM yöntemi kullanılarak % 75,76 oranında bir sınıflandırma ACC'sı elde edilmiştir.

2.2.5. EEG Kullanılan Çalışmalar

Emin Tagluk ve Sezgin OSA+ bireyleri ayırt etmek için bispektral analizi ve ANN'yı birlikte kullanan bir sistem geliştirmeyi amaçlamışlardır (Emin Tagluk ve Sezgin, 2011: 5346). EEG sinyalleri hastalardan 256 Hz örnekleme frekansıyla kaydedilmiştir. İlk olarak, kaydedilen veriler iki uzman tarafından sınıflandırılmış ve ağı eğitmek için 150 OSA+ ve 150 OSA- birey rastgele seçilmiştir. Eğitim aşamasını kontrol etmek sistem tasarımında, eğitim veri setinin %20'si, tasarlanan sistemi çapraz doğrulama olarak test etmek için kalan veriler daha sonra sırasıyla test seti olarak kullanılmaktadır. ANN'ye girilecek veri sayısını en aza indirmek için, EEG numuneleri ilk önce bispektral analiz ve ön işleme modülü yoluyla değerlendirilmektedir. Bispektraların hesaplanmasında 0,1 saniye genişliğe sahip bir Hanning penceresi kullanılmıştır. EEG'nin her alt bandındaki (yani; delta, teta, alfa, beta ve gama) kuadratik faz bağlanma miktarı, EEG bispektral yoğunluğundan hesaplanır ve ANN'nin girişine verilir. ANN iki çıkışla (biri OSA+ için diğeri OSA- durumunun tahmini için) yapılandırılmıştır. Bu teknik ile % 96,15'lik ACC elde edilmiştir.

2.2.6. Birleşik Yaklaşımlar Kullanılan Çalışmalar

Ríos ve Erazo çocuklarda apne tespiti için bir model geliştirmeyi amaçlamışlardır (Ríos ve Erazo, 2016: 42). OSA teşhisi için 2-16 yaşları arasındaki 78 farklı hastanın 78 tam gece PSG kayıtları alınmıştır. Öznitelik çıkarımı WT ile yapılmış ve ECG sinyalinden HRV ve EDR öznitelikleri elde edilmiştir. Yine WT ile karın ve torasik çaba ekstraksiyon sinyallerinden, bacak hareketi sinyallerinden, vücut pozisyonu sinyallerinden, Resp, EMG, EOG, horlama, darbe sinyallerinden öznitelik çıkarımı yapılmıştır. Öznitelik seçimi işlemi için korelasyon analizi ve PCA kullanılmıştır. Hastaları tanımlanan iki gruba sınıflandırmak için; SVM, NN ve LR modelleri kullanılmış ve sırasıyla %100, % 28,36, %47,30 AUC performansı elde edilmiştir.

Peker, uyku apnesi teşhisi için hava akışı, oksijen doyum oranı ve ECG sinyallerini ayrı ayrı kullanarak gerçek zamanlı apne tespiti yapmayı amaçlamıştır (Peker, 2018: 12). Apne tespiti için sinyallerin her birinden farklı dinamik öznitelikler elde edilerek, yapay sinir ağlarına giriş olarak verilmiştir. Sınıflandırma sonucunda, %89,6 doğruluk oranı ile elde edilmiştir.

Wang vd. antropometrik (örn. Cinsiyet, yaş, ağırlık, boy vb.) ve anketlere (örn. Epworth uykululuk skalası, horlama sonuçları anketi) dayalı OSA teşhisi için yöntem geliştirmeyi amaçlamışlardır (Wang vd., 2011: 7828). Sistem üç aşamada modellenmiştir. İlk aşamada; OSA verileri antropomorfik ölçümler, sistolik kan basıncı, diyastolik kan basıncı, desatürasyon sıklıkları, paroksizmal bacak hareketi, anket ölçümlerinin değerlendirilmesi ve frekans dahil 12 öznitelik toplanmıştır. İkinci adımda, öznitelikleri seçmek için kaba set analitik yaklaşımı kullanılmıştır. Son adımdaysa mahalnobis mesafesi OSA modelini ayırt etmek için kullanılmıştır. LR, Geri yayılım sinir, öğrenme vektör nicemleme, SVM, C4.5 DT kullanılarak gerçekleştirilen sınıflandırmada g ortalamaları sırasıyla 0,9258, 0,8660, 0,7319, 0,4755, 0,8660, 0,7905 ve 0,4082 elde edilmiştir. Sonuçlara göre LR, diğer yöntemlerden daha iyi performans gösterdiğini görülmektedir.

2.3. OSA/ CSA/MSA Teşhisi Yapılan Çalışmalar

Sezgin ve Emin Tagluk, karın efor sinyalinin alt bant enerjisi ile SAS'yı OSA/CSA/MSA olarak sınıflandırmayı amaçlamışlardır (Sezgin ve Emin Tagluk, 2009: 1043). Dicle Üniversitesi Tıp Fakültesi Uyku Laboratuvarı'nda yaşları 21 ile 57 arasında değişen, ortalama yaşları 37 olan 7 kadın ve 14 erkekten oluşan 21 SAS hastasından 8 saat boyunca sürekli olarak 128 Hz örnekleme hızında sinyaller alınmıştır. Kaydedilen karın eforu sinyallerinden ayırık dalgacık dönüşümü ile spektral alt-bantları çıkarılmıştır. Sinyalin alt-bant enerjisi dalgacık katsayılarının karelerinin toplamı olarak hesaplanmıştır. Spektral bileşenlerin enerjisi, ANN'nın girişlerine uygulanmıştır. ANN, SAS durumunu sınıflandırmak için üç çıktı verecek şekilde yapılandırılmıştır. Test setine göre elde edilen ACC % $83,78 \pm 1,90$ ve sınıfların her biri için elde edilen ortalama ACC aralığı % $80,90 \pm 2,53$ (obstrüktif), % $80,48 \pm 3,65$ (karışık) ve % $89,95 \pm 2,71$ (merkezi) olarak bulunmuştur.

Emin Tagluk vd. WT ve ANN'yı kullanarak SAS'yı OSA/CSA/MSA olarak sınıflandırmayı amaçlamışlardır (Emin Tagluk vd. , 2010: 1600) . Dicle Üniversitesi Tıp Fakültesi Uyku Laboratuvarı'nda sinyaller, hasta gece uyurken PSG yoluyla bir PC'ye kaydedilmiştir. Bu kayıtlarda bulunan apnelere, alandaki bir uzman tarafından 450 OSA, 120 CSA ve 220 MSA olarak sınıflandırılmıştır. Dengeli bir eğitim/test seti elde etmek için her

sınıftan 120, toplam 360 kayıt seçilmiştir. Karın efor sinyalleri, sürekli dalgacık dönüşümü kullanılarak 7 seviyeli spektral bileşenlere ayrılmıştır. Bu spektral bileşenler, ANN'nin girişlerine uygulanmadan önce girdi sayısını azaltmak ve sabitlemek için bir ön işleme aşaması olarak ayrı bir WT kullanılmıştır. ANN, hastanın SAS durumunu sınıflandırmak için üç çıkış verecek şekilde yapılandırılmıştır. ACC, 0.95, 0.75 ve 0.50 momentum katsayıları için sırasıyla %78.85, %78.03 ve %76.93 bulunmuştur. Ayrıca, sınıfların her biri için elde edilen ortalama ACC %73,42 (OSA), %94,23 (CSA) ve % 66,16 (MSA) olarak hesaplanmıştır.

Guijarro-Berdinas vd. OSA/CSA/MSA apne türlerinin ayırt etmek için, sinyalin farklı bölümlerinde gösterdiği özniteliklere dayanan bir sınıflandırma yaklaşımı önermişlerdir (Guijarro-Berdiñas vd. , 2012: 7084). Torasik çaba sinyalinin önceden apne olarak etiketlenmesi için SAMOA olarak adlandırılan akıllı izleme sistemi kullanılmıştır. SAMOA, hastanın SAS'nin olası varlığına göre özel olarak teşhis edilmesini sağlayan solunum analizi ve uyku çalışması için bilgisayarlı bir sistemdir. SAMOA'da bulunan sınıflandırma modülü bir ANN'ye dayanmaktadır, girdisi torasik çaba sinyalindeki apnenin ham örneklerine uygulanan WT'nin katsayıları tarafından oluşturulmaktadır. SAMOA ile 217'si obstrüktif, 40'si merkezi ve 82'si karışık olmak üzere toplam 339 apne bulunmuştur. Dengeli bir eğitim seti elde etmek için 120 apne (her sınıfın 40'ı) seçilmiştir. Sunulan model sınıflandırma için ana girdileri ve sınıflandırma modelinin kendisini oluşturan öznitelikleri seçme aşaması olmak üzere iki aşamadan oluşturulmuştur. Girdiler, torasik çaba sinyalindeki apnenin ham örneklerine uygulanan WT yöntemiyle elde edilen katsayılardan oluşturulmuştur. Bu katsayılar bir öznitelik seçme yöntemi olan SVM RFE ile belirlenmiştir. Modelin gerçek hata oranının daha iyi tahmin edilmesi için 10 farklı 10 kat çapraz doğrulama seti oluşturulmuştur. Her sınıf apnenin değerleri % 94,62 (OSA),% 95,47 (CSA) ve % 90,45 (MSA) olarak elde edilmiştir.

3. MATERYAL ve YÖNTEM

Bu bölümde, CAD sistemi için gerekli olan uygulama ve yöntemler tanıtılmaktadır. Bölümde sırasıyla, çalışmada kullanılan veri tabanından, ECG sinyallerinde sınıflandırma aşamasında daha iyi bir performans için yapılan ön işleme ve öznelik çıkarma yöntemlerinden, son olarak kullanılan sınıflandırıcılardan bahsedilmektedir.


3.1. Apne-ECG Veri Tabanı

Tez çalışmasında, kullanıma açık olan PhysioBank Apnea-ECG veri tabanı üzerinde işlem yapılmaktadır (Penzel vd. , 2000: 255) . Veri tabanı 35 kayıttan oluşan (a01'den a20'ye, b01'den b05'e, c01'den c10'a) eğitim seti ve 35 kayıttan oluşan (x01'den x35'e) test setinden meydana gelmektedir Her bir kayıt 7-10 saatten oluşmakta, apne ve R-noktası belirtilerini içermektedir. Veri tabanında ki a01'den a04'e, b01 ve c01'den c03'e kadar olan sekiz kayıt, ECG sinyaline ek olarak Resp A, Resp C, Resp N, göğüs ve abdominal solunum çabası, orozonal hava akımı sinyalleri içermektedir.

Veri tabanında her kayıt birkaç dosya ile ilişkilendirilmiştir. Bunlar;

- .dat dosyaları, sayısallaştırılmış ECG sinyalleri içermektedir. Her ECG sinyali saniyede 100 örnek nominal olarak mili volt başına saniyede 200 A/D birimdir.

Her çifte en az önemli bayt önce ve örnek başına 16 bit olarak oluşturulmuştur. Şekil 3.1.'de. dat dosyalarında bulunan ECG sinyalinin bir örneği görülmektedir.



Şekil 3.1. Eğitim setinde bulunan hastanın ECG sinyali kaydı

- .hea dosyaları, sinyal dosyalarının adları ve formatlarını belirten metin dosyalarıdır.

- .apn dosyaları, her kaydın her dakikası için apne varlığı veya yokluğunu gösteren açıklama dosyalarıdır. Bu dosyalar test setinde bulunmamaktadır. "A" ek açıklaması, takip eden bir dakikalık aralıkta apnenin meydana geldiğini belirtir ve bir "N" ek açıklaması, sonraki bir dakikalık aralıkta apne olmadığını göstermektedir.
- .qrs dosyaları, sqrt 125 kullanılarak oluşturulmuş, açıklama dosyalarıdır. Sqrt 125 tek kanallı bir QRS detektörüdür. ECG sinyalindeki QRS komplekslerinin tespit edilmesinde kullanılmaktadır.

PhysioBank'taki verileri görüntülemek, incelemek, analiz etmek için Dalga Biçimi Veri tabanları (WaveForm Databases - WFDB) yazılım paketi kullanılmaktadır (Gürüler, 2013: 28). WFDB 3 ana bileşenden oluşur:

1. WFDB kütüphanesi
2. WFDB araç kutusu
3. WAVE yazılımı

ECG kayıt dosyalarındaki QRS noktalarını tespit etmek ve daha sonra kullanmak üzere açıklama dosyası oluşturmak için WFDB araç kutusu kullanılmaktadır. WFDB araç kutusunda çeşitli kod ve algoritmalarından meydana gelmektedir. ECG'lerin ve açıklama dosyalarının seçilen bölümlerinin gözden geçirilmesi WAVE 'den yararlanılmaktadır.

Tablo 3.1. PhysioBank Apnea-ECG veri tabanındaki kayıt ve hastaların ortalama özellikleri

Ortalama özellikler	Toplam Dakika	Apnesiz Dakika	Apneli Dakika	Saateki Apne Sayısı Oranı	AI	HI	AH I	Yaş	Cinsiyet E/K	Boy cm	Kilo kg
Kayıt											
Eğitim Seti Kayıtları	489,34	303,17	186,11	5,17	21	7,4	28,6	45	30/5	171,7	87,2
Test Seti Kayıtları	479,62	307,17	187,2	4,74	22	4,9	27,4	48,8	27/8	175	83

Kaynak: (Apne-ECG Veritabanı, 2021)

Tablo 3.1.'de ki kayıt ve hastaların ortalama özellikleri oluşturulurken, her kayıt bir dakikalık bölümlere ayrılmıştır. Bu bölümlerin ortalama sayısı tablonun ikinci sütununda

verilmiştir. Üçüncü sütunda apne olmayan dakikalar ve dördüncü sütunda apne dakikaları ortalama değerlerini içermektedir. Bir dakikalık bölümler, her kayıt için 60 dakikalık bölümler halinde gruplanır ve 5 ila 60 apne dakikasını içeren bu grupların sayısı, apneli saatler olarak beşinci sütunda belirtilmiştir. AI, saat başına gözlemlenen apne sayısı ve HI, saat başına gözlenen hipopne sayısıdır. AHI, AI ve HI toplamı olarak tanımlanmaktadır. Veri kümesinde apne hastasının baskın olduğunu ve erkek ağırlığı bulunduğunu, apne ve hipopne görülen deneklerin aynı zamanda kilo problemlerine sahip olduğu görülmektedir.

PhysioBank Apnea-ECG veri tabanında AHI'lere göre, kayıtlarda apne içeren kısım 100 dakika ve üzeri ise uyku apnesi hastası, 5 ila 99 dakika arası sınırdadır ve 5 dakikadan az ise sağlıklı olarak sınıflandırılmaktadır. Sınıflandırma için kayıtlar öğrenme ve test kümelerine eşit olarak ayrılmaktadır.

3.2. Ön İşleme

Ön işleme aşaması; sınıflandırma aşamasında daha yüksek bir performans sonucu elde edilmesi için gerekmektedir. Ön işleme veri tabanından elde edilen ECG sinyallerine uygulanan z-skor normalizasyonu, bant geçiren filtre yöntemlerini içermektedir.

3.2.1. Z-skor Normalizasyonu

Normalizasyon işlemi ile tüm veri noktaları aynı ölçeğe sahip olması ve eşit derecede önem kazanması amaçlanmıştır (M. Sharma et al. , 2018).

Z-skoru normalizasyonu için formül şu şekildedir (Mcleod, 2019):

$$Z = \frac{x - \mu}{\sigma} \quad (3.1)$$

$$\mu = \frac{\sum x_i}{n} \quad (3.2)$$

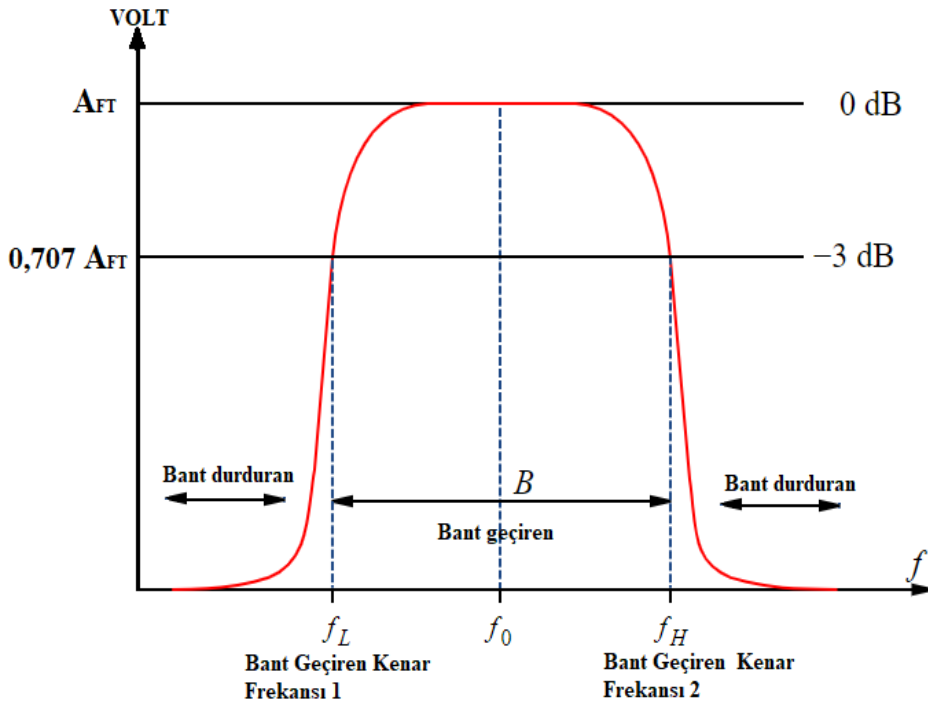
$$\sigma = \sqrt{\frac{(\sum (x_i - \mu)^2)}{n}} \quad (3.3)$$

(3.1) nolu denklemde; μ , özniteliğin ortalama değeri ve σ , standart sapması ve x normal dağılım değerini temsil etmektedir. μ 'nin formülü (3.2)'de, σ 'nin formülü (3.3)'de gösterilmektedir. Z-skoru, standart sapmayla belirtildiğinde, normal dağılım değerinin ortalamaya olan uzaklığı cinsinden konumunu tanımlamaktadır. Normal dağılım değeri, özniteliğin tüm değerlerinin ortalamasına eşitse, 0'a normalize edilir, değer ortalamanın üzerindeyse z-skoru pozitif, ortalamanın altındaysa negatif olmaktadır. Negatif ve pozitif skorların boyutu, orijinal özniteliğin standart sapmasıyla belirlenmektedir. Normalize

edilmemiş verilerin büyük bir standart sapması varsa, normalize edilmiş değerler 0'a yakın olmaktadır.

3.2.2. Butterworth Bant Geçiren Filtreleme

Butterworth filtre yapısı ilk olarak İngiliz bilim adamı Stephen Butterworth tarafından 1930 yılında "Experimental Wireless and the Wireless Engineer" dergisinde "On the Theory of Filter Amplifiers" makalesinde ortaya atılmıştır. Butterworth standart filtre çeşitleri içerisinde geçiş bandı en düz ve dalgalanmanın neredeyse hiç olmadığı bir filtre çeşididir. Bu sebeple maksimum düzlüklü filtre cevabı olarak adlandırılmaktadır. (Arslan, 2020) Butterworth bant geçiren filtresi, belirli frekans aralıklarında iletim yapmakta ve bu aralıkların dışındaki frekansları zayıflatmaktadır. Şekil 3.2.'de, bant geçiren filtre özelliklerini ve frekans yanıtını gösterilmektedir.



Şekil 3.2. Bant Geçiren filtre özellikleri ve frekans yanıtı

Kaynak: (Ünverdi ve Yıldız, 2012: 274)

Butterworth Bant Geçiren Filtre (Band Pass Filter - BPF), Alçak Geçiren Filtre (Low Pass Filter - LPF) ve Yüksek Geçiren Filtre (High Pass Filter - HPF)'nin birleşiminden oluşturulmaktadır. Bant geçiren filtre frekans cevabı (3.4) nolu denklemde ve (3.5) nolu denklemde frekans cevabı gösterilmektedir. Denklem (3.4)'te V_{out} çıkış sinyali voltajını, V_{in}

giriş sinyali voltajını ve denklem (3.5)'de transfer fonksiyonu gösterilmektedir. (Ünverdi ve Yıldız, 2012: 272).

$$H = \left[\frac{V_{out}}{V_{in}} \right]_{BPF} = \left[\frac{V_{out}}{V_{in}} \right]_{HPF} \left[\frac{V_{out}}{V_{in}} \right]_{PF} \quad (3.4)$$


$$H \left[\frac{V_{out}}{V_{in}} \right]_{BPF} = \left(-\frac{1}{1+j\omega C_1 R} \right) \left(-\frac{j\omega C_2 R}{1+j\omega C_2 R} \right) \left(-\frac{R_f}{R_i} \right) \quad (3.5)$$

3.3. Öznitelik Çıkarımı

Öznitelik çıkarımı yöntemleri ile sinyallerimizin ait olduğu sınıflarını ayırt edebilecek şekilde betimlemeye çalışılmıştır. Öznitelik çıkarımı aşamasıyla, sınıfların iyi temsil edilmesi yüksek sınıflandırma performansı anlamına gelmektedir. Tez çalışmasında farklı öznitelik çıkarma teknikleri kullanılmıştır. Bu tekniklerin ayrıntılı açıklamaları aşağıda belirtilmektedir.

3.3.1. Yerel Konfigürasyon Örüntüsü

LCP yöntemi bir imgenin Yerel Bölge Bilgisi (Local Binary Pattern - LBP) ile Mikroskobik Konfigürasyon (Microscopic Configuration - MİC) yöntemlerini birleştiren bir algoritma ile öznitelik çıkarma işlemi yapmaktadır (Guo vd. , 2011: 1). İmgeden LBP yöntemi ile yerel öznitelikler, MİC yöntemiyle mikroskobik öznitelikler Şekil 3.3.'de gösterildiği gibi elde edilmektedir.



Şekil 3.3. LCP öznitelik çıkarımı yönteminin yapısı

Kaynak: (Guo vd. , 2011: 2)

$$LBP(P, R) = \sum_{i=0}^{P-1} u(g_i - g_c) \cdot 2^i \quad u(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.6)$$

(3.6)'da P komşuluktaki piksel sayısını, R yarıçapı, g_i i. komşuluktaki pikselin şiddetini, g_c komşuluktaki merkez pikselin şiddetini belirtmektedir. $LBP(P, R)$, komşuluktaki piksellerin şiddetini [0 1] olarak ikili gösterimde tanımlamaktadır. Dairesel ikili gösterimde en fazla 2 bit

değişimi olan örüntüler bir biçimli olarak, değişim 2 bitten fazla olduğu durumlarda bir biçimli değil olarak adlandırılmaktadır. Bir biçimli ikili gösterim ‘ u_2 ’ biçiminde gösterilmektedir. Dönme açısından bağımsız örüntüler, her bir bittin en büyük eleman olacak şekilde, minimum değere döndürülmesiyle elde edilmekte ve ‘ r_i ’ olarak adlandırılmaktadır. Bu iki yöntemin birleştirilmesiyle oluşturulan ve ‘ u_2r_i ’ olarak adlandırılan LBP yöntemiyle ikili örüntüler (3.7)’deki gibi hesaplanmaktadır.

$$LBP^{u_2r_i}(P, R) = \begin{cases} \sum_{i=0}^{P-1} u(g_i - g_c) & , \quad U(LBP(P, R)) \leq 2 \\ P + 1 & , \quad U(LBP(P, R)) > 2 \end{cases} \quad (3.7)$$

LBP algoritmaları imgedeki şiddet değişimlerinde başarılı olmasına rağmen gri-seviye şiddet değişimlerini ikili gösterime çevirmede sorunlar gözlemlenmektedir. İmgelerin biçimleri aynı olduğunda Yerel Varyans (VAR) hesaplanarak sorun giderilmeye çalışılmaktadır.

$$VAR = \frac{1}{p} \sum_{i=0}^{p-1} (g_i - \mu)^2 \quad (3.8)$$

$$O = \frac{LBP^{u_2r_i}}{VAR} \quad (3.9)$$

(3.8) ‘de ‘ μ ’ komşu piksellerin ortalama şiddeti ile VAR hesaplanılmakta ve (3.9) nolu denklemde gösterilen şekilde Yerel Öznitelikler (O) elde edilmektedir.

Biçimleri aynı çıkmış örüntülerin varyanslarında eşit olması durumunda, imgelerin pikselleri farklı olsa bile aynı öznitelikler elde edilmektedir. Bu durumu ortadan kaldırmak için MİC algoritması kullanılmaktadır. Merkezi piksel yoğunluğunu doğrusal olarak yeniden yapılandırmak üzere, komşu piksellerin şiddetleri yeniden ağırlandırılarak, merkez pikseli yeniden tanımlayacak doğrusal bir model oluşturulmaya çalışılmaktadır.

$$E(a_0, \dots, \dots, a_{p-1}) = |g_c \sum_{i=0}^{p-1} a_i g_i| \quad (3.10)$$

Ağırlık ile ilgili parametreler $a_i (i=0, \dots, p-1)$ ile temsil edilmektedir. (3.10)’da gösterilen E, ağırlıklar hakkındaki modelleme hatalarını içermektedir. Modelleme hatasını en aza indiren En Uygun Ağırlık Vektörü (A_L) en küçük kareler yöntemiyle hesaplanmaktadır.

$$A_L = (V_L^T V_L)^{-1} \cdot V_L^T \cdot C_L \quad (3.11)$$

N_L : Bir imgede, belirli bir L tipi örüntünün meydana gelmesini temsil etmektedir.

A_L : L örüntüsü için en uygun ağırlık vektörüdür.

C_L : N_L piksel yoğunluklarını içermektedir.

V_L : N_L pikselinin P komşularının yoğunluklarından oluşmaktadır.

$$C_L = V_L \cdot A_L \quad (3.12)$$

Denklem (3.11) en küçük kareler yöntemiyle çözülür ve A_L değerini vermektedir. A_L 'yi dönme açısından bağımsız hale getirilerek ' H_L ' elde edilmektedir.


$$H_{L(k)} = \sum_{i=0}^{P-1} A_{L(i)} e^{-j2\pi k_i/P} \quad (3.13)$$

$$H_{L(k)} = [|H_L(0)|; |H_L(1)|; \dots \dots \dots; |H_L(P-1)|] \quad (3.14)$$

(3.13) nolu denklemde gösterilen H_L vektörünün büyüklüğü mikroskobik öznitelik vektörü olarak hesaplanmaktadır.

$$LCP = \left[[|H_0|; O_0]; [|H_1|; O_1]; \dots \dots \dots; [|H_q|; O_q] \right] \quad (3.15)$$

LCP öznitelik vektörü (3.15)'de gösterilmektedir. LCP yönteminde kullanılan imge matris formatındadır. PhysioNet Apnea-ECG veri tabanındaki öznitelikler vektör formatındadır. Bu yöntemi vektör şeklindeki veri setinde uygulamak için g_c 'nin komşu pikselleri dairesel formattan vektör şekline çevrilmiştir.



Şekil 3.4. Dairesel şekilde g_c ve g_i 'lerin gösterimi

Kaynak: (Guo vd. , 2011: 4)

Şekil 3.4.'teki imgenin LBP gösterimi denklem (3.6)'de gösterildiği şekilde yapılmaktadır. Eğer g_c 'nin şiddeti komşu merkezdeki piksellerin şiddetinden küçük ve eşit ise '1', değilse '0' olarak ikili gösterime çevrilmektedir. Vektör şeklindeki veri setimizden LBP gösterimi elde edebilmek için Şekil 3.5.'deki gösterilen formata çevrilmiştir (Tuncer ve Aydemir, 2020: 60).

g_{-4}	g_{-3}	g_{-2}	g_{-1}	g_c	g_{+1}	g_{+2}	g_{+3}	g_{+4}
----------	----------	----------	----------	-------	----------	----------	----------	----------

Şekil 3.5. Vektör formatında g_c ve g_i 'lerin gösterimi

Vektör formatına çevirme işlemi yapılırken, doğrusal haldeki vektörün son dört özniteliği vektörün başına, ilk dört özniteliği doğrusal vektörün sonuna yerleştirilecek bir döngü oluşturulmuştur. Merkez piksel için vektör koordinatları = [0 -4; 0 -3; 0 -2; 0 -1; 0 1; 0 2; 0 3; 0 4] şeklinde oluşturulmuştur. Bu şekilde LBP gösterimi vektör formatından elde edilmektedir. Örüntünün bir biçimli olup olmadığı tespit edilip, (3.7), (3.8) ve (3.9) nolu denklemlerdeki işlemler ile ilk olarak $LBP^{u_2 r_i}$ hesaplanır, biçimleri aynı olan komşuluklarda VAR hesaplanarak yerel öznitelikler çıkarılmaktadır. Biçimleri ve varyansları eşit olan komşuluklarda MİC (3.10), (3.11), (3.12), (3.13) ve (3.14), nolu denklemler yardımıyla mikroskobik öznitelikler elde edilmektedir. Çıkarılan yerel ve mikroskobik öznitelikler (3.15)'deki şekilde birleştirilerek LCP oluşturulmaktadır.

3.3.2. İstatistiksel öznitelik çıkarımı

İstatistiksel özniteliklerin sınıflandırma başarısındaki olumlu etkisi bilinmektedir (Işık Esener, 2017: 46). Sınıflandırma çalışmalarında ECG sinyallerin enerji, varyans, standart sapma, çarpıklık ve basıklık gibi istatistiksel öznitelikler kullanılmaktadır.

Sinyallerin karelerinin toplamından elde edilen enerji ayırt edilebilirliği artırıcı etki göstermektedir. Denklem (3.16)'da x_i sinyalleri temsil etmektedir

$$e = \sum_{i=1}^N x_i^2 \quad (3.16)$$

Dağılımın ortalaması, o dağılımdaki her bir veriyi temsil eden tek bir orta değeri tek bir sayı ile ifade eden bir istatistik ölçüsü olarak hesaplanmaktadır.

$$m = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.17)$$

Standart Sapma, bir dağılımın, dağılımın ortalamasına göre nasıl yayılım gösterdiğini incelemektedir. Standart sapmanın düşük çıkması o dağılımdaki verilerin birbirine benzer olduğunu, yüksek olması ise elemanların birbirinden farklı olduğunu ifade etmektedir.

$$SS = \sqrt{\frac{\sum_{n=1}^N (x_n - m)^2}{N-1}} \quad (3.18)$$

Çarpıklık (Skewness – S), ortalama etrafındaki üçüncü momentini hesaplanmaktadır. Normal dağılımların çarpıklık değeri sıfır, negatif çarpıklık dağılımın ortalamasının soluna, pozitif çarpıklık ise dağılımın ortalamasının sağına doğru yayılım gösterdiği gözlemlenmektedir. Basıklık (Kurtosis - K), ortalama etrafındaki dördüncü moment olarak hesaplanmaktadır.

$$S = \frac{\sum_{n=1}^N (x_n - m)^3}{(N-1).SD^3} \quad (3.19)$$

$$K = \frac{\sum_{n=1}^N (x_n - m)^4}{(N-1).SD^4} \quad (3.20)$$

Entropi ile verinin düzensiz bir dağılım gösterip göstermediği incelenmektedir.

Bir dağılımın varyansı, ortalama etrafındaki ikinci momenti, o dağılımdaki her bir elemanın dağılım ortalamasından ne kadar farklı olduğunu göstermektedir. Herhangi bir dağılımın varyansının düşük olması o dağılımdaki elemanların birbirine benzer olduğunu, yüksek olması ise elemanların birbirinden farklı olduğunu göstermektedir.

Alan-tanımlayıcısı; standart sapmanın ortalamaya oranı olarak hesaplanmaktadır.

3.4. Öznitelik Seçimi

Öznitelik seçimi yöntemleri ile elde edilen öznitelik kümelerinin daha hızlı bir sınıflandırma performansı için boyutları küçültülmektedir. Tez çalışmasında farklı öznitelik seçimi teknikleri kullanılmıştır. Bu tekniklerin ayrıntılı açıklamaları aşağıda belirtilmektedir.

3.4.1. Temel Bileşen Analizi

PCA veri setinin dağılımı koruyarak daha düşük boyutlu yeni bir veri uzayına taşımaktadır (Janbakhshi ve Shamsollahi, 2018: 210). Taşıma işlemi sonucunda öznitelik uzayının boyutu da azaltılmış olmaktadır. PCA yöntemi ile veri kümesini bir uzaydan daha küçük bir diğer uzaya taşıırken en az bilgi kaybını sağlamaktadır. PCA yöntemi sınıfların ayırt edilebilirliğinden daha çok verinin daha az boyutta en iyi nasıl temsil edilebileceği ile ilgilenmektedir.

d-boyutlu uzaydaki vektörlerin kümesi (3.21) deki gibi olduğunda;

$$x = x_1, x_2 \dots \dots \dots, x_m \quad (3.21)$$

Vektörlerden elde edilebilecek kovaryans matrisi (3.22)'de gösterilmektedir.

$$\epsilon = \sum_{i=1}^M (x_i - \mu) \cdot (x_i - \mu)^T \quad (3.22)$$

Verinin, izdüşüm hatası en küçük olacak şekilde 1-boyutlu alt uzaya izdüşümü bulunmaktadır. Varyansın en büyük olduğu yönde ayırt edici özniteliklerin olabileceği kanısına varılmıştır. Bu nedenle PCA yeni uzaydaki eksenleri oluştururken en büyük varyansların yönünde koordinat dönüşümü yapmaktadır. Ayrıca hatanın küçük olmasını sağlayacak şekilde seçilen varyansın, en büyük varyans olduğu bulunmuştur.

Bir sonraki aşamada, büyük varyansın yönünü, kovaryans matrisinin öz vektörleri ve öz değerleri ile bulunmaktadır.

$\{V_1, V_2, \dots \dots \dots, V_d\}$ kovaryans matrisinin azalan şekilde sıralanmış özdeğerlerine karşılık gelen özvektörleridir. Bu özvektörler (3.23)'te matris şeklinde gösterilmektedir.

$$\omega = [V_1, V_2, \dots \dots \dots, V_d] \quad (3.23)$$

Daha yüksek özdeğerleri olan özvektör, veri kümesinin daha önemli temel bileşenlerini vermektedir. Böylece, daha önemli olanlardan başlamak için daha büyük özvektörler seçilir ve yeni bir öznitelik kümesi olarak kullanılmaktadır.


x_i vektörü (3.24) nolu denklemde olduğu gibi yazılabilmektedir.

$$x_i = \sum_{j=1}^d \alpha_j V_j = \alpha_1 V_1 +, \dots \dots \dots, + \alpha_k V_k + \alpha_{k+1} V_{k+1} +, \dots \dots \dots, + \alpha_d V_d \quad (3.24)$$

Burada $\alpha_m = x_i^T V_m$ katsayıları temel bileşen olarak adlandırılmaktadır. PCA yönteminde en önemli 'k' bileşenini seçilir ve bu 'k' katsayısı x_i vektörünün yaklaşık değerlerini hesaplamaktadır.

$$\gamma = \omega^T X \quad (3.25)$$

PCA algoritması son olarak x_i verisinin en büyük 'k' özdeğere karşılık gelen özvektörleri kullanarak γ izdüşümünü hesaplamaktadır. (3.25)'de gösterildiği şekilde tüm veri seti için yapılan bu işlemler sonucunda veri setinin boyutu azaltılarak, en az bilgi kaybı sağlanmaktadır. Şekil 3.6.'da PCA yöntemiyle aynı boyuta indirgenmiş bir veri setinin grafiği gösterilmektedir.



Şekil 3.6. PCA uygulanmış bir veri tabanı gösterimi

Kaynak: (Joseph, 2021)

3.4.2. Ortak Vektör Yaklaşımı

CVA, ilk olarak bir ses tanıma çalışmasında kullanılmıştır (Gülmezoğlu, 1999). CVA'da, aynı sınıfa ait olduğu bilinen vektörler tek bir ortak vektörle temsil edilmektedir. Ayrıca, sınıfın özneliği olarak sınıf ortak vektörünü kullanmaktır. Sınıftaki özneliklerin farklılıkları çıkarıldıktan sonra kalan vektöre ortak vektör denilmektedir. Bu nedenle vektörler, sınıf ortak vektörü ve sınıf farklılık vektörlerinin birleşiminden oluşmaktadır. CVA'daki en önemli aşamalardan biri farklılık ve farksızlık alt uzay tanımlamaları ve bu alt uzaylara olan izdüşümlerin belirlenmesi aşamasıdır (Gülmezoğlu vd., 2001: 668). R uzayında, birbirine tümleyen olan farklılık ve farksızlık alt uzayları, a_k öznelik vektörün boyutu (n), vektör sayılarının (M)'den küçük veya eşit olduğu durumda bulunabilmektedir. Bu durum, yetersiz veri durumu olarak, Eğer n, M'den büyük olduğu durumda ise yeterli veri durumu olarak adlandırılmaktadır (Gülmezoğlu vd., 2007: 278).

Sınıf sayısı: S ; c =1, 2,..., S, her bir sınıftaki örnek sayısı: N ; i =1, 2,..., N, eğitim kümesindeki toplam örnek sayısı: S.N, eğitim kümesindeki örneklerin boyutu: n x1, \overline{X}_1^c sınıftaki i. örneği olmak üzere , her bir sınıfın ilk örneği \overline{X}_1^c referans vektörleri ile fark vektörleri bulunmaktadır. Daha sonra farklılık alt uzayı izdüşümü elde edilmektedir. Her bir sınıfa ait farklılık alt uzayına iz düşürülerek her bir sınıfın ayırt edici vektörü ($\overline{X}_{ayırt\ edici}^c$) elde edilmektedir. Denklem (3.26)'da gösterildiği şekilde (\overline{X}_{ortak}^c) vektörü elde edilmektedir.

$$\overline{X}_{ortak}^c = \overline{X}_1^c - \overline{X}_{ayırt\ edici}^c \quad (3.26)$$

3.4.3. Ayırt Edici Ortak Vektör Yaklaşımı

DCVA, CVA ve doğrusal diskriminant analizi teorilerinin birleştirilmesiyle oluşturulmuştur (Cevikalp vd. , 2005: 6). Örnek uzayı boyutu, sınıf verilerinden daha büyük ise bu yöntem kullanılmaktadır. DCVM’de tüm sınıfların değişim matrislerinden faydalanılmaktadır. Ortak değişim matrisi yöntemi kullanarak DCVM yöntemi uygulanabilmektedir. Ortak değişim matrisi yaklaşımında, sınıf içi saçılımlar ile sınıf ortak vektörleri bulunmakta ve ortak vektörler, öznitelik vektörlerinin, tüm sınıflara ait ortak değişim matrisinin farksızlık alt uzayına iz düşürülmesiyle elde edilmektedir. Ayırt edici ortak vektörler ise, elde edilen öznitelik vektörü boyutundaki ortak vektörlerin, ortak vektörlere ait değişim matrisinin farklılık alt uzayına iz düşürülmesi ile elde edilir. Sonuçta boyutu ortak vektörlere ait değişim matrisinin farklılık alt uzayını geren birimdik vektör sayısına eşit olan ayırt edici ortak vektörler elde edilmektedir.

Sınıf sayısı: S ; $c = 1, 2, \dots, S$, her bir sınıftaki örnek sayısı: N ; $i = 1, 2, \dots, N$, eğitim kümesindeki toplam örnek sayısı: $S.N$, eğitim kümesindeki örneklerin boyutu: $n \times 1$ olmak üzere, \overline{X}_i^c sınıftaki i . örneği, ortak vektörlerin ortalaması ($\overline{\mu_{ortak}^c}$) bulunmaktadır. Daha sonra ortak vektörlerin kovaryans matrisi bulunur. Sıfır olmayan özdeğerlere karşılık gelen özvektörler ile izdüşüm matrisi oluşturmaktadır. Ortak vektörlerin farklılık alt uzayına izdüşürülerek ayırt edici ortak vektörler denklem 3.27’de gösterildiği gibi elde edilmektedir.

$$\overline{X_{ayırt\ edici-ortak}^c} = \omega^T \cdot \overline{X}_i^c \quad (3.27)$$

3.5. Sınıflandırma

Tez çalışmasında, sınıflandırma aşamalarında, LLC, LDC, FLDA, BC, k-NN sınıflandırıcıları kullanılmıştır. Sınıflandırıcı seçimi, performans doğrudan etkilediğinden başarılı bir sınıflandırma süreci için çok önem taşımaktadır.

3.5.1. Lojistik Doğrusal Sınıflandırıcı

LLC, bağımlı ve bağımsız değişkenler arasındaki bağlantıyı bulmak için veri setinden en az sayıda öznitelikle modele en iyi uyumu sağlamayı hedeflemektedir (Antonogeorgos vd., 2009: 3). Değişkenler arasındaki ilişki LOGR ile belirlendikten sonra LDA yöntemiyle sınıflandırma modeli oluşturulmaktadır. LLDA modeli oluşturulurken LOGR’de kullanılan bağımlı değişkenin alacağı değerlerden birinin gerçekleşme olasılığı üzerinden yöntem geliştirilmiştir. Gerçekleşme olasılığı (3.28) ‘de gösterilmektedir.

$$\log\left(\frac{p(\vec{x}|w_1)}{p(\vec{x}|w_2)}\right) = \vec{\beta}^T \cdot \vec{x} + \beta_0 \quad (3.28)$$

LLC modeli oluşturulurken sınıfların olasılıklarının ve kovaryans matrislerinin eşit olduğu ve bu sınıflar için lojistik ve doğrusal bir model oluşturulabileceği varsayılmıştır. $\beta_0' = \beta_0 + \log\left(\frac{p(w_1)}{p(w_2)}\right)$ şeklinde tanımlanmaktadır. LLC modeli karar kriterleri (3.29) ve (3.30) deki denklemlerde belirtilmiştir.

$$\vec{x} \in \begin{cases} w_1 & , \quad \frac{p(w_1|\vec{x})}{p(w_2|\vec{x})} > 1 \\ w_2 & , \quad \frac{p(w_1|\vec{x})}{p(w_2|\vec{x})} < 1 \end{cases} \quad (3.29)$$

$$\vec{x} \in \begin{cases} w_1 & , \quad \vec{\beta}^T \cdot \vec{x} + \beta_0 > 1 \\ w_2 & , \quad \vec{\beta}^T \cdot \vec{x} + \beta_0 < 1 \end{cases} \quad (3.30)$$

3.5.2. Doğrusal Ayırtaç Sınıflandırıcı

LDC, doğrusal bir sınıflandırma yöntemi olarak çalışmaktadır (Işıklı Esener, 2017: 61). Sınıflandırma performansını en üst düzeye çıkartmak için sınıfları ayırt edebilecek öznelik alanları oluşturmaktadır. LDC öznelik alanlarını oluştururken bu özneliklerin doğrusal bir özneliğini kullanmaktadır. Doğrusal öznelikler elde edildikten sonra bir hiperdüzlem hesaplanarak sınıflandırma yapılması amaçlanmaktadır. Hiperdüzlem doğrusal ayırtaç fonksiyonu olarak adlandırılmaktadır.

LDC çalışma prensibi 2 boyutlu bir sistemde incelendiğinde, \vec{x} test vektörü $g(\vec{x})$ doğrusal ayırtaç fonksiyonuna iz düşürülerek (3.31)'da verilen karar kriterlerine göre sınıflandırma yapılmaktadır.

$$\vec{x} \in \begin{cases} w_1 & , \quad \vec{w}^T \cdot \vec{x} + w_0 > 0 \\ w_2 & , \quad \vec{w}^T \cdot \vec{x} + w_0 < 0 \end{cases} \quad (3.31)$$

3.5.3. Fisher Doğrusal Ayırtaç Analizi Sınıflandırıcısı

LDC yöntemiyle sınıfların ayrılabilirliğini en üst düzeye çıkarmak için verileri yansıtan öznelik alanı bulunması gerekmektedir (Işıklı Esener, 2017: 62). Ayrıca her yeni öznelik

alanı adayı için sınıfları ayırma performansının ölçmenin bir yolunu bulunmalıdır. Her bir sınıfın öznitelikleri arasındaki mesafe, ölçülerden biridir, ancak yalnızca bu mesafe, verilerin yayılmasını hesaba katmadığı için çok iyi bir performans göstermemektedir. Bu dezavantajı ortadan kaldırmak için 1988'de, Ronald Fisher adlı bir istatistikçi sınıf içi değişkenliğin bir ölçüsü ile normalize edilen, ortalamalar arasındaki farkı temsil eden işlevi maksimize edilmesini önermiştir (Fisher, 1936: 179). Önerilen bu yöntem ile her bir sınıfın ortalaması arasındaki mesafeyi maksimize edilir ve sınıfın kendi içindeki yayılmayı en aza indirilmektedir. FLDA veri setini sınıflandırmak için eğitim verisini sınıf-içi varyansı minimum, sınıflar-arası varyansı maksimum olacak şekilde sınıfları ayıran bir hiperdüzlem oluşturmaktadır.

$$J_{\vec{w}} = \frac{\vec{w}^T \cdot S_B \cdot \vec{w}}{\vec{w}^T \cdot S_W \cdot \vec{w}} \quad (3.32)$$

(3.32) nolu denklemde \vec{w} eğitim kümesini, S_B sınıflar-arası saçılım matrislerini, S_W sınıflar-içi saçılım matrislerini temsil etmektedir. Eğitim aşamasında FLDA sınıflandırıcısı, \vec{w} 'nin S_W ve S_B 'nin özdeğer/özvektörlerini bulmaktadır. Eğitim kümesindeki öznitelikler, en büyük özvektöre karşılık gelen özdeğerler ile oluşturulan izdüşüm matrisine izdüşürülerek sınıfları birbirinden ayırılmasını sağlayan hiperdüzlem elde edilmektedir. Test aşamasında, test vektörü izdüşüm matrisine iz düşürülmekte ve iz düşürülmüş eğitim vektörleri ile arasındaki uzaklık hesaplanmaktadır. Test vektörü aralarındaki uzaklık en az çıkan sınıfa atanmaktadır.

3.5.4. Bayes Sınıflandırıcısı

BC, test vektörlerinin hangi sınıfa ait olduklarını belirlemek için olasılıktan faydalanmaktadır (Ranganathan, 2019: 403). Bayes karar kuramına göre test vektörünün, ait olma olasılığı en yüksek olan sınıfa atanmaktadır. 2-sınıflı bir sınıflandırma problemi için Bayes karar kuralı (3.33)'da gösterilmektedir.

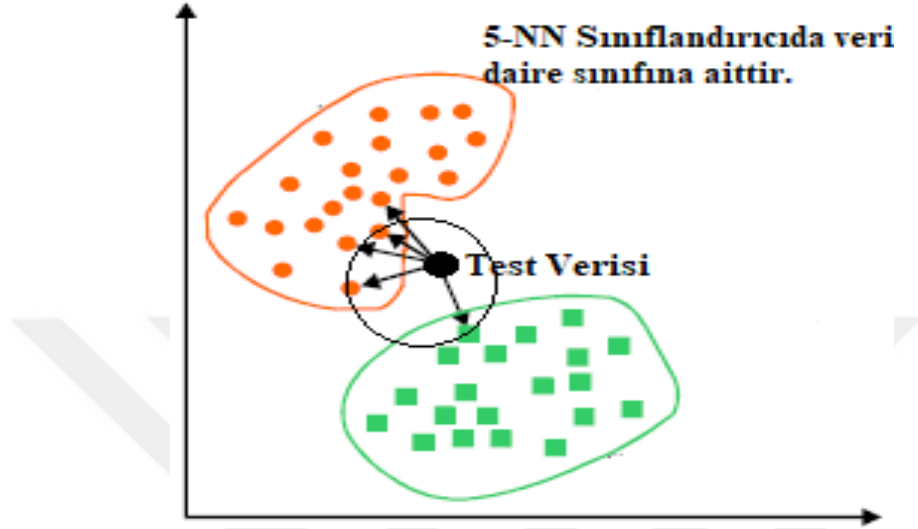
$$P(w_i | \vec{x}_i) > P(w_j | \vec{x}_j), \forall j \neq i \leftrightarrow \vec{x} \in w_i \quad (3.33)$$

$P(w_i | \vec{x}_i)$, \vec{x}_i 'nin w_i sınıfına ait olma olasılığını, $P(w_j | \vec{x}_j)$, \vec{x}_i 'nin w_j sınıfına ait olma olasılığını göstermektedir.

3.5.5. k-En Yakın Komşu Sınıflandırıcısı

k-NN sınıflandırıcısı ile seçilen bir öznitelik veri setindeki diğer öznitelikler ile arasındaki mesafe kullanarak sınıflandırma yapılmaktadır (Altman, 1992: 178). Bu

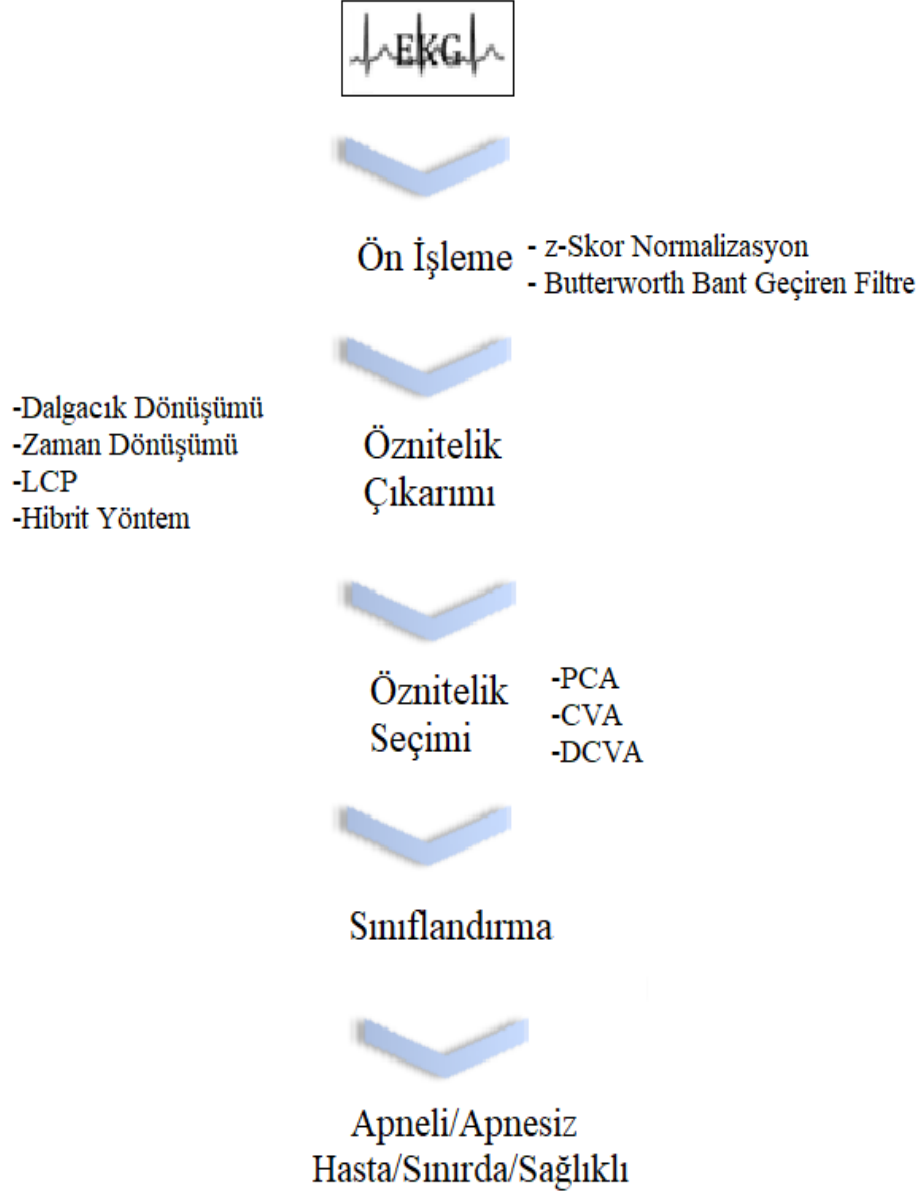
algoritmada, sınıfı bilinen öznitelikler test özniteliğinin sınıfının belirlenmesinde kullanılmaktadır. Eğitim setinde belirlenen özniteliklerin test özniteliğine uzaklıkları Kosinüs, Öklid ya da Manhattan uzaklığı gibi yöntemler ile hesaplanmaktadır. Bu yöntemde k adet en yakın öznitelikler seçilir ve seçilen bu k adet öznitelik çoğunlukla hangi sınıfta ise test özniteliği o sınıfa atanmaktadır. Çalışma prensibi Şekil 3.8. 'de gösterilmektedir.



Şekil 3.7. k-NN sınıflandırıcı çalışma prensibi

4. DENEYSEL ÇALIŞMALAR

Tez çalışmasında, PhysioBank Apnea-ECG veri tabanı üzerinden, 2- sınıflı teşhis ve 3- sınıflı teşhis çalışması yapılması amaçlanmaktadır. Kullanılan öznitelik çıkarımı, öznitelik seçimi ve sınıflandırıcıların performansları karşılaştırılmaktadır. Şekil 4.1.'de, çalışmanın akışını özet olarak gösterilmektedir.



Şekil 4.1. Tez çalışması basamakları

4.1. Eğitim ve Test Kümelerinin Belirlenmesi

PhysioBank Apnea-ECG veri tabanından elde edilen öznitelikler sınıflandırma aşaması için eğitim ve test kümelerine ayrılmaktadır. Eğitim ve test kümelerinin belirlenmesinde k-katlamalı çapraz doğrulama yönteminden faydalanılmıştır.

Veri tabanı k alt küme altına bölünmekte ve k kez tekrarlanmaktadır (Berrar, 2018: 542). Her seferinde, k tane alt kümeden biri test kümesi olarak kullanılırken diğer k-1 tane alt kümeden bir eğitim kümesi oluşturulmaktadır. Bu yöntemin son aşamasında tüm k


denemelerinde elde edilen performans değerlendirme metriklerinin ortalaması hesaplanmaktadır.

4.2. Ön İşleme

PhysioBank Apnea-ECG veri tabanındaki sinyallerden daha iyi performans sonuçları elde edilmesi için ön işleme yapılmaktadır. Bu aşamada veri tabanında R-noktalarının düzeltilmesi, normalizasyon, sinyal bölütleme yapılmakta ve bant geçiren filtreden geçirilmektedir.

4.2.1. RR Aralıklarının Elde Edilmesi

ECG sinyalinde, apne tespiti için HRV'in oluşturduğu desenlerdeki farklılıklar kullanılmaktadır. Sürekli değişim içinde olan ECG periyodu, P-QRS-T dalga parçacıklarından oluşmaktadır (Kaplan Berkaya vd., 2018: 220). RR arasındaki boyut ve şekilce değişiklikler göstermektedir. Bu RR aralıklarındaki değişimlerin apne tespitinde kullanılması amaçlanmaktadır. Şekil 4.2.'de görüldüğü gibi iki tepe noktası arasındaki mesafe RR aralığı, Q, R ve S noktaları arasındaki mesafe QRS aralığı olarak adlandırılmaktadır.



Şekil 4.2. ECG sinyalinde QRS kompleksleri ve RR aralığı gösterimi

Kaynak: (ECGI, 2021)

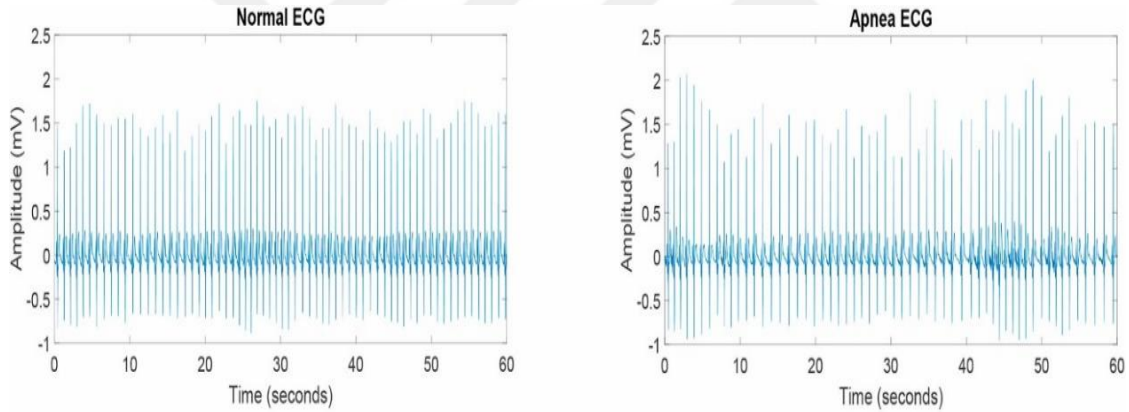
PhysioBank Apnea-ECG veri tabanından elde edilen tek kanallı ECG sinyallerinin, QRS bilgileri veri tabanında .qrs ek bilgi dosyalarında bulunmaktadır. Sqrt fonksiyonu ile QRS dalga parçacıkları elde edilmektedir. Fakat bu ek bilgi dosyalarında R tepe noktalarında hatalar gözlemlendiği veri tabanında belirtilmektedir. RR aralıklarının doğru belirlenmesi için doğru R tepe noktalarının tespiti yapılmaktadır. Her biri 7-8 saatten oluşan ECG kayıtları bir-dakikalık bölütlere ayrılmaktadır.

Sonraki aşamada Da Silva Pinho vd.'lerinin 2016'da (Da Silva Pinho vd. , 2016: 2) ve Pombo vd.'lerin 2020'de (Pombo vd. , 2020: 200479) yaptığı çalışmalar incelendiğinde veri tabanında belirtilen R noktasının bulunduğu 0,25 saniyelik pencere içerisinde belirtilen R noktasından daha yüksek bir genliğe sahip nokta tespit edilirse bu nokta yeni R noktası olarak belirlenmektedir. Pencere içerisinde daha yüksek bir R noktası bulunmadığında belirtilen R noktası değiştirilmemektedir.

R tepe noktalarının düzeltilmesiyle oluşan ECG sinyallerinde, veri noktalarının aynı ölçeğe sahip olması ve eşit önlem kazanması için denklem (3.1), (3.2), ve (3.3)'te açıklanan z-skor normalizasyon yöntemi uygulanmaktadır (Almutairi vd., 2021: 1384).

4.2.2. RR Aralıklarının Filtrelenmesi

RR aralıkları bant aralığı 0,4-40 Hz olan bant geçiren filtreden geçirilmektedir. Kullanılan bant geçiren filtre Bölüm 3'te ayrıntılı olarak anlatılmaktadır. Şekil 4.3'de 1 dk'lık bölütlere bölünmüş normal ve apneli ECG sinyalleri gösterilmektedir.



Şekil 4.3. 1 dk'lık bölütlere bölünmüş normal ve apneli ECG sinyali

Kaynak: (Rajesh vd. , 2021: 3)

Ön işleme sonucunda veri tabanının 4 farklı hali elde edilmektedir. Bunlar;

- 1 dk'lık bölütlere bölünmüş ECG sinyali
- 1 dk'lık bölütlere bölünmüş ECG sinyalinin normalize edilmiş hali (Norm)
- 1 dk'lık bölütlere bölünmüş ECG sinyaline butterworth bant geçiren filtre uygulanmış hali (BP)

- 1 dk'lık bölütlere bölünmüş ECG sinyalinin hem normalize edilmiş hem de butterworth bant geçiren filtre uygulanmış hali (BP-Norm)

4.3. Öznitelik Çıkarımı


Özniteliklerin belirlenmesi için çalışmada; bir-dakikalık bölütler, uzamsal düzlem ve frekans düzleminde elde edilen özniteliklerin, hesaplanma yöntemleri açıklanmaktadır.

4.3.1. Dalgacık Düzlemi Öznitelikleri

Tez çalışmasında 3 seviyeli ayrık dalgacık dönüşümü kullanılmaktadır (Rajesh vd., 2021: 4). Kandala vd. Ayrık dalgacık dönüşümü tabanlı istatistiksel özellikler kullanarak obstrüktif uyku apnesi tespiti yapmayı amaçlayan çalışmaları referans alınarak 3 seviyeli ayrık dalgacık dönüşümü seçilmektedir (Kandala vd, 2020: 4). Ayrık dalgacık dönüşümü sinyali alçak frekans ve yüksek frekans bileşenlerine ayıran bir filtredir. Dalgacık dönüşümü, veri sayısı istenilen seviyeye kadar, her seviyede yarıya düşürerek devam etmektedir. 3 seviyeli dalgacık dönüşümü uygulanırken elde edilen alt bant frekans aralıkları;

- $x(n) : 0 - \frac{f_s}{2} = 0 - 50 H_z$
- $A1 : 0 - \frac{f_s}{8} = 0 - 12,5 H_z$
- $D1 : \frac{f_s}{8} - \frac{f_s}{4} = 12,5 - 25 H_z$
- $A2 : 0 - \frac{f_s}{16} = 0 - 6,5 H_z$
- $D2 : \frac{f_s}{16} - \frac{f_s}{32} = 6,25 - 12,5 H_z$
- $A3 : 0 - \frac{f_s}{32} = 0 - 3,125 H_z$
- $D3 : \frac{f_s}{32} - \frac{f_s}{16} = 3,125 - 6,25 H_z$

Referansa göre ECG sinyalinin morfolojisinden en iyi şekilde yararlanabilmek için db6 dalgacık fonksiyonu kullanılmaktadır. Literatürde farklı sinyallerde saklı desenleri analiz etmek için çeşitli dalgacık fonksiyonları kullanılmaktadır. Çalışmada kullanılan db6 dalgacığı Şekil 4.4'de gösterilmektedir.



Şekil 4.4. db6 dalgacık fonksiyonu

Kaynak: (Işıklı Esener, 2012: 36)

Bu çalışmada referans dikkate alınarak, sınıflandırma sorunlarının çözüme yardımcı olması amacıyla öznitelik olarak ayrıştırılmış alt bantlar hesaplanmaktadır. Bu öznitelikler, sinyalin istatistiksel ve güç spektral özelliklerinden türetilmektedir. Öznitelikler üç set halinde gruplanabilir:

1. Güç spektrumunun momentleri
2. Dalga biçimi karmaşıklık ölçüleri
3. Daha yüksek sıralı momentler.

Tablo 4.1.'de A1, A2, A3, D3 dalgacık bileşeninden elde edilen, öznitelikler ve matematiksel gösterimleri gösterilmektedir.

Tablo 4.1. Dalgacık düzlemi öznitelikleri ve matematiksel gösterimleri

Dalgacık Dönüşümü Öznitelikleri	Matematiksel Gösterimleri
---------------------------------	---------------------------

1. Güç Spektrumlarının Momentleri	
Ortalama Frekans (Mean Frequency - MF)	$MF = \left(\frac{2}{E_x}\right) \sum_{t=0}^{\frac{f_s}{2}} f_l P_{XX}(f_l)$
Varyans (Variance - V)	$V = \left(\frac{2}{E_x}\right) \sum_{t=0}^{\frac{f_s}{2}} (f_l - MF)^2 P_{XX}(f_l)$
2. Dalga Biçimi Karmaşıklık Ölçütleri	
Kök Ortalama Kare Değeri (Root mean square - RMS value)	$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_{(n)} ^2}$
Form Faktörü (Form factor - FF)	$FF = \frac{M_{X'}}{M_X}$
3. Daha Yüksek Sıralı Momentler	
Ortalama (Mean - μ)	$\mu = \frac{1}{N} \sum_{n=1}^N x_{(n)}$
Standart Sapma (Standard Deviation - std)	$std = \left(\frac{1}{N} \sum_{n=1}^N (x_{(n)} - m_x)^2\right)^{\frac{1}{2}}$
Çarpıklık (Skewness - s)	$s = \frac{\frac{1}{N} \sum_{n=1}^N (x_{(n)} - m_x)^3}{\left(\frac{1}{N} \sum_{n=1}^N (x_{(n)} - m_x)^2\right)^{\frac{3}{2}}}$
Basıklık (Kurtosis - k)	$k = \frac{\frac{1}{N} \sum_{n=1}^N (x_{(n)} - m_x)^4}{\left(\frac{1}{N} \sum_{n=1}^N (x_{(n)} - m_x)^2\right)^2}$

4.3.2. HRV Öznitelikleri

HRV'den istatistiksel öznitelik çıkarım yöntemleri kullanılarak öznitelikler elde edilmektedir (Pombo vd. , 2020: 200480), (Razi vd. , 2021: 2). Referanslar dikkate alınarak çalışmada HRV'den 17 öznitelik çıkarılmaktadır. Bu çıkarılan öznitelikler ve matematiksel gösterimleri Tablo 4.2.'de gösterilmektedir.

Tablo 4.2. HRV öznitelikleri ve matamatiksel gösterimleri

HRV Öznitelikleri	Matematiksel Gösterimleri
Ortalama (Mean - μ)	$\mu = \frac{\sum rr_i}{m}$
Standart Sapma (Standard Deviation - std)	$\sigma = \sqrt{\frac{\sum (rr_i - \mu_{rr})^2}{m}}$
50 ms'den Fazla Vuruşlar Arası Fark ile Vuruşların Toplamı, Varyant 1 (Sum of Beats with İnterbeat Difference Over 50 ms, Variant 1 – NN50V1)	$NN50V1 = \sum_{i=2}^m unit [rr_i - rr_{i+1} - 50ms]$
50 ms'den Fazla Vuruşlar Arası Fark ile Vuruşların Toplamı, Varyant 2 (Sum of Beats with İnterbeat Difference Over 50 ms, Variant 2 – NN50V2)	$NN50V2 = \sum_{i=2}^m unit [rr_{i+1} - rr_i - 50ms]$
NN50v1'in segment uzunluğuna oranı (Ratio of NN50v1 to segment length - PNN50V1)	$PNN50V1 = \frac{NN50V1}{m}$
NN50v2'in segment uzunluğuna oranı (Ratio of NN50v2 to segment length - PNN50V2)	$PNN50V2 = \frac{NN50V2}{m}$
Atımlar arası diferansiyellerin ortalaması (Mean of interbeat differentials – MRD)	$MRD = \frac{\sum rd_i}{m}$
Atımlar arası diferansiyellerin standart sapması ,(Standard deviation of interbeat differentials – SDRD)	$SDRD = \sqrt{\frac{\sum (rd_i - \mu_{rd})^2}{m}}$

Tablo 4.2. HRV öznitelikleri ve matematiksel gösterimleri (devamı)

Seri korelasyon katsayıları ($k = 1,2,3,4,5$) (Serial correlation coefficients ($k=1,2,3,4,5$)- corr-ceof)	$\text{corr - ceof} = \frac{\sum_{i=1}^m (rr_i - \mu_{rd})(rr_{i+k} - \mu_{rr})}{\sum_{i=1}^m (rr_i - \mu_{rr})^2}$
Uç noktaların sayısı (Number of extreme points – NEP)	$NEP = \frac{1}{m-2} \sum_{i=2}^{m-1} (1 - \text{unit}[(rr_i - rr_{i-1})(rr_{i+1} - rr_i)])$
SDRD değişiklik oranı Ortalama (Ratio of changes SDRD to Mean – CVNN)	$CVNN = \frac{SDRD}{\mu}$
RR aralıkları arasındaki farkların mutlak değerlerinin medyanı (The median of the absolute values of the differences between RR intervals – medianNN)	$\text{medianNN} = \text{median}(rd)$
20 ms'den Fazla Vuruşlar Arası Fark ile Vuruşların Toplamı, Varyant 1 (Sum of Beats with İnterbeat Difference Over 20 ms, Variant 1 – NN20V1)	$NN20V1 = \sum_{i=2}^m \text{unit} [rr_i - rr_{i-1} + 1 - 20ms]$
20 ms'den Fazla Vuruşlar Arası Fark ile Vuruşların Toplamı, Varyant 2 (Sum of Beats with İnterbeat Difference Over 20 ms, Variant 2 – NN20V2)	$NN20V1 = \sum_{i=2}^m \text{unit} [rr_{i+1} - rr_i - 20ms]$
NN20V1'in segment uzunluğuna oranı (Ratio of NN20V1 to segment length – PNN20V1)	$PNN20V1 = \frac{NN20V1}{m}$
NN20V2'in segment uzunluğuna oranı (Ratio of NN20V2 to segment length – PNN20V2)	$PNN20V2 = \frac{NN20V2}{m}$

4.3.3. Yerel Konfigürasyon Örüntüsü Öznitelikleri

Bölüm 3’de ayrıntılı olarak açıklanan LCP yöntemiyle ECG sinyalleri referansta gösterildiği gibi 1 boyutlu vektöre çevrilmektedir. Şekil 3.5.’de gösterildiği gibi vektör formuna çevrilir. 1 piksel uzaklıktaki 8 komşuluk kullanılmaktadır. Vektör koordinatları denklem (4.1)’de gösterildiği şekildedir.

$$\text{Vektör koordinatları} = [0 \ -4; 0 \ -3; 0 \ -2; 0 \ -1; 0 \ 1; 0 \ 2; 0 \ 3; 0 \ 4] \quad (4.1)$$

4.3.4. Hibrit yöntem öznitelikleri

Hibrit öznitelik çıkartımı için ön işleme yapılan sinyaller öncelikle ayrık dalgacık dönüşümü yöntemiyle db1 dalgacığı kullanılarak üçüncü seviyede ayrık dalgacık dönüşümü yapılmaktadır. Dalgacık dönüşümü sonucunda her bir alt bandan Alçak/Alçak (AA), Alçak/Yüksek (AY), Yüksek/Alçak (YA), Yüksek/Yüksek (YY) olmak üzere öznitelikler elde edilmektedir. Elde edilen bu frekans bantlarına uygulanan P=8 komşuluklu 1-boyutlu LCP yöntemi ile LCP vektör (AA), LCP vektör (AY), LCP vektör (YA), LCP vektör (YY) öznitelikleri bulunmaktadır. Bulan LCP vektörleri (Işıklı Esener, 2017: 68) Işıklı Esener 2017’de yaptığı çalışma referans alınarak katsayılarla çarpılmaktadır. Kullanılan katsayılar Tablo 4.3.’de gösterilmektedir.

Tablo 4.3. LCP katsayısı ve kodu

LCP kodu	AA-AY-YA-YY katsayıları
LCP 1,4-1-1-0	1,4-1-1-0

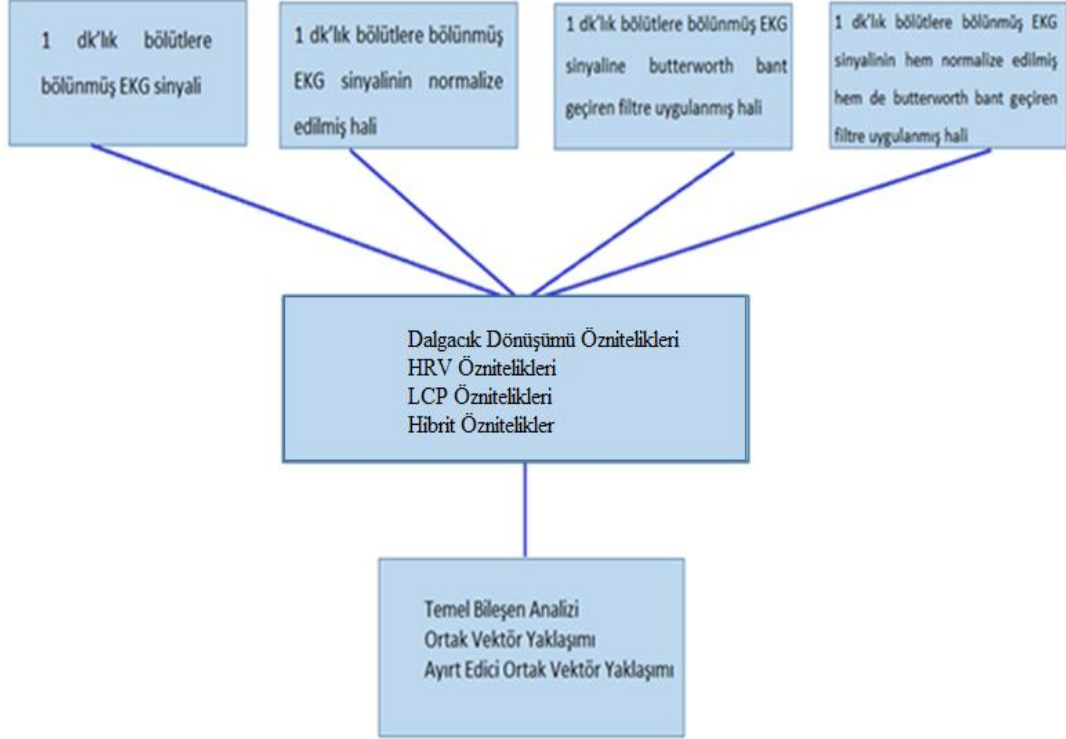
Tablo 4.3.’de gösterilen katsayı referans dikkatte alınarak kullanılmıştır. LCP vektörleri 1,4-1-1-0 katsayıları ile çarpılarak 70x1 boyutlu LCP vektör öznitelikleri elde edilmiştir. Bu özniteliklerden sıfır olanlar elenerek 32x1 boyutlu LCP vektörler öznitelikleri oluşturulmuştur. LCP 1,4-1-1-0 kodlu LCP vektör özniteliklerine istatistiksel öznitelik çıkarım yöntemleri uygulanarak 12x1 boyutlu LCP istatistiksel öznitelikleri elde edilmektedir. Ayrık dalgacık dönüşümünün 15.seviye’li hali uygulanarak 16x1 boyutlu dalgacık dönüşümü öznitelikleri elde edilmektedir. Elde edilen bu LCP vektör öznitelikleri, LCP istatistiksel öznitelikler ve dalgacık dönüşümü özniteliklerinden oluşan öznitelik grupları Tablo 4.4.’de gösterildiği gibi birleştirilerek 60x1 boyutlu hibrit öznitelik vektörü oluşturulmuştur.

Tablo 4.4. 60-boyutlu hibrit öznitelik vektörlerinin oluşturulması

LCP Öznitelik Vektörü	İstatistiksel Öznitelikler	Dalgacık Dönüşümü Öznitelikleri	60-Boyutlu Hibrit Öznitelik Vektörü
32x1	12x1	16x1	60x1
LCPvektör 1.4 1 1 0	LCP 1,4-1-1-0: Enerji	AAAA: Enerji	60-Boyutlu LCP-Tabanlı Öznitelik Vektörü
	LCP 1,4-1-1-0: Ortalama	AAAY: Enerji	
	LCP 1,4-1-1-0: Varyans	AAYA: Enerji	
	LCP 1,4-1-1-0: Maksimum	AAYY: Enerji	
	LCP 1,4-1-1-0: Minimum	AYAA: Enerji	
	LCP 1,4-1-1-0: Standart Sapma	AYAY: Enerji	
		AYYA: Enerji	
	LCP 1,4-1-1-0: Çarpıklık	AYYY: Enerji	
	LCP 1,4-1-1-0: Basıklık	YAAA: Enerji	
	LCP 1,4-1-1-0: Alan- Tanımlayıcısı	YAAY: Enerji	
		YAYA: Enerji	
	LCP 1,4-1-1-0: Ortalama Enerji	YAYY: Enerji	
		YYAA: Enerji	
	LCP 1,4-1-1-0: Enerji Varyansı	YYAY: Enerji	
YYYA: Enerji			
LCP 1,4-1-1-0: Entropi	YYYY: Enerji		

4.4. Öznitelik Seçimi

Çalışma kapsamında daha küçük bir veri kümesi elde edilmesi ve veri seti içerisinde en ayırt edici öznitelikleri seçilmesi için öznitelik seçimi yapılmaktadır. Bu seçim sınıflandırma modelinin performansını etkilemektedir. Bölüm 3'te ayrıntılı olarak anlatılan PCA CVA ve DCVA yöntemleri Şekil 4.5.'de gösterildiği gibi ön işleme ve öznitelik çıkarımı yapılan veri kümelerini uygulanmaktadır.

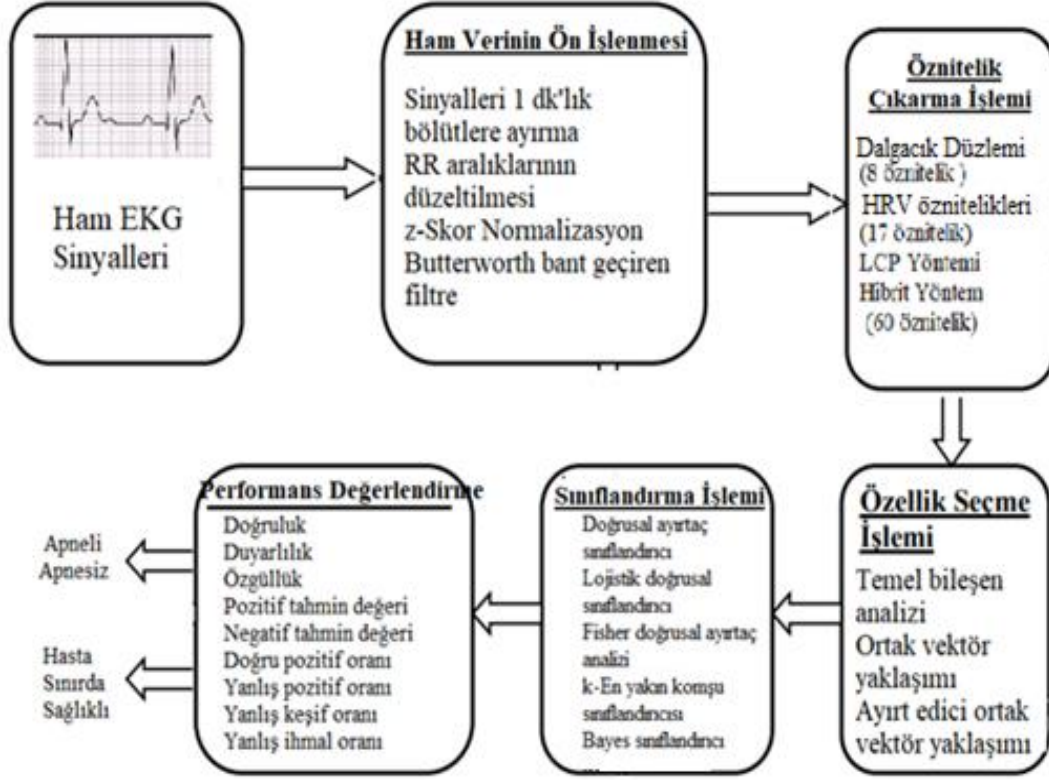


Şekil 4.5. Öznitelik seçimi için uygulanan aşamalar

Şekil 4.5.'de gösterilen aşamalar sonucunda her durum için; veri tabanından elde edilen dört ön işleme uygulanan hali, her bir ön işleme halinden 7 öznitelik grubu ve bu 7 öznitelik grubu için 3 öznitelik seçimi uygulanarak alt uzay öznitelik grupları oluşturulmaktadır.

4.5. Sınıflandırma

Bu çalışmada, Bölüm 3'te ayrıntılı olarak anlatılan LLC, LDC, FLDA, BC, k-NN sınıflandırıcıları kullanılmaktadır. Sınıflandırma aşamaları Şekil 4.6.'de gösterilmektedir. Burada gösterildiği gibi ham ECG sinyalleri ön işleme, öznitelik çıkarımı ve öznitelik seçimi aşamaları sonucunda elde edilen öznitelik grupları ve alt uzay öznitelik grupları sınıflandırıcılara girdi olarak verilmektedir. 2- ve 3- sınıflı teşhis çalışmaları yapılmaktadır.



Şekil 4.6. Sınıflandırma çalışma aşamaları

Sınıflandırma kodları Matlab programı ve prtools kullanılarak oluşturulmuştur. Prtools istatistiksel örüntü tanımada ve deneysel veri kümelerindeki örüntülerin tanınmasında kullanılacak karar kurallarını ve veri kümeleri için teknikler içeren bir araç kutusudur. Veri analizi ve prosedürlerin değerlendirilmesi için sayısal programların esnek bir şekilde kullanılmasını gerektiren güçlü bir hesaplama karakterine sahiptir. Matlab'da bulunan prtools araç kutusuyla sınıflandırma işlemlerinin kolaylaşması hedeflenmektedir. Bu çalışmada da bu özellikleri göz önüne alınarak bu araç kutusundan faydalanılmaktadır.

4.6. Performans Değerlendirme Metrikleri

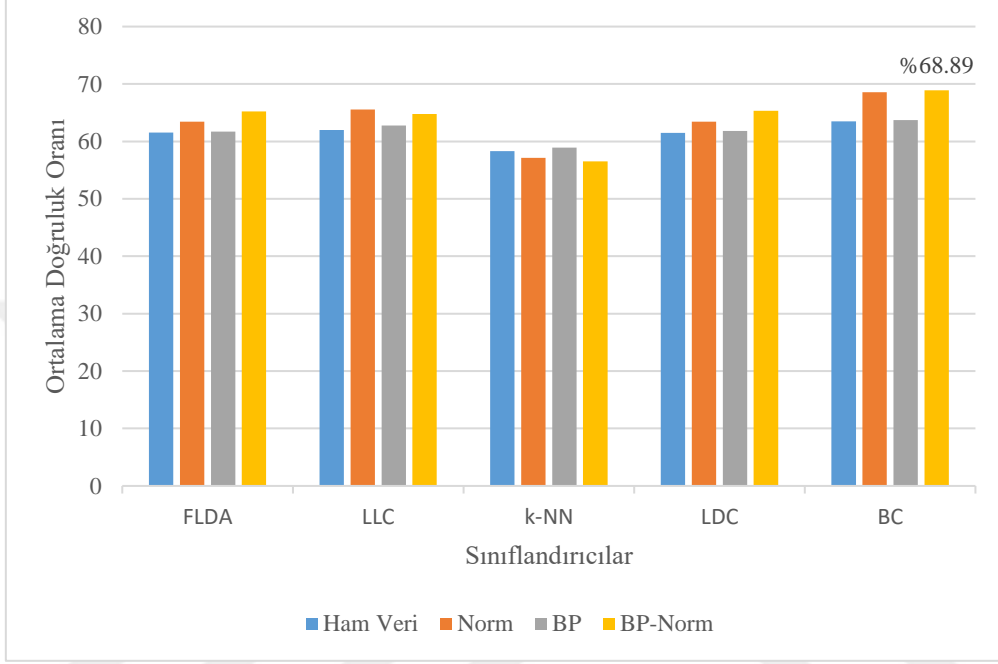
Literatürde önerilen SAS-CAD sistemlerinin performansı genellikle Doğruluk (Accuracy – ACC), Duyarlılık (Sensitivity – SNS), Özgüllük (Specificity – SPC), Pozitif Tahmin Değeri (Positive Predictive Value – PPV), Negatif Tahmin Değeri (Negative Predictive Value – NPV), Doğru Pozitif Oranı (False Positive Rate - FPR), Yanlış Pozitif Oranı (False Negative rate - FNR), Yanlış Keşif Oranı (False Discovery Rate - FDR) ve Yanlış İhmal Oranı (False Omission Rate - FOR) metrikleri ile değerlendirilmektedir. Bu metriklerin matematiksel gösterimleri Tablo 4.5.'de verilmektedir.

Tablo 4.5. Performans değerlendirme metrikleri

Performans Değerlendirme Metrikleri	Matematiksel Gösterimleri
TP: Gerçek Pozitif (True Positive) TN: Gerçek Negatif (True Negative) FP: Yanlış Pozitif (False Positive) FN: Yanlış Negatif (False Negative)	
C: Sınıf Sayısı N_i : i. sınıfa ait veri sayısı	
Doğruluk (ACC)	$\% ACC = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100$
Hassaslık (SNS)	$\% SNS = \frac{TP}{TP + FN} \cdot 100$
Özgüllük (SPC)	$\% SPC = \frac{TN}{TN + FP} \cdot 100$
Pozitif Tahmin Değeri (PPV)	$\% PPV = \frac{TP}{TP + FP} \cdot 100$
Negatif Tahmin Değeri (NPV)	$\% NPV = \frac{TN}{TN + FN} \cdot 100$
Doğru Pozitif Oranı (False Positive Rate - FPR)	$\% FPR = \frac{FP}{FP + TN} \cdot 100$
Yanlış Pozitif Oranı (False Negative rate - FNR)	$\% FNR = \frac{FN}{TP + FN} \cdot 100$
Yanlış Keşif Oranı (False Discovery Rate - FDR)	$\% FDR = \frac{FP}{TP + FP} \cdot 100$
Yanlış İhmal Oranı (False Omission Rate - FOR)	$\% FOR = \frac{FN}{TN + FN} \cdot 100$


5. BULGULAR ve TARTIŞMA

Tez çalışmasında, uyku apnesi teşhisi, PhysioNet Apnea-ECG veri tabanı üzerinde bir-dakikalık bölütlerin 2-sınıflı teşhis çalışmasında dalgacık düzlemi öznitelikleri Bölüm 3’de anlatılan sınıflandırıcılar kullanılarak gerçekleştirilmiştir. Çalışma sonucunda elde edilen ortalama doğruluk oranları Şekil 5.1.’de gösterilmektedir.



Şekil 5.1. Dalgacık düzlemi öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları

BP-Norm ön işleme yöntemi kullanılan, dalgacık düzlemi öznitelikleri ile gerçekleştirilen 2-sınıflı teşhis çalışmasında BC sınıflandırıcı en yüksek doğruluk oranı, %68,89 olarak bulunmaktadır. En iyi doğruluk oranını elde edilen BC sınıflandırıcıya ait performans değerlendirmesi Şekil 5.2.’de, karmaşıklık matrisi Tablo 5.1.’de gösterilmektedir.

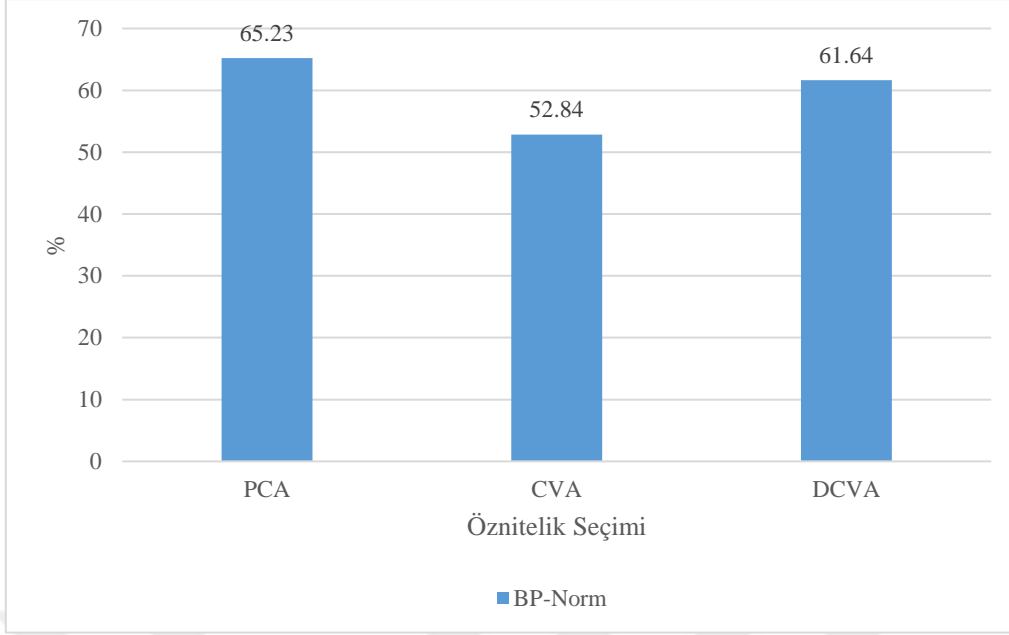


Şekil 5.2. BP-Norm, dalgacık düzlemi öznelikleri kullanılan BC sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.1. BP-Norm, dalgacık düzlemi öznelikleri kullanılan BC sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu	
		Apneli	Apnesiz
Referans Sonuçları	Apneli	3579	2941
	Apnesiz	3338	7142


Maksimum doğruluk oranı tespit edilen dalgacık düzlemi öznelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları Şekil 5.3.'de gösterilmiştir.



Şekil 5.3. BP-Norm, dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri ve kullanılarak BC sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.3. incelendiğinde en yüksek performans %65,23 ile PCA yöntemiyle elde edilmektedir.

2-sınıflı teşhis çalışmasında HRV öznitelikleri Bölüm 3’de anlatılan sınıflandırıcılar kullanılarak gerçekleştirilmiştir. Çalışmadan elde edilen ortalama doğruluk oranları Şekil 5.4.’de gösterilmektedir.



Şekil 5.4. HRV öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları

BP-Norm ön işleme yöntemi kullanılan, HRV öznitelikleri ile gerçekleştirilen 2-sınıflı teşhis çalışmasında FLDA sınıflandırıcı en yüksek doğruluk oranı, %72,29 olarak bulunmaktadır. En iyi doğruluk oranını elde edilen FLDA sınıflandırıcıya ait performans değerlendirmesi Şekil 5.5.'de, karmaşıklık matrisi Tablo 5.2.'de gösterilmektedir.




Şekil 5.5. BP-Norm, HRV öznitelikleri kullanılan FLDA sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.2. BP-Norm, HRV öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu	
		Apneli	Apnesiz
Referans Sonuçları	Apneli	3987	2533
	Apnesiz	2950	7530


Maksimum doğruluk oranı tespit edilen HRV öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.6.'da gösterilmiştir.



Şekil 5.6. BP-Norm, HRV öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.6. incelendiğinde en yüksek performans %67,00 ile PCA yöntemiyle elde edilmektedir.

2-sınıflı teşhis çalışmasında LCP özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.7.'de gösterilmektedir.



Şekil 5.7. LCP öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları

LCP öznitelikleri kullanılan LDC sınıflandırıcısı ile en yüksek doğruluk oranı, %65,95 olarak bulunmaktadır. En iyi doğruluk oranını elde edilen LDC sınıflandırıcısına ait performans değerlendirmesi Şekil 5.8.'de, karmaşıklık matrisi Tablo 5.3.'de gösterilmektedir.

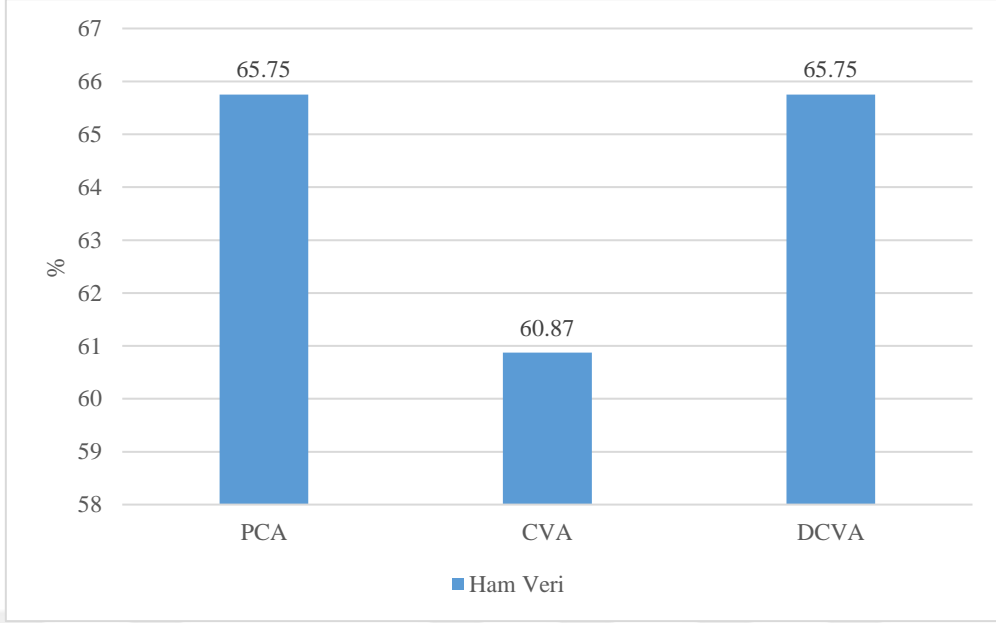


Şekil 5.8. Ham veri, LCP öznitelikleri kullanılan LDC sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.3. Ham veri, LCP öznitelikleri kullanılan LDC sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu	
		Apneli	Apnesiz
Referans Sonuçlar	Apneli	135	6385
	Apnesiz	117	10383

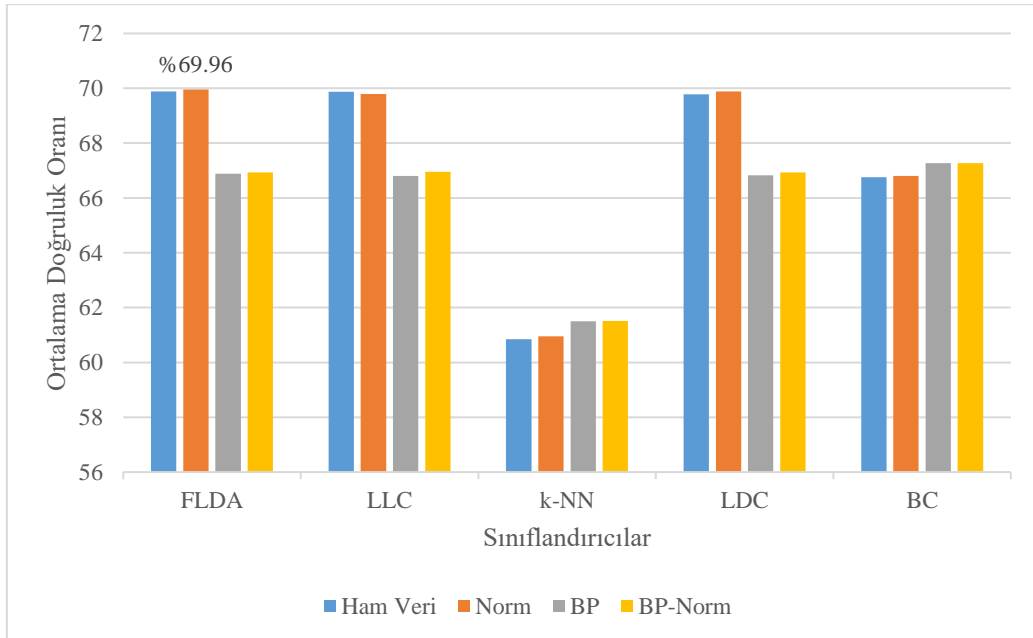
Maksimum doğruluk oranı tespit edilen LCP öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.9.'da gösterilmiştir.



Şekil 5.9. LCP öznitelikleri boyut indirgeme yöntemleri kullanılarak LDC sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.9. incelendiğinde en yüksek performans %65,75 ile PCA ve DCVA yöntemleriyle elde edilmektedir.

2-sınıflı teşhis çalışmasında LCP vektör özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.10.'da gösterilmektedir.



Şekil 5.10. LCP vektör öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları

Norm ön işleme yöntemi kullanılan LCP vektör öznitelikleri kullanılan FLDA sınıflandırıcısı ile en yüksek doğruluk oranı, %69,96 olarak bulunmaktadır. En iyi doğruluk oranını elde edilen FLDA sınıflandırıcısına ait performans değerlendirme Şekil 5.11.'de, karmaşıklık matrisi Tablo 5.4.'de gösterilmektedir.




Şekil 5.11. Norm, LCP vektör öznitelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.4. Norm, LCP vektör öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu	
		Apneli	Apnesiz
Referans Sonuçlar	Apneli	3080	3440
	Apnesiz	2528	7952


Maksimum doğruluk oranı tespit edilen LCP vektör öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.12'de gösterilmektedir.



Şekil 5.12. Norm, LCP vektör öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.12. incelendiğinde en yüksek performans %66,72 ile DCVA yöntemi ile elde edilmektedir.

2-sınıflı teşhis çalışmasında LCP istatistiksel özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.13.'de gösterilmektedir.



Şekil 5.13. LCP istatistiksel öznitelikler kullanılarak elde edilen ortalama doğruluk oranları

LCP istatistiksel öznitelikleri kullanılan BC sınıflandırıcısı ile en yüksek doğruluk oranı, %69,01 olarak bulunmaktadır. En iyi doğruluk oranını elde edilen BC sınıflandırıcısına ait performans değerlendirmesi Şekil 5.14.'de, karmaşıklık matrisi Tablo 5.5.'de gösterilmektedir.




Şekil 5.14. Ham veri, LCP istatistiksel öznitelikleri BC sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.5. Ham veri, LCP istatistiksel öznitelikleri kullanılan BC sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu	
		Apneli	Apnesiz
Referans Sonuçlar	Apneli	1928	4592
	Apnesiz	1467	9013


Maksimum doğruluk oranı tespit edilen LCP istatistiksel öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.15.'de gösterilmiştir.



Şekil 5. 15. LCP istatistiksel öznitelikleri boyut indirgeme yöntemleri kullanılarak BC sınıflandırıcısı ortalama doğruluk oranları

Şekil 5.15. incelendiğinde en yüksek performans %65,78 ile CVA yöntemi ile elde edilmektedir.


2-sınıflı teşhis çalışmasında LCP dalgacık düzlemi özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.16.'de gösterilmektedir.



Şekil 5.16. LCP dalgacık düzlemi öznitelikleri kullanarak elde edilen ortalama doğruluk oranları

BP-Norm ön işleme yöntemi kullanılan LCP dalgacık düzlemi öznitelikleri kullanılan BC sınıflandırıcısı ile en yüksek doğruluk oranı, %67,82 olarak bulunmaktadır. En iyi doğruluk

oranını elde edilen FLDA sınıflandırıcıya ait performans değerlendirme Şekil 5.17.'de, karmaşıklık matrisi Tablo 5.6.'da gösterilmektedir.




Şekil 5.17. BP-Norm, LCP dalgacık düzlemi öznelikleri BC sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.6. BP-Norm, LCP dalgacık düzlemi öznelikleri kullanılan BC sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu	
		Apneli	Apnesiz
Referans Sonuçlar	Apneli	4500	2020
	Apnesiz	4582	5898

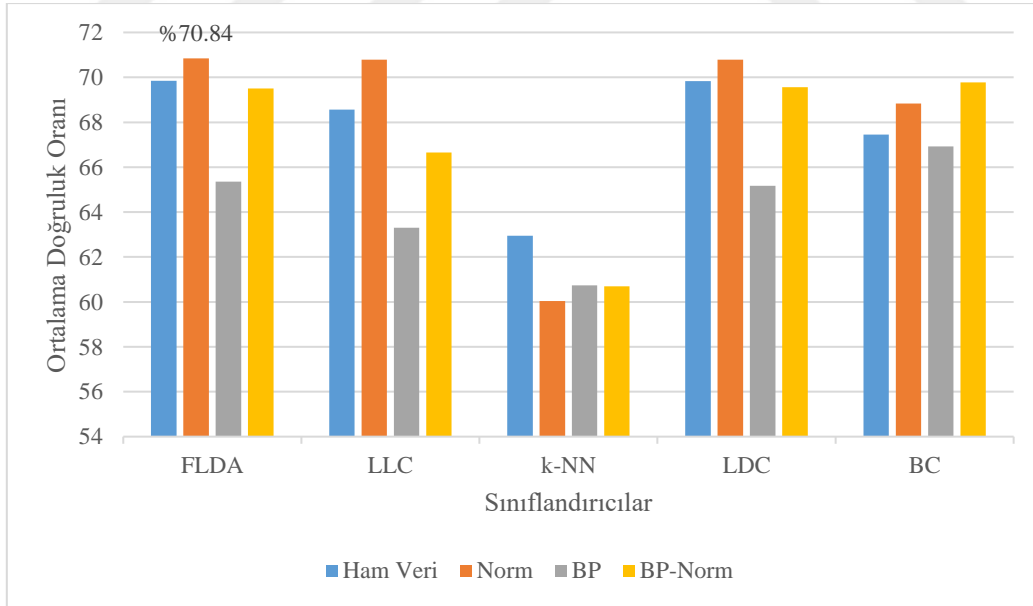
Maksimum doğruluk oranı tespit edilen LCP dalgacık düzlemi öznelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.18.'de gösterilmiştir.



Şekil 5.18. BP-Norm, LCP dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri kullanılarak BC sınıflandırıcısı ortalama doğruluk oranları

Şekil 5.18. incelendiğinde en yüksek performans %66,78 ile PCA yöntemi ile elde edilmektedir.

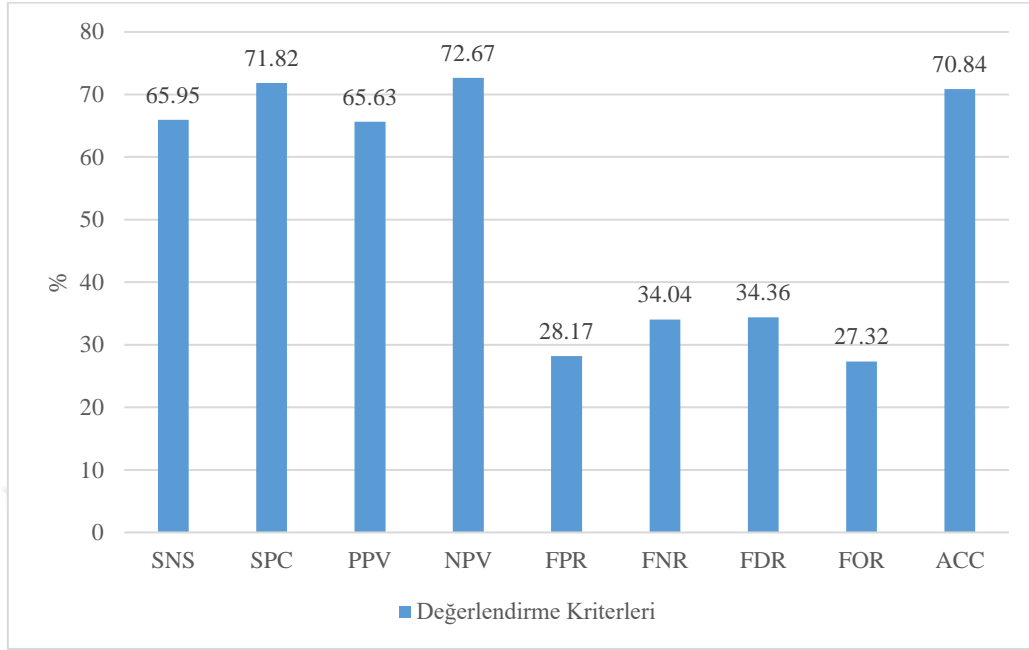
2-sınıflı teşhis çalışmasında hibrit özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.19.'da gösterilmektedir.



Şekil 5.19. Hibrit öznitelik çıkarımı yöntemi öznitelikleri kullanarak elde edilen ortalama doğruluk oranı

BP-Norm ön işleme yöntemi kullanılan hibrit öznitelikler kullanılan FLDA sınıflandırıcısı ile en yüksek doğruluk oranı, %70,84 olarak bulunmaktadır. En yüksek doğruluk

oranını elde edilen FLDA sınıflandırıcıya ait performans değerlendirme Şekil 5.20.'de, karmaşıklık matrisi Tablo 5.7.'de gösterilmektedir.




Şekil 5.20. Norm, Hibrit öznelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.7. Norm, Hibrit öznelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu	
		Apneli	Apnesiz
Referans Sonuçlar	Apneli	3451	3069
	Apnesiz	2718	7762

Maksimum doğruluk oranı tespit edilen hibrit öznelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.21.'de gösterilmiştir.




Şekil 5.21. Norm, hibrit öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları

Şekil 5.21. incelendiğinde en yüksek performans %65,72 ile PCA ve DCVA yöntemleri ile elde edilmektedir.


2-sınıflı teşhis çalışmaları performans sonuçları karşılaştırdığında en iyi sonuç HRV öznitelikleri kullanılarak BP-Norm önışleme ve FLDA sınıflandırıcı ile %72,29 doğruluk elde edilmiştir. Bu öznitelik PCA öznitelik seçimi boyut indirgendiğinde en yüksek doğruluk %67,00 olarak bulunmaktadır.

3-sınıflı teşhis çalışmasında dalgacık düzlemi öznitelikleri Bölüm 3’de anlatılan sınıflandırıcılar kullanılarak gerçekleştirilmiştir. Çalışmadan elde edilen ortalama doğruluk oranları Şekil 5.22.’de gösterilmektedir.



Şekil 5.22. Dalgacık düzlemi öznitelikleri kullanarak elde edilen ortalama doğruluk oranları

BP-Norm ön işleme yöntemi kullanılan dalgacık düzlemi öznitelikleri kullanılan LDC sınıflandırıcısı ile en yüksek doğruluk oranı, %62,21 bulunmaktadır. En yüksek doğruluk oranını elde edilen LDC sınıflandırıcısına ait performans değerlendirmesi Şekil 5.23.'de, karmaşıklık matrisi Tablo 5.8.'de gösterilmektedir.




Şekil 5.23. BP-Norm, Dalgacık düzlemi öznitelikleri LDC sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.8. BP-Norm, Dalgacık düzlemi öznitelikleri kullanılan LDC sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu		
		Hasta	Sınırda	Sağlıklı
Referans Sonuçlar	Hasta	6099	1399	2532
	Sınırda	1114	1185	1
	Sağlıklı	4501	22	157


Maksimum doğruluk oranı tespit edilen dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.24.'de gösterilmiştir.



Şekil 5.24. BP-Norm, Dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri kullanılarak LDC sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.24. incelendiğinde en yüksek performans %67,03 ile DCVA yöntemi ile elde edilmektedir.

3-sınıflı teşhis çalışmasında HRV öznitelikleri Bölüm 3’de anlatılan sınıflandırıcılar kullanılarak gerçekleştirilmiştir. Çalışmadan elde edilen ortalama doğruluk oranları Şekil 5.25.’de gösterilmektedir.



Şekil 5.25. HRV öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları

Norm ön işleme yöntemi kullanılan HRV öznitelikleri kullanılan LDC sınıflandırıcısı ile en yüksek doğruluk oranı, %68,67 olarak bulunmaktadır. En yüksek doğruluk oranını elde edilen LDC sınıflandırıcısına ait performans değerlendirmesi Şekil 5.26.’da, karmaşıklık matrisi Tablo 5.9.’da gösterilmektedir.




Şekil 5.26. Norm, HRV öznitelikleri LDC sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.9. Norm, HRV öznitelikleri kullanılan LDC sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu		
		Hasta	Sınırdaki	Sağlıklı
Referans Sonuçlar	Hasta	9965	65	0
	Sınırdaki	2163	137	0
	Sağlıklı	4666	12	2


Maksimum doğruluk oranı tespit edilen HRV öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.27.'de gösterilmiştir.



Şekil 5.27. Norm, HRV öznitelikleri boyut indirgeme yöntemleri kullanılarak LDC sınıflandırıcısı ortalama doğruluk oranları

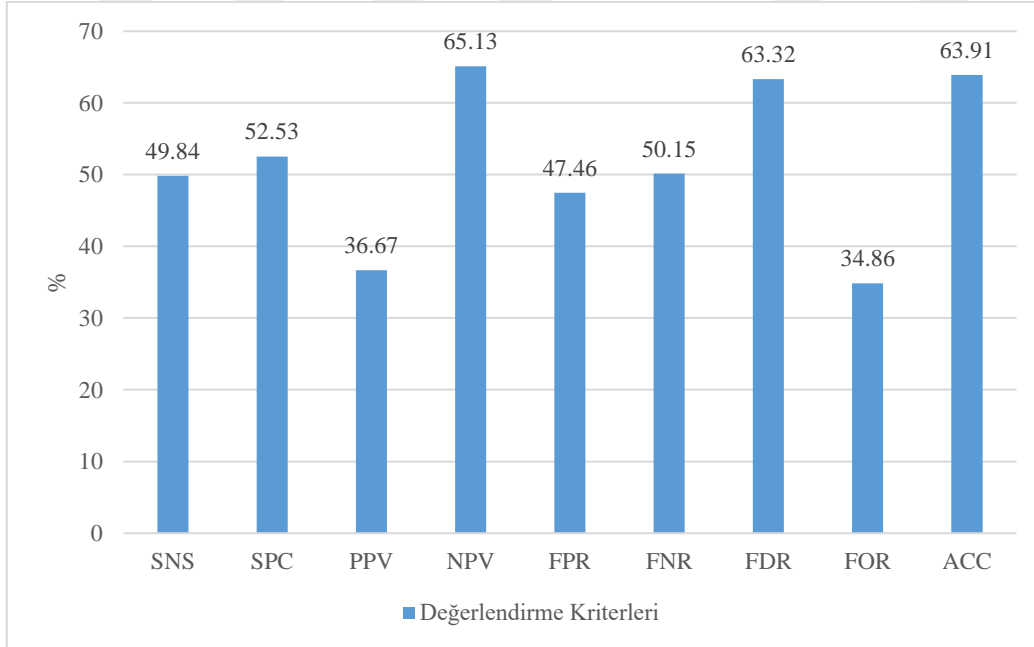
Şekil 5.27. incelendiğinde en yüksek performans %68,67 ile PCA yöntemi ile elde edilmektedir.

3-sınıflı teşhis çalışmasında LCP özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.28.'de gösterilmektedir.



Şekil 5.28. LCP öznelikleri kullanılarak elde edilen ortalama doğruluk oranları

BP-Norm ön işleme yöntemi kullanılan LCP öznelikleri kullanılan FLDA sınıflandırıcısı ile en yüksek doğruluk oranı, %63,91 olarak bulunmaktadır. En yüksek doğruluk oranını elde edilen FLDA sınıflandırıcısına ait performans değerlendirmesi Şekil 5.29.'da, karmaşıklık matrisi Tablo 5.10.'da gösterilmektedir.




Şekil 5.29. BP-Norm, LCP öznelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.10. BP-Norm, LCP öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu		
		Hasta	Sınırdaki	Sağlıklı
Referans Sonaçlar	Hasta	8215	208	1607
	Sınırdaki	2233	7	60
	Sağlıklı	4413	11	256

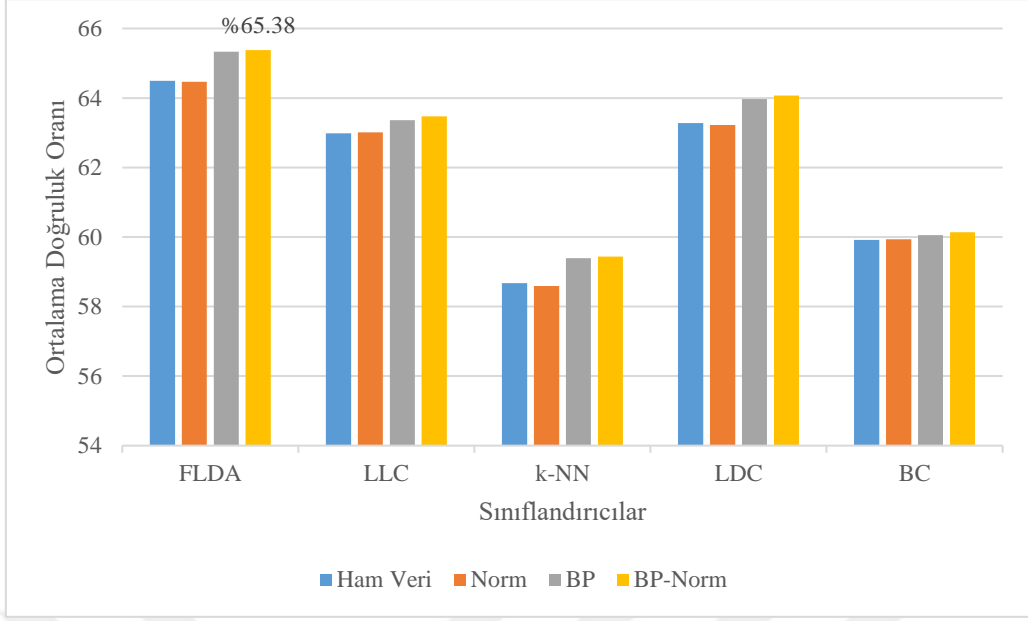
Maksimum doğruluk oranı tespit edilen LCP öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.30.'da gösterilmiştir.



Şekil 5.30. BP-Norm, LCP öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.30. incelendiğinde en yüksek performans %68,25 ile CVA yöntemi ile elde edilmektedir.

3-sınıflı teşhis çalışmasında LCP vektör özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.31.'de gösterilmektedir.



Şekil 5.31. LCP vektör öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları

BP-Norm ön işleme yöntemi kullanılan LCP vektör öznitelikleri kullanılan FLDA sınıflandırıcısı ile en yüksek doğruluk oranı, %65,38 olarak bulunmaktadır. En yüksek doğruluk oranını elde edilen FLDA sınıflandırıcısına ait performans değerlendirme Şekil 5.32.'de, karmaşıklık matrisi Tablo 5.11.'de gösterilmektedir.




Şekil 5.32. BP-Norm, LCP vektör öznitelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.11. BP-Norm, LCP vektör öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu		
		Hasta	Sınırdaki	Sağlıklı
Referans Sonuçlar	Hasta	8400	459	1171
	Sınırdaki	1853	405	42
	Sağlıklı	4579	34	67


Maksimum doğruluk oranı tespit edilen LCP vektör öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.33.'de gösterilmiştir.



Şekil 5.33. BP-Norm, LCP vektör öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.33. incelendiğinde en yüksek performans %68,51 ile DCVA yöntemi ile elde edilmektedir.

3-sınıflı teşhis çalışmasında LCP istatistiksel özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.34.'de gösterilmektedir.



Şekil 5.34. LCP istatistiksel öznitelikler kullanılarak elde edilen ortalama doğruluk oranları

BP ön işleme yöntemi kullanılan LCP istatistiksel öznitelikleri kullanılan BC sınıflandırıcısı ile en yüksek doğruluk oranı, %65,38 olarak bulunmaktadır. En yüksek doğruluk oranını elde edilen BC sınıflandırıcısına ait performans değerlendirmesi Şekil 5.35.'de, karmaşıklık matrisi Tablo 5.12.'de gösterilmektedir.

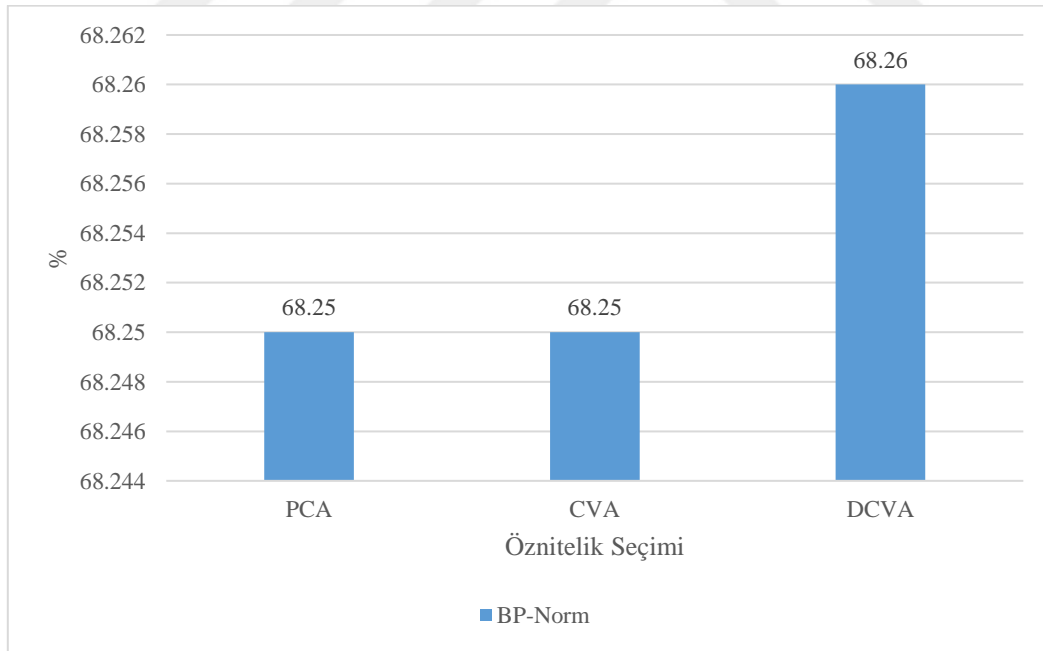


Şekil 5.35. BP, LCP istatistiksel öznitelikleri BC sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.12. BP, LCP istatistiksel öznitelikleri kullanılan BC sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu		
		Hasta	Sınırdaki	Sağlıklı
Referans Sonuçlar	Hasta	9269	550	201
	Sınırdaki	1897	353	50
	Sağlıklı	4377	280	13


Maksimum doğruluk oranı tespit edilen LCP istatistiksel öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.36.'da gösterilmiştir.



Şekil 5.36. BP, LCP istatistiksel öznitelikleri boyut indirgeme yöntemleri kullanılarak BC sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.36. incelendiğinde en yüksek performans %68,26 ile DCVA yöntemi ile elde edilmektedir.

3-sınıflı teşhis çalışmasında LCP dalgacık düzlemi özneliklerinden elde edilen ortalama doğruluk oranları Şekil 5.37.'de gösterilmektedir.



Şekil 5.37. LCP dalgacık düzlemi öznelikleri kullanılarak elde edilen ortalama doğruluk oranı

LCP dalgacık dönüşümü öznelik vektörleri kullanılarak gerçekleştirilen 3-sınıflı sınıflandırma çalışmasında en yüksek doğruluk oranı %65,06 BP ön işleme yöntemi kullanılarak sınıflandırıldığında elde edilmiştir. FLDA sınıflandırıcısı ile sınıflandırılmasına ait performans değerlendirmesi Şekil 5.38.'de, oluşturulan toplam karmaşıklık matrisi ise Tablo 5.13.'de verilmektedir.




Şekil 5.38. BP, LCP dalgacık düzlemi öznelikleri FLDA sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.13. BP, LCP dalgacık düzlemi öznitelikleri kullanılan FLDA sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu		
		Hasta	Sınırdaki	Sağlıklı
Referans Sonuçlar	Hasta	8796	373	861
	Sınırdaki	2298	1	11
	Sağlıklı	4551	29	110


Maksimum doğruluk oranı tespit edilen LCP dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.39.'da gösterilmiştir.



Şekil 5.39. BP, LCP dalgacık düzlemi öznitelikleri boyut indirgeme yöntemleri kullanılarak FLDA sınıflandırıcısı ortalama doğruluk oranları


Şekil 5.39. incelendiğinde en yüksek performans %68,20 ile CVA yöntemi ile elde edilmektedir.

3-sınıflı teşhis çalışmasında hibrit özniteliklerinden elde edilen ortalama doğruluk oranları Şekil 5.40.'da gösterilmektedir.



Şekil 5.40. Hibrit öznitelikleri kullanılarak elde edilen ortalama doğruluk oranları

Hibrit öznitelik çıkarımı yöntemi öznitelikleri kullanılarak gerçekleştirilen 3-sınıflı teşhis çalışmasında en yüksek doğruluk oranı %61,98 Norm ön işleme yöntemi kullanılarak sınıflandırıldığında elde edilmiştir. Bu öznitelik vektörlerinin çalışmada en başarılı olan LLC sınıflandırıcısı ile sınıflandırılmasına ait performans değerlendirmesi Şekil 5.41.'de, oluşturulan toplam karmaşıklık matrisi ise Tablo 5.14.'de verilmektedir.

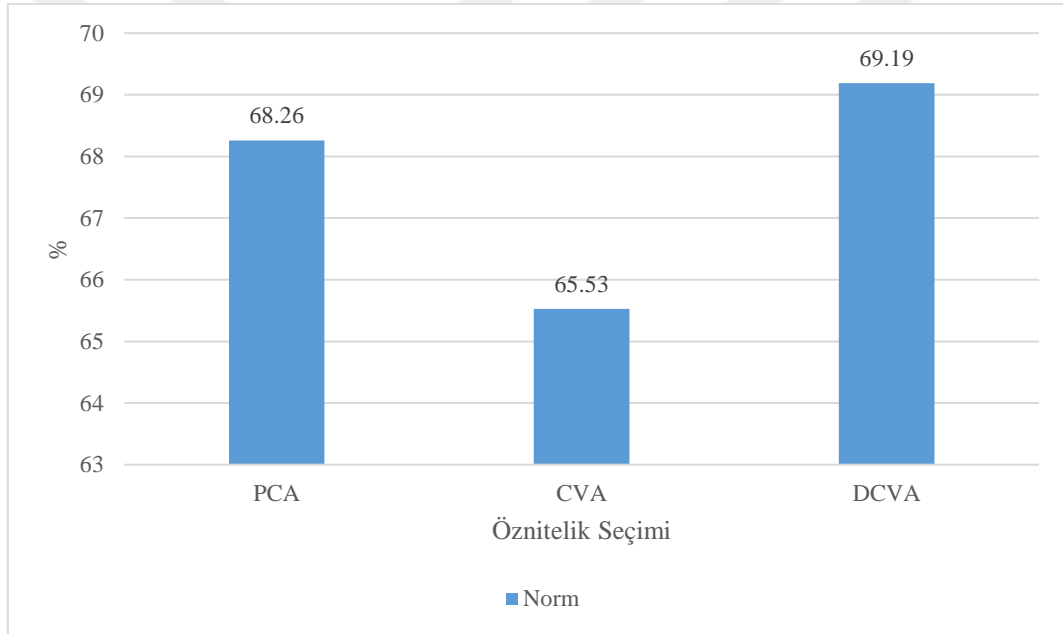


Şekil 5.41. Norm, hibrit öznitelikleri LLC sınıflandırıcısı performans değerlendirme kriterleri

Tablo 5.14. Norm, hibrit öznitelikleri kullanılan LLC sınıflandırıcısı karmaşıklık matrisleri

		Sınıflandırma Sonucu		
		Hasta	Sınırdaki	Sağlıklı
Referans Sonuçlar	Hasta	5445	1423	3152
	Sınırdaki	1179	964	157
	Sağlıklı	3880	104	686

Maksimum doğruluk oranı tespit edilen hibrit öznitelikleri boyut indirgeme yöntemleri kullanılarak elde edilen ortalama doğruluk oranları sırasıyla Şekil 5.42.'de gösterilmiştir.



Şekil 5.42. Norm, hibrit öznitelikleri boyut indirgeme yöntemleri kullanılarak LLC sınıflandırıcısı ortalama doğruluk oranları

Şekil 5.42. incelendiğinde en yüksek performans %69,19 ile DCVA yöntemi ile elde edilmektedir.

3-sınıflı teşhis çalışmaları performans sonuçları karşılaştırdığında en iyi sonuç HRV öznitelikleri kullanılarak Norm önileme ve LDC sınıflandırıcı ile %68,67 doğruluk elde edilmiştir. Bu öznitelik PCA öznitelik seçimi boyut indirgendiğinde en yüksek doğruluk %68,67 olarak bulunmaktadır.

6. SONUÇ

İnsan sağlığı açısından taşıdığı riskler nedeniyle uyku hastalıkları arasındaki en önemlilerinden biri olan SAS erken teşhis ile ölüm oranı azaltılabilmektedir. Türkiye’de uyku apnesi hastalarının %95-98 henüz tanı konulamadığı sanılmaktadır (Demir et vd., 2015: 300). SAS tanısında kabul gören PSG’den fizyolojik uyku evrelerini inceleyerek uyku kalitesini değerlendirmek ve uyku bozukluklarını teşhis etmede de yararlanılmaktadır. PSG kaydının yapılabilmesi için uyku laboratuvarlarına ve yetişmiş teknik elemanlara ihtiyaç duyulması, dünyada uyku laboratuvarlarının az olması nedeniyle uzun bekleme listelerinin oluşması, PSG kayıtların gece boyunca ve en az 7 saat süreyle yapılması, personelin ve cihazların tüm gece boyunca çalışmasından dolayı uyku testleri pahalı olmaktadır. Bu dezavantajlarından dolayı, SAS tanısında PSG dışında başka yöntemler araştırılmaktadır. Elektrofizyolojik işaretlerin, hastalıkların tanı ve teşhisinde işaret işleme, matematiksel yöntemler, modelleme yöntemleri ve sınıflandırma algoritmalarıyla kullanımıyla başarılı sonuçlar elde edildiği gözlemlenmektedir. Bu nedenlerden dolayı çalışmada kişilerin ev ortamında ve tek sinyale ile SAS teşhisi koyulması amaçlanmaktadır. Bu sinyallerden biri olan ECG sinyali, kalbin aktivitelerini elektriksel olarak temsil etmektedir (Sharma ve Sharma, 2016: 118). Sürekli değişim içinde olan ECG periyodu, P-QRS-T dalga parçacıklarından oluşmakta ve RR arasındaki boyut ve şekilce değişiklikler göstermektedir. Bu bilgiler ışığında ECG sinyalindeki değişimler kullanılarak hastaların sağlık durumları, hastalığın tanısı hakkında bilgi edinmede kullanışlı olabileceği görülmektedir.

Bu tez çalışmasında, uyku apnesi tanısı, bir CAD sistemi önerilmiştir. Önerilen CAD sistemi literatürde kabul görmüş PhysioNet Apnea-ECG veri tabanı kullanılarak gerçekleştirilmiştir. Önerilen sisteminde ilk olarak, sinyallerin RR aralıkları düzeltilmiş ve 1 dk’lık bölütlere ayrılarak belirlenmiştir. z-skor normalizasyon ve butterworth bant geçiren filtre ile ön işleme yapılmaktadır. Öznitelik çıkarımı aşamasında, ön işlenmiş sinyallere db6 dalgacığı ile dalgacık dönüşümü, istatistiksel yöntemler ve 1-boyutlu LCP dönüşümü uygulanmıştır. Ayrıca db1 dalgacığı ile uygulanan sinyallerden 1-boyutlu LCP vektörleri, LCP istatistiksel öznitelikleri, LCP dalgacık dönüşümü öznitelikleri ve bunların birleşiminden oluşturulmuş 60x1 boyutlu hibrit öznitelikleri elde edilmiştir. Öznitelik seçimi aşamasında PCA, CVA ve DCVA yöntemleri kullanılmaktadır. Uyku apnesi tanısı için elde edilen öznitelik kümeleri, FLDA, LLC, LDC, k-NN (k=10) ve BC sınıflandırıcıları kullanılarak sınıflandırılması ile gerçekleştirilmiştir.

Sınıflandırma sonuçları karşılaştırılarak, 2-sınıflı teşhis çalışmasında BP-Norm ön işleme yöntemi kullanılan HRV öznitelikleri kullanılarak maksimum %72,29, HRV özniteliklerinin PCA yöntemi ile boyut indirilmesi yapıldıktan sonra %67,00 doğruluk sağlandığı tespit edilmiştir. Öznitelik seçimi yapıldığında daha düşük bir doğruluk oranı tespit edilmiştir. HRV özniteliklerinin PCA yöntemi ile boyut indirilmesi yapıldığında sınıflandırma süresi 0,14 dakika tespit edilmiştir. Öznitelik seçimi uygulanmadığında HRV özniteliklerinin sınıflandırma süreleri 0,18 dakika olarak bulunmuştur. Sınıflandırma sürelerinin boyut indirilmesi yapıldığında kısaldığı görülmektedir. Eş zamanlı uygulama çalışmalarında sınıflandırma süreleri de önemli olduğundan öznitelik seçimi yöntemleri kullanılmaktadır. Bu yöntemler kullanıldığında daha hızlı teşhis yapılmaktadır.

3-sınıflı teşhis çalışması sonuçları incelendiğinde norm ön işleme yapılan, HRV öznitelikleri kullanılarak maksimum %68,67, HRV özniteliklerinin PCA yöntemi ile boyut indirilmesi yapıldıktan sonra %68,67 doğruluk sağlandığı tespit edilmiştir. Elde edilen sonuçlar incelendiğinde PCA ile boyut indirilmesi yapıldığında daha yüksek bir doğruluk oranı bulunmadığı görülmektedir. HRV özniteliklerinin PCA yöntemi ile boyut indirilmesi yapıldığında sınıflandırma süresi 0,38 dakika tespit edilmiştir. Öznitelik seçimi uygulanmadığında HRV özniteliklerinin sınıflandırma süreleri 0,43 dakika olarak bulunmuştur. Boyut indirilmesi yapıldığında daha kısa sürede sınıflandırma yapılmaktadır.

3-sınıflı teşhis çalışması sonuçları incelendiğinde öznitelik yöntemleri kullanıldığında maksimum doğruluk oranı, norm ön işleme yapılan hibrit özniteliklerinin DCVA yöntemi ile boyut indirilmesi yapıldıktan sonra maksimum %69,19 tespit edilmiştir. Hibrit öznitelikleri kullanılarak maksimum %61,98 doğruluk elde edilmiştir. Elde edilen sonuçlar incelendiğinde boyut indirilmesi yapıldığında daha yüksek doğruluk elde edildiği görülmektedir. Hibrit özniteliklerinin DCVA yöntemi ile boyut indirilmesi yapıldığında sınıflandırma süresi 0,88 dakika tespit edilmiştir. Öznitelik seçimi uygulanmadığında hibrit özniteliklerinin sınıflandırma süreleri 3,37 dakika olarak bulunmuştur. Boyut indirilmesi yapıldığında daha kısa sürede sınıflandırma yapılmadığı görülmektedir.

Bulgular incelendiğinde 2-sınıflı teşhis çalışmasında BP-norm ön işleme yöntemi, 3-sınıflı teşhis çalışmasında norm ön işleme yöntemi uygulanan veri kümesinden daha yüksek doğruluk oranı elde edildiği görülmektedir. 2-sınıflı teşhis çalışmasında FLDA sınıflandırıcı 3-sınıflı teşhis çalışmasında LLC sınıflandırıcı ile maksimum doğruluk oranı elde edildiği görülmektedir.

Tez çalışması değerlendirildiğinde, öznelik seçimi yöntemlerinin sınıflandırma sürelerini kısalttığı görülmüştür. İlerleyen dönemlerde, uyku apnesi teşhisinde apneli ve apnesiz sınıfları arasında ayırt edici özneliklerin bulunması ile sınıflandırma başarısının yükseltilebileceği ve daha başarılı sonuçlar elde edilebileceği düşünülmektedir.



KAYNAKÇA

- Al-ani, T., Karmakar, C. K., Khandoker, A. H., & Palaniswami, M.** (2008). Automatic Recognition of Obstructive Sleep Apnoea Syndrome Using Power Spectral Analysis of Electrocardiogram and Hidden Markov Models, *In 2008 International Conference on Intelligent Sensors, Sensor Networks and Information Processing*, 285–290.
- Almutairi, H., Hassan, G. M., & Datta, A.** (2021). Detection of obstructive sleep apnoea by ECG signals using deep learning architectures, *In European Signal Processing Conference*, 1382–1386.
- Altman, N. S.** (1992). An introduction to kernel and nearest-neighbor nonparametric regression, *American Statistician*, 46(3), 175–185.
- Alvarez-Estevez, D., & Moret-Bonillo, V.** (2016). Spectral Heart Rate Variability analysis using the heart timing signal for the screening of the Sleep Apnea–Hypopnea Syndrome, *Computers in Biology and Medicine*, 71, 14–23.
- Álvarez-Estévez, D., & Moret-Bonillo, V.** (2009). Fuzzy reasoning used to detect apneic events in the sleep apnea-hypopnea syndrome, *Expert Systems with Applications*, 36(4), 7778–7785.
- Alvarez, D., Gutierrez-Tobal, G. C., Vaquerizo-Villar, F., Barroso-Garcia, V., Crespo, A., Arroyo, C. A., ... Hornero, R.** (2016). Automated analysis of unattended portable oximetry by means of Bayesian neural networks to assist in the diagnosis of sleep apnea, *In 2016 Global Medical Engineering Physics Exchanges/Pan American Health Care Exchanges (GMEPE/PAHCE)*, 1–4.
- Álvarez, D., Hornero, R., Abásolo, D., Campo, F. del, & Zamarrón, C.** (2006). Nonlinear characteristics of blood oxygen saturation from nocturnal oximetry for obstructive sleep apnoea detection, *Physiological Measurement*, 27(4), 399–412.
- Arslan, E.,** (2020). Mikroşerit alçak geçiren filtre tasarımı ve analizi, (Yüksek Lisans Tezi). Ankara Üniversitesi, Fen Bilimleri Üniversitesi, Ankara.
- Apne-ECG Veritabanı 1.0.0** (2021). [Erişim: 26.04.2021, <https://physionet.org/content/apnea-ecg/1.0.0/additional-information.txt>]
- Antonogeorgos, G., Panagiotakos, D. B., Priftis, K. N., & Tzonou, A.** (2009). Logistic Regression and Linear Discriminant Analyses in Evaluating Factors Associated with Asthma Prevalence among 10- to 12-Years-Old Children: Divergence and Similarity of

- the Two Statistical Methods, *International Journal of Pediatrics*, 1–6.
- Bailey, D. R., & Attanasio, R.** (2012). The History of Sleep Medicine. *Dental Clinics of North America*, 313-494.
- Berrar, D.** (2018). *Cross-validation*. In *Encyclopedia of Bioinformatics and Computational Biolog, ABC of Bioinformatics*, 542–545.
- Bixler, E. O., V, Gontzas, A. N., Lin, H.-M., Ten, T., Rein, J., Vela-Bueno, A., & Kales, A.** (2001). Prevalence of Sleep-disordered Breathing in Women, *American Journal of Respiratory and Critical Care Medicine*, 163(3), 608–613.
- Boostani, R., Karimzadeh, F., & Nami, M.** (2017). A comparative review on sleep stage classification methods in patients and healthy individuals, *Computer Methods and Programs in Biomedicine*, 77-91.
- Bozkurt, F., Uçar, M. K., Bozkurt, M. R., & Bilgin, C.** (2020). Detection of Abnormal Respiratory Events with Single Channel ECG and Hybrid Machine Learning Model in Patients with Obstructive Sleep Apnea, *IRBM*, 41(5), 241–251.
- Cabrero-Canosa, M., Castro-Pereiro, M., Graña-Ramos, M., Hernandez-Pereira, E., Moret-Bonillo, V., Martin-Egaña, M., & Vereza-Hernando, H.** (2003). An intelligent system for the detection and interpretation of sleep apneas, *Expert Systems with Applications*, 24(4), 335–349.
- Caseiro, P., Fonseca-Pinto, R., & Andrade, A.** (2010). Screening of obstructive sleep apnea using Hilbert–Huang decomposition of oronasal airway pressure recordings, *Medical Engineering & Physics*, 32(6), 561–568.
- Cevikalp, H., Neamtu, M., Wilkes, M., & Barkana, A.** (2005). Discriminative common vectors for face recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(1), 4–13.
- Chokroverty, S., Bhatt, M., & Goldhammer, T.** (2005). Polysomnographic Recording Technique, In *Atlas of Sleep Medicine*, 1–28.
- Cohen, G., & de Chazal, P.** (2015). Automated detection of sleep apnea in infants: A multi-modal approach, *Computers in Biology and Medicine*, 63, 118–123.
- Da Silva Pinho, A. M., Pombo, N., & Garcia, N. M.** (2016). Sleep apnea detection using a feed-forward neural network on ECG signal. In *2016 IEEE 18th International Conference*

on e-Health Networking, Applications and Services, *Healthcom 2016*, 1–6.

- Dai, H., Mei, Z., An, A., & Wu, J. (2019).** Association between sleep problems and health-related quality of life in Canadian adults with chronic diseases, *Sleep Medicine*, *61*, 26–30.
- Demir, A. U., Ardiç, S., Firat, H., Karadeniz, D., Aksu, M., Ucar, Z. Z., Bulbul, Y. (2015).** Prevalence of sleep disorders in the Turkish adult population epidemiology of sleep study, *Sleep and Biological Rhythms*, *13*(4), 298–308.
- ECG Interpretation Characteristics of the Normal ECG (P-Wave, QRS Complex, ST Segment, T-Wave).** (2021). [Erişim: 21.03.2021, <https://ecgwaves.com/topic/ecg-normal-p-wave-qrs-complex-st-segment-t-wave-j-point/>]
- Emin Tagluk, M., Akin, M., & Sezgin, N. (2010).** Classification of sleep apnea by using wavelet transform and artificial neural networks, *Expert Systems with Applications*, *37*(2), 1600–1607.
- Emin Tagluk, M., & Sezgin, N. (2011).** A new approach for estimation of obstructive sleep apnea syndrome, *Expert Systems with Applications*, *38*(5), 5346–5351.
- Faust, O., Barika, R., Shenfield, A., Ciaccio, E. J., & Acharya, U. R. (2021).** Accurate detection of sleep apnea with long short-term memory network based on RR interval signals, *Knowledge-Based Systems*, *212*, 992-1007.
- Flemons, W. W., & McNicholas, W. T. (1997).** Clinical prediction of the sleep apnea syndrome. *Sleep Medicine Reviews*, *1*(1), 19–32.
- Fisher, R. A. (1936).** The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, *7*(2), 179–188.
- Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Stanley, H. E. (2000).** PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, *101*(23), 215-220.
- Guijarro-Berdiñas, B., Hernández-Pereira, E., & Peteiro-Barral, D. (2012).** A mixture of experts for classifying sleep apneas. *Expert Systems with Applications*, *39*(8), 7084–7092.
- Guo, Y., Zhao, G., & Pietikäinen, M. (2011).** Texture Classification using a Linear Configuration Model based Descriptor, *BMVC*, 1-10.
- Gülmezoğlu, B. M. (1999).** A Novel Approach to Isolated Word Recognition, *IEEE*

Transactions on Speech and Audio Processing, 7(6), 620–627.

Gülmezoğlu, B. M., M., Dzhafarov, V., & Barkana, A. (2001). The common vector approach and its relation to principal component analysis, *IEEE Transactions on Speech and Audio Processing*, 9(6), 655–662.

Gülmezoğlu, B. M., M., Dzhafarov, V., Edizkan, R., & Barkana, A. (2007). The common vector approach and its comparison with other subspace methods in case of sufficient data, *Computer Speech and Language*, 21(2), 266–281.

Gürüler, H. (2013). ECG işaretlerinden YSA ve korelasyon matrislerine dayalı tıkaçıcı uyku apnesi teşhisi. (Doktora Tezi). Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.

Hassan, A. R. (2016). Computer-aided obstructive sleep apnea detection using normal inverse Gaussian parameters and adaptive boosting. *Biomedical Signal Processing and Control*, 29, 22–30.

Hassan, A. R., & Haque, M. A. (2016). Computer-aided obstructive sleep apnea screening from single-lead electrocardiogram using statistical and spectral features and bootstrap aggregating, *Biocybernetics and Biomedical Engineering*, 36(1), 256–266.

Huang, W., Guo, B., Shen, Y., & Tang, X. (2017). A novel method to precisely detect apnea and hypopnea events by airflow and oximetry signals. *Computers in Biology and Medicine*, 88, 32–40.

Işıklı Esener, İ. (2012). *Akıllı sistemler kullanılarak güç sistemlerinde yük tahmini analizi ve uygulaması*. (Yüksek Lisans Tezi). Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik.

Işıklı Esener, İ. (2017). *Meme Kanseri için Şüpheli Bölgelerin Mamografi İmgeleri Üzerinde Belirlenmesi ve Meme Kanseri Türünün Sınıflandırılması*. (Doktora Tezi). Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.

Jafari, A. (2013). Sleep apnoea detection from ECG using features extracted from reconstructed phase space and frequency domain. *Biomedical Signal Processing and Control*, 8(6), 551–558.

Janbakhshi, P., & Shamsollahi, M. B. (2018). Sleep Apnea Detection from Single-Lead ECG Using Features Based on ECG-Derived Respiration (EDR) Signals. *IRBM*, 39(3), 206–218.

- Joseph, T.**, (2021). *Ana Bileşen Analizini Anlama*. [Erişim: 15.03.2021, <https://ichi.pro/tr/ana-bilesen-analizini-anlama-243744578876986>]
- Jung, D. W., Hwang, S. H., Cho, J. G., Choi, B. H., Baek, H. J., Lee, Y. J., Park, K. S.** (2018). Real-Time Automatic Apneic Event Detection Using Nocturnal Pulse Oximetry. *IEEE Transactions on Biomedical Engineering*, 65(3), 706–712.
- Kandala, N.V.P.S.R., Ravindra, D., Kumar, S, T.**, (2020). Obstructive sleep apnea detection using discrete wavelet transform-based statistical features, *Computers in Biology and Medicine*,130, 1-10.
- Kaplan Berkaya, S., Uysal, A. K., Sora Gunal, E., Ergin, S., Gunal, S., & Gulmezoglu, M. B.** (2018). A survey on ECG analysis. *Biomedical Signal Processing and Control*, Biomedical Signal Processing and Control, 43, 216-235.
- Karunajeewa, A. S., Abeyratne, U. R., & Hukins, C.** (2011). Multi-feature snore sound analysis in obstructive sleep apnea–hypopnea syndrome. *Physiological Measurement*, 32(1), 83–97.
- Khandoker, A. H., Karmakar, C. K., & Palaniswami, M.** (2009). Automated recognition of patients with obstructive sleep apnoea using wavelet-based features of electrocardiogram recordings. *Computers in Biology and Medicine*, 39(1), 88–96.
- Koley, B., & Dey, D.** (2012). Automated detection of apnea and hypopnea events. In *2012 Third International Conference on Emerging Applications of Information Technology*, 85–88.
- Koley, B. L., & Dey, D.** (2013). Automatic detection of sleep apnea and hypopnea events from single channel measurement of respiration signal employing ensemble binary SVM classifiers. *Measurement*, 46(7), 2082–2092.
- Le Bon, O.** (2020). Relationships between REM and NREM in the NREM-REM sleep cycle: a review on competing concepts. *Sleep Medicine*, 6-16.
- Li, K., Pan, W., Li, Y., Jiang, Q., & Liu, G.** (2018). A method to detect sleep apnea based on deep neural network and hidden Markov model using single-lead ECG signal. *Neurocomputing*, 294, 94–101.
- Liguori, C., Palmieri, M. G., Pierantozzi, M., Cesareo, M., Romigi, A., Izzi, F., Placidi, F.** (2016). Optic Nerve Dysfunction in Obstructive Sleep Apnea: An Electrophysiological Study. *Sleep*, 39(1), 19–23.

- Maali, Y., & Al-Jumaily, A.** (2013). Multi Neural Networks Investigation based Sleep Apnea Prediction. *Procedia Computer Science*, 24, 97–102.
- Marcos, J. V., Hornero, R., Álvarez, D., del Campo, F., & Zamarrón, C.** (2009). Assessment of four statistical pattern recognition techniques to assist in obstructive sleep apnoea diagnosis from nocturnal oximetry, *Medical Engineering & Physics*, 31(8), 971–978.
- Marcos, J. V., Hornero, R., Álvarez, D., del Campo, F., Zamarrón, C., & López, M.** (2008). Utility of multilayer perceptron neural network classifiers in the diagnosis of the obstructive sleep apnoea syndrome from nocturnal oximetry, *Computer Methods and Programs in Biomedicine*, 92(1), 79–89.
- Martín-González, S., Navarro-Mesa, J. L., Juliá-Serdá, G., Kraemer, J. F., Wessel, N., & Ravelo-García, A. G.** (2017). Heart rate variability feature selection in the presence of sleep apnea: An expert system for the characterization and detection of the disorder, *Computers in Biology and Medicine*, 91, 47–58.
- Martínez-Vargas, J. D., Sepulveda-Cano, L. M., Travieso-Gonzalez, C., & Castellanos-Dominguez, G.** (2012). Detection of obstructive sleep apnoea using dynamic filter-banked features. *Expert Systems with Applications*, 39(10), 9118–9128.
- Mcleod, S.** (2019). *Z-Score: Definition, Calculation and Interpretation What is a z-score?*. [Erişim: 15.02.2021, <https://www.simplypsychology.org/zscore.html#:~:text=A%20z%2Dscore%20describes%20the,it%20lies%20below%20the%20mean.>]
- Mendez, M. O., Bianchi, A. M., Matteucci, M., Cerutti, S., & Penzel, T.** (2009). Sleep Apnea Screening by Autoregressive Models From a Single ECG Lead. *IEEE Transactions on Biomedical Engineering*, 56(12), 2838–2850.
- Montero Benavides, A., Fernández Pozo, R., Toledano, D. T., Blanco Murillo, J. L., López Gonzalo, E., & Hernández Gómez, L.** (2014). Analysis of voice features related to obstructive sleep apnoea and their application in diagnosis support. *Computer Speech & Language*, 28(2), 434–452.
- Morales, J. F., Varon, C., Deviaene, M., Borzee, P., Testelmans, D., Buyse, B., & van Huffel, S.** (2017). Sleep Apnea Hypopnea Syndrome classification in SpO₂ signals using wavelet decomposition and phase space reconstruction. In *2017 IEEE 14th International Conference on Wearable and Implantable Body Sensor Networks (BSN)*, 43–46.

- Mostafa, S. S., Mendonça, F., Morgado-Dias, F., Ravelo-García, A.,** (2017). SpO₂ based sleep apnea detection using deep learning, *NES 2017 - IEEE 21st International Conference on Intelligent Engineering Systems, Proceedings*, 91-96.
- Nieto, F. J., Young, T. B., Lind, B. K., Shahar, E., Samet, J. M., Redline, S., D'Agostino, R. B.,** (2000). Association of Sleep-Disordered Breathing, Sleep Apnea, and Hypertension in a Large Community-Based Study, *JAMA*, 283(14), 1829-1836.
- Özdemir, G., Nasifoğlu, H., & Erogül, O.** (2016). A Time-Series Approach to Predict Obstructive Sleep Apnea (OSA), *Konferansı: The 2nd World Congress on Electrical Engineering and Computer Systems and Science*, 117-128
- Partinen, M.** (2011). Epidemiology of sleep disorders, *Handbook of Clinical Neurology*, 98, 275–314.
- Peker, O.,** (2018). Zaman gecikmeli yapay sinir ağları tabanlı apne tespiti ve karşılaştırmalı analizi. (Yüksek Lisans Tezi). Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Penzel, T., Moody, G. B., Mark, R. G., Goldberger, A. L., & Peter, J. H.** (2000). The apnea-ECG database, In *Computers in Cardiology 2000. Vol.27*, 255–258.
- Pombo, N., Silva, B. M. C., Pinho, A. M., & Garcia, N.** (2020). Classifier Precision Analysis for Sleep Apnea Detection Using ECG Signals, *IEEE Access*, 8, 200477–200485.
- Praydas, T., Wongkittisuksa, B., & Tanthanuch, S.** (n.d.). Obstructive Sleep Apnea Severity Multiclass Classification Using Analysis of Snoring Sounds, *Konferansı: 2nd World Congress on Electrical Engineering and Computer Systems and Science (EECSS'16)*, 142 1-5.
- Rajesh, K. N. V. P. S., Dhuli, R., & Kumar, T. S.** (2021). Obstructive sleep apnea detection using discrete wavelet transform-based statistical features, *Computers in Biology and Medicine*, 130, 1-11.
- Ranganathan, S., Gribskov, M., Nakai, K., Schönbach, C.** (2019). Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics, *Nazabayev University, School of Science and Technology, Department of Science and Technology*, 1-1004, Bayes Theorem and Naive Bayes Classifier, 403-413.
- Ravelo-García, AG** (2018). *APNEA HRV DATASET* [Veri kümesi]. Mendeley. [Erişim: 18.02.2020 <https://doi.org/10.17632/VV6WDPBRSH.1>]

- Razi, A. P., Einalou, Z., & Manthouri, M.** (2021). Sleep Apnea Classification Using Random Forest via ECG. *Sleep and Vigilance*, 1–6.
- Ríos, S. A., & Erazo, L.** (2016). An automatic apnea screening algorithm for children. *Expert Systems with Applications*, 48, 42–54.
- Rolón, R. E., Larrateguy, L. D., Di Persia, L. E., Spies, R. D., & Rufiner, H. L.** (2017). Discriminative methods based on sparse representations of pulse oximetry signals for sleep apnea–hypopnea detection. *Biomedical Signal Processing and Control*, 33, 358–367.
- Sánchez-Morillo, D., López-Gordo, M. A., & León, A.** (2014). Novel multiclass classification for home-based diagnosis of sleep apnea hypopnea syndrome. *Expert Systems with Applications*, 41(4), 1654–1662.
- Sateia, M. J.** (2014). International Classification of Sleep Disorders-Third Edition Highlights and Modifications. *Chest*, 146, 1387–1394.
- Sezgin, N., & Emin Tagluk, M.** (2009). Energy based feature extraction for classification of sleep apnea syndrome. *Computers in Biology and Medicine*, 39(11), 1043–1050.
- Sharma, H., & Sharma, K. K.** (2016). An algorithm for sleep apnea detection from single-lead ECG using Hermite basis functions, *Computers in Biology and Medicine*, 77, 116–124.
- Sharma, M., Agarwal, S., & Acharya, U. R.** (2018). Application of an optimal class of antisymmetric wavelet filter banks for obstructive sleep apnea diagnosis using ECG signals. *Computers in Biology and Medicine*, 100, 100–113.
- Tabak, Z.** (2015). Kalp ve solunum seslerinden uyku apnesi tespitinin yapılabilirliğinin incelenmesi. (Yüksek Lisans Tezi). Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Tripathy, R. K.** (2018). Application of intrinsic band function technique for automated detection of sleep apnea using HRV and EDR signals, *Biocybernetics and Biomedical Engineering*, 38(1), 136–144.
- Troxel, W. M., Buysse, D. J., Matthews, K. A., Kip, K. E., Strollo, P. J., Hall, M., Reis, S. E.** (2010). Sleep Symptoms Predict the Development of the Metabolic Syndrome, *Sleep*, 33(12), 1633–1640.
- Tuncer, T., & Aydemir, E.** (2020). An Automated Local Binary Pattern Ship Identification Method by Using Sound Ses Kullanarak Otomatik Yerel İkili Model Yöntemi ile Gemi

Tanımlama, *Acta Infologica*, 4(1), 57–63.

Übeyli, E. D., Cvetkovic, D., Holland, G., & Cosic, I. (2010). Analysis of sleep EEG activity during hypopnoea episodes by least squares support vector machine employing AR coefficients. *Expert Systems with Applications*, 37(6), 4463–4467.

Ünverdi, E., Yildiz, B. A., (2012). Butterworth Yüksek Geçiren Filtre Devresinin Kontrol edilebilir Kanonik Formda Tasarlanması ve Gerçeklenmesi, *ELECO '2012 Elektrik - Elektronik ve Bilgisayar Mühendisliği Sempozyumu*, 271-275.

Wang, P.-C., Su, C.-T., Chen, K.-H., & Chen, N.-H. (2011). The application of rough set and Mahalanobis distance to enhance the quality of OSA diagnosis. *Expert Systems with Applications*, 38(6), 7828–7836.

Yıldız, A., Akın, M., & Poyraz, M. (2011). An expert system for automated recognition of patients with obstructive sleep apnea using electrocardiogram recordings. *Expert Systems with Applications*, 38(10), 12880–12890.

Young, T., Palta, M., Dempsey, J., Skatrud, J., Weber, S., & Badr, S. (1993). The Occurrence of Sleep-Disordered Breathing among Middle-Aged Adults. *New England Journal of Medicine*, 328(17), 1230–1235.

Yörük, A., (2019). Uyku apnesinde EEG verilerinin spektral analizi. (Yüksek Lisans Tezi). Kütahya Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya.

Zhang, G. Q., Cui, L., Mueller, R., Tao, S., Kim, M., Rueschman, M. Redline, S. (2018). The National Sleep Research Resource: Towards a sleep data commons, *Journal of the American Medical Informatics Association*, 25(10), 1351–1358.