

**T.C.**  
**KASTAMONU ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**BİYOMEDİKAL MÜHENDİSLİĞİ ANA BİLİM DALI**



**EKG SİNYALLERİNDEN YAPAY ZEKA YÖNTEMLERİ**  
**KULLANILARAK UYKU APNESİ TEŞHİSİNİN YAPILMASI**

**BAHAR NAZLI**

**YÜKSEK LİSANS TEZİ**

**DR. ÖĞR. ÜYESİ HAYRİYE ALTURAL ÖZKAN**

**TEMMUZ - 2021**

**KASTAMONU**

## TEZ ONAYI

**Bahar NAZLI** tarafından hazırlanan “**EKG Sinyallerinden Yapay Zeka Yöntemleri Kullanılarak Uyku Apnesi Teşhisinin Yapılması**” adlı tez çalışmasının savunma sınavı **07.07.2021** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Biyomedikal Mühendisliği Ana Bilim Dalı Yüksek Lisans Tezi** olarak kabul edilmiştir.

<b>Danışman</b>	Dr. Öğr. Üyesi Hayriye ALTURAL ÖZKAN .....
	Kastamonu Üniversitesi
<b>Jüri Üyesi</b>	Dr. Öğr. Üyesi Seda ŞAHİN .....
	Çankırı Karatekin Üniversitesi
<b>Jüri Üyesi</b>	Doç. Dr. M. Serdar ÇAVUŞ .....
	Kastamonu Üniversitesi

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitü Müdürü	Prof. Dr. İzzet ŞENER .....
----------------	-----------------------------

## TAAHHÜTNAME

*Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranıř ve akademik kurallar çerçevesinde elde edilerek sunulduđunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalıřmada bana ait olmayan her türlü ifade ve bilginin kaynađına eksiksiz atıf yapıldıđını, bilimsel etiđe uygun olarak kaynak gösterildiđini bildirir ve taahhüt ederim.*

**Bahar NAZLI**

## ÖZET

### YÜKSEK LİSANS TEZİ

## EKG SİNYALLERİNDEN YAPAY ZEKA YÖNTEMLERİ KULLANILARAK UYKU APNESİ TEŞHİSİNİN YAPILMASI

BAHAR NAZLI

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ  
BİYOMEDİKAL MÜHENDİSLİĞİ ANA BİLİM DALI

DANIŞMAN:DR. ÖĞR. ÜYESİ HAYRIYE ALTURAL ÖZKAN

Uyku, canlıların dış uyaranlara karşı minimum seviyede tepki verdiği veya tepki vermediği tekrarlanan bir durumdur. Kronik uykusuzluk, yeme bozuklukları, huzursuz bacak sendromu ve uyku apnesi gibi rahatsızlıklar uyku kalitesini etkileyen ve ciddi sorunlara yol açan hastalıklar arasındadır. Üst solunum yollarının daralması veya tıkanması sonucunda solunumun 10 sn veya daha uzun süre boyunca tekrarlayan ataklarla durması sendromuna uyku apnesi denilmektedir ve en yaygın olanı Obstrüktif Uyku Apnesidir (OUA). Bu tez çalışması kapsamında EKG sinyalleri üzerinden makine öğrenmesi ve derin öğrenme algoritmaları kullanarak uyku apnesi tespiti yapılmıştır. İlk aşamada EKG sinyali bölütlere ayrılarak R tepe noktaları belirlenmiş ve her bir bölütün uyku apnesi olup olmadığı sınıflandırılmıştır. İkinci aşamada ise bölütlere dayalı sınıflandırma yapılan 35 EKG kaydının her birinin OUA hastası olup olmadığı sınıflandırılmıştır. Makine öğrenmesi algoritmaları olarak yedi farklı sınıflandırıcı, derin öğrenme algoritması olarak üç farklı sınıflandırıcı kullanılmıştır. Bölütlere dayalı sınıflandırmada Evrişimsel Sinir Ağı (CNN) algoritması % 89,11 doğruluk; % 94,31 hassasiyet; % 80,72 seçicilik; 0,89 F1 Puanı ve 0,87 AUC değerleri ile en yüksek sonucu veren algoritma olmuştur. Her bir kaydın Apne - Hipopne İndeksine göre yapılan OUA ve normal sınıflandırması sonuçlarında CNN mimarisi %97,14 doğruluk; %100 seçicilik; %95,65 hassasiyet; 0,97 F1 puanı ve 0,98 AUC değeri ile en yüksek başarıyı veren algoritma olmuştur.

**ANAHTAR KELİMELER:** Uyku Apnesi, EKG, Makine Öğrenmesi, Derin Öğrenme, Sınıflandırma

Temmuz 2021, 78 Sayfa

## **ABSTRACT**

### **MSC THESIS**

#### **DIAGNOSIS OF SLEEP APNEA USING ARTIFICIAL INTELLIGENCE METHODS FROM ECG SIGNALS**

**BAHAR NAZLI**

**KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE  
DEPARTMENT OF BIOMEDICAL ENGINEERING**

**SUPERVISOR: ASST. PROF. DR. HAYRIYE ALTURAL OZKAN**

Sleep is a repetitive state in which living creatures react minimally or unresponsively to external stimuli. Diseases such as chronic insomnia, eating disorders, restless legs syndrome and sleep apnea are among the diseases that affect sleep quality and cause serious problems. The syndrome of recurrent episodes of cessation of breathing for 10 seconds or longer because of narrowing or obstruction of the upper airways called sleep apnea, and the most common is Obstructive Sleep Apnea (OSA). In this thesis, sleep apnea detected with using machine learning and deep learning algorithms from ECG signals. In the first stage, the ECG signal divided into segments and R peaks determined and each segment classified that segments sleep apnea or not. In the second stage, each of the 35 ECG recordings that were classified based on segments classified that records OSA or not. Seven different classifiers used as machine learning algorithms and three different classifiers used as deep learning algorithms. In classification based on segments, the Convolutional Neural Network (CNN) algorithm that obtained the highest results with 89.11% accuracy; 94.31% sensitivity; 80.72% selectivity; 0.89 F1 score and 0.87 AUC values. In the results of OSA and normal classification of each recording according to the Apnea-Hypopnea Index, the CNN model was the algorithm that obtained the highest results with 97.14% accuracy; 100% selectivity; 95.65% sensitivity; 0.97 F1 score and 0.98 AUC value.

**KEYWORDS:** Sleep Apnea, ECG, Machine Learning, Deep Learning, Classification

July 2021, 78 Pages

## TEŞEKKÜR

Tez çalışmam boyunca yakın ilgisini eksik etmeyen, hoşgörüsü ve yönlendirmesiyle destek veren danışmanım Dr. Öğr. Üyesi Hayriye ALTURAL ÖZKAN' a, değerli katkılarından dolayı jüri üyeleri Doç. Dr. M. Serdar ÇAVUŞ ve Dr. Öğr. Üyesi Seda ŞAHİN'e, bugünlere gelmemde büyük emekleri olan ve hayatım boyunca benden desteklerini esirgemeyen aileme, tez süreci boyunca gösterdiği anlayış ve sevgiyle her anımda destek olan eşim Celal NAZLI' ya ve çalışmam boyunca küçük veya büyük katkıda bulunan tüm arkadaşlarıma en içten duygularıyla teşekkür ederim.

Bahar NAZLI

Kastamonu, 2021

# İÇİNDEKİLER

## Sayfa

<b>TEZ ONAYI</b> .....	<b>ii</b>
<b>TAAHHÜTNAME</b> .....	<b>iii</b>
<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>v</b>
<b>TEŞEKKÜR</b> .....	<b>vi</b>
<b>İÇİNDEKİLER</b> .....	<b>vii</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>ix</b>
<b>TABLolar DİZİNİ</b> .....	<b>xi</b>
<b>SİMGELER VE KISALTMALAR DİZİNİ</b> .....	<b>xii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Uyku Apnesi Tanımı .....	1
1.2 Uyku Apnesi Tedavi Yöntemleri.....	2
1.3 Uyku Apnesi Teşhisi .....	2
1.4 Elektrokardiyogram.....	4
1.5 Sinyal İşleme .....	6
1.5.1 Fourier Dönüşümü .....	7
1.5.2 Ayrık Fourier Dönüşümü.....	7
1.5.3 Hızlı Fourier Dönüşümü .....	8
1.5.4 Kısa Zamanlı Fourier Dönüşümü .....	8
1.5.5 Welch Metodu.....	8
1.6 Sınıflandırma Algoritmaları .....	9
1.6.1 K En Yakın Komşuluk.....	10
1.6.2 Destek Vektör Makineleri.....	10
1.6.3 Karar Ağaçları.....	11
1.6.4 Rastgele Orman.....	11
1.6.5 Lineer Diskriminant Analiz .....	11
1.6.6 Kuadratik Diskriminant Analiz.....	12
1.6.7 Yapay Sinir Ağları .....	12
1.6.8 Evrimsel Sinir Ağları .....	15
1.6.9 Tekrarlayan Sinir Ağı ve Uzun Kısa Vadeli Hafıza .....	17
1.6.10 Derin Sinir Ağları .....	19
<b>2. LİTERATÜR TARAMASI</b> .....	<b>20</b>
<b>3. YÖNTEM</b> .....	<b>23</b>
3.1 Bölütlere Dayalı Sınıflandırma.....	23
3.1.1 Makine Öğrenmesi Yöntemleri Kullanılarak Sınıflandırma .....	23
3.1.1.1 Veri seti .....	24
3.1.1.2 Ön işleme .....	25
3.1.1.3 Öznitelik belirleme.....	26
3.1.1.4 Sınıflandırma.....	28
3.1.1.5 Değerlendirme.....	29
3.1.2 Derin Öğrenme Yöntemleri Kullanılarak Yapılan Çalışma .....	32
3.1.2.1 Veri seti .....	33
3.1.2.2 Ön işleme .....	33
3.1.2.3 Sınıflandırma.....	35

3.1.2.3.1	CNN.....	35
3.1.2.3.2	LSTM.....	37
3.1.2.3.3	DNN.....	37
3.1.2.4	Başarı iyileştirme .....	38
3.1.2.5	Değerlendirme.....	39
3.2	Her Bir Kaydın Sınıflandırması .....	40
<b>4.</b>	<b>BULGULAR .....</b>	<b>41</b>
4.1	Bölütlere Dayalı Sınıflandırma Bulguları .....	41
4.1.1	Makine Öğrenmesi Yöntemleri Kullanılarak Sınıflandırma .....	41
4.1.1.1	DVM sınıflandırma sonucu.....	42
4.1.1.2	KA sınıflandırma sonucu .....	45
4.1.1.3	RO sınıflandırma sonucu.....	47
4.1.1.4	KEK sınıflandırma sonucu.....	48
4.1.1.5	ÇKS sınıflandırma sonucu .....	50
4.1.1.6	LDA sınıflandırma sonucu.....	51
4.1.1.7	KDA sınıflandırma sonucu .....	53
4.1.2	Derin Öğrenme Yöntemleri Kullanılarak Sınıflandırma .....	59
4.1.2.1	CNN modelin sonuçları.....	59
4.1.2.2	LSTM modelin sonuçları .....	61
4.1.2.3	DNN modelinin sonuçları .....	63
4.2	Her Bir Kaydın Sınıflandırma Bulguları .....	67
<b>5.</b>	<b>SONUÇ VE ÖNERİLER .....</b>	<b>71</b>
	<b>KAYNAKLAR .....</b>	<b>73</b>
	<b>ÖZGEÇMİŞ.....</b>	<b>78</b>

## ŞEKİLLER DİZİNİ

### Sayfa

Şekil 1.1 EKG sinyali ve bileşenleri .....	5
Şekil 1.2 Biyolojik ve yapay sinir hücresi .....	13
Şekil 1.3 Yapay sinir ağı modeli .....	13
Şekil 1.4 En sık kullanılan aktivasyon fonksiyonları .....	14
Şekil 1.5 Temel bir CNN model .....	15
Şekil 1.6 Konvolüsyon işlemi .....	16
Şekil 1.7 Maksimum havuzlama .....	17
Şekil 1.8 Tek birimli RNN yapısı .....	18
Şekil 1.9 LSTM yapısı .....	18
Şekil 3.1 Makine öğrenmesi akış şeması .....	24
Şekil 3.2 ROC eğrisi altındaki alan .....	31
Şekil 3.3 Derin öğrenme akış şeması .....	33
Şekil 3.4 K katlı çapraz doğrulama .....	34
Şekil 3.5 Erken durdurma .....	39
Şekil 4.1 'a07' sinyalin R tepe noktaları .....	41
Şekil 4.2 Güç spektral yoğunluğu .....	42
Şekil 4.3 KHD sinyallerinin sınıflandırılmasında DVM - Gaussian kernele ait ROC eğrisi .....	44
Şekil 4.4 KHD ve EDR sinyallerinin sınıflandırılmasında DVM - Lineer kernele ait ROC eğrisi .....	44
Şekil 4.5 KHD sinyallerinin sınıflandırılmasında KA'ya ait ROC eğrisi .....	46
Şekil 4.6 KHD ve EDR sinyallerinin sınıflandırılmasında KA'ya ait ROC eğrisi .....	46
Şekil 4.7 KHD sinyallerinin sınıflandırılmasında RO'ya ait ROC eğrisi .....	47
Şekil 4.8 KHD ve EDR sinyallerinin sınıflandırılmasında RO'ya ait ROC eğrisi ..	48
Şekil 4.9 KHD sinyallerinin sınıflandırılmasında KEK'e ait ROC eğrisi .....	49
Şekil 4.10 KHD ve EDR sinyallerinin sınıflandırılmasında KEK'e ait ROC eğrisi .....	49
Şekil 4.11 KHD sinyallerinin sınıflandırılmasında ÇKS'ye ait ROC eğrisi .....	50
Şekil 4.12 KHD ve EDR sinyallerinin sınıflandırılmasında ÇKS'ye ait ROC eğrisi .....	51
Şekil 4.13 KHD sinyallerinin sınıflandırılmasında LDA'ya ait ROC eğrisi .....	52
Şekil 4.14 KHD ve EDR sinyallerinin sınıflandırılmasında LDA'ya ait ROC eğrisi .....	52
Şekil 4.15 KHD sinyallerinin sınıflandırılmasında KDA'ya ait ROC eğrisi .....	53
Şekil 4.16 KHD ve EDR sinyallerinin sınıflandırılmasında KDA'ya ait ROC eğrisi .....	54
Şekil 4.17 KHD ve EDR sinyallerine ait makine öğrenmesi sınıflandırma sonuçlarının grafiksel gösterimi .....	55
Şekil 4.18 KHD sinyallerine ait makine öğrenmesi sınıflandırma sonuçlarının grafiksel gösterimi .....	56
Şekil 4.19 KHD ve EDR sinyallerine ait hata analizi sonuç grafiği .....	57
Şekil 4.20 KHD sinyallerine ait hata analizi sonuç grafikleri .....	58
Şekil 4.21 CNN modelin doğruluk grafiği .....	59

Şekil 4.22 CNN modelin kayıp grafiği .....	60
Şekil 4.23 CNN modelin segmentasyon sınıflandırılmasına ait ROC eğrisi .....	61
Şekil 4.24 LSTM modelin kayıp grafiği .....	62
Şekil 4.25 LSTM modelin doğruluk grafiği.....	62
Şekil 4.26 LSTM modelin segmentasyon sınıflandırılmasına ait ROC eğrisi .....	63
Şekil 4.27 DNN modelin doğruluk grafiği.....	64
Şekil 4.28 DNN modelin kayıp grafiği .....	64
Şekil 4.29 DNN modelin segmentasyon sınıflandırılmasına ait ROC eğrisi.....	65
Şekil 4.30 Sınıflandırma sonuçlarının grafiksel gösterimi.....	66
Şekil 4.31 Derin öğrenme yöntemlerine ilişkin hata analizi sonuç grafiği.....	67
Şekil 4.32 Kayıtların sınıflandırma sonuçlarına ait grafiksel gösterimi .....	69
Şekil 4.33 Kayıtların hata analizi grafiksel gösterimi.....	70

## TABLolar DİZİNİ

### Sayfa

Tablo 1.1 PSG ile kaydedilen sinyaller.....	3
Tablo 1.2 EKG dalgaları .....	5
Tablo 2.1 2000-2019 yılları arası literatür taraması.....	22
Tablo 3.1 Zaman uzayı öznitelikleri .....	26
Tablo 3.2 Frekans uzayı öznitelikleri.....	28
Tablo 3.4 CNN mimarisi.....	35
Tablo 3.5 Kullanılan LSTM modeli.....	37
Tablo 3.6 DNN model.....	38
Tablo 4.1 KHD ve EDR sinyallerine ait DVM sınıflandırma sonuçları .....	43
Tablo 4.2 KHD sinyallerine ait DVM sınıflandırma sonuçları.....	43
Tablo 4.3 KHD ve EDR sinyallerine ait DVM hata analizi sonuçları .....	45
Tablo 4.4 KHD sinyallerine ait DVM hata analizi sonuçları.....	45
Tablo 4.5 KA hata oranları.....	47
Tablo 4.6 RO hata oranları.....	48
Tablo 4.7 KEK hata oranları .....	50
Tablo 4.8 ÇKS hata oranları.....	51
Tablo 4.9 LDA hata oranları .....	53
Tablo 4.10 KDA hata oranları.....	54
Tablo 4.11 KHD ve EDR sinyallerine ait makine öğrenmesi sınıflandırma sonuçları .....	55
Tablo 4.12 KHD sinyallerine ait makine öğrenmesi sınıflandırma sonuçları.....	56
Tablo 4.13 KHD ve EDR sinyallerine ait hata analizi sonuçları .....	57
Tablo 4.14 KHD sinyallerine ait hata analizi sonuçları .....	58
Tablo 4.15 CNN hata oranları.....	61
Tablo 4.16 LSTM hata oranları.....	63
Tablo 4.17 DNN hata oranları.....	65
Tablo 4.18 Derin öğrenme yöntemlerine ilişkin sınıflandırma sonuçları .....	66
Tablo 4.19 Derin öğrenme yöntemlerine ilişkin hata analizi sonuçları .....	66
Tablo 4.20 Karışıklık matrisi değerleri .....	68
Tablo 4.21 Kayıtların sınıflandırma sonuçları .....	69
Tablo 4.22 Kayıtların hata analizi sonuçları .....	69

## SİMGELER VE KISALTMALAR DİZİNİ

### Simgeler

<b>f</b>	: Frekans
<b>w</b>	: Açısal frekans
<b><math>\omega</math></b>	: Pencere fonksiyonu
<b><math>\tau</math></b>	: Öteleme parametresi

### Kısaltmalar

<b>AF</b>	: Alçak Frekans
<b>AFD</b>	: Ayrık Fourier Dönüşümü
<b>AHI</b>	: Apne Hipopne İndeksi
<b>AUC</b>	: Eğri Altında Kalan Alan
<b>CNN</b>	: Evrişimsel Sinir Ağı
<b>CAF</b>	: Çok Alçak Frekans
<b>ÇKS</b>	: Çok Katmanlı Sinir Ağı
<b>DNN</b>	: Derin Sinir Ağları
<b>DVM</b>	: Destek Vektör Makineleri
<b>EDR</b>	: EKG'den türetilen solunum
<b>EEG</b>	: Elektroensefalogram
<b>EKG</b>	: Elektrokardiyogram
<b>EMG</b>	: Elektromiyogram
<b>EOG</b>	: Elektrookülografi
<b>FD</b>	: Fourier Dönüşümü
<b>FN</b>	: Yanlış Negatif
<b>FP</b>	: Yanlış Pozitif
<b>GSY</b>	: Güç Spektral Yoğunluğu
<b>HFD</b>	: Hızlı Fourier Dönüşümü
<b>KA</b>	: Karar Ağaçları
<b>KDA</b>	: Kuadratik Diskriminant Analiz
<b>KEK</b>	: K En Yakın Komşuluk
<b>KHD</b>	: Kalp Hızı Değişkenliği
<b>KZFD</b>	: Kısa Zamanlı Fourier Dönüşümü
<b>LDA</b>	: Lineer Diskriminant Analiz
<b>LSTM</b>	: Uzun Kısa Vadeli Hafıza
<b>MAE</b>	: Ortalama Mutlak Hata
<b>MSE</b>	: Ortalama Karesel Hata
<b>NREM</b>	: Yavaş göz hareketi
<b>OUA</b>	: Obstrüktif Uyku Apnesi
<b>PAP</b>	: Pozitif Hava Basıncı
<b>PSG</b>	: Polisomnografi
<b>ReLU</b>	: Doğrultulmuş Lineer Birim
<b>REM</b>	: Hızlı göz hareketi
<b>RMSE</b>	: Kök Ortalama Karesel Hata

<b>RNN</b>	: Tekrarlayan Sinir Ağları
<b>RO</b>	: Rastgele Orman
<b>ROC</b>	: Alıcı Operatör Özellikleri Eğrisi
<b>SpO<sub>2</sub></b>	: Oksijen Saturasyonu
<b>TN</b>	: Doğru Negatif
<b>TP</b>	: Doğru Pozitif
<b>YF</b>	: Yüksek Frekans
<b>YSA</b>	: Yapay Sinir Ağları

## 1. GİRİŞ

Uyku, canlıların dış uyaranlara karşı minimum seviyede tepki verdiği veya tepki vermediği tekrarlanan bir durumdur. Normal bir uyku hızlı göz hareket (rapid eye movement, REM) evresi ve yavaş göz hareket (non-rapid eye movement, NREM) evresi olmak üzere iki evreden oluşmaktadır. Bir insanın günlük uyku saati kişiden kişiye değişmekle beraber ortalama 8 saat sürmektedir. Uyku evreleri gece uyku boyunca 4-5 kez tekrarlanmaktadır. Bir kişi uyuduktan yaklaşık 90 dakika sonra REM uykusuna geçmektedir. REM uykusu 70-110 dakika arasında sürmektedir (Bora ve Bican, 2007). İnsanların sağlıklı bir hayat sürebilmesi için uyku önemli bir yere sahiptir. Uyku beyin aktiviteleri ile yakından ilgilidir ve çeşitli nedenlerle uyku bozukluğu yaşanabilmektedir. Uyku bozukluğu yaşayan bireylerde dikkat dağınıklığı, kazalara daha sık yakalanma, stres bozukluğu gibi durumlar yaşanmaktadır. Uyku kalitesini etkileyen ve daha ciddi sorunlara yol açan hastalıklar da vardır. Bunlar uyku apnesi, kronik uykusuzluk, yeme bozuklukları, huzursuz bacak sendromu olarak sıralanabilir (Algın vd., 2016).

### 1.1 Uyku Apnesi Tanımı

Üst solunum yollarının daralması veya tıkanması sonucunda solunumun 10 sn veya daha uzun süre boyunca tekrarlayan ataklarla durması sendromuna uyku apnesi denilmektedir. Tıkayıcı uyku apnesi, santral uyku apnesi ve mikst uyku apnesi olmak üzere farklı türleri olmakla beraber en yaygın olanı obstrüktif uyku apnesidir (Bayrak, 2011). Obstrüktif Uyku Apnesi (OUA) sendromunda hava akımı durmasına rağmen solunum çabası devam etmektedir. Santral uyku apnesi sendromunda hem solunum çabası hem de hava akımı durmuştur. Mikst uyku apnesi sendromunda apne santral tipte başlamıştır ancak daha sonra solunum çabası gelişmesine rağmen hava akışı oluşmamıştır.

Solunumun geçici olarak durması sonucunda oksijen saturasyonunda %3-4 oranında azalma meydana gelmekte ve bu durum terleme, kalp ritminin bozulması ve uykunun sık sık bölünmesine neden olmaktadır (Doukas vd., 2012). Uyku apnesinin tedavi edilmemesi sonucunda hipertansiyon, kalp rahatsızlıkları, obezite, böbrek

rahatsızlıkları ve sinir bozukluğu gibi ciddi sorunlar meydana gelebilmektedir (Budhiraja vd., 2010). Yaş ilerledikçe uyku apnesi sendromu artmaktadır. Kadın ve erkeklerin uyku apnesi olma durumları karşılaştırıldığında erkeklerde kadınlardan yaklaşık iki kat daha yaygındır.

## **1.2 Uyku Apnesi Tedavi Yöntemleri**

Horlama ve hafif şiddetli uyku apnesinde ilk olarak uyku pozisyonu düzeltilmesi, kilolu hastalar için kilo verimi, sigara gibi alışkanlıkların bırakılması denenmektedir. Uyku apnesinin tedavisi şiddetine göre değişmektedir. Basit horlama, hafif ve orta şiddet hastalar için cerrahi müdahale de tercih edilebilmektedir. Ağır seyreden hastalarda ciddi bir anatomik bozukluk yoksa cerrahi müdahale tercih edilmemektedir (Javaheri vd., 2017). Orta ve şiddetli uyku apnesi sendromları için basit PAP (pozitif hava yolu basıncı – positive airway pressure) cihazları hastalara verilmekte ve uzun süre kullanması istenmektedir. Ancak hastaların büyük çoğunluğunun 2-3 yıl sonra cihazı bıraktıkları gözlemlenmiştir (Calik, 2016).

## **1.3 Uyku Apnesi Teşhisi**

OUA'nın varlığı Apne-Hipopne İndeksi (AHİ) ile ölçülür. AHİ uykuda meydana gelen apne ve hipopnelerin saatlik ortalamasını vermektedir (Hafezi vd., 2020). Apne 10 sn veya daha uzun süre hava akışının olmaması olarak ve hipopne %4 veya daha fazla oksijen desatürasyonu ile solunum çabasında azalma olarak tanımlanır (Medical Advisory Secretariat, 2006).

- $AHI < 5$  ise normal
- $5 \leq AHI < 15$  ise hafif derecede uyku apnesi
- $15 \leq AHI < 30$  ise orta derecede uyku apnesi
- $AHI \geq 30$  ise şiddetli uyku apnesi

Uyku apnesinin gözlemlenmesinde, altın standart olarak kabul edilen ve hastanın solunum sistemi, sinir sistemi ve dolaşım sistemi hakkında bilgileri kaydeden Polisomnografi (PSG) kayıtları kullanılmaktadır (Madhav, 2011). PSG kayıtlarında elektroensafalogram (EEG), elektromiyogram (EMG), elektrookülogram (EOG), elektrokardiyogram (EKG), oksijen saturasyonu (SpO<sub>2</sub>), horlama sesleri, hava akımı, vücut pozisyonu, ayak hareketleri bilgileri kaydedilmektedir ve ölçülen sinyallere ilişkin bilgiler Tablo 1.1’de verilmiştir. OUA’nın tedavi aşamasının doğru ve verimli bir şekilde yapılabilmesi için teşhisinin yapılabilmesi önem arz etmektedir. Teşhis çalışması uyku laboratuvarında elde edilen ve bir veya iki gece süre ile kaydedilen PSG kayıtlarının incelenmesi ve yorumlanması ile yapılmaktadır.

Tablo 1.1 PSG ile kaydedilen sinyaller

EKG	Depolarizasyon ile polarizasyon arasında düzenli bir şekilde devam eden bir kalp atımı, vücuda yerleştirilen elektrotlar vasıtasıyla EKG cihazı kullanılarak ölçülmektedir. EKG sinyali her bir kalp döngüsüne ait önemli bilgileri içermektedir.
EMG	Kasların sinir sistemi tarafından uyarılması sonucunda üretilen elektriksel potansiyele EMG ve bu sinyali ölçmek için kullanılan cihaza da elektromiyografi denilmektedir (Kleissen vd., 1998). EMG, kasların fizyolojik ve anatomik özellikleriyle ilgili olan ve sinir sistemi bileşenleri ile kontrol edilen bir sinyaldir.
EOG	Gözün ışığa duyarlılığının sonucu olarak retinada 0,4-1 mV aralığında elektriksel potansiyel oluşmaktadır ve bu elektriksel potansiyel ölçülebilmektedir (Young ve Sheena, 1975). Gözün etrafına yerleştirilen iki adet yüzey elektrotu kullanarak göz hareketlerinin çalışması hakkında detaylı bilgi edinmemizi sağlayan bu ölçüm yöntemine elektrookülografi ve ölçülen sinyale de elektrookülogram denilmektedir.
EEG	Sinir sisteminin bir parçası olan beyindeki aktiviteler kafa derisinde potansiyel değişimlere neden olmaktadır. Bu potansiyel değişimler kafa derisine yerleştirilen elektrotlar vasıtasıyla EEG cihazı kullanılarak ölçülebilmektedir. Ölçülen bu sinyallere EEG sinyalleri denilmektedir ve genlikleri 1-400 $\mu$ V arasındadır (Subha vd., 2010).


Tablo 1.1' in devamı

Solunum Sinyalleri	Nefes alma ve nefes verme sırasında solunum sistemi organlarında meydana gelen sinyallere solunum sinyalleri denilmektedir. Solunum sinyalleri ağız ve burundan veya abdominal bölgeden steteskop veya çeşitli sensörler kullanılarak ölçülebilmektedir (Taha vd., 1997).
SpO <sub>2</sub>	SpO <sub>2</sub> kandaki oksijen miktarının bilgisini vermektedir. Parmaktan invazif olmayan (müdahalesiz) yöntemlerle ölçülebilmektedir. İnvazif olmayan yöntemlerle SpO <sub>2</sub> ölçmek için pulse oksimetre cihazı kullanılmaktadır. Pulse oksimetre cihazı parmaktan kızılötesi ışınlar yardımı ile kandaki oksijen miktarını ölçebilmektedir.

PSG kayıtları uyku laboratuvarlarında en az bir gece boyunca alınmalıdır. Bu durumun sürecin uzun olması, hastalara çok fazla elektrot bağlanması sonucu fazla parametreliliğe ihtiyaç duyması ve hastaların laboratuvarında kendilerini rahatsız hissetmesi gibi dezavantajları bulunmaktadır. Bu sorunun önüne geçebilmek için son yıllarda tek parametre kullanarak teşhis yapılabilmesi için çalışmalar yapılmaya başlanmıştır. Bunun için EEG, EKG, EOG, EMG ve solunum sinyallerinden birine bakarak uyku apnesinin teşhisine yönelik çalışmalar yapılmaktadır. Bu sinyaller arasında en çok tercih edilenleri EKG ve EEG sinyalleridir ve bu çalışmada EKG sinyalleri kullanılmıştır.

#### 1.4 Elektrokardiyogram

Kalbin kasılıp gevşemesi sırasında meydana gelen ve iki çevrim arasında önemli bilgileri içeren işarete kalp atımı denilmektedir. Depolarizasyon ile polarizasyon arasında düzenli bir şekilde devam eden bir kalp atımı, vücuda yerleştirilen elektrotlar vasıtasıyla elektrokardiyografi cihazı kullanılarak ölçülmektedir. EKG sinyali her bir kalp döngüsüne ait önemli bilgileri içermektedir ve Şekil 1.1'de EKG sinyaline ait bileşenleri verilmiştir.



Şekil 1.1 EKG sinyali ve bileşenleri (Yildiz, 2017)

Kalpte meydana gelen elektriksel aktiviteler hakkında bilgiler içeren EKG sinyali ilk kez Willem Einthoven tarafından ölçülmüştür (Davey ve Sharman, 2018). Daha sonra Einthoven üçgeni olarak isimlendirilen olan sağ kol, sol kol ve sol bacadan ölçüm gerçekleştirilmiştir. Kalp atımının kulakçıklardan karıncıklara doğru yayılım göstermesi ve ardından dinlenmeye geçmesi ile temel bir EKG dalgası meydana gelmektedir (Hassanien vd., 2017). Genel olarak bir EKG dalgası P dalgası, PR aralığı, Q-R-S dalgalarının oluşturduğu QRS kompleksi, ST segmenti, QT aralığı, T dalgası ve U dalgasından oluşmaktadır (Jambukia vd., 2015). Tablo 1.2’de bu bileşenlerin normal bir kalp atımında göstermiş oldukları genlik ve zaman aralığı değerleri verilmiştir.

Tablo 1.2 EKG dalgaları

<b>BİLEŞENLER</b>	<b>GENLİK (mV)/ SÜRE (saniye)</b>
<b>P dalgası</b>	0,1 mV -0,2 mV / 0,06 sn - 0,1 sn
<b>PR aralığı</b>	0,12 sn - 0,20 sn
<b>QRS kompleksi</b>	1 mV/ 0,10 sn – 0,12 sn
<b>ST aralığı</b>	0,05 sn – 0,15 sn
<b>QT aralığı</b>	0,35 sn – 0,44 sn
<b>T dalgası</b>	0,1 mV- 0,3 mV / 0,12 sn - 0,16 sn
<b>U dalgası</b>	Her dalgada gözükmez.

Sağlıklı bir EKG’de dalga aralıkları ve segmentler belirtilen süre içerisinde. Ancak ritim bozukluğu, uyku apnesi, taşikardi gibi durumlarda EKG dalgasının şekli bozulmaktadır. EKG sinyalleri üzerinden uyku apnesi tespiti için Kalp Hızı Değişkenliği (KHD) ve EKG'den türetilen solunum (ECG-Derived Respiration, EDR) sinyalleri incelenmektedir (Janbakhshi ve Shamsollahi, 2018). KHD, QRS kompleksinin bir parçası olan iki ardışık R tepe noktaları arasında uzaklığı ifade etmektedir (Kiran kumar vd., 2021). EDR sinyalleri EKG’nin solunum bilgilerini iletmektedir. KHD sinyallerinin elde edilebilmesi için EKG sinyalinin QRS kompleksinden R tepe aralıklarının tespitinin doğru bir şekilde yapılması gerekmektedir. R tepe noktalarının doğru tespiti özellikle gece ve uzun süreli EKG kayıtlarının incelenmesi gereken OUA gibi hastalıklarda önem arz etmektedir.

QRS tespiti için Pan Tompkins Algoritması, Hamilton Algoritması, Hilbert Dönüşümü gibi yöntemler kullanılmaktadır (Canento vd., 2012). Bunlardan en popüler olanı Pan Tompkins ve Hamilton algoritmalarıdır (Arzeno vd., 2008). Pan Tompkins algoritmasında, eğim, genlik ve genişlik bilgileri kullanılarak QRS komplekslerinin güvenilir bir şekilde tespit edilmesi sağlanır (Pan ve Tompkins, 1985). Bir bant geçiren filtre, gürültüyü azaltmak için sinyali önceden işler ve yüksek algılama hassasiyeti elde etmek için düşük genlikli eşiklerin kullanımına izin verir. Algoritmada, çift eşikli bir teknik kullanılır ve kaçırılan vuruşlar için geri arama yapılır. Algoritma, her eşiği ve RR aralığı sınırını otomatik ve periyodik olarak uyarlar. Bu uyarlanabilir yaklaşım, çok çeşitli sinyal özelliklerine, QRS morfolojilerine ve kalp hızı değişikliklerine sahip EKG sinyallerinde doğru kullanım sağlar. Hamilton algoritması da Pan Tompkins algoritmasına benzer bir yapıdadır. Bant geçiren filtreden geçirilen EKG sinyalinin türevi alınır. Daha sonra elde edilen sinyalin ortalaması ve karesi alınır (Hamilton, 2002).

## 1.5 Sinyal İşleme

Sinyalleri farklı frekans ve genlik bilgisine sahip sinüs fonksiyonlarının toplamından oluşan dalga formları olarak tanımlamak mümkündür. EKG, EMG, EEG ve solunum sinyalleri gibi karmaşık bilgiler içeren sinyallerin analizini kolaylaştırmak için bu sinyalleri sinüs ve kosinüs fonksiyonlarının birer fonksiyonu olarak ifade etmek için

sinyal işleme çalışmaları yapılmaktadır. Sinyal işleme aşamasında zaman uzayında karmaşık bilgiler içeren ve çözümü zor olan sinyallerin frekans uzayına aktarılarak çözümü sağlanmaktadır (Cerutti vd., 2011) Bu amaçla Fourier dönüşümü, Ayırık Fourier dönüşümü, Hızlı Fourier dönüşümü, Dalgacık dönüşümü, Ayırık Dalgacık dönüşümü ve istatistiksel yöntemler gibi yöntemler yaygın olarak kullanılmaktadır. Bu çalışmada Fourier dönüşümü temelli öznelik çıkarma yöntemi kullanılmış ve Fourier dönüşümü çeşitleri açıklanmıştır.

### 1.5.1 Fourier Dönüşümü

Sürekli zamanlı bir sinyalin zaman uzayından frekans uzayına aktarılarak işlem yapılmasına Fourier Dönüşümü (FD) denilmektedir (Jain, 2016). Sürekli zamanlı bir  $x(t)$  sinyalinin Fourier dönüşümü  $X(w)$  Eşitlik 1.1'de verildiği şekilde hesaplanmaktadır.

$$X(w) = \int x(t)e^{-j\omega t} dt \quad (1.1)$$

Burada  $w$  açısal frekans olup  $w=2\pi f$  (rad/sn) formülü ile ifade edilmektedir. Sinyal işleme çalışmalarında en çok tercih edilen yöntemlerden biridir.

### 1.5.2 Ayırık Fourier Dönüşümü

Zaman uzayında karmaşık olan ayırık zamanlı bir sinyalin daha kolay analiz edebilmek için frekans uzayında ifade edilmesine Ayırık Fourier dönüşümü (AFD) denilmektedir. Ayırık zamanlı bir  $x[n]$  sinyalinin  $N$  uzunluklu  $k$  ya bağlı Ayırık Fourier dönüşümü olan frekans sinyali  $X[k]$  Eşitlik 1.2'de verilmiştir.

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j\frac{2\pi}{N}kn} \quad k = 0,1,2,\dots, N-1 \quad (1.2)$$

Ayırık Fourier dönüşümü simetriklik, lineerlik, periyodiklik gibi özelliklere sahiptir. Ters AFD için Eşitlik 1.3 kullanılmaktadır.

$$X[n] = \frac{1}{N} \sum_{k=0}^{N-1} x[k]e^{-j\frac{2\pi}{N}kn} \quad n = 0,1,2,\dots, N-1 \quad (1.3)$$

### 1.5.3 Hızlı Fourier Dönüşümü

Ayrık Fourier dönüşümünün doğrudan hesaplanmasında her bir  $X[k]$  değeri için  $N$  adet kompleks çarpma ve  $N - 1$  adet kompleks toplama işlemi yapılmaktadır. Bu da  $N$  sayısı büyük bir sayı olursa işlem yükünün çok fazla olması demektir. Cooley ve Tukey işlem yükünün azaltılması için yeni bir yöntem geliştirmişlerdir. (Cooley ve Tukey, 1965). Hızlı Fourier dönüşümü (HFD) olarak bilinen bu yöntemin geliştirilmesi ile sayısal işaret işleme çalışmalarının sayısında bir artış sağlamıştır. Hızlı Fourier dönüşümü AFD'den çok farklı bir algoritma değildir.

### 1.5.4 Kısa Zamanlı Fourier Dönüşümü

Sinyal işleme çalışmalarında Fourier dönüşümü frekans bilgisinin önemli olduğu çalışmalarda sıkça tercih edilen bir yöntemdir. Ancak Fourier dönüşümleri kullanıldığı durumda sinyal, frekans ekseninde ifade edilir. Fourier dönüşümünde frekans ekseninde ifade edilmiş bir sinyalin zaman bilgisine ulaşabilmek için pencereleme yöntemi geliştirilmiştir. Bu yöntem ile pencere süresi boyunca sinyalin frekans bilgisi analiz edilmiştir. Bu metot Kısa Zamanlı Fourier dönüşümü (KZFD) olarak adlandırılmıştır. KZFD ile pencere boyutu ile sınırlı olmak şartıyla zaman-frekans bilgisi elde edilmektedir (Owens ve Murphy, 1988). Bir  $x(t)$  sürekli sinyalinin KZFD dönüşümü Eşitlik 1.4'de verildiği şekilde hesaplanmaktadır.

$$X(\omega, \tau) = \int x(t) \omega(t - \tau) e^{-j\omega t} dt \quad (1.4)$$

Burada  $\omega$  pencere fonksiyonu ve  $\tau$  öteleme parametresidir. KZFD  $x(t)$  sürekli sinyaline  $\omega$  pencere fonksiyonu yerleştirilerek Fourier hesabı yapılmakta ve pencere  $\tau$  kadar ötelenerek işlem tekrarlanmaktadır. Bu yöntemde pencere boyutunun seçimi büyük önem taşımaktadır. Pencere çeşitleri Bant durduran (Bandpass), Butterworth, Hanning, Hamming, Chebyshev ve Bessel olarak sıralanabilir.

### 1.5.5 Welch Metodu

Welch'in yöntemi periyodogram yöntemi olarak da bilinmektedir ve verileri örtüşen bölümlere bölerek, her bölüm için değiştirilmiş bir periyodogram hesaplayarak ve

periyodogramların ortalamasını alarak Güç Spektral Yoğunluğunun (GSY) bir tahminini hesaplar (Solomon, 1991).

Bölütlere ayrılmış bir sinyalin her bir bölüm için ( $m=1,2,3, \dots, M-1$ ) periyodogram değerinin hesaplanma formülü Eşitlik 1.6'da verilmiştir.

$$P_m(k) = \left(\frac{1}{M}\right) |X_m(k)|^2 \quad m=0,1,2,\dots, M-1 \quad (1.6)$$

Formülde  $X_m(k)$  Fourier dönüşümü alınmış bir sinyaldir. Periyodogram değerlerinin ortalaması alınarak Welch metoduna göre GSY hesaplaması  $S_x(k)$  Eşitlik 1.7'de verilmiştir.

$$S_x(k) = \left(\frac{1}{M}\right) \sum_{m=0}^{M-1} P_m(k) \quad (1.7)$$

Güç Spektral Yoğunluğu alçak frekans (AF), yüksek frekans (YF) ve çok alçak frekans (ÇAF) bilgilerinden oluşmaktadır. Uyku apnesi olan kişilerde frekans bölgeleri farklılık göstermektedir. Bu yüzden uyku apnesi tespiti çalışmalarında güç spektral yoğunluğu hesaplamaları tercih edilmektedir. GSY hesaplanarak öznitelikler oluşturulmakta ve sınıflandırıcı algoritmalarının giriş bilgisi oluşturulmaktadır.

## 1.6 Sınıflandırma Algoritmaları

Zemouri ve arkadaşlarının yapmış olduğu çalışmaya göre biyomedikal uygulamalarda makine öğrenmesi algoritmaları temel olarak erken tanı çalışmaları, hastanın kişisel bakımın geliştirilmesi ve beyin bilgisayar ara yüzü uygulamalarında kullanılmaktadır (Zemouri vd., 2019). Uyku apnesi teşhisi yapılan çalışmalarda sınıflandırma için istatistiksel yöntemler, makine öğrenmesi algoritmaları ve derin öğrenme algoritmaları kullanılmaktadır. Makine öğrenmesi, eldeki verilere istatistiksel ve matematiksel yöntemler uygulayarak çıkarımlarda bulunan ve bu çıkarımlar üzerinden tahmin yaparak bilinmeyene ulaşmaya çalışan yöntem paradigmasıdır (Elhaj vd., 2016). Makine öğrenmesi ve derin öğrenme algoritmaları, kendi kendine herhangi bir insan müdahalesi gereksizden mevcut verilerden öğrenebilme ve gelişebilme yeteneğine sahiptir.

Makine öğrenmesi algoritmalarından Karar Ağaçları (KA), Genetik Algoritma, Destek Vektör Makineleri (DVM), Rastgele Orman (RO), K En Yakın Komşuluk (KEK), Yapay Sinir Ağları (YSA) ve Lineer Diskriminant Analiz (LDA) yaygın olarak kullanılmaktadır. Derin öğrenme algoritmaları olarak Evrişimsel Sinir Ağı (Convolutional Neural Network - CNN), Uzun Kısa Vadeli Hafıza (Long Short Term Memory - LSTM), Derin Sinir Ağları (Deep Neural Network - DNN) algoritmaları sinyal işleme çalışmalarında tercih edilen algoritmalar arasındadır. Bu çalışma kapsamında hem makine öğrenmesi algoritmaları hem de derin öğrenme algoritmaları kullanılarak sınıflandırma çalışması yapılmıştır ve kullanılan sınıflandırma algoritmalarına ait teorik bilgiler açıklanmıştır.

### **1.6.1 K En Yakın Komşuluk**

Örnek tabanlı bir algoritma olan K en yakın komşu algoritması, sınıflandırma problemlerinde kullanılan ve parametrik olmayan, tembel (lazy) bir öğrenme algoritmasıdır (Kramer, 2013). Tembel öğrenme algoritmalarında eğitim aşaması yoktur ve eğitim verilerini öğrenme işlemi gerçekleştirmez, bunun yerine eğitim veri kümesini ezberler. Bir tahmin yapmak istediğimizde, tüm veri setinde en yakın komşuları arar.

Algoritmada bakılacak olan eleman sayısını ifade eden bir K değeri belirlenir. Hangi sınıfa ait olduğunun belirlenmesi gereken bir değer olduğunda en yakın K kadar eleman seçilerek değer ile arasındaki uzaklık hesaplanır. Bu uzaklık hesaplama işlemi için Öklid, Manhattan, Minkowski ve Hamming fonksiyonlarından biri kullanılır. Hesaplanan uzaklık bilgisine göre sıralama yapılır ve değer için en uygun sınıfa atama yapılır.

### **1.6.2 Destek Vektör Makineleri**

1963 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından temelleri atılan Destek vektör makineleri istatistiksel öğrenme temeline dayalı sınıflandırma algoritmalarında sıkça kullanılan gözetimli öğrenme algoritmasıdır (Ayhan, 2014). Destek vektör makineleri, genellikle iki sınıf bilgisi içeren verileri birbirlerinden ayırarak değerleri olabilecek en iyi şekilde ayırmak için kullanılır (Garrett vd., 2003).

Sınıflandırmayı yapmak için karar sınırları da denilen hiper düzlemler belirlenir. Sonsuz tane hiper düzlem mevcut olsa da ana hedef en uygun hiper düzlemi belirlemektir (Martis vd., 2013). Doğrusal ve doğrusal olmayan olarak iki sınıfa ayrılır. Doğrusal olmayan DVM’de çekirdek (kernel) yöntemi kullanılarak doğruluğun artırılması hedeflenmiştir. En sık Polynomial, Sigmoid, Gaussian ve Linear kernel kullanılmaktadır.

### **1.6.3 Karar Ağaçları**

Karar ağaçları makine öğrenmesi algoritmalarından gözetimli öğrenme sınıfına dahildir. Sınıflandırma ve regresyon çalışmalarında kullanılabilir (Song ve Lu, 2015). Hiyerarşik bir yapıda olan algoritmanın terminolojisine göz atmak gerekirse; ağaç üzerindeki koşul ifadeleri ‘düğüm’ olarak adlandırılırken en üstteki düğüm ‘kök düğüm’ olarak ifade edilir. Düğümler arası bağlantı ‘kenar’ olarak adlandırılır. Koşul belirtmeyen ve ‘yaprak’ olarak isimlendirilen ifadeler karar verme noktaları olup sınıf etiketlerini gösterir. Ağaç üzerindeki ilerleme; düğümdeki karar durumuna bağlı olarak ilgili kenar aracılığı ile ulaşılacak düğüm ya da yaprağa ilerleyerek gerçekleştirilir.

### **1.6.4 Rastgele Orman**

Gözetimli öğrenme sınıfına dahil olan Rastgele Orman algoritması çok sayıda karar ağacı kullanarak sınıflandırma yapan bir algoritmadır (Cutler vd., 2012). RO, varyansı azaltmak amacıyla aynı eğitim setinin farklı bölümlerinde eğitilmiş birden fazla Karar Ağacının ortalamasını almanın bir yoludur (Breiman, 2001). Sınıflandırma ve regresyon çalışmalarında kullanılmaktadır. Rastgele Orman algoritması çoğunlukla KA’dan daha iyi performans göstermektedir.

### **1.6.5 Lineer Diskriminant Analiz**

Lineer diskriminant analiz sınıfları en iyi şekilde ayırabilmek için gerekli olan değişkenlerin lineer bir kombinasyonunu bulmaya yönelik olan bir sınıflandırma algoritmasıdır. Sınıflandırma ve özellik çıkarma aşamasında kullanılabilir. LDA, sınıf içi frekansların eşit olmadığı ve performanslarının rastgele oluşturulan test

verileri üzerinde incelendiği durumu kolayca ele alır. Bu yöntem, sınıflar arasındaki maksimum ayrılabilirlik için sınıflar arası varyansın sınıf içi varyansa oranını maksimuma çıkarır (Balakrishnama ve Ganapathiraju, 2015).

### **1.6.6 Kuadratik Diskriminant Analiz**

Kuadratik diskriminant analizi (KDA), LDA ile yakından ilişkilidir ve burada her sınıftan alınan ölçümlerin normal olarak dağıldığı varsayılır. Ancak LDA'dan farklı olarak, KDA'da sınıfların her birinin kovaryansının aynı olduğu varsayımı yoktur. LDA sınıflandırıcısında karar yüzeyi lineer iken KDA'daki karar sınırı lineer değildir (Tharwat, 2016). KDA, kovaryans matrisi için daha fazla esneklik sağladığından, verilere LDA'dan daha iyi uyma eğilimindedir, ancak daha sonra tahmin etmesi gereken daha fazla parametreye sahip olur. KDA ile parametre sayısı önemli ölçüde artar çünkü KDA ile her sınıf için ayrı bir kovaryans matrisine sahip olunur.

### **1.6.7 Yapay Sinir Ağları**

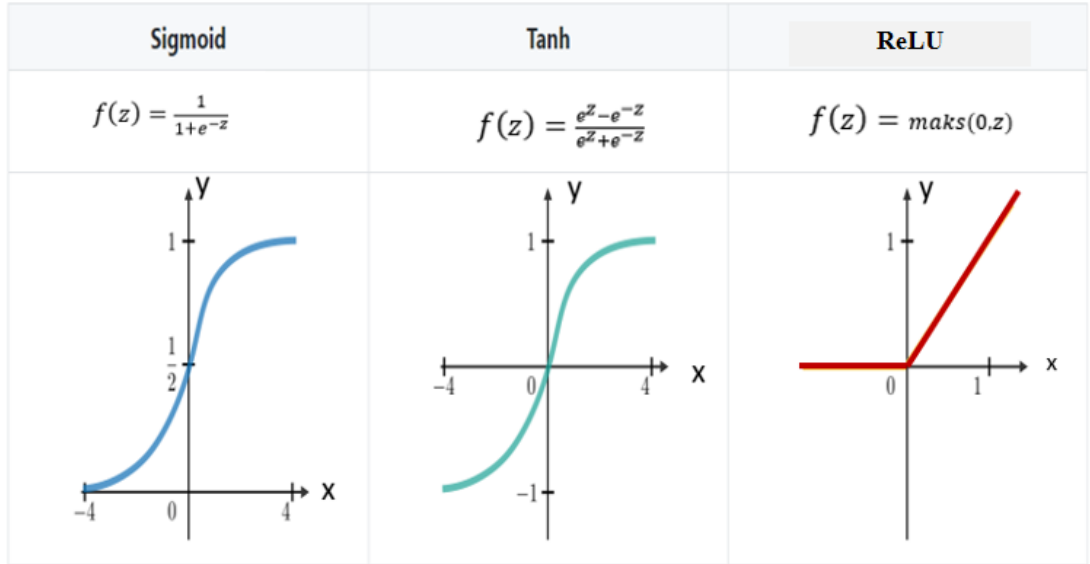
Yapay sinir ağları, insan sinir hücresinin çalışma mekanizmasından esinlenerek geliştirilmiş öğrenme algoritmasıdır (Basheer ve Hajmeer, 2000). YSA ile sinir sisteminin temeli olan sinir hücreleri taklit edilerek oluşturulmuştur. Şekil 1.2'de A biyolojik sinir hücresini, B yapay sinir hücresini, C biyolojik sinir ağını ve D yapay sinir ağını göstermektedir. Biyolojik sinir hücresi dentrit, hücre gövdesi, akson ve terminal aksondan oluşmaktadır. İki sinir hücresinin aksonları arasında oluşan ve bilgi alışverişinin olduğu kısma sinaps denilmektedir. Yapay sinir ağlarında da sinir ağlarına benzer şekilde temeli nöronlar oluşturmaktadır ve bu nöronlar birbirine sinapslar gibi bağlantılar kurarak ağı meydana getirir.



Sinir ağı Eşitlik 1.8’de formüle edildiği şekilde, girdi ile ağırlıkların toplamını aktivasyon fonksiyonundan geçirerek hesaplama yapar ve çıkış bilgisini öğrenir. Bir sinir ağının eğitimi örnek bir çıktı bilgisi ile kendi tahmin edilen çıktısı arasındaki farkın hesaplanması ile olur. Bu farka hata denilmektedir. Ağ kendi ağırlıkları üzerinden hatanın azaltılması için tekrar tekrar deneme yapar ve sonunda hata azaltılarak öğrenme tamamlanır.

$$y = f(\sum_{i=0}^n(x_i w_i)) + b \quad i=0,1,2,\dots, n \quad (1.8)$$

Eşitlikte x girişi, w ağırlıklar, f aktivasyon fonksiyonunu, b biası ve y çıkışı ifade etmektedir. En sık kullanılan aktivasyon fonksiyonları Şekil 1.4’de gösterilen doğrultulmuş lineer birim (Rectified linear unit, ReLU ), Sigmoid ve Tanh’dır.




Şekil 1.4 En sık kullanılan aktivasyon fonksiyonları

Çok Katmanlı Sinir Ağı (ÇKS), giriş katmanı, çıkış katmanı ve gizli katman olmak üzere üç tür katmandan oluşan bir sinir ağı modelidir. Giriş katmanı, işlenecek giriş sinyalini alır. Tahmin ve sınıflandırma gibi gerekli görevler çıktı katmanı tarafından gerçekleştirilir. Giriş ve çıkış katmanı arasına yerleştirilen rastgele sayıda gizli katman, ÇKS’nin gerçek hesaplama birimidir. Bir ÇKS modelinde veriler ileri beslemeli ağa benzer şekilde girişten çıkış katmanına ileri yönde akar (Marius-Constantin vd., 2009). ÇKS'nin başlıca örüntü sınıflandırması, tanıma ve tahmin alanlarında kullanılmaktadır.

### 1.6.8 Evrişimsel Sinir Ağları

Derin öğrenme, bir veya daha fazla gizli katmana sahip lineer olmayan bir denetimsiz yapay sinir ağı modelidir (Faust vd., 2018). Derin öğrenmedeki temel fark her katmanın ayrı ayrı eğitilmesidir. Derin öğrenmenin Evrişimsel Sinir Ağı, Tekrarlayan Sinir Ağı (Recurrent Neural Network - RNN), Üretken Çekişmeli Ağları (Generative Adversarial Networks), Özyinelemeli Sinir Ağları (Recursive Neural Networks), Derin Sinir Ağı ve Transfer Öğrenme gibi farklı uygulamaları vardır. Son yıllarda biyomedikal sinyal işleme alanında yapılan çalışmalarda derin öğrenme mimarileri sıkça tercih edilmektedir (Kuazaqui, 2018).

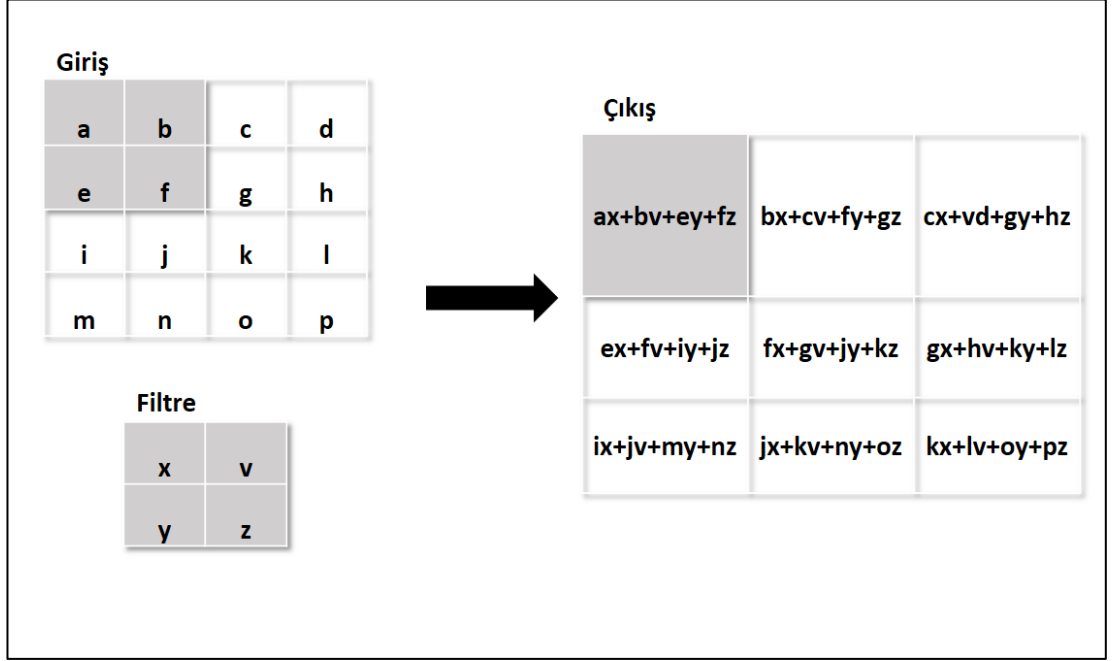
CNN'ler, yerel zaman dilimlerine uygulanan tekrarlayan filtreler veya çekirdekler içeren ve böylece yüksek düzeyde soyut özellikler oluşturan daha karmaşık bir derin öğrenme yöntemidir (Mostafa vd., 2019a). Evrişimli ağlar, pratik uygulamalarda muazzam derecede başarılı olmuştur. Temel bir CNN modeli Şekil 1.5'de gösterildiği şekilde giriş, konvolüsyon katmanı, havuzlama katmanı, düzleştirme katmanı, tam bağlantılı katman ve çıkış katmanlarından oluşur.



Şekil 1.5 Temel bir CNN model

"Evrişimsel Sinir Ağı" adı, ağın evrişim (konvolüsyon) adı verilen matematiksel bir işlem kullandığını gösterir. Konvolüsyon, özel bir doğrusal işlem türüdür. Evrişimli ağlar, katmanlarından en az birinde genel matris çarpımı yerine evrişimi kullanan basit sinir ağlarıdır. Evrişimli bir ağın tipik bir katmanı üç aşamadan oluşur. İlk aşamada, katman, bir dizi önsinaptik (presinaptik) aktivasyon üretmek için paralel olarak birkaç konvolüsyon gerçekleştirilir. Konvolüsyon katmanı, giriş verisine filtre uygulayarak düşük ve yüksek seviyeli özelliklerin çıkarılmasını sağlar. Konvolüsyon işleminde Şekil 1.6' da gösterildiği şekilde filtre, matrisin sol üst köşesinden konumlandırılarak


filtrenin deęerleri ile karřılık gelen matris deęerleri arpılıp toplanarak matrisin yeni deęerini oluřturur. Daha sonra filtre bir birim kaydırılarak iřlem tekrarlanır. Bu iřleme tm matris boyunca devam edilir.



řekil 1.6 Konvolsyon iřlemi

İkinci ařamada, her nsinaptik aktivasyon, ReLU fonksiyonu gibi lineer olmayan bir aktivasyon fonksiyonundan geirilir. Sigmoid, ReLU, Softmax, Tanh gibi aktivasyon fonksiyonları olmakla beraber konvolsyon iřleminde en hızlı sonucu ReLU aktivasyon fonksiyonu verdięi iin genellikle ReLU tercih edilmektedir.

nc ařamada, katmanın ıktısını iyileřtirmek iin bir havuzlama iřlemi yapılır. Havuzlama iřleminde, aęın belirli bir konumdaki ıktısını, yakındaki ıktıların bir zet istatistięi ile deęiřtirilir. Bu katmanın grevi, gsterimin kayma boyutunu ve aę iindeki parametreleri ve hesaplama sayısını azaltmaktır. Havuzlama iřlemlerinde popler olarak ortalama havuzlama, merkezi pikselden uzaklıęa dayalı aęırlıklı bir ortalama, maksimum havuzlama ve L2-norm havuzlama algoritmaları kullanılmaktadır. řekil 1.7'de gsterildięi gibi maksimum havuzlama iřlemi, dikdrtgen bir komřulukta maksimum ıktıyı bildirir ve en popler havuzlama iřlemdir (Bengio vd., 2016)



Şekil 1.7 Maksimum havuzlama

Konvolüsyon sinir ağının çıkışı düzleştirme katmanı ve tam bağlantılı çıkış katmanı ile ayarlanır. Düzleştirme katmanında tam bağlantılı katmanın girişindeki veriler tek boyutlu hale getirilir. Tam bağlantılı bir katmandaki nöronlar, önceki katmandaki tüm aktivasyonlarla bağlantılara sahiptir. Tam bağlantılı katman sinir ağının öğrenme işleminin gerçekleştiği katmandır. Çıkış katmanında genellikle softmax aktivasyon fonksiyonu seçilir.

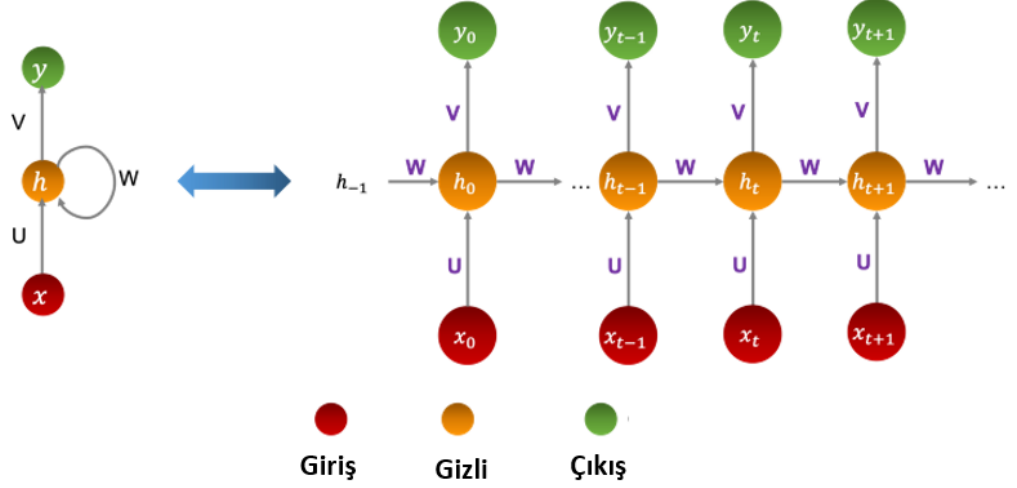
### 1.6.9 Tekrarlayan Sinir Ağı ve Uzun Kısa Vadeli Hafıza

Tekrarlayan Sinir Ağı, Eşitlik 1.9’da formüle edilen, gizli düğüm çıkışı  $h_t$ ’nin mevcut değerinin önceki  $h_{t-1}$  birime ve akım girişi  $x_t$ 'ye göre güncellendiği tekrarlayan bağlantılara sahip sinir ağıdır (Mostafa vd., 2019b). RNN, birbirine bağlı nöronların ve girişin döngülü bir mimarisidir; son gizli durum, bir sonraki gizli durumun çıktısını etkiler.

$$h_t = f(W^{x,h}, x_t + W^{h,h} h_{t-1} + b) \quad (1.9)$$

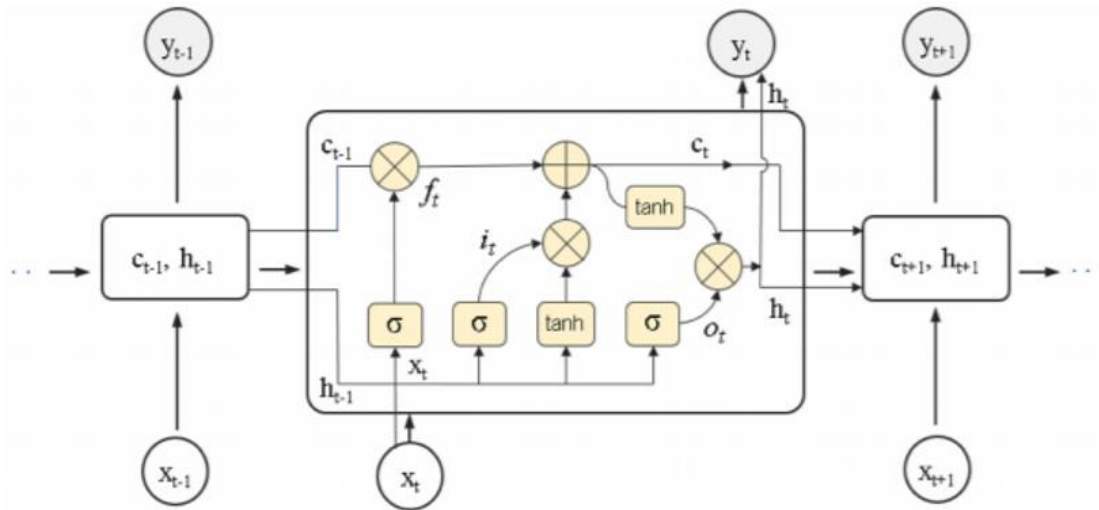
Burada f aktivasyon fonksiyonu, b bias,  $W^{x,h}$  t anındaki ağırlık matrisi,  $W^{h,h}$  t – 1 anındaki ağırlık matrisidir. Şekil 1.8’de RNN yapısı gösterilmiştir. Şekilde U, V ve W ağırlıklarıdır. Solda sıkıştırılmış şema ve sağda açılmış versiyonu vardır. RNN’ler üst ve alt katman nöronları arasındaki dairesel bağlantılardan ve isteğe bağlı kendi kendine geri bildirim bağlantılarından kaynaklanan dinamik bir yapıya sahiptir. Geri bildirim bağlantıları, RNN’lerin verileri önceki olaylardan mevcut işlem

adımlarına yaymasını sağlar. Böylece, RNN'ler zaman serisi olaylarının bir hafızasını oluşturur. RNN'ler bilgileri işlemek için belleklerini kullanabildikleri için el yazısı tanıma ve konuşma tanıma gibi alanlarda uygulanabilirler (Sherstinsky, 2020).



Şekil 1.8 Tek birimli RNN yapısı

Uzun Kısa Vadeli Hafıza (LSTM), zaman adımlarının etkisinin basit bir RNN ile mümkün olandan daha uzağa geçmesine izin veren bir RNN çeşididir (Hochreiter ve Schmidhuber, 1997). LSTM, zaman içinde zamansal ilişkileri öğrenmeyi kolaylaştırmak için bellek hücrelerine sahip RNN' nin basit bir uzantısıdır. Şekil 1.9'da temel bir LSTM yapısı gösterilmiştir.



Şekil 1.9 LSTM yapısı (Urtnasan vd., 2020)

LSTM’de her bellek hücresi giriş kapısı ( $i_t$ ), çıkış kapısı ( $o_t$ ) ve unutma kapısı ( $f_t$ ) olmak üzere üç ana kapı içerir (Staudemeyer ve Morris, 2019). Giriş kapısı, giriş aktivasyonlarının bellek hücresine akışını kontrol eder. Çıkış kapısı, hücre aktivasyonlarının ağın geri kalanına çıkış akışını kontrol eder. Unutma kapısı, hücrenin kendi kendini tekrarlayan bağlantısı aracılığıyla girdi olarak eklemeyen önce hücrenin iç durumunu ölçer.

#### **1.6.10 Derin Sinir Ağları**

Geleneksel sinir ağları bir veya iki gizli katmandan oluşan sinir ağları olarak tanımlanır. Derin sinir ağları ise ikiden fazla gizli katmandan oluşan sinir ağları olarak tanımlanmaktadır. (Canziani vd., 2016).

## 2. LİTERATÜR TARAMASI

Hafezi vd. (2020), PSG kayıtları ile birlikte kaydettikleri trakeal solunum sinyalleri kullanarak uyku apnesi tespiti çalışmışlardır. Sinyallerden 25 öznitelik çıkarmışlardır. CNN ve LSTM'nin kombinasyonundan oluşan hibrit bir derin öğrenme algoritması ile sınıflandırma yapmışlardır. Sınıflandırma sonucunda doğruluk %84; hassasiyet %81 ve seçicilik %87 bulunmuştur.

Bozkurt vd. (2020), EKG sinyalinden türetilmiş KHD sinyallerini kullanarak uyku apnesi tespiti yapmışlardır. EKG sinyallerinden çıkarılan öznitelikleri karar ağacı, destek vektör makineleri, K en yakın komşu algoritması ve bu üç sınıflandırıcı algoritmasından oluşan bir grup sınıflandırıcı ile sınıflandırmışlardır. Çalışma sonunda 3 öznitelik kullanarak yapılan sınıflandırma sonucunda %82,11 doğruluk ve 13 öznitelik kullanarak yapılan sınıflandırma sonucunda %85,12 doğruluk elde etmişlerdir. 3 öznitelik için hassasiyet ve seçicilik değerlerinin ikisini de %82 bulmuşlardır.

Fatimah vd. (2020), uyku apnesi tespiti çalışmalarında birer dakikalık bölütlere ayırdığı tek kanallı EKG sinyalini kullanmışlardır. Bölütlere ayrılan sinyallerden HFD kullanarak öznitelikler elde etmişler ve dört farklı makine öğrenme algoritmaları kullanılarak EKG bölütlerini sınıflandırmışlardır. Sınıflandırmada %92,59 doğruluk; %89,70 hassasiyet; %94,67 seçicilik ve %91,27 kesinlik değerleri ile DVM sınıflandırıcısı en yüksek başarımlarına ulaşan algoritma olmuştur.

Faust vd. (2021), EKG sinyallerinden uyku apnesi tespiti yapmışlardır. EKG sinyallerine bant geçiren filtre uygulamış ve RR aralıklarını elde etmişlerdir. Elde ettikleri verileri ilk olarak 10 katlı çapraz doğrulama yöntemi kullanarak LSTM sınıflandırıcısı ile sınıflandırmışlar ve çalışmalarında %99,80 doğruluk; %99,85 hassasiyet ve %99,73 seçicilik elde etmişlerdir. İkinci olarak dışarıda tutma (holdout validation) yöntemi kullanarak sınıflandırma yapmışlar ve aynı ağ ile %81,30 doğruluk; %59,90 hassasiyet ve %91,75 seçicilik elde etmişlerdir. Tasarım sırasında, bant geçiren filtrenin sınıflandırma doğruluğunu %20'nin üzerinde iyileştirdiğini belirtmişlerdir.

Mashrur vd. (2021), EKG sinyallerini kullanarak OUA tespit etmek için Skalogram Tabanlı Evrişimsel Sinir Ağı (SCNN) kullanmıştır. Apne-EKG veri setinde, önerilen model segment başına sınıflandırmada %94,30 doğruluk; %94,30 hassasiyet; %94,51 seçicilik ve %95,85 F1 puanı elde etmişlerdir. Model ile ayrıca UCDDDB veri kümesi (University College Dublin database) için %81,86 doğruluk; %71,62 hassasiyet; %86,05 seçicilik ve %69,63 F1 puanı elde etmişlerdir.

Taran vd. (2021), EEG sinyalleri kullanarak uyku apnesi sınıflandırması yapmışlardır. EEG sinyallerine dalgacık dönüşümü uygulayarak öznelikleri elde etmiş ve diskriminant analiz, karar ağacı ve topluluk sınıflandırıcı algoritmaları ile sınıflandırma yapmışlardır. En yüksek doğruluk değerini topluluk sınıflandırma tekniği alt alanı K en yakın komşuluk algoritması ile %96 olarak bulmuşlardır.

Uyku apnesi çalışmalarında EKG sinyalleri en çok tercih edilen sinyaldir. Sinyal işleme çalışmasında Fourier dönüşümü ve Dalgacık dönüşümü sıklıkla tercih edilmektedir. Son yıllarda sınıflandırma algoritması olarak derin öğrenme mimarileri daha çok tercih edilmektedir. Tablo 2.1’de 2020 yılından önce yapılan çalışmalara ait literatür taraması verilmiştir.

Tablo 2.1 2000-2019 yılları arası literatür taraması

Yapılan Çalışmalar	Yıl	Veri	Kullanılan Sinyal	Sinyal İşleme Yöntemi	Sınıflandırma Algoritması	Sonuçlar %
Schrader vd., 2000	2000	Marburg Uyku Laboratuvarı Physionet	EKG	Dalgacık ve Fourier Dönüşümü	LDA	Hassasiyet: 90,8 Seçicilik: 92,7
Drinnan vd., 2000	2000	Physionet Apnea-ECG	EKG	Fourier Dönüşümü	Eşikleme	Doğruluk: 90,0
Fontenla-Romero vd., 2005	2005	120 Apne Kaydı	Toratik Efor Sinyali	Dalgacık Dönüşümü	İleri Beslemeli Sinir Ağı	Doğruluk: 83,78
Khandoker, Palaniswami, vd., 2009	2009	Physionet Apnea-ECG	EKG	Dalgacık Dönüşümü	DVM	Doğruluk: 97,59 Hassasiyet:98,46 Seçicilik: 94,44
Eiseman vd., 2011	2011	SHHS Veri Tabanı	PSG, EKG	-	KEK, Naive Bayes, DVM	Seçicilik: 96,5 Hassasiyet: 59,0
Maali ve Al-Jumaily, 2013	2013	Concord Hastanesi/Sidney (5 hasta)	Göğüs ve Toratik Hareket	Dalgacık Dönüşümü	YSA	AUC: 0,8662
Almazaydeh vd., 2013	2013	50 Kişinin Solunum Verileri	Solunum	Hızlı Fourier Dönüşümü	Konuşma Algılama Algoritması	Doğruluk: 97,0
Rachim vd., 2014	2014	Physionet Apnea-ECG	SpO <sub>2</sub>	Dalgacık Dönüşümü	DVM	Doğruluk: 97,20 Hassasiyet:92,65 Seçicilik: 94,3
Kaguara ve Kaguara, 2015	2015	Physionet Apnea-ECG	EKG	-	DNN	Doğruluk: 90,0
Avcı ve Akbaş, 2015	2015	Physionet Apnea-ECG	Respirasyon Sinyali	Dalgacık Dönüşümü	AdaBoost, RO, RS	Doğruluk: 98,68
Kaguara ve Kaguara, 2015	2015	Physionet Apnea-ECG	EKG	-	DNN	Doğruluk: 90,0
Cohen ve Chazal, 2015	2015	Ulusal İşbirlikçi Evde Bebek İzleme Değerlendirmesi (CHIME) veriseti	EKG, SpO <sub>2</sub>	Hızlı Fourier Dönüşümü	LDA	Doğruluk: 66,7 Hassasiyet: 67,0 Seçicilik: 58,1
Andreotti vd., 2018	2018	Physionet Sleep-EDF, Montreal Uyku Araştırmaları Arşivi	EEG, EOG, EMG	-	CNN, RNN	Doğruluk: 99,6
Emoto vd., 2018	2018	Anan Kyoei Hastanesi	Solunum Sinyalleri	-	YSA	Doğruluk: 91,79 Hassasiyet: 89,9 Seçicilik:92,96
Nakano vd., 2019	2019	PSG Kayıtları	Trakeal Sesler	-	DNN	Hassasiyet: 92,0 Seçicilik: 94,0 AUC 98,0
Lakhan vd., 2019	2019	OUAHS Veri Seti	PSG- AF	-	DVM, DNN, AB-CART	Doğruluk: DNN 63,70 DVM 51,85 AB-CART 45,93

### 3. YÖNTEM

Bu tez çalışmasında EKG sinyallerinden farklı makine öğrenmesi ve derin öğrenme algoritmaları kullanılarak uyku apnesi tespiti çalışması yapılmıştır. Çalışma iki aşamadan oluşmaktadır. İlk olarak birer dakikalık bölütlere ayrılan EKG kayıtlarından bölütlere dayalı apne sınıflandırılması yapılmıştır. Bölütlere dayalı sınıflandırmada Makine Öğrenmesi yöntemleri ile sınıflandırma ve Derin Öğrenme yöntemleri ile sınıflandırma olmak üzere iki farklı aşamadan oluşmaktadır. Çalışmanın ikinci aşamasında her bir bölütün apne sınıflandırılması yapılan ilk aşamanın sınıflandırma sonuçları kullanılarak farklı kişilere ait kayıtların her birinin OUA hastası olup olmadığının tespiti yapılmıştır.

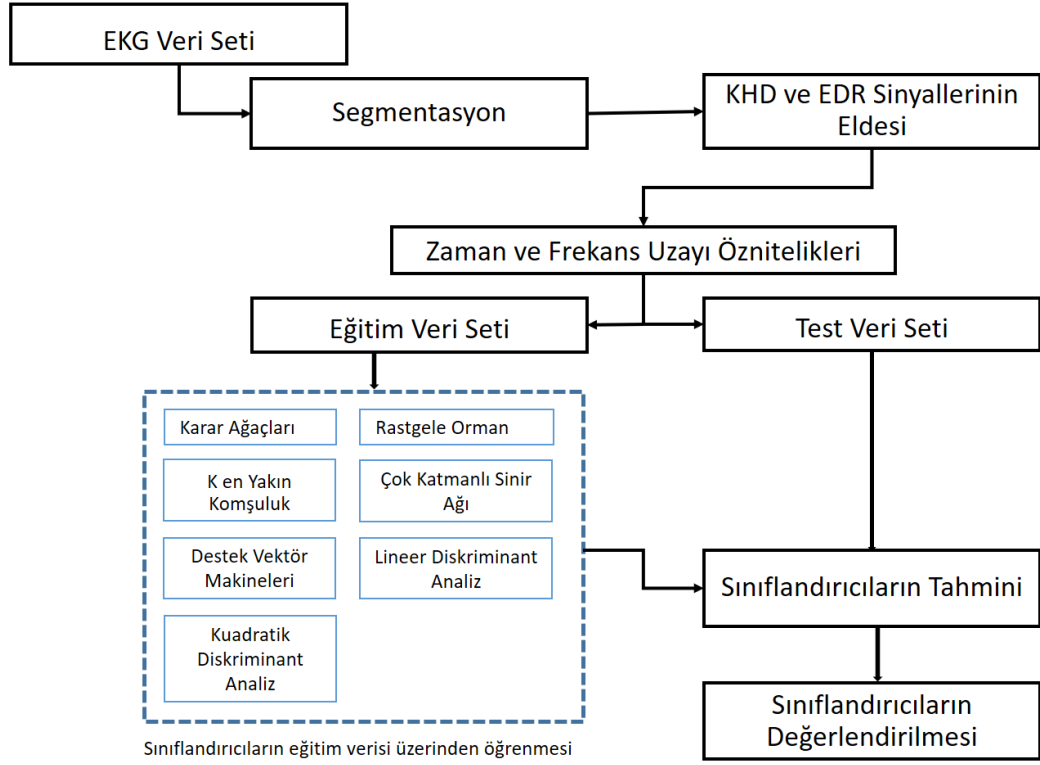
Bu tez çalışmasında Python 3.7 programı ve Keras, Numpy, Matplotlib, Scipy, Sklearn, Tensorflow, Os, Pickle, Wfdn, Biospy, Pandas, Tqdm, Hrvanalysis, Warnings, Math, Biosppy kütüphaneleri kullanılmıştır.

#### 3.1 Bölütlere Dayalı Sınıflandırma

Çalışmanın bu kısmı, bölüt sınıflandırma veya dakika dakika sınıflandırma olarak adlandırılmaktadır. Amaç her bir dakikalık EKG segmentini apne veya normal bölütler olarak sınıflandırmaktır.

##### 3.1.1 Makine Öğrenmesi Yöntemleri Kullanılarak Sınıflandırma

Tez çalışmasının birinci bölümünde EKG sinyallerinden Welch metodu kullanılarak elde edilen KHD ve EDR sinyallerinden klasik makine öğrenmesi algoritmaları kullanılarak apne tespiti yapılmıştır. Çalışmanın bu kısmına ait akış şeması Şekil 3.1'de verilmiştir. Çalışmamız sırasıyla veri setinin elde edilmesi, birer dakikalık bölütlere ayrılan sinyallerin R tepe noktasının belirlenerek KHD ve EDR sinyallerinin elde edilmesi, KHD sinyallerinden 25 adet ve KHD ve EDR sinyallerinden 34 adet olmak üzere özniteliklerin belirlenmesi, yedi farklı sınıflandırıcı ile sınıflandırma yapılması ve değerlendirme aşamalarından oluşmaktadır.



Şekil 3.1 Makine öğrenmesi akış şeması

### 3.1.1.1 Veri seti

Çalışmamız Physionet Apnea ECG veri seti kullanılarak yapılmıştır. Veri seti 35 test ve 35 eğitim seti olmak üzere 70 kayıttan oluşmaktadır. ‘dat’ uzantılı dosyalar sinyalleri, ‘apn’ ve ‘qrs’ uzantılı dosyalar ise etiket (label) dosyalarıdır. Veri setinde apne olan zamanlar ‘A’ ile apne olmayan zamanlarsa ‘N’ ile etiketlenmiştir.

Veri setinde üç grup kayıt bulunmaktadır. İlk grup 20 kayıttan oluşmaktadır ve bu kişilerin kayıtlarının 100 dakikadan fazlası apneli kayıttır. İkinci grupta 5 kişinin kaydı bulunmaktadır ve bu kişilerin kayıtlarındaki apne sayısı 5-99 dakika arasındadır. Üçüncü grup kayıtlar 10 kişiden oluşmaktadır ve bu kişilerin kayıtlarındaki apneli dakika sayısı 5’ten azdır.

Kısaca veri setinin eğitim grubunda 20 hasta kaydı (a01-a20), 5 apne sınırında kayıt (b01-b05) ve 10 sağlıklı kayıt (c01-c10) vardır. Test grubunda 35 kişinin kaydı bulunmaktadır (x01-x35).

### 3.1.1.2 Ön işleme

İlk olarak 35 test ve 35 eğitim sinyalinden oluşan Physionet veri bankasından elde edilen ‘Apnea ECG’ veri setinde bulunan her sinyal tek tek okunarak kaydedilmiştir.

Ardından her bir sinyal birer dakikalık bölütlere ayrılmıştır. Bölütlere ayrılan sinyallerden gürültü içeren kısımlarının temizlenmesi için bant aralığı 3-45 Hz olan Sonsuz Dürtü Yanıtı (Finite Impulse Response - FIR) bant geçiren filtre uygulanmıştır. Filtre uygulanan sinyallerden R tepe noktası tespiti yapılmıştır. R tepe noktasını belirlenmesinde dikkat edilmesi gereken aşağıda listelenen belli başlı kurallar vardır.

- Daha büyük tepelerden önce veya sonra 200 ms'den daha kısa sürede gelen tüm tepeler yok sayılmalıdır.
- Bir tepe meydana gelirse, EKG sinyalinin hem pozitif hem de negatif eğimler içerip içermediği kontrol edilir. Değilse, tepe bir temel kaymayı temsil eder.
- Tepe, önceki bir tespitten sonraki 360 ms içinde meydana gelmişse ve maksimum eğimi, önceki tespitin maksimum eğiminin yarısından daha azsa, bunun bir T-dalgası olduğu varsayılır.
- Tepe, algılama eşiğinden daha büyükse QRS kompleksi olarak, aksi takdirde gürültü olarak adlandırılır.
- Ortalama iki R tepe aralığının 1,5 katına eşit bir aralık, bu aralık içindeki en son tespitten bu yana geçiyse, tespit eşiğinin yarısından daha büyük bir tepe varsa ve tepe, önceki tespitten en az 360 ms sonra ise bu tepe QRS kompleksi olarak sınıflandırılır.

Literatürde R dalgalarının tespitinde dalgacık dönüşümü, Hamilton algoritması ve Pan-Tomkins algoritması gibi yöntemler kullanılmaktadır (Diker vd., 2019). Yukarıda listelenen kurallara dikkate edilerek tüm R tepe noktaları Hamilton algoritması kullanılarak tespit edilmiştir. R tepe noktalarının belirlenmesinde fazladan R tepe noktası belirlenmesi veya R tepe noktasının eksik belirlenmesi gibi problemlerle

karşılaşılmaktadır. Bu problemleri aşmak için kernel boyutu 3 olan ortalama (medyan) filtre uygulanmıştır.

Son olarak elde edilen R tepelerinde iki R tepesi aralığı olan KHD ve R tepe noktalarına karşılık gelen frekans bilgisini içeren EDR sinyalleri tespit edilmiştir. KHD ve EDR sinyallerinin bilgileri sağlıklı ve apneli kişiler arasında farklılıklar göstermektedir. Bu bilgiler kullanılarak bir sonraki aşamada öznitelik belirleme çalışması yapılmıştır.

### 3.1.1.3 Öznitelik belirleme

Elde edilen KHD ve EDR sinyallerinden zaman uzayı ve frekans uzayından farklı öznitelikler elde edilmiştir. Zaman uzayı özniteliklerinin belirlenmesi için istatistiksel yöntemler kullanılmıştır. KHD sinyallerinden Tablo 3.1’de açıklamaları verilen 16 adet zaman uzayı öznitelikleri elde edilmiştir.

Tablo 3.1 Zaman uzayı öznitelikleri

Öznitelikler	Açıklama
Mean_nni	Ardışık kalp atışı aralıklarının ortalaması
Sdnn	Ardışık normal kalp atışları arasındaki zaman aralığının standart sapması
Sdsd	Bitişik RR aralıkları arasındaki farklılıkların standart sapması
Rmssd	Bitişik RR aralıkları arasındaki farkların karelerinin toplamının ortalamasının karekökü
Median_nni	RR aralıkları arasındaki ardışık farklılıkların ortalama mutlak değerleri
Nni_50	50 ms'den büyük ardışık RR aralıklarının aralık farklarının sayısı
Pnni_50	50 ms'den büyük ardışık RR aralıklarının aralık farklarının sayısının toplam RR aralıklarının sayısına bölünmesiyle elde edilen oran

Tablo 3.1'in devamı

Nni_20	20 ms'den büyük ardışık RR aralıklarının aralık farklarının sayısı
Pnni_20	20 ms'den büyük ardışık RR aralıklarının aralık farklarının sayısının toplam RR aralığı sayısına bölünmesiyle elde edilen oran
Range_nni	Maksimum ve minimum RR aralıkları arasındaki fark
Cvvd	Rmssd'ye eşit olan ardışık farklılıkların değişim katsayısının ortalama RR aralıklarına bölünmesi
Cvnni	Sdnn oranının Median_nni'ye bölünmesine eşit varyasyon katsayısı
Mean_hr	Ortalama kalp hızı
Max_hr	Maksimum kalp hızı
Min_hr	Minimum kalp hızı
Std_hr	Kalp hızının standart sapması

KHD'nin frekans bilgisi kalbin çalışma hızını vermektedir. Frekans spektrumunun analizinde elde edilen her bir bölütün GSY hesaplanmıştır. GSY, adını Peter D. Welch'ten alan ve Hızlı Fourier Dönüşümü temelli olan Welch yöntemi kullanılarak yapılmıştır. Güç spektral yoğunluğu, yüksek frekans, alçak frekans ve çok alçak frekans bölgelerinden oluşmaktadır. Uyku apnesi olan kişilerde KHD'nin güç spektral yoğunluğundaki AF bölgesinin toplam enerjisi daha büyük çıkmaktadır. GSY bilgisine göre Tablo 3.2'de açıklamaları verilen 9 adet frekans uzayı öznitelikleri hem KHD sinyalleri için hem EDR sinyalleri için hesaplanmıştır.

Elde edilen öznitelik değerlerinin yayılımını dengelemek için normalizasyon yapılmıştır. Normalizasyon yöntemi olarak en küçük değeri 0, en büyük değeri 1'e eşitleyerek değerlerin 0 ile 1 arasına dağılımını sağlayan ve hesaplama formülü Eşitlik 3.1'de verilen min-max normalizasyon yöntemi seçilmiştir.

$$z = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.1)$$

Tablo 3.2 Frekans uzayı öznitelikleri

Öznitelikler	Açıklama
Total_power	Toplam güç yoğunluğu spektrumu
VLF	Çok düşük frekansta (0,003 - 0,04 Hz) KHD'deki varyans
LF	Alçak frekansta (0,04 - 0,15 Hz) KHD'deki varyans
HF	Yüksek frekansta (0,15 - 0,40 Hz) KHD'deki varyans
LF/HF	Alçak frekans varyansının yüksek frekans varyansına oranı
LFnu	Normalize edilmiş alçak frekansın gücü
HFnu	Normalize edilmiş yüksek frekansın gücü
HF/LFnu	Yüksek frekans varyansının normalize edilmiş alçak frekansın gücüne oranı
LF/HFnu	Alçak frekans varyansının normalize edilmiş yüksek frekansın gücüne oranı

Elde edilen KHD ve EDR özniteliklerinde öznitelik seçilimi yapılmıştır. Bunun için Varyans Eşiği (Variance Threshold) yöntemi kullanılmıştır. Varyans Eşiği, öznitelik seçimine yönelik basit temel bir yaklaşımdır. Varyansı bir eşiğini karşılamayan tüm öznitelikleri kaldırır. Varsayılan olarak, tüm sıfır varyans özniteliklerini, yani tüm örneklerde aynı değere sahip olan öznitelikleri kaldırır.

#### 3.1.1.4 Sınıflandırma

Özellik seçilimi yapıldıktan sonra karar ağaçları, rastgele orman, K en yakın komşuluk, çok katmanlı sinir ağı, destek vektör makineleri, lineer diskriminant analiz ve kuadratik diskriminant analiz kullanılarak sınıflandırma çalışması yapılmıştır. Sınıflandırma KHD sinyallerinden elde edilen 25 öznitelik için ve KHD ve EDR sinyallerinden elde edilen 35 öznitelik için iki ayrı aşamada yapılmıştır. Öznitelik sayısının sınıflandırıcı performansı üzerindeki etkileri gözlemlenmek istenmiş ve elde

edilen sonuçlar Bölüm 4'te verilmiştir. Her iki durum için aynı sınıflandırıcılar kullanılmıştır. Destek vektör makinesi sınıflandırıcısında sınıflandırma çalışmaları için Sigmoid, Gaussian, Lineer ve Polinomial gibi farklı kernel tipleri mevcuttur. Çalışmada 4 farklı kernel için sınıflandırma ayrı ayrı yapılmıştır. KEK algoritması için 3-15 arasındaki komşuluk değerleri için Öklid, Manhattan, Minkowski ve Hamming uzaklık hesaplama fonksiyonları ayrı ayrı denenmiş ve yüksek doğruluk veren fonksiyon sonuçları bulgulara eklenmiştir. ÇKS modeli giriş katmanı, çıkış katmanı ve eğitim verisinin uzunluğunun yarısı kadar da gizli katmandan oluşmaktadır.

### 3.1.1.5 Değerlendirme

Sınıflandırma sonuçlarının başarı değerlendirmesi karışıklık matris değerlerine göre hesaplanan doğruluk, hassasiyet ve seçicilik değerleri ile ölçülmektedir (Subasi ve Gursoy, 2010). Ayrıca Alıcı Operatör Özellikleri Eğrisi (Receiver Operator Characteristics Curve - ROC eğrisi) grafiği çizdirilerek Eğri Altında Kalan Alan (Area Under the Curve - AUC) değerinin hesaplanması ile çalışmaların başarı ölçütü ortaya konulmaktadır. Tablo 3.3'te karışıklık (confusion) matrisi verilmiştir.

Tablo 3.3 Karışıklık Matrisi

KARIŞIKLIK MATRİSİ		Yanlış Sınıflama	Doğru Sınıflama
		0	1
Hasta Değil	0	TN	FP
Hasta	1	FN	TP

Karışıklık matrisinin her bir hücrenin ifade ettiği açıklamaların açıklamaları şu şekildedir:

Gerçek pozitif (True Positive - TP) sayısı; gerçekte pozitif olan ve modelin de pozitif sonucunu verdiği toplam olgu sayısıdır.

Gerçek negatif (True Negative - TN) sayısı; gerçekte negatif olan ve modelin de negatif sonucunu verdiği toplam olgu sayısıdır.

Yanlış pozitif (False Positive - FP) sayısı; gerçekte negatif olan fakat modelin pozitif sonucunu verdiği toplam olgu sayısıdır.

Yanlış negatif (False Negative - FN) sayısı; gerçekte pozitif olan fakat modelin negatif sonucunu verdiği toplam olgu sayısıdır.

Karışıklık matrisinden elde edilen ve doğruluk metriklerimiz olan doğruluk; hassasiyet; seçicilik, F1 puanı ve ROC eğrisi terimlerinin açıklaması aşağıda verilmiştir.

**Doğruluk:** Sınıflandırma sonucunda doğru olarak sınıflandırılan ögelerin tüm ögelere oranını verir. Eşitlik 3.5'te verilen formüle göre hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.5)$$

**Hassasiyet:** Pozitif olarak sınıflandırılan ögelerin gerçekte pozitif olan ögelere oranını verir. Eşitlik 3.6'da verilen formüle göre hesaplanmaktadır.

$$\text{Hassasiyet} = \frac{TP}{TP + FN} \quad (3.6)$$

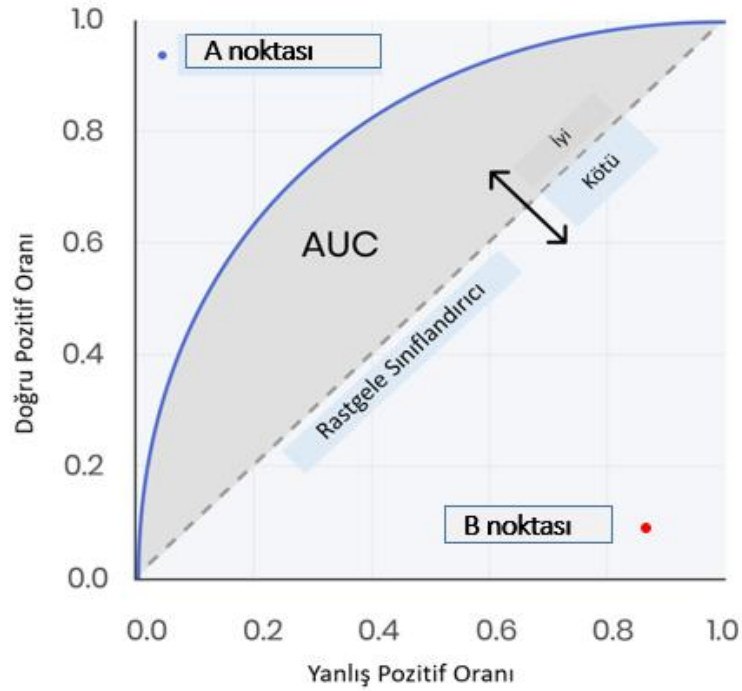
**Seçicilik:** Pozitif olarak sınıflandırılmayan ögelerin gerçekte pozitif olan ögelere oranını verir. Eşitlik 3.7'de verilen formüle göre hesaplanmaktadır.

$$\text{Seçicilik} = \frac{FP}{FP + TN} \quad (3.7)$$

**F1 Puanı:** Hassasiyet ve seçicilik arasında genellikle ters bir ilişki vardır. Yani, hassasiyeti azaltma pahasına kesinliği artırmak veya tam tersi mümkündür. Bu nedenle bunları, hassasiyet ve seçiciliğin harmonik ortalamasını hesaplayan F1 puanı gibi tek bir ölçü olarak birleştirmek daha kullanışlıdır. Eşitlik 3.8'de verilen formüle göre hesaplanmaktadır.

$$F1 \text{ Puanı} = \frac{2*TP}{2*TP + FP + FN} \quad (3.8)$$

**ROC Eğrisi Altındaki Alan:** Bir sınıflandırıcının rastgele seçilen bir pozitif örneği rastgele seçilen bir negatif örnekten daha yüksek derecelendirme olasılığını temsil eder (Yang ve Berdine, 2017). Bu nedenle, AUC, bir sınıflandırıcının içsel geçerliliğini değerlendirmek için etkili ve birleşik bir hassasiyet ve seçicilik ölçüsü olarak tanımlanır. Eğrinin altındaki alan, yanlış pozitif oranı Şekil 3.2'deki gibi gerçek pozitif orana göre çizildiğinde eğrinin altındaki alanı temsil eder. Şekilde gösterilen A noktası iyi bir sınıflandırıcı bölgesini, B noktası kötü bir sınıflandırıcı bölgesini göstermektedir. AUC, 0 ile 1 arasında değişir. 0 değeri, modelin tahmininin %100 yanlış olduğu anlamına gelir. 1 değeri, modelin tahmininin %100 doğru olduğu anlamına gelir.



Şekil 3.2 ROC eğrisi altındaki alan

Ayrıca makine öğrenmesi yöntemlerinde model performansının değerlendirilmesinde kullanılan temel performans ölçüm kriterleri arasında; Ortalama Karesel Hata (Mean Squared Error - MSE) , Kök Ortalama Karesel Hata (Root Mean Squared Error - RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE) bulunmaktadır. MSE,

RMSE ve MAE birer hata ölçüsü olduklarından dolayı düşük değerlerin daha iyi performansa işaret ettiği ölçülerdir. Örneğin RMSE sifıra eşit olması durumunda daha iyi performans sonucuna işaret ettiği söylenebilmektedir.

**Ortalama Karesel Hata (MSE):** Sınıflandırıcı modelin tahmin edilen değeri ile gerçek değeri arasındaki hataların karelerinin ortalamasını ölçer (Němcová vd., 2018). Hata  $e_i$  olmak üzere MSE Eşitlik 3.9’da verilen formüle göre hesaplanmaktadır.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (3.9)$$

**Kök Ortalama Karesel Hata (RMSE):** RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların ikinci örnek momentinin karekökünü veya bu farklılıkların ikinci dereceden ortalamasını temsil eder. Eşitlik 3.10’da verilen formüle göre hesaplanmaktadır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (3.10)$$

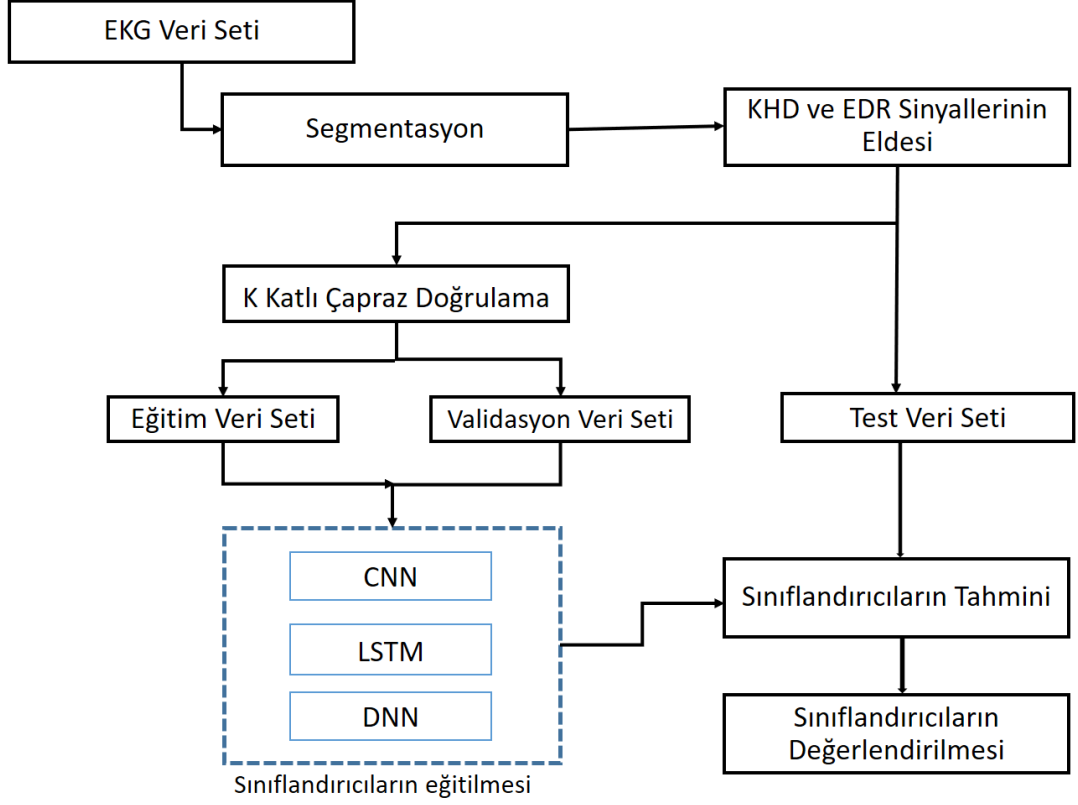
**Ortalama Mutlak Hata (MAE):** MAE, yönlerini dikkate almadan bir dizi tahmindeki hataların ortalama büyüklüğünü ölçer. Tüm bireysel farklılıkların eşit ağırlığa sahip olduğu tahmin ile gerçek gözlem arasındaki mutlak farklılıkların test örneği üzerindeki ortalamasıdır. İki değişken arasındaki farkın bir ölçüsü olarak tanımlanır. Eşitlik 3.11’de verilen formüle göre hesaplanmaktadır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (3.11)$$

### 3.1.2 Derin Öğrenme Yöntemleri Kullanılarak Yapılan Çalışma

Bölütlere dayalı sınıflandırmanın ikinci kısmında EKG sinyallerinden elde edilen KHD sinyallerinden derin öğrenme mimarileri kullanılarak apne tespiti yapılmıştır. Çalışmanın bu kısmına ait akış şeması Şekil 3.3’te verilmiştir. Çalışma sırası ile veri setinin elde edilmesi, birer dakikalık bölütlere ayrılan sinyallerin R tepe noktasının belirlenerek KHD sinyallerinin elde edilmesi, CNN, LSTM ve DNN olmak üzere 3

farklı derin öğrenme mimarisi ile sınıflandırmanın yapılması ve değerlendirme aşamalarından oluşmaktadır.



Şekil 3.3 Derin öğrenme akış şeması

### 3.1.2.1 Veri seti

Derin öğrenme çalışması için makine öğrenmesi aşamasında kullanılan Apnea-ECG veri seti kullanılmıştır. Veri setinin eğitim grubunda 20 hasta kaydı (a01-a20), 5 apne sınırında kayıt (b01-b05) ve 10 sağlıklı kayıt (c01-c10) vardır. Test grubunda 35 kişinin kaydı bulunmaktadır (x01-x35).

### 3.1.2.2 Ön işleme


Veri setinde yaklaşık 7 saatlik kayıtlardan oluşan her bir verinin etiket dosyaları birer dakikalık aralıklarla apneli veya normal olarak etiketlendiği için her bir kayıt birer dakikalık bölütlere ayrılmıştır. Bölütlere ayırma işlemi Hamilton Segmentasyon yöntemi kullanılarak yapılmıştır. Bölütlere ayrılan sinyallerin her bir bölüt için ayrı

ayrı R tepe noktaları belirlenmiştir. Ortalama filtre kullanılarak fazladan R tepe noktası belirleme ve eksik R tepe noktası belirleme sorununun önüne geçilmiştir. Elde edilen R tepe noktası bilgisinden KHD ve EDR sinyalleri elde edilmiştir. Bu sinyaller eğitim ve test verileri olarak kaydedilmiştir.

Derin öğrenme yöntemleri kullanılarak yapılacak sınıflandırma işlemi için ön işleme aşaması tamamlanan sinyaller ve etiket dosyaları eğitim ve test verileri olarak kaydedilmiştir. Eğitim seti uzunluğu 16.711, test seti uzunluğu 16.948'dir.

Bazı çalışmalarda validasyon verisi olarak test verisinin kullanıldığı görülmüştür. Buna karşın validasyon verisi olarak test verisini kullanmak ve sonrasında tahminleme aşamasını yine aynı test verisi ile yapmak çalışmanın güvenilirliği açısından yanlış sonuçlar çıkarılabilmektedir. Bunun için kullanılacak modellerin öğrenme aşamasında eğitim grubunda bulunan verilerin %20'si validasyon seti olarak belirlenmiştir. Test grubu verileri sadece modellerin tahminleme aşamasında test grubu olarak kullanılmıştır. Validasyon verilerini belirleme aşamasında sınıflandırma algoritmaları eğitilirken ezberlemenin önüne geçmek için çapraz doğrulama yöntemi kullanılmıştır.

Çapraz doğrulama, tahmine dayalı modellerin genelleme yeteneğini değerlendirmek ve ezberlemeyi önlemek için kullanılan veri yeniden örnekleme yöntemidir (Berrar, 2018). Çapraz doğrulama yöntemi olarak K katlı çapraz doğrulama yöntemi seçilmiştir. Bu yöntemde veri seti eşit sayıda örnek içeren k adet alt gruba bölünmektedir. Alt gruplardan bir tanesi test olarak diğerleri eğitim olarak seçilmektedir. Yöntemin şekilsel gösterimi Şekil 3.4'te verilmiştir.



Şekil 3.4 K katlı çapraz doğrulama

### 3.1.2.3 Sınıflandırma

#### 3.1.2.3.1 CNN

Bu çalışma kapsamında Evrişimsel Sinir Ağı modeli olarak Tablo 3.3'te gösterilen ve bir giriş katmanı, altı konvolüsyon katmanı, bir tam bağlantılı katman ve bir çıkış katmanından oluşan model uygulanmıştır.

Tablo 3.3 CNN mimarisi

Katman	Filtre	Aktivasyon Fonksiyonu	Çekirdek Boyutu	Adım	Çıkış Boyutu
Giriş					(900, 2)
Konvolüsyon 1	128	ReLU	50	3	(300, 128)
Batch Normalizasyon					(300, 128)
Maksimum Havuzlama			2	3	(100, 128)
Konvolüsyon 2	32	ReLU	7	1	(100, 32)
Batch Normalizasyon					(100, 32)
Maksimum Havuzlama					(50, 32)
Konvolüsyon 3	64	ReLU	10	1	(20, 64)
Konvolüsyon 4	64	ReLU	64	5	(25, 64)
Maksimum Havuzlama			2	2	(12, 64)
Konvolüsyon 5	128	ReLU	5	1	(12, 128)
Konvolüsyon 6	64	ReLU	5	1	(12, 64)
Flatten					768
Dense	128	ReLU			128
Dropout					128
Çıkış		Softmax			2

Modelin giriş katmanının uzunluğu (900,2) matris boyutlarında olan eğitim veri setine göre ayarlanmıştır. Konvolüsyon katmanlarının tamamında aktivasyon fonksiyonu olarak 'ReLU' seçilmiştir. Adım (stride) bilgisi ile filtrenin matris üzerinde ilerleyeceği adım sayısı belirlenmektedir. Tablo 3.5'de katmanlarda kullanılan adım bilgisi verilmiştir. İlk iki konvolüsyon katmanından sonra Yığın Normalleştirme (Batch Normalizasyon) işlemi yapılmıştır. Yığın normalleştirme, özellikle derin öğrenme çalışmalarında son yıllarda tercih edilen ve katmanlar arasındaki kovaryansı azaltmak için kullanılan normalizasyon tekniğidir (Ioffe, 2017). Yığın normalleştirme, öğrenme sürecini stabilize etmek ve derin ağları eğitmek için gereken eğitim epoklarının sayısını önemli ölçüde azaltma etkisine sahiptir.

Düzleştirme (Flatten) katmanında iki boyutlu matris şeklindeki verinin düzleştirilmesi sağlanarak çıkış verileri düzenlenmektedir. Tam bağlantılı (fully connected) katmanın aktivasyon fonksiyonu 'ReLU' olarak ayarlanmıştır. 'Apne' ve 'Normal' olarak iki çıkış veren çıkış katmanında aktivasyon fonksiyonu olarak 'Softmax' seçilmiştir Model tasarlandıktan sonra modeli eğitmek için derleme (compile) işlemi yapılmaktadır. Çünkü eğitim optimizasyonu ve kayıp fonksiyonu kullanılmaktadır. Derleme aşamasında optimizasyon metodu, kayıp değeri, metrikler argümanları ayarlanmaktadır. SGD, Adam, Momentum, Adagrad, Adadelta ve RMSProp yöntemleri hata oranını en aza indirmek için sıklıkla tercih edilen optimizasyon yöntemleridir. Optimizasyon yöntemi olarak 'adam' seçilmiştir. Kayıp fonksiyonu modelin tahmin değerlerinin gerçek değerlerden ne kadar uzak olduğunun hesabıdır. Binary Cross Entropy, Categorical Cross Entropy ve MSE gibi yöntemlerle hesaplanır. Bu çalışmada kayıp fonksiyonu olarak Categorical Cross Entropy yöntemi seçilmiştir. Categorical Cross Entropy yönteminde iki veya daha fazla sınıflı problemlerde tercih edilmektedir. Metrikler, modelin eğitim ve test sırasında değerlendirileceği metrik çeşididir ve bu çalışmada başarı metriği olarak doğruluk seçilmiştir.

CNN modelin toplam parametresi 247.778, eğitilebilir parametresi 247.458'dir. Modelin eğitiminde epok sayısı 75, adım boyutu (batch size) 128 olarak seçilmiştir.

### 3.1.2.3.2 LSTM

Çalışmada kullanılan LSTM modelinin bilgileri Tablo 3.4’te verilmiştir. Model iki LSTM katmanı, üç dense katmanı, bir tam bağlantılı katman ve bir seyreltme (dropout) katmanından oluşmaktadır.

Tablo 3.4 Kullanılan LSTM modeli

Katman	Filtre	Aktivasyon Fonksiyonu	Çıkış Boyutu
LSTM	64	ReLU	(900, 64)
Batch Normalizasyon			(900, 64)
LSTM			(900, 32)
Dense	16	ReLU	(900, 16)
Dense	8	ReLU	(900, 8)
Flatten			7200
Dropout			7200
Çıkış		Softmax	2

Giriş katmanının boyutu eğitim verisinin boyutuna göre ayarlanmıştır. İlk LSTM katmanından sonra yığın normalleştirme yapılmıştır. Modelin ezberlemesinin önüne geçmek için seyreltme (dropout) katmanı kullanılmış ve seyreltme değeri 0,2 olarak seçilmiştir. İki çıkışlı ayarlanan çıkış katmanında aktivasyon fonksiyonu olarak ‘softmax’ kullanılmıştır. Derleme aşamasında CNN model ile aynı metrikler seçilmiştir.

LSTM modelin toplam parametresi 44.890, eğitilebilir parametresi 44.762’dir. Modelin eğitiminde epok sayısı 75, adım boyutu 128 olarak seçilmiştir.

### 3.1.2.3.3 DNN

Çalışmada kullanılan DNN modelinin bilgileri Tablo 3.5’te verilmiştir. DNN model 7 dense katman, 2 seyreltme katman, 1 tam bağlantılı katman ve çıkış katmanından

oluşmaktadır. Dense standart bir katman türüdür. Modelde Dense katmanların aktivasyon fonksiyonları ReLU, çıkış katmanının aktivasyon fonksiyonu Softmax olarak seçilmiştir. Seyreltme katmanlarından ilkinin kesim oranı 0,2 ve ikincisi 0,3 seçilmiştir.

Tablo 3.5 DNN model

<b>Katman</b>	<b>Filtre</b>	<b>Aktivasyon Fonksiyonu</b>	<b>Çıkış Boyutu</b>
Dense	128	ReLU	(900, 128)
Dense	64	ReLU	(900, 64)
Dense	256	ReLU	(900, 256)
Dense	64	ReLU	(900, 64)
Dropout			(900, 64)
Dense	128		(900, 128)
Dense	64		(900, 64)
Flatten			57600
Dense	32		32
Dropout			32
Çıkış		Softmax	2


DNN modelin toplam parametresi ve eğitilebilir parametresi 1.872.674'dir. Modelin eğitiminde epok sayısı 75, adım boyutu 128 olarak seçilmiştir.

#### 3.1.2.4 Başarı iyileştirme

Modellerin başarı oranının iyileştirilmesi için çeşitli yöntemler uygulanmıştır. Her modelde seyreltme kullanılmıştır. Seyreltme ile tam bağlantılı katmanlardaki bağlar koparılarak düğümlerin ağırlık değişimlerinden daha az etkilenmesi sağlanır.

Modellerin ezberlemesinin önüne geçmek için Erken Durdurma (Early Stopping) denilen ezberlemeden önce durdurma yöntemi kullanılmıştır. Erken durdurma ile model eğitim ve validasyon verisinin öğrenme aşamasında ezberlemenin önüne

geçilmesi sağlanır. Şekil 3.5'te gösterildiği şekilde her bir epokta validasyon kayıp veya validasyon doğruluk değerlerinde değişimin olup olmadığı ve validasyon hatasının yükselmeye başlayıp başlamadığı kontrol edilir. Çalışmada erken durdurma kontrol birimi validasyon kayıp olarak seçilerek her bir epokta validasyon kayıp değerinin azalıp azalmadığı kontrol edilmiştir. Eğitim sırasında gözlemlenen en iyi modeli daha sonra kullanmak üzere kaydetmek için Model Checkpoint geri araması kullanılmıştır.



Şekil 3.5 Erken durdurma

### 3.1.2.5 Değerlendirme

Her bir sınıflandırma işleminden sonra karışıklık matrisi hesaplanmıştır. Elde edilen karışıklık matrisi bilgilerinden makine öğrenmesi aşamasında kullanılan doğruluk; hassasiyet; seçicilik ve F1 puanı başarı metrikleri çalışmanın bu aşamasında da kullanılmıştır. ROC eğrisi çizdirilmiş ve AUC değeri hesaplanmıştır. Her sınıflandırma algoritmasına ait MAE, MSE ve RMSE hataları hesaplanmıştır.

### 3.2 Her Bir Kaydın Sınıflandırması

İlk aşamada bölütlerin apne tespiti yapıldıktan sonra bu kısımda her bir kişiye ait EKG kaydı apne veya normal olarak sınıflandırılmıştır. Bunun için her kayıttaki saat başına apne sayısı olan AHİ standardı kullanılmıştır. AHİ standardına göre bir kayıttaki bir saatteki apneli dakika sayısı 5'ten büyükse o kayıt OUA, değilse normal olarak kabul edilmektedir. AHİ hesaplaması Eşitlik 3.12'de verildiği şekilde yapılmıştır.

$$AHİ = \frac{T}{60}x(OUA \text{ segment sayısı}) \quad (3.12)$$

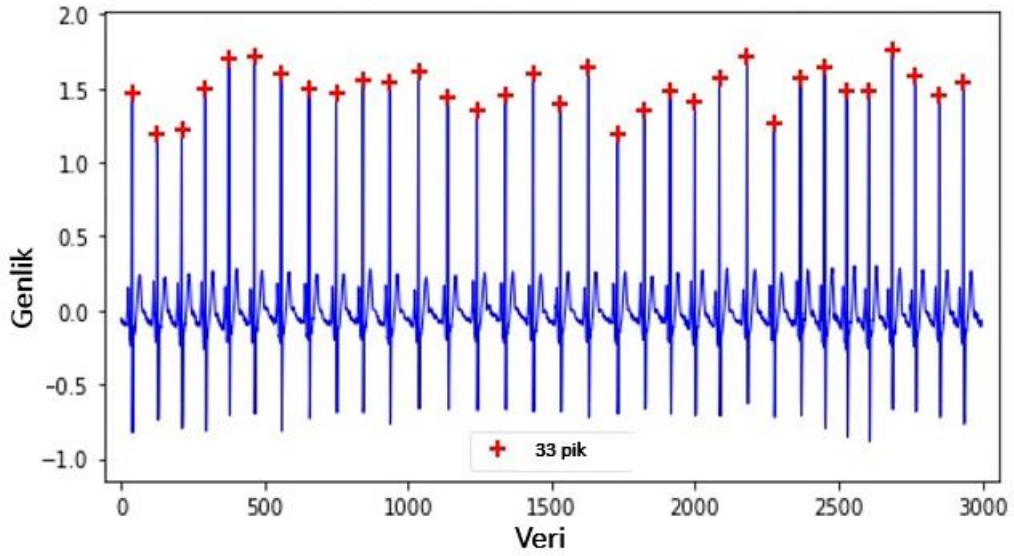
Burada T dakika olarak kaydın uzunluğunu vermektedir. AHİ hesaplandıktan sonra her bir kaydın tahmin edilen durumu ile gerçek durumu karşılaştırılmış ve sınıflandırıcıların performansına ait karışıklık matrisi hesaplanmıştır. Karışıklık matrisi bilgilerinde doğruluk; hassasiyet; seçicilik, F1 puanı ve AUC hesaplanmıştır. Sonuçların karşılaştırılması için MAE, MSE ve RMSE hataları hesaplanmıştır.

## 4. BULGULAR

### 4.1 Bölütlere Dayalı Sınıflandırma Bulguları


#### 4.1.1 Makine Öğrenmesi Yöntemleri Kullanılarak Sınıflandırma

Çalışmanın ilk aşamasında bölütlere dayalı sınıflandırma yapılmıştır. Bunun için 60 saniyelik bölütlere ayrılarak her bir sinyalin R tepe noktaları belirlenmiştir. Şekil 4.1’de örnek olarak göstermek için veri setinde bulunan ‘a07’ numaralı sinyalin bir kısmının Hamilton segmentasyon yöntemi kullanılarak elde edilen R tepe noktaları gösterilmiştir.



Şekil 4.1 ‘a07’ sinyalin R tepe noktaları

KHD sinyalleri elde edilen kayıtlardan GSY elde edilmiştir. Şekil 4.2’de, GSY’nin çok alçak frekans, alçak frekans, yüksek frekans bölgelerini göstermektedir.



Şekil 4.2 Güç spektral yoğunluğu

GSY, sinyallerdeki değişimlerin frekansa bağlı olarak gözlemlenebilmesine olanak sağlamaktadır. GSY analizinde ÇAF, AF ve YF olmak üzere üç temel frekans bölgesi bulunmaktadır. Çok alçak frekans bölgesi 0,015-0,04 Hz; alçak frekans bölgesi 0,04-0,15 Hz ve yüksek frekans bölgesi 0,15-0,4 Hz aralığındadır. Bu üç spektral bölgenin incelenmesi ile kalbin çalışması hakkında bilgi sahibi olunabilir. YF bölgesi solunum esnasındaki parasempatik aktivitenin, AF bölgesi ise hem sempatik hem de parasempatik aktivitenin belirleyicisidir. Ayrıca LF/HF oranı da sempatik sistemin etkilerinin belirlenebilmesi bakımında ayırt edicidir.

#### 4.1.1.1 DVM sınıflandırma sonucu

KHD sinyallerinden elde edilen 25 öznitelik ve KHD ve EDR sinyallerinden elde edilen 34 öznitelik için ayrı ayrı olmak üzere DVM kullanılarak sınıflandırma yapılmıştır. Çekirdek fonksiyonu olarak Polinomial, Lineer, Sigmoid ve Gaussian kernel tiplerinin hepsi ayrı ayrı denenmiş ve sonuçlar Tablo 4.1 ve Tablo 4.2'de verilmiştir.

KHD ve EDR sinyalleri kullanılarak yapılan sınıflandırma sonuçları Tablo 4.1’de verilmiştir. Elde edilen sonuçlara göre KHD ve EDR sinyalleri ile yapılan sınıflandırmada DVM sınıflandırıcısı için en iyi başarı sonuçları Lineer çekirdek fonksiyonu kullanılarak elde edilmiştir. Lineer çekirdek fonksiyonu ile elde edilen doğruluk, hassasiyet, seçicilik ve F1 puanı değerleri sırasıyla %79,3; %85,86; %72,1 ve 0,79 olarak bulunmuştur.


Tablo 4.1 KHD ve EDR sinyallerine ait DVM sınıflandırma sonuçları

Çekirdek Fonksiyonu	Sınıflandırma Sonuçları			
	<i>Doğruluk (%)</i>	<i>Hassasiyet (%)</i>	<i>Seçicilik (%)</i>	<i>F1 Puanı</i>
Gaussian	77,01	79,28	74,52	0,77
Sigmoid	77,82	83,03	72,1	0,77
Polinomial	50,23	87,92	8,91	0,50
<b>Lineer</b>	<b>79,3</b>	85,86	72,1	0,79

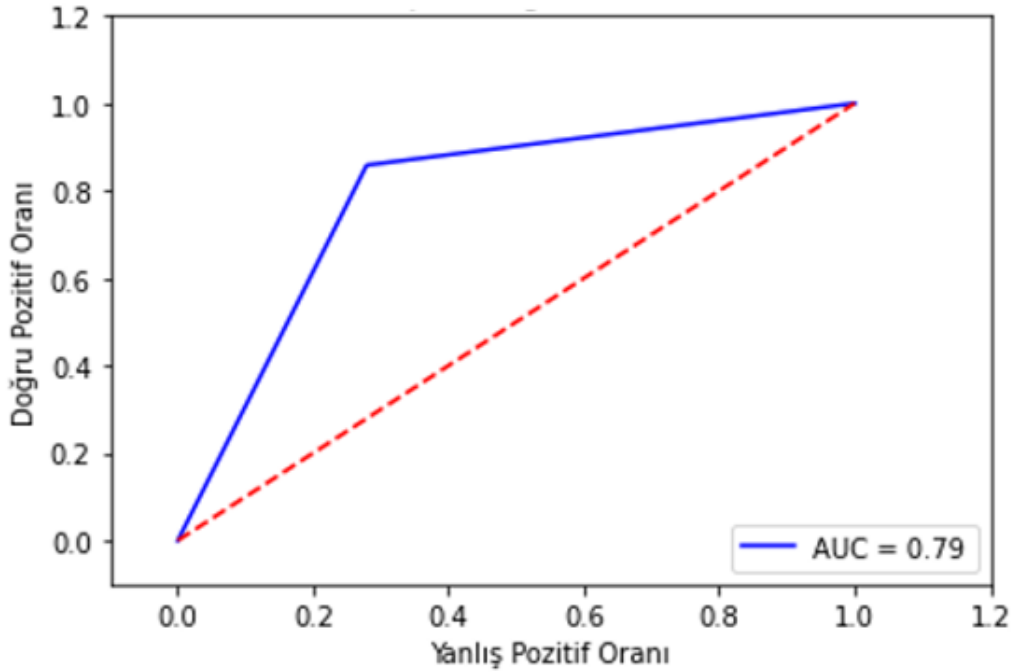
KHD sinyalleri kullanılarak yapılan sınıflandırma sonuçları Tablo 4.2’de verilmiştir. Elde edilen sonuçlara göre KHD sinyalleri ile yapılan sınıflandırmada DVM sınıflandırıcısı için en iyi başarı sonuçları Gaussian çekirdek fonksiyonu kullanılarak elde edilmiştir. Gaussian çekirdek fonksiyonu ile elde edilen doğruluk, hassasiyet, seçicilik ve F1 puanı değerleri sırasıyla %83,99; %74,21; %90,11 ve 0,83 olarak bulunmuştur.

Tablo 4.2 KHD sinyallerine ait DVM sınıflandırma sonuçları

Çekirdek Fonksiyonu	Sınıflandırma Sonuçları			
	<i>Doğruluk (%)</i>	<i>Hassasiyet (%)</i>	<i>Seçicilik (%)</i>	<i>F1 Puanı</i>
<b>Gaussian</b>	<b>83,99</b>	74,21	90,11	0,83
Sigmoid	71,21	71,7	74,16	0,73
Polinomial	71,21	35,01	93,86	0,71
Lineer	81,21	71,65	87,19	0,81



Şekil 4.3 KHD sinyallerinin sınıflandırılmasında DVM - Gaussian kernele ait ROC eğrisi



Şekil 4.4 KHD ve EDR sinyallerinin sınıflandırılmasında DVM - Lineer kernele ait ROC eğrisi

Sınıflandırma performansının değerlendirilmesinde sıklıkla tercih edilen ROC eğrisi grafiği çizdirilmiş ve AUC hesaplanmıştır. Sınıflandırma yapılan her bir çekirdek fonksiyonu için AUC hesaplanmış ve sadece en yüksek AUC değerini veren fonksiyon için grafik verilmiştir. KHD sinyalleri ile sınıflandırma için Gaussian kernele ait grafik

Şekil 4.3'te, KHD ve EDR ile yapılan sınıflandırmada Lineer kernele ait grafik Şekil 4.4'te verilmiştir. KHD sinyalleri için AUC 0,78; KHD ve EDR sinyalleri için AUC 0,79 olarak bulunmuştur.

Sınıflandırma sonuçlarının hata oranlarını hesaplamak için MAE, MSE ve RMSE hataları hesaplanmış ve sonuçlar Tablo 4.3 ve Tablo 4.4'de verilmiştir.

Tablo 4.3 KHD ve EDR sinyallerine ait DVM hata analizi sonuçları

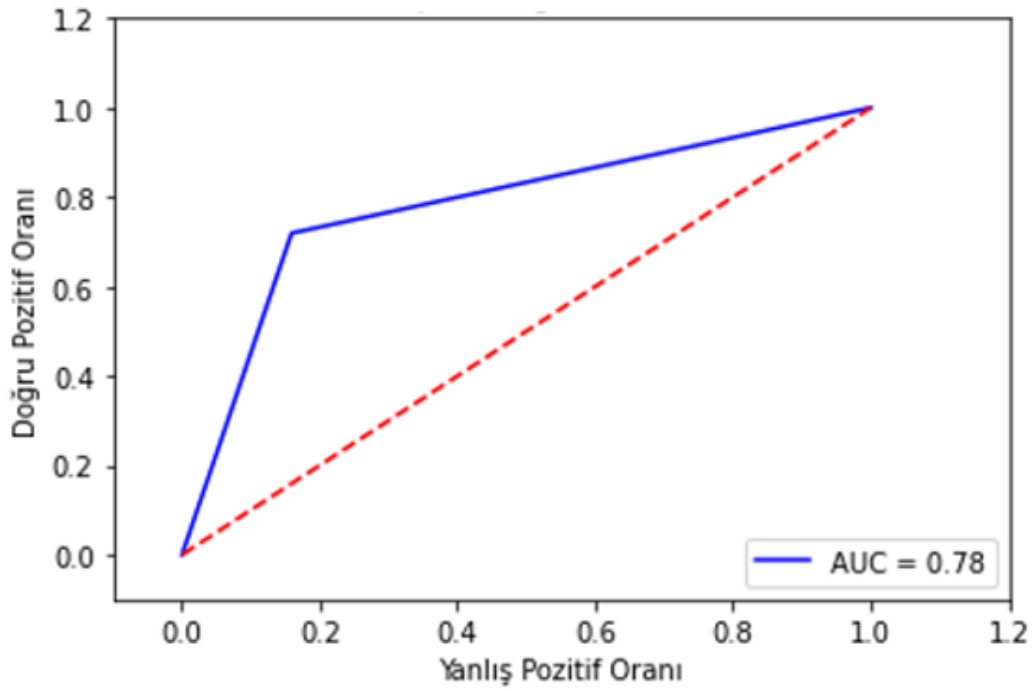
<b>DVM Kernel Tipi</b>	<b>MAE</b>	<b>MSE</b>	<b>RMSE</b>
Gaussian	0,22	0,22	0,47
Sigmoid	0,22	0,22	0,47
Polinomial	0,49	0,49	0,70
<b>Lineer</b>	<b>0,20</b>	<b>0,20</b>	<b>0,45</b>

Tablo 4.4 KHD sinyallerine ait DVM hata analizi sonuçları


<b>DVM Kernel Tipi</b>	<b>MAE</b>	<b>MSE</b>	<b>RMSE</b>
<b>Gaussian</b>	<b>0,16</b>	<b>0,16</b>	<b>0,40</b>
Sigmoid	0,26	0,26	0,51
Polinomial	0,28	0,28	0,53
Lineer	0,18	0,18	0,43

#### 4.1.1.2 KA sınıflandırma sonucu

KA algoritması ile KHD sinyalleri ile yapılan sınıflandırmada %79,41 doğruluk; %71,93 hassasiyet; %84,09 seçicilik ve 0,79 F1 puanı hesaplanmıştır. KHD ve EDR sinyalleri ile yapılan sınıflandırmada %78,22 doğruluk; %83,34 hassasiyet; %72,6 seçicilik ve 0,78 F1 puanı hesaplanmıştır.



Şekil 4.5 KHD sinyallerinin sınıflandırılmasında KA'ya ait ROC eğrisi



Şekil 4.6 KHD ve EDR sinyallerinin sınıflandırılmasında KA'ya ait ROC eğrisi

KA algoritması için ROC eğrisi ve AUC hesaplanmıştır. Şekil 4.5'te KHD sinyalleri için ROC eğrisi grafiği, Şekil 4.6'da KHD ve EDR sinyalleri için ROC eğrisi grafiği gösterilmektedir. KHD sinyalleri için AUC 0,78; KHD ve EDR sinyalleri için AUC


0,78 olarak bulunmuştur. Sınıflandırma sonuçlarının hata oranlarını hesaplamak için MAE, MSE ve RMSE hataları hesaplanmış ve sonuçlar Tablo 4.5'te verilmiştir.

Tablo 4.5 KA hata oranları


Sınıflandırıcı	MAE	MSE	RMSE
KA - KHD ve EDR	0,21	0,21	0,46
KA - KHD	0,20	0,20	0,45

#### 4.1.1.3 RO sınıflandırma sonucu

RO algoritması KHD sinyalleri ile yapılan sınıflandırmada %85,26 doğruluk; %75,44 hassasiyet; %91,4 seçicilik ve 0,85 F1 Puanı hesaplanmıştır. KHD ve EDR sinyalleri ile yapılan sınıflandırmada doğruluk %81,02; hassasiyet %85,3; seçicilik %76,32 ve F1 puanı 0,81 olarak hesaplanmıştır. RO algoritması için ROC eğrisi ve AUC hesaplanmıştır. Şekil 4.7'de KHD sinyalleri için ROC eğrisi, Şekil 4.8'de KHD ve EDR sinyalleri için ROC eğrisi grafiği gösterilmektedir.



Şekil 4.7 KHD sinyallerinin sınıflandırılmasında RO'ya ait ROC eğrisi



Şekil 4.8 KHD ve EDR sinyallerinin sınıflandırılmasında RO'ya ait ROC eğrisi


RO algoritması sınıflandırma sonuçlarına ilişkin hesaplanan hata oranları Tablo 4.6'da verilmiştir.

Tablo 4.6 RO hata oranları


Sınıflandırıcı	MAE	MSE	RMSE
RO - KHD ve EDR	0,18	0,18	0,43
RO - KHD	0,14	0,14	0,38

#### 4.1.1.4 KEK sınıflandırma sonucu

KEK algoritması farklı uzaklık metrikleri ve 3 ile 15 arasındaki komşuluk değerleri için denenmiş ve en yüksek başarı değerleri Manhattan uzaklık metriği ve 10 komşuluk değeri seçildiğinde bulunmuştur. KHD sinyalleri ile yapılan sınıflandırmada doğruluk %81,87; hassasiyet %77,09; seçicilik %84,86 ve F1 puanı 0,81 olarak hesaplanmıştır. KHD ve EDR sinyalleri ile yapılan sınıflandırmada doğruluk %74,62; hassasiyet %80,1; seçicilik %68,6 ve F1 Puanı 0,74 olarak hesaplanmıştır.



Şekil 4.9 KHD sinyallerinin sınıflandırılmasında KEK'e ait ROC eğrisi



Şekil 4.10 KHD ve EDR sinyallerinin sınıflandırılmasında KEK'e ait ROC eğrisi

KNN algoritması için ROC eğrisi ve AUC hesaplanmıştır. Şekil 4.9'da KHD sinyalleri için ROC eğrisi grafiği, Şekil 4.10'da KHD ve EDR sinyalleri için ROC eğrisi grafiği gösterilmektedir. KHD sinyalleri için AUC 0,81; KHD ve EDR sinyalleri için AUC


0,74 olarak bulunmuştur. KEK algoritmasının sınıflandırma sonuçlarının hata oranları Tablo 4.7’de verilmiştir.

Tablo 4.7 KEK hata oranları


Sınıflandırıcı	MAE	MSE	RMSE
KEK-KHD ve EDR	0,25	0,25	0,50
KEK-KHD	0,18	0,18	0,42

#### 4.1.1.5 ÇKS sınıflandırma sonucu

ÇKS ile yapılan sınıflandırmada gizli katman sayısı eğitim verisinin iki katı olarak seçilmiştir. KHD sinyalleri ile yapılan sınıflandırmada başarı sonuçları %84,16 doğruluk; %77,91 hassasiyet ; % 88,07 seçicilik ve 0,85 F1 Puanı hesaplanmıştır. KHD ve EDR sinyalleri ile yapılan sınıflandırmada doğruluk %80,05; hassasiyet %80,67; seçicilik %79,37 ve F1 puanı 0,80 olarak hesaplanmıştır.



Şekil 4.11 KHD sinyallerinin sınıflandırılmasında ÇKS’ye ait ROC eğrisi



Şekil 4.12 KHD ve EDR sinyallerinin sınıflandırılmasında ÇKS'ye ait ROC eğrisi


ÇKS algoritması için ROC eğrisi ve AUC hesaplanmıştır. Şekil 4.11'de KHD sinyalleri için ROC eğrisi, Şekil 4.12'de KHD ve EDR sinyalleri için ROC eğrisi grafiği gösterilmektedir. KHD sinyalleri için AUC 0,84; KHD ve EDR sinyalleri için AUC 0,80 olarak bulunmuştur. ÇKS'nin sınıflandırma sonuçlarının hata oranları Tablo 4.8'de verilmiştir.

Tablo 4.8 ÇKS hata oranları


Sınıflandırıcı	MAE	MSE	RMSE
ÇKS-KHD ve EDR	0,19	0,19	0,44
ÇKS-KHD	0,18	0,18	0,42

#### 4.1.1.6 LDA sınıflandırma sonucu

LDA sınıflandırıcısının KHD sinyalleri ile yapılan sınıflandırmada doğruluk %81,54; hassasiyet %71,2; seçicilik %88,01 ve F1 puanı 0,81 olarak hesaplanmıştır. KHD ve EDR sinyalleri ile yapılan sınıflandırmada doğruluk %80,29; hassasiyet %86,94; seçicilik %73 ve F1 Puanı 0,80 olarak hesaplanmıştır.



Şekil 4.13 KHD sinyallerinin sınıflandırılmasında LDA'ya ait ROC eğrisi



Şekil 4.14 KHD ve EDR sinyallerinin sınıflandırılmasında LDA'ya ait ROC eğrisi

LDA algoritması için ROC eğrisi ve AUC hesaplanmıştır. Şekil 4.13'te KHD sinyalleri için ROC eğrisi. Şekil 4.14'te KHD ve EDR sinyalleri için ROC eğrisi


grafiği gösterilmektedir. KHD sinyalleri için AUC 0,80; KHD ve EDR sinyalleri için AUC 0,80 olarak bulunmuştur. LDA algoritmasının sınıflandırma sonuçlarının hata oranları Tablo 4.9'da verilmiştir.

Tablo 4.9 LDA hata oranları


Sınıflandırıcı	MAE	MSE	RMSE
LDA-KHD ve EDR	0,19	0,19	0,44
LDA-KHD	0,18	0,18	0,42

#### 4.1.1.7 KDA sınıflandırma sonucu

KDA sınıflandırıcısının KHD sinyalleri ile yapılan sınıflandırmada doğruluk %73,43; hassasiyet %79,17; seçicilik %69,84 ve F1 puanı 0,73 olarak hesaplanmıştır. KHD ve EDR sinyalleri ile yapılan sınıflandırmada doğruluk %64,64; hassasiyet %94,7; seçicilik %31,68 ve F1 puanı 0,64 olarak hesaplanmıştır.



Şekil 4.15 KHD sinyallerinin sınıflandırılmasında KDA'ya ait ROC eğrisi



Şekil 4.16 KHD ve EDR sinyallerinin sınıflandırılmasında KDA'ya ait ROC eğrisi

KDA algoritması için ROC eğrisi ve AUC hesaplanmıştır. Şekil 4.15'te KHD sinyalleri için ROC eğrisi, Şekil 4.16'da KHD ve EDR sinyalleri için ROC eğrisi grafiği gösterilmektedir. KHD sinyalleri için AUC 0,75; KHD ve EDR sinyalleri için AUC 0,63 olarak bulunmuştur. KDA algoritmasının sınıflandırma sonuçlarının hata oranları Tablo 4.7'de verilmiştir.

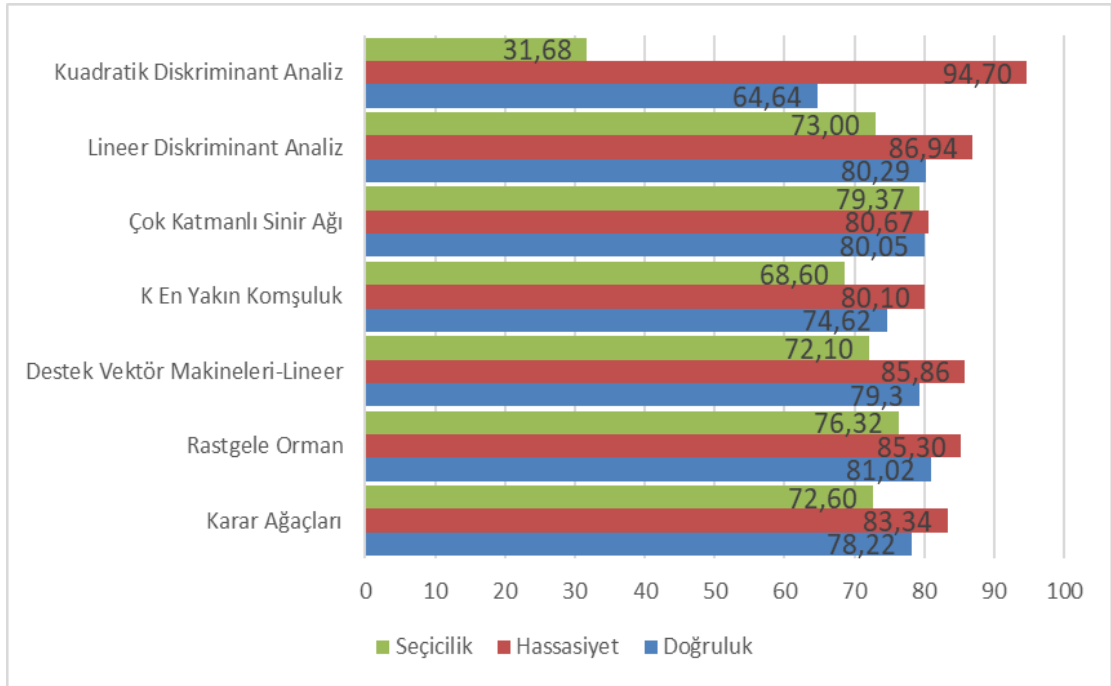
Tablo 4.10 KDA hata oranları

Sınıflandırıcı	MAE	MSE	RMSE
<b>KDA-KHD ve EDR</b>	0,35	0,35	0,59
<b>KDA-KHD</b>	0,26	0,26	0,51

Tüm sınıflandırma algoritmalarının KHD ve EDR sinyallerinden elde edilen 34 öznitelik kullanılarak yapılan sınıflandırma çalışmasının başarı metrikleri Tablo 4.11'de ve bulguların grafiksel gösterimi Şekil 4.17'de verilmiştir.

Tablo 4.11 KHD ve EDR sinyallerine ait makine öğrenmesi sınıflandırma sonuçları

Sınıflandırma Algoritmaları	Sınıflandırma Sonuçları			F1 Puanı
	Doğruluk (%)	Hassasiyet (%)	Seçicilik (%)	
KA	78,22	83,34	72,6	0,78
<b>RO</b>	<b>81,02</b>	85,3	76,32	0,81
DVM-Lineer	79,3	85,86	72,1	0,79
KEK	74,62	80,1	68,6	0,74
ÇKS	80,05	80,67	79,37	0,80
LDA	80,29	86,94	73,0	0,80
KDA	64,64	94,7	31,68	0,64




Şekil 4.17 KHD ve EDR sinyallerine ait makine öğrenmesi sınıflandırma sonuçlarının grafiksel gösterimi

Tablo 4.12 KHD sinyallerine ait makine öğrenmesi sınıflandırma sonuçları

Sınıflandırma Algoritmaları	Sınıflandırma Sonuçları			F1 Puanı
	Doğruluk (%)	Hassasiyet (%)	Seçicilik (%)	
KA	79,41	71,93	84,9	0,79
<b>RO</b>	<b>85,3</b>	76,12	91,04	0,85
DVM-Gaussian	83,99	74,21	90,11	0,83
KEK	81,87	77,09	84,86	0,81
ÇKS	85,5	78,09	90,13	0,85
LDA	81,54	71,2	88,0	0,81
KDA	73,43	79,17	69,84	0,73

KHD sinyallerinden elde edilen 25 öznitelik kullanılarak yapılan sınıflandırma çalışmasının başarı metrikleri Tablo 4.12’de ve bulguların grafiksel gösterimi Şekil 4.18’de verilmiştir.

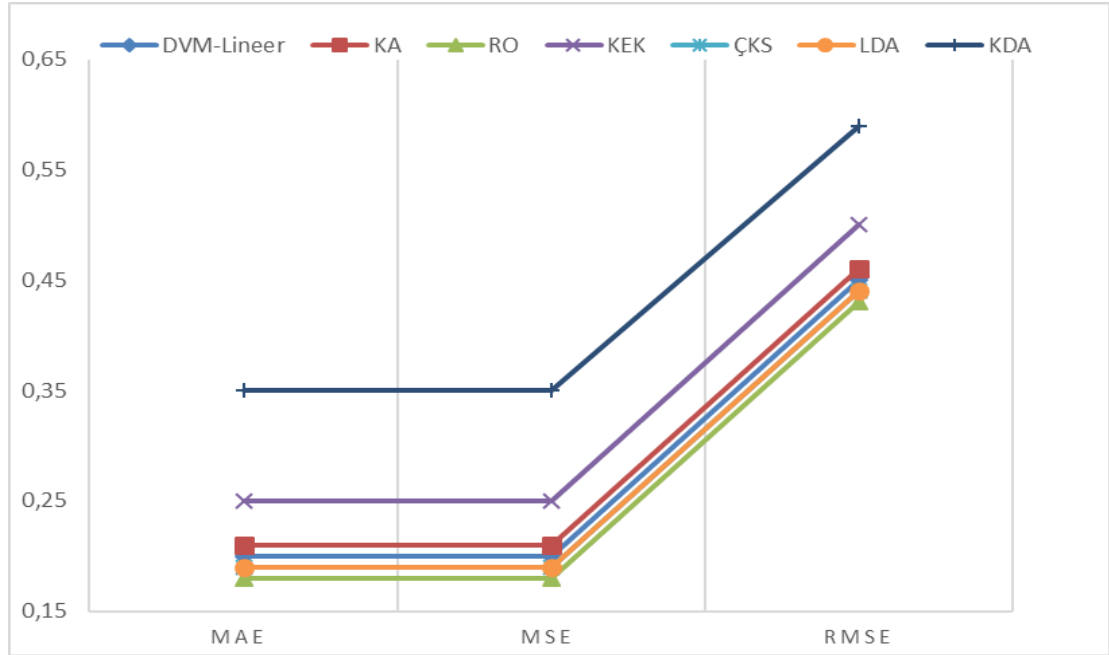


Şekil 4.18 KHD sinyallerine ait makine öğrenmesi sınıflandırma sonuçlarının grafiksel gösterimi

Tüm sınıflandırma algoritmalarının KHD ve EDR sinyallerinden elde edilen 34 öznitelik kullanılarak yapılan sınıflandırma çalışmasının hata analiz sonuçları Tablo 4.13’de ve bulguların grafiksel gösterimi Şekil 4.19’da verilmiştir.

Tablo 4.13 KHD ve EDR sinyallerine ait hata analizi sonuçları

Sınıflandırıcı	MAE	MSE	RMSE
<b>DVM-Lineer</b>	0,20	0,20	0,45
<b>KA</b>	0,21	0,21	0,46
<b>RO</b>	<b>0,18</b>	<b>0,18</b>	<b>0,43</b>
<b>KEK</b>	0,25	0,25	0,50
<b>ÇKS</b>	0,19	0,19	0,44
<b>LDA</b>	0,19	0,19	0,44
<b>KDA</b>	0,35	0,35	0,59

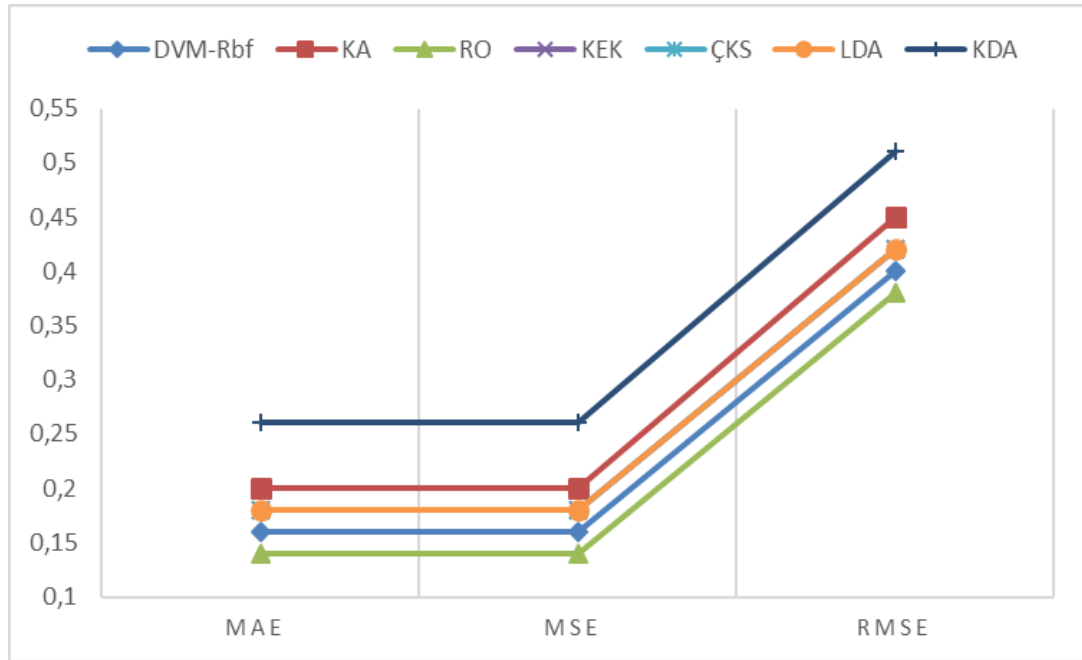


Şekil 4.19 KHD ve EDR sinyallerine ait hata analizi sonuç grafiği

Tüm sınıflandırma algoritmalarının KHD sinyallerinden elde edilen 25 öznitelik kullanılarak yapılan sınıflandırma çalışmasının hata analiz sonuçları Tablo 4.14’te ve bulguların grafiksel gösterimi Şekil 4.20’de verilmiştir.

Tablo 4.14 KHD sinyallerine ait hata analizi sonuçları

Sınıflandırıcı	MAE	MSE	RMSE
<b>DVM - Gaussian</b>	0,16	0,16	0,4
<b>KA</b>	0,20	0,20	0,45
<b>RO</b>	<b>0,14</b>	<b>0,14</b>	<b>0,38</b>
<b>KEK</b>	0,18	0,18	0,42
<b>ÇKS</b>	0,18	0,18	0,42
<b>LDA</b>	0,18	0,18	0,42
<b>KDA</b>	0,26	0,26	0,51



Şekil 4.20 KHD sinyallerine ait hata analizi sonuç grafikleri


Tüm algoritmalar karşılaştırıldığında hem KHD sinyalleri ile yapılan sınıflandırma sonucunda hem de KHD ve EDR sinyalleri kullanılarak yapılan sınıflandırma sonucunda en düşük hata oranları RO algoritması ile elde edilmiştir. 25 öznitelik kullanılmasını ve 34 öznitelik kullanılmasının karşılaştırılması yapıldığında ise tüm algoritmalar için 25 öznitelik kullanılarak yapılan sınıflandırma çalışmasında daha yüksek sonuçlar elde edilmiştir.

## 4.1.2 Derin Öğrenme Yöntemleri Kullanılarak Sınıflandırma


### 4.1.2.1 CNN modelin sonuçları

CNN modelinde adım boyutu 64, epok 75 olarak belirlenmiştir. Çalışmada erken durdurma kontrol birimi validasyon kayıp olarak seçilerek her bir epokta validasyon kayıp değerinin azalıp azalmadığı kontrol edilmiştir. Erken durdurma bekleme değeri 5 seçilen CNN modelde sekizinci epogunda 0,22 validasyon kayıp değeri elde edilmiş ve eğitim 12 epok sonunda tamamlanmıştır.

Modelin hesaplanan doğruluk ve kayıp değerleri Şekil 4.21 ve Şekil 4.22’de verilmiştir. Hesaplanan değerlere göre sekizinci epoktaki eğitim verisi doğruluk değeri 0,97; validasyon verisi doğruluk değeri 0,91 ve eğitim verisi kayıp değeri 0,07; validasyon verisi kayıp değeri 0,22 olarak bulunmuştur.




Şekil 4.21 CNN modelin doğruluk grafiği



Şekil 4.22 CNN modelin kayıp grafiği

CNN modelin karışıklık matrisinden elde edilen başarı sonuçları doğruluk %89,11; hassasiyet %94,31; seçicilik %80,72 ve F1 Puanı 0,89 olarak hesaplanmıştır.

CNN modelin sınıflandırılmasına ilişkin ROC eğrisi grafiğinden elde edilen AUC 0,88 olarak hesaplanmış ve ROC eğrisi grafiği Şekil 4.23'te verilmiştir. Sınıflandırma sonuçlarının hata analizleri yapılmış ve MAE, MSE ve RMSE değerleri hesaplanmıştır. Hesaplanan hata oranları Tablo 4.15'te verilmiştir.



Şekil 4.23 CNN modelin segmentasyon sınıflandırılmasına ait ROC eğrisi

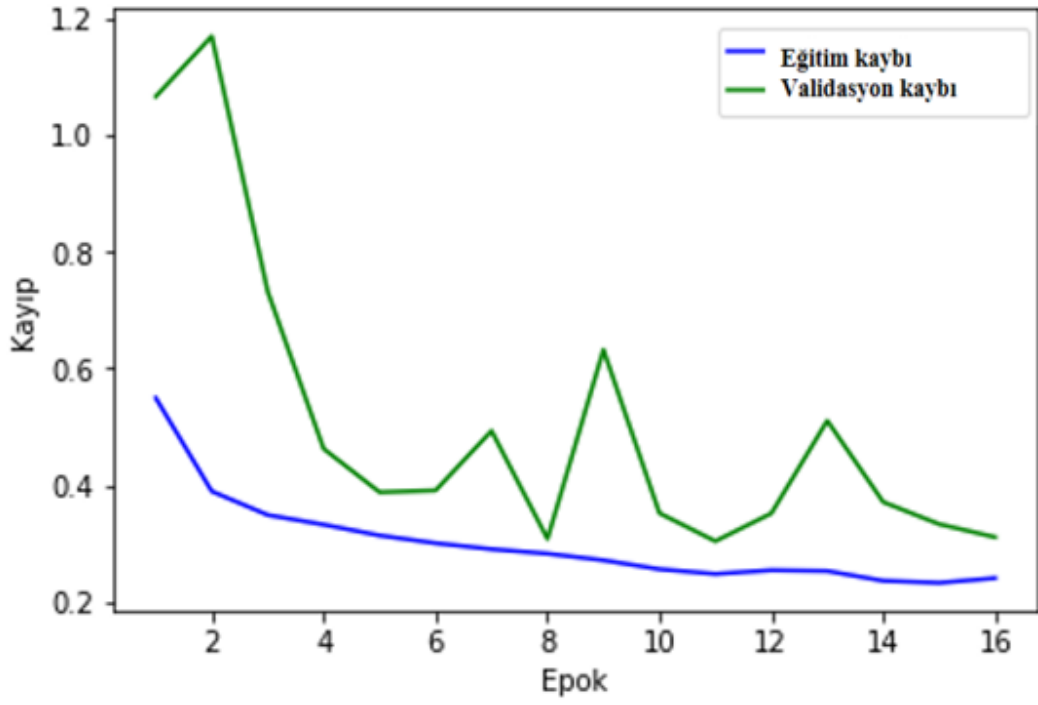
Tablo 4.15 CNN hata oranları

Sınıflandırıcı	MAE	MSE	RMSE
CNN	0,11	0,09	0,30

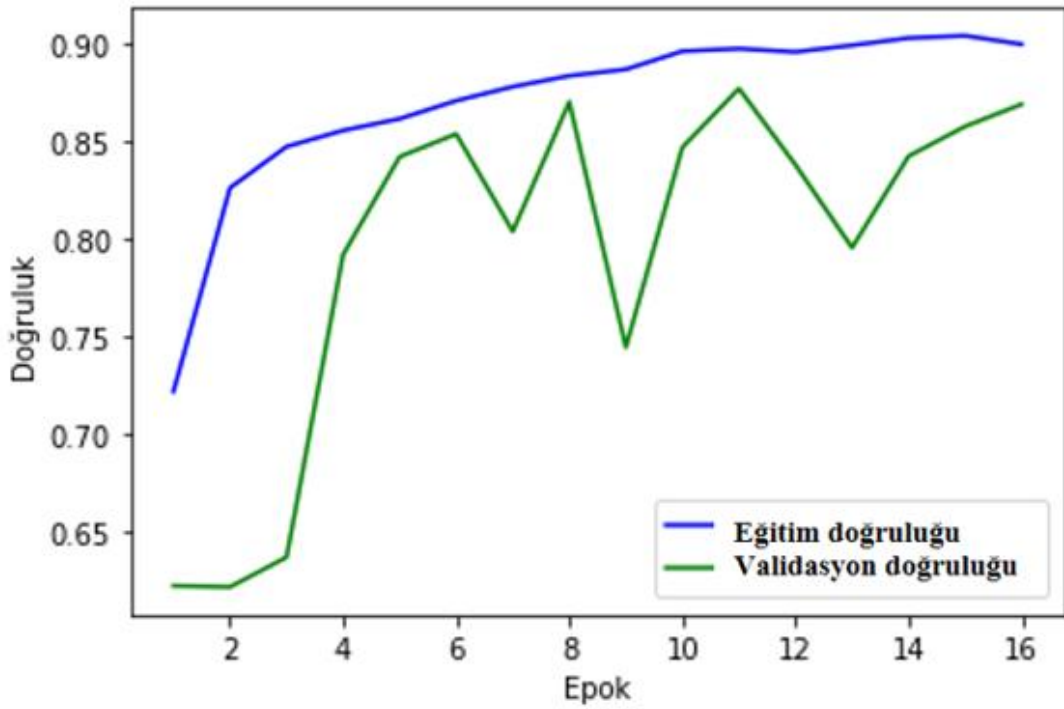
#### 4.1.2.2 LSTM modelin sonuçları

LSTM modelinde adım boyutu 64, epok 75 olarak belirlenmiştir. Çalışmada Erken durdurma kontrol birimi validasyon kayıp olarak seçilerek her bir epokta validasyon kayıp değerinin azalıp azalmadığı kontrol edilmiştir. Erken durdurma bekleme değeri 5 seçilen LSTM modelde on birinci epogunda 0,30 validasyon kayıp değeri elde edilmiş ve eğitim 16 epok sonunda tamamlanmıştır.

Modelin doğruluk ve kayıp grafikleri Şekil 4.24 ve Şekil 4.25'te verilmiştir. Hesaplanan değerlere göre on birinci epok eğitim verisi doğruluk değeri 0,89; validasyon verisi doğruluk değeri 0,83 ve eğitim verisi kayıp değeri 0,25; validasyon verisi kayıp değeri 0,30 olarak bulunmuştur.




Şekil 4.24 LSTM modelin kayıp grafiği



Şekil 4.25 LSTM modelin doğruluk grafiği

Karışıklık matrisinden elde edilen LSTM modelin başarı sonuçları doğruluk %83,37; hassasiyet %79,04; seçicilik %87,7 ve F1 puanı 0,82 olarak hesaplanmıştır.

LSTM modelin sınıflandırılmasına ilişkin ROC eğrisi grafiğinden elde edilen AUC 0,83 olarak hesaplanmış ve ROC eğrisi grafiği Şekil 4.26’da verilmiştir. Sınıflandırma sonuçlarının hata analizleri yapılmış ve hesaplanan hata oranları MAE, MSE ve RMSE değerleri Tablo 4.16’da verilmiştir.




Şekil 4.26 LSTM modelin segmentasyon sınıflandırılmasına ait ROC eğrisi

Tablo 4.16 LSTM hata oranları


Sınıflandırıcı	MAE	MSE	RMSE
LSTM	0,20	0,12	0,36

#### 4.1.2.3 DNN modelinin sonuçları

DNN modelinde adım boyutu 64, epok 75 olarak belirlenmiştir. Çalışmada erken durdurma kontrol birimi validasyon kayıp olarak seçilerek her bir epokta validasyon kayıp değerinin azalıp azalmadığı kontrol edilmiştir. Erken durdurma bekleme değeri 5 seçilen DNN modelde beşinci 0,50 validasyon kayıp değeri elde edilmiş ve eğitim 10 epok sonunda tamamlanmıştır.



Şekil 4.27 DNN modelin doğruluk grafiği




Şekil 4.28 DNN modelin kayıp grafiği

Modelin hesaplanan doğruluk ve kayıp değerleri Şekil 4.27 ve Şekil 4.28'de verilmiştir. Hesaplanan değerlere göre beşinci epok eğitim verisi doğruluk değeri 0,78; validasyon verisi doğruluk değeri 0,78 ve eğitim verisi kayıp değeri 0,45; validasyon verisi kayıp değeri 0,50 olarak bulunmuştur.

DNN modelin karışıklık matrisinden elde edilen başarı sonuçları; doğruluk %76,46; hassasiyet %86,81; seçicilik %59,78 ve F1 puanı 0,76 olarak hesaplanmıştır.

DNN modelin sınıflandırılmasına ilişkin ROC eğrisi grafiğinden elde edilen AUC 0,73 olarak hesaplanmış ve ROC eğrisi grafiği Şekil 4.29’da verilmiştir.



Şekil 4.29 DNN modelin segmentasyon sınıflandırılmasına ait ROC eğrisi

Sınıflandırma sonuçlarının hata analizleri yapılmış ve MAE, MSE ve RMSE değerleri hesaplanmıştır. Hesaplanan hata oranları Tablo 4.17’de verilmiştir


Tablo 4.17 DNN hata oranları

Sınıflandırıcı	MAE	MSE	RMSE
DNN	0,17	0,28	0,41

Tüm derin öğrenme sınıflandırma algoritmalarının KHD sinyalleri kullanılarak yapılan sınıflandırma çalışmasının başarı metrikleri doğruluk, hassasiyet, seçicilik ve F1 puanı hesaplamalarına ilişkin sonuçlar Tablo 4.18’de ve bulguların grafiksel gösterimi Şekil 4.30’da verilmiştir.

Tablo 4.18 Derin öğrenme yöntemlerine ilişkin sınıflandırma sonuçları

Sınıflandırma Algoritmaları	Sınıflandırma Sonuçları			F1 Puanı
	Doğruluk (%)	Hassasiyet (%)	Seçicilik (%)	
CNN	89,11	94,31	80,72	0,89
LSTM	83,37	79,77	89,17	0,83
DNN	76,46	86,81	59,78	0,76




Şekil 4.30 Sınıflandırma sonuçlarının grafiksel gösterimi

Tablo 4.19 Derin öğrenme yöntemlerine ilişkin hata analizi sonuçları

Sınıflandırıcı	MAE	MSE	RMSE
CNN	0,11	0,09	0,30
LSTM	0,19	0,12	0,34
DNN	0,28	0,17	0,41

Tüm derin öğrenme sınıflandırma algoritmalarının KHD sinyalleri kullanılarak yapılan sınıflandırma çalışmasının hata analiz sonuçları Tablo 4.19’da ve bulguların grafiksel gösterimi Şekil 4.31’de verilmiştir.



Şekil 4.31 Derin öğrenme yöntemlerine ilişkin hata analizi sonuç grafiği

Derin öğrenme sınıflandırma sonuçları incelendiğinde en yüksek başarı değerlerinin CNN modele ait olduğu görülmektedir. Derin Öğrenme algoritmaları ile sınıflandırma bulgularını ve makine öğrenmesi sınıflandırma bulgularını karşılaştırdığımız zaman en yüksek başarı metrikleri derin öğrenme çalışması olan CNN modele aittir.

## 4.2 Her Bir Kaydın Sınıflandırma Bulguları

Bu tez çalışmasının ilk aşamasında segmentasyona dayalı sınıflandırma yapılmış ve tüm sınıflandırıcıların her bir bölüme ait tahmin değerleri kaydedilmiştir. Kişilere ait tüm segmentlerin tahmin değerleri kullanılarak bir saatteki apneli dakika sayısı hesaplanmıştır. Hesaplanan AHİ indeksine göre kişiler OUA ve normal olarak iki grupta sınıflandırılmıştır.

Sınıflandırıcılara ait karışıklık matrisi hesaplanmıştır. Veri setinde bulunan 35 kaydın gerçek değerleri ile hesaplanan karışıklık matrisi değerlerinin karşılaştırmaları Tablo 4.20’de verilmiştir. Test grubunda bulunan 36 kayıttan 23 kişi sağlıklı ve 12 kişi

obstruktif uyku apnesidir. Sağlıklı kişiler TP, OUA olan kişiler TN grubundadır. Sınıflandırma sonuçlarına göre CNN sınıflandırıcı modeli 22 kişiyi sağlıklı olarak doğru sınıflandırmış, 11 kişiyi OUA olarak doğru sınıflandırmış ve 1 kişiyi sağlıklı olmasına rağmen OUA olarak yanlış sınıflandırmıştır.


Tablo 4.20 Karışıklık matrisi değerleri

Sınıflandırma Algoritmaları	Karışıklık Matrisi			
	<i>TP</i>	<i>TN</i>	<i>FP</i>	<i>FN</i>
DVM	22	9	3	1
KA	23	3	9	0
RO	22	9	3	1
KEK	23	6	6	0
ÇKS	22	9	3	1
LDA	22	7	5	1
KDA	23	3	9	0
<b>CNN</b>	22	12	0	1
LSTM	23	9	3	0
DNN	23	8	4	0
<b>VERİ SETİ</b>	23	12	0	0

Sınıflandırmanın başarı performansı görmek için doğruluk; hassasiyet; seçicilik, F1 puanı ve AUC hesaplanmıştır. Sınıflandırma sonuçlarına ilişkin başarı metrikleri Tablo 4.21’de ve grafiksel gösterimi Şekil 4.32’de verilmiştir. Hesaplanan değerler göre CNN sınıflandırma algoritması %97,14 doğruluk; %100 hassasiyet; %95,65 seçicilik; 0,97 F1 puanı ve 0,98 AUC değeri ile en yüksek başarı değerlerine ulaşan algoritmadır.

Tablo 4.21 Kayıtların sınıflandırma sonuçları

Sınıflandırma Algoritmaları	Sınıflandırma Sonuçları				
	<i>Doğruluk (%)</i>	<i>Hassasiyet (%)</i>	<i>Seçicilik (%)</i>	<i>F1 Puanı</i>	<i>AUC</i>
DVM	88,57	75	95,65	0,88	0,85
KA	74,29	25,0	100	0,74	0,62
RO	88,58	75,0	95,65	0,88	0,85
KEK	82,86	50,0	100	0,82	0,75
ÇKS	88,57	75,0	95,65	0,88	0,85
LDA	82,86	58,33	95,65	0,82	0,77
KDA	74,29	25,0	100	0,74	0,62
<b>CNN</b>	<b>97,14</b>	<b>100</b>	<b>95,65</b>	<b>0,97</b>	<b>0,98</b>
LSTM	91,43	75,0	100	0,91	0,88
DNN	88,57	66,67	100	0,88	0,83




Şekil 4.32 Kayıtların sınıflandırma sonuçlarına ait grafiksel gösterimi

Sınıflandırma sonuçlarına ilişkin MSE, MAE ve RMSE hata analizleri yapılmıştır. Yapılan hata analiz sonuçları Tablo 4.22’de ve grafiksel gösterimi Şekil 4.33’te

verilmiştir. Hesaplanan değerlere göre hata oranı en düşük olan sınıflandırıcı CNN modeldir.

Tablo 4.22 Kayıtların hata analizi sonuçları

Sınıflandırıcı	MAE	MSE	RMSE
DVM	0,11	0,11	0,33
KA	0,25	0,25	0,50
RO	0,11	0,11	0,33
KEK	0,17	0,17	0,41
ÇKS	0,11	0,11	0,33
LDA	0,17	0,17	0,41
<b>CNN</b>	<b>0,02</b>	<b>0,02</b>	<b>0,16</b>
LSTM	0,08	0,08	0,29
DNN	0,11	0,11	0,33



Şekil 4.33 Kayıtların hata analizi grafiksel gösterim

## 5. SONUÇ VE ÖNERİLER

Bu tez çalışması kapsamında EKG sinyalleri üzerinden makine öğrenmesi ve derin öğrenme sınıflandırıcıları kullanılarak uyku apnesi tespiti yapılmıştır. Çalışmada bölütlere dayalı sınıflandırma ve her bir kaydın sınıflandırması olarak iki aşamada sınıflandırma yapılmıştır. Tez çalışmasının bölütlere dayalı sınıflandırılması makine öğrenmesi ve derin öğrenme yöntemleri ile sınıflandırma olmak üzere iki aşamadan oluşmaktadır.

Bölütlere dayalı sınıflandırma yapmak için EKG sinyalleri birer dakikalık bölütlere ayrılmıştır. Bölütlere ayrılan sinyallerinden Hamilton Segmentasyon yöntemi kullanılarak R tepe noktaları belirlenmiştir. Belirlenen R tepeleri bilgileri kullanılarak KHD ve EDR sinyalleri elde edilmiştir. Makine öğrenmesi sınıflandırıcıları için elde edilen KHD ve EDR sinyallerinden öznitelikler belirlenmiştir. Frekans uzayı öznitelikleri için Welch metodu, zaman uzayı öznitelikleri için istatistikler yöntemleri kullanılmıştır. Çalışmada KHD sinyallerinden 16 adet zaman uzayı özniteliği ve 9 adet frekans uzayı özniteliği belirlenmiş toplamda 25 adet öznitelik bilgisi sınıflandırıcı girişi olarak kullanılmıştır. İkinci bir öznitelik çalışması olarak KHD sinyallerinden belirlenen 25 adet özniteliğe ek olarak EDR sinyallerinden 9 adet frekans uzayı özniteliği belirlenerek toplam 34 adet öznitelik bilgisi sınıflandırıcı girişi olarak kullanılmıştır. Makine öğrenmesi algoritmaları olarak karar ağaçları, rastgele orman, K en yakın komşuluk, çok katmanlı sinir ağı, destek vektör makineleri, lineer diskriminant analiz ve kuadratik diskriminant analiz kullanılmıştır. Tüm algoritmalar karşılaştırıldığında RO algoritması KHD sinyalleri ile yapılan sınıflandırmada %85,26 doğruluk; %75,44 hassasiyet; %91,4 seçicilik; 0,85 F1 Puanı ve AUC 0,84 ile en yüksek başarı değerlerine ulaşan makine öğrenmesi algoritması olmuştur. KHD ve EDR sinyalleri ile yapılan sınıflandırmada RO algoritması %81,02 doğruluk; %85,3 hassasiyet; %76,32 seçicilik; 0,81 F1 Puanı ve AUC 0,81 ile en yüksek başarı değerlerine ulaşan makine öğrenmesi algoritması olmuştur. En düşük hata oranları RO algoritması ile elde edilmiştir. 25 öznitelik kullanılmasını ve 34 öznitelik kullanılmasının karşılaştırılması yapıldığında ise tüm algoritmalar için 25 öznitelik kullanılarak yapılan sınıflandırma çalışmasında daha yüksek sonuçlar elde edilmiştir.

Bölütlere dayalı sınıflandırmanın ikinci kısmında EKG sinyallerinden elde edilen KHD sinyallerinden derin öğrenme mimarileri kullanılarak apne tespiti yapılmıştır. Derin öğrenme modeli olarak evrimsel sinir ağları, uzun kısa vadeli hafıza ve derin sinir ağları kullanılmıştır. Üç modelin sonuçları karşılaştırıldığında CNN model %89,11 doğruluk; %94,31 hassasiyet; %80,72 seçicilik; 0,89 F1 Puanı ve 0,87 AUC değerleri ile en yüksek başarı oranına sahip model olmuştur.

Her bir segmente ait apne sınıflandırması yapıldıktan sonra her bir kaydın OUA olup olmadığı sınıflandırılmıştır. Bunun için modellerin tahmin edilen değerlerine göre saat başına apneli dakika sayısı hesaplanmıştır. AHİ standardına göre yapılan OUA ve normal sınıflandırmasına göre CNN mimarisi %97,14 doğruluk; %100 seçicilik; %95,65 hassasiyet; 0,97 F1 puanı ve 0,98 AUC değeri ile en yüksek başarıyı veren algoritma olmuştur.

Elde edilen sonuçlara göre derin öğrenme mimarilerinin makine öğrenmesi mimarilerine göre daha yüksek başarı göstermektedir. OUA tespitinde derin öğrenme mimarilerinden CNN 0,02 MAE değeri ile en az hata oranına ulaşan çalışma olmuştur. LSTM 0,08 MAE oranı ile CNN modelden sonra en az hata oranına sahip model olmuştur.

Bu tez çalışmasında Apnea ECG veri seti kullanılmış ve 35 kişinin EKG kaydından oluşan test verileri üzerinden hem birer dakikalık bölütlere ayrılan sinyallerden bölütlere dayalı uyku apnesi sınıflandırılması hem de her bir kaydın OUA ve normal sınıflandırılması yapılmıştır. Çalışmamızın amacı, OUA'nın otomatik tespitini yapabilmek için algoritma geliştirilmesidir. OUA bir veya iki gece boyunca uyku laboratuvarında çoklu parametrelerin ölçümleri alınarak teşhis edilebilmektedir. Çoklu ölçüm alınmadan sadece EKG sinyalleri kullanılarak OUA tespit edilebilmesi hastaların konforu ve ölçüm kolaylığı sağlayacaktır. Bu çalışmada yapay zeka teknikleri kullanarak EKG sinyalleri üzerinden OUA tespiti için algoritma geliştirilmiştir. Gelişen teknolojilerle beraber hastaların evde bakım sistemlerine entegre edilebilecek bir OUA tespit sisteminin geliştirilmesi sağlanabilir. İlerleyen çalışmalarda bu amaçla tezimizde yazmış olduğumuz algoritmaların farklı veri setleri ile test edilerek çalışma performansının değerlendirilmesi planlanmaktadır.

## KAYNAKLAR

- Algın, D. İ., Akdağ, G., & Erdinç, O. O. (2016). Kaliteli uyku ve uyku bozuklukları. *Osmangazi Journal of Medicine*, 38(0), 29–34. <https://doi.org/10.20515/otd.40263>
- Arzeno, N. M., Deng, Z. De, & Poon, C. S. (2008). Analysis of first-derivative based QRS detection algorithms. *IEEE Transactions on Biomedical Engineering*, 55(2), 478–484. <https://doi.org/10.1109/TBME.2007.912658>
- Ayhan, S. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175–201. <https://doi.org/10.17153/eoguiibfd.33265>
- Balakrishnama, S., & Ganapathiraju, A. (2015). Linear Discriminant Analysis - a Brief Tutorial. *Compute, October*.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3–31. [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
- Bayrak, T. (2011). *Uyku Bozukluklarının Araştırılmasında Biyomedikal Mühendislik Yaklaşımları*. 12–14.
- Bengio, Y., Courville, A., & Goodfellow, I. (2016). Deep learning. In *Nature*. 29, Issue 7553).
- Berrar, D. (2018). Cross-validation. *Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics*, 1–3(January 2018), 542–545. <https://doi.org/10.1016/B978-0-12-809633-8.20349-X>
- Bora, İ. H., & Bican, A. (2007). Uyku Fizyolojisi. *Turkiye Klinikleri J Surg Med Sci*, 3(23), 1–6.
- 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. <https://doi.org/10.1016/j.irbm.2020.05.006>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1201/9780429469275-8>
- Budhiraja, R., Budhiraja, P., Quan, S. F., Breathing, S., & Failure, C. H. (2010). Sleep-Disordered Breathing and Cardiovascular Disorders Obstructive Sleep Apnea and Hypertension. *Respiratory Care*, 55(10), 1322–1332.
- Calik, M. W. (2016). Treatments for obstructive sleep apnea. *Journal of Clinical Outcomes Management*, 23(4), 181–192. [https://doi.org/10.1007/978-1-59745-421-6\\_11](https://doi.org/10.1007/978-1-59745-421-6_11)
- Canento, F., Lourenço, A., Silva, H., & Fred, A. (2012). *Review and Comparison of*

*Real Time Electrocardiogram Segmentation Algorithms for Biometric Applications* (Issue i, p. 9).

- Canziani, A., Paszke, A., & Culurciello, E. (2016). *An Analysis of Deep Neural Network Models for Practical Applications*. 1–7. <http://arxiv.org/abs/1605.07678>
- Cerutti, S., Baselli, G., Bianchi, A. M., Caiani, E., Contini, D., Cubeddu, R., Dercole, F., Di Rienzo, L., Liberati, D., Mainardi, L., Ravazzani, P., Rinaldi, S., Signorini, M. G., & Torricelli, A. (2011). Biomedical signal and image processing. *IEEE Pulse*, 2(3), 41–54. <https://doi.org/10.1109/MPUL.2011.941522>
- Cooley, J. W., & Tukey, J. W. (1965). An algorithm for the machine calculation of complex Fourier series. *Mathematics of Computation*, 19(90), 297–297. <https://doi.org/10.1090/s0025-5718-1965-0178586-1>
- Cutler, A., Cutler, D. R., & Stevens, J. R. (2012). Random Forest. In *Ensemble Machine Learning* (Issue February 2014, pp. 157–177). <https://doi.org/10.1007/978-1-4419-9326-7>
- Davey, P., & Sharman, D. (2018). The electrocardiogram. *Medicine (United Kingdom)*, 46(8), 443–452. <https://doi.org/10.1016/j.mpmed.2018.05.004>
- Diker, A., Avci, D., Avci, E., & Gedikpinar, M. (2019). A new technique for ECG signal classification genetic algorithm Wavelet Kernel extreme learning machine. In *Optik*.180, pp. 46–55). <https://doi.org/10.1016/j.ijleo.2018.11.065>
- Doukas, C., Petsatodis, T., Boukis, C., & Maglogiannis, I. (2012). Automated sleep breath disorders detection utilizing patient sound analysis. *Biomedical Signal Processing and Control*, 7(3), 256–264. <https://doi.org/10.1016/j.bspc.2012.03.002>
- Elhaj, F. A., Salim, N., Harris, A. R., Swee, T. T., & Ahmed, T. (2016). Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals. *Computer Methods and Programs in Biomedicine*, 127, 52–63. <https://doi.org/10.1016/j.cmpb.2015.12.024>
- Fatimah, B., Singh, P., Singhal, A., & Pachori, R. B. (2020). Detection of apnea events from ECG segments using Fourier decomposition method. *Biomedical Signal Processing and Control*, 61, 102005. <https://doi.org/10.1016/j.bspc.2020.102005>
- 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, 106591. <https://doi.org/10.1016/j.knosys.2020.106591>
- Garrett, D., Peterson, D. A., Anderson, C. W., & Thaut, M. H. (2003). Comparison of linear, nonlinear, and feature selection methods for EEG signal classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2), 141–144. <https://doi.org/10.1109/TNSRE.2003.814441>
- Hafezi, M., Montazeri, N., Saha, S., Zhu, K., Gavrilovic, B., Yadollahi, A., & Taati, B. (2020). Sleep Apnea Severity Estimation from Tracheal Movements Using a Deep Learning Model. *IEEE Access*, 8, 22641–22649.

<https://doi.org/10.1109/ACCESS.2020.2969227>

- Hamilton, P. (2002). Open Source ECG Analysis P Hamilton. *Computers in Cardiology*, 29, 101–104.
- Hassanien, A. E., Kilany, M., & Houssein, E. H. (2017). ECG signals classification: a review. *International Journal of Intelligent Engineering Informatics*, 5(4), 376. <https://doi.org/10.1504/ijiei.2017.10008807>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Ioffe, S. (2017). Batch Renormalization: Towards reducing minibatch dependence in batch-normalized models. *Advances in Neural Information Processing Systems, 2017-Decem*, 1946–1954.
- Jain, A. (2016). Recent Application of Fourier Transform In Medical Engineering. *International Journal of Creative Research Thoughts*, 4(3), 25–26.
- Jambukia, S. H., Dabhi, V. K., & Prajapati, H. B. (2015). Classification of ECG signals using machine learning techniques: A survey. *Conference Proceeding - 2015 International Conference on Advances in Computer Engineering and Applications, ICACEA 2015*, 714–721. <https://doi.org/10.1109/ICACEA.2015.7164783>
- 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. <https://doi.org/10.1016/j.irbm.2018.03.002>
- Javaheri, S., Barbe, F., Campos-Rodriguez, F., Dempsey, J. A., Khayat, R., Javaheri, S., Malhotra, A., Martinez-Garcia, M. A., Mehra, R., Pack, A. I., Polotsky, V. Y., Redline, S., & Somers, V. K. (2017). Sleep Apnea: Types, Mechanisms, and Clinical Cardiovascular Consequences. *Journal of the American College of Cardiology*, 69(7), 841–858. <https://doi.org/10.1016/j.jacc.2016.11.069>
- Kiran kumar, C., Manaswini, M., Maruthy, K. N., Siva Kumar, A. V., & Mahesh kumar, K. (2021). Association of Heart rate variability measured by RR interval from ECG and pulse to pulse interval from Photoplethysmography. *Clinical Epidemiology and Global Health*, 10(January), 100698. <https://doi.org/10.1016/j.cegh.2021.100698>
- Kleissen, R. F. M., Buurke, J. H., Harlaar, J., & Zilvold, G. (1998). Electromyography in the biomechanical analysis of human movement and its clinical application. *Gait and Posture*, 8(2), 143–158. [https://doi.org/10.1016/S0966-6362\(98\)00025-3](https://doi.org/10.1016/S0966-6362(98)00025-3)
- Kramer, O. (2013). Dimensionality Reduction with Unsupervised Nearest Neighbors. In *Intelligent Systems Reference Library*.51. <https://doi.org/10.1007/978-3-642-38652-7>
- Madhav, V. N. V. (2011). Diagnosis and management of obstructive sleep apnea. *Journal of International Dental and Medical Research*, 4(1), 35–41. [https://doi.org/10.1016/s1526-0542\(13\)70009-5cf](https://doi.org/10.1016/s1526-0542(13)70009-5cf)

- Marius-Constantin, P., Balas, V. E., Perescu-Popescu, L., & Mastorakis, N. (2009). Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems*, 8(7), 579–588.
- Martis, R. J., Acharya, U. R., & Min, L. C. (2013). ECG beat classification using PCA, LDA, ICA and Discrete Wavelet Transform. *Biomedical Signal Processing and Control*, 8(5), 437–448. <https://doi.org/10.1016/j.bspc.2013.01.005>
- Mashrur, F. R., Islam, M. S., Saha, D. K., Islam, S. M. R., & Moni, M. A. (2021). SCNN: Scalogram-based Convolutional Neural Network to Detect Obstructive Sleep Apnea using Single-lead Electrocardiogram Signals. *Computers in Biology and Medicine*, 134(December 2020), 104532. <https://doi.org/10.1016/j.combiomed.2021.104532>
- Medical Advisory Secretariat. (2006). Polysomnography in patients with obstructive sleep apnea: an evidence-based analysis. In *Ontario health technology assessment series*, 6(13). <http://www.ncbi.nlm.nih.gov/pubmed/23074483> <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC3379160>
- Mostafa, S. S., Mendonça, F., Ravelo-García, A. G., & Morgado-Dias, F. (2019a). A systematic review of detecting sleep apnea using deep learning. *Sensors (Switzerland)*, 19(22), 1–26. <https://doi.org/10.3390/s19224934>
- Mostafa, S. S., Mendonça, F., Ravelo-García, A. G., & Morgado-Dias, F. (2019b). A systematic review of detecting sleep apnea using deep learning. *Sensors (Switzerland)*, 19(22), 1–26. <https://doi.org/10.3390/s19224934>
- Němcová, A., Smíšek, R., Maršánová, L., Smital, L., & Vitek, M. (2018). A comparative analysis of methods for evaluation of ECG signal quality after compression. *BioMed Research International*, 2018. <https://doi.org/10.1155/2018/1868519>
- Owens, F. J., & Murphy, M. S. (1988). A Short-Time Fourier Transform. *Signal Processing*, 14, 3–10.
- Pan, J., & Tompkins, W. J. (1985). A Real-Time QRS Detection Algorithm. *IEEE Transactions On Biomedical Engineering*, BME-32(3). <https://doi.org/10.1097/AOG.0b013e3181cec0b5>
- Rachim, V. P., Li, G., & Chung, W. Y. (2014). Sleep apnea classification using ECG-signal wavelet-PCA features. *Bio-Medical Materials and Engineering*, 24(6), 2875–2882. <https://doi.org/10.3233/BME-141106>
- Schrader, M., Zywietz, C., Widiger, B., & Joseph, G. (2000). Detection of Sleep Apnea in Single Channel ECGs from the PhysioNet Data Base. *Computers in Cardiology*, 27, 263–266.
- Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404(March), 1–43. <https://doi.org/10.1016/j.physd.2019.132306>
- Solomon, M. O. (1991). PSD Computations Using Welch's Method. *Sandia National*

*Laboratories, SAND91-1533, 64.*

- Song, Y. Y., & Lu, Y. (2015). Decision tree methods: applications for classification and prediction. *Shanghai Archives of Psychiatry, 27*(2), 130–135. <https://doi.org/10.11919/j.issn.1002-0829.215044>
- Staudemeyer, R. C., & Morris, E. R. (2019). – Understanding LSTM – a tutorial into Long Short-Term Memory Recurrent Neural Networks. *September*.
- Subasi, A., & Gursoy, M. I. (2010). EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert Systems with Applications, 37*(12), 8659–8666. <https://doi.org/10.1016/j.eswa.2010.06.065>
- Subha, D. P., Joseph, P. K., Acharya U, R., & Lim, C. M. (2010). EEG signal analysis: a survey. *Journal of Medical Systems, 34*(2), 195–212. <https://doi.org/10.1007/s10916-008-9231-z>
- Taha, B. H., Dempsey, J. A., Weber, S. M., Badr, M. S., Skatrud, J. B., Young, T. B., Jacques, A. J., & Seow, K. C. (1997). Automated detection and classification of sleep-disordered breathing from conventional polysomnography data. *Sleep, 20*(11), 991–1001. <https://doi.org/10.1093/sleep/20.11.991>
- Taran, S., Bajaj, V., Sinha, G. R., & Polat, K. (2021). Detection of sleep apnea events using electroencephalogram signals. *Applied Acoustics, 181*, 108137. <https://doi.org/10.1016/j.apacoust.2021.108137>
- Tharwat, A. (2016). Linear vs. quadratic discriminant analysis classifier: a tutorial. *International Journal of Applied Pattern Recognition, 3*(2), 145. <https://doi.org/10.1504/ijapr.2016.079050>
- Yang, S., & Berdine, G. (2017). The receiver operating characteristic (ROC) curve. *The Southwest Respiratory and Critical Care Chronicles, 5*(19), 34. <https://doi.org/10.12746/swrccc.v5i19.391>
- Yildiz, A. (2017). Tek kanallı EKG kayıtları analizinden uyku apne tespiti. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 1*(8), 111–122. <http://www.dicle.edu.tr/muhendislikdergisi/cilt8sayi1/MD-16-085.pdf>
- Young, L. R., & Sheena, D. (1975). Survey of eye movement recording methods. *Behavior Research Methods & Instrumentation, 7*(5), 397–429. <https://doi.org/10.3758/BF03201553>
- Zemouri, R., Zerhouni, N., & Racoceanu, D. (2019). Deep learning in the biomedical applications: Recent and future status. *Applied Sciences (Switzerland), 9*(8). <https://doi.org/10.3390/app9081526>