

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DÜŞÜK ÇÖZÜNÜRLÜKLÜ SENSÖRLERLE
BİYOMETRİ

Fatma Saba KOÇKAN

DOKTORA TEZİ
Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Elektronik Programı

Danışman
Doç. Dr. Bülent BOLAT

Şubat, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DÜŞÜK ÇÖZÜNÜRLÜKLÜ SENSÖRLERLE BİYOMETRİ

Fatma Saba KOÇKAN tarafından hazırlanan tez çalışması 26.02.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Elektronik Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Bülent BOLAT
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Bülent BOLAT, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Mehmet SAĞBAŞ, Üye
İzmir Bakırçay Üniversitesi

Prof. Dr. Umut Engin AYTEN, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Peyman MAHOUTİ, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Gökalg TULUM, Üye
İstanbul Topkapı Üniversitesi

Danışmanım Doç. Dr. Bülent BOLAT sorumluluğunda tarafımca hazırlanan Düşük Çözünürlüklü Sensörlerle Biyometri başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Fatma Saba KOÇKAN

İmza

Dünyam Mustafa Alp' e,



TEŞEKKÜR

Bu uzun tez çalışması boyunca, değerli rehberliği sayesinde çalışmamı tamamlamamı mümkün kılan kıymetli danışmanım Doç. Dr. Bülent BOLAT'a derin şükranlarımı sunmak istiyorum.

Tez izleme jürimde yer alan saygıdeğer hocalarım Prof. Dr. Mehmet SAĞBAŞ ve Prof. Dr. Umut Engin AYTEN'e, katkıları ve değerli geri bildirimleri için içten teşekkürlerimi iletiyorum. Onların eleştirileri ve önerileri, bu tezin kalitesini artırmamda büyük rol oynamıştır.

Tez savunma sınavımda yer alarak tezimin son şeklinin oluşmasına katkı sağlayan değerli jüri üyelerim Doç. Dr. Peyman MAHOUTİ ve Dr. Öğr. Üyesi Gökalp TULUM'a da, kıymetli yorumları ve yönlendirmeleri için teşekkür ederim.

Arkadaşlarım Sinem ve Hüsamettin UYSAL'a, samimiyetleri ve sürekli destekleri için teşekkür ederim. Sizinle yaptığım paylaşımlar, bu süreci daha keyifli hale getirmiştir.

EKG verilerini sağlayan tüm katılımcılara da içten teşekkürlerimi sunmak istiyorum. Katkılarınız, bu çalışmanın temelini oluşturmuş ve sonuçlarının geçerliliğini sağlamıştır.

Canım annem ve babam, biricik kardeşim Seda, her zaman bana inandınız ve cesaretlendirdiniz. Sevgili Koçkan ailem, her ihtiyaç duyduğumda yanımda oldunuz. Eşim Murat ve güzel yavrum Mustafa Alp, sizin sevginiz ve desteğiniz, bu tez sürecindeki tüm zorlukların üstesinden gelmemde en büyük motivasyonum olmuştur. Hepinize derin teşekkürlerimi sunuyorum.

Fatma Saba KOÇKAN

İÇİNDEKİLER

SİMGE LİSTESİ	viii
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	xi
TABLO LİSTESİ	xiii
ÖZET	xv
ABSTRACT	xvii
1 GİRİŞ	1
1.1 Biyometri ve Kavramsal Temeller	2
1.2 Mobil Biyometrik Uygulamalar	3
1.3 Elektrokardiyogram (EKG) ve Biyometrik Öznitelikler	5
1.4 Tezin Amacı ve Kapsamı	9
1.5 Literatür Özeti	9
1.5.1 Literatürde i-vektörlerin EKG ile Kullanımı	20
1.6 Hipotez	21
2 ELEKTROKARDİYOGRAM (EKG) BİYOMETRİSİ: KİMLİK DOĞRULAMADA TEMEL İLKELER VE YÖNTEMSEL YAKLAŞIMLAR	24
2.1 Ön İşleme: Gürültü Giderme ve R-Peak Tespiti ile EKG Sinyal Segmentasyonu	25
2.2 Öznitelik Çıkarma Yöntemleri	26
2.2.1 Mel Frekansı Kepstrum Katsayıları (MFCC)	27
2.2.2 Gammatone Frekansı Kepstrum Katsayıları (GFCC)	29
2.3 i-vektör ve İlgili Yöntemler	30
2.3.1 Doğrusal Diskriminant Analiz (LDA)	32
2.3.2 Sınıf İçi Kovaryans Normalizasyonu (WCCN)	33
2.4 Sınıflandırma Yöntemleri ve Benzerlik Ölçütleri	33
2.4.1 Destek Vektör Makineleri (SVM)	34

2.4.2	Çok Katmanlı Algılayıcı (MLP)	35
2.4.3	Rastgele Orman (RF)	36
2.4.4	Konvolüsyonel Sinir Ağları (CNN)	37
2.4.5	Tekrarlayan Sinir Ağları (RNN)	38
2.4.6	Kosinüs Mesafesi (Cosine Distance)	38
2.4.7	Öklid Mesafesi (Euclidean Distance)	39
2.4.8	Manhattan Mesafesi (Manhattan Distance)	39
2.4.9	Pearson Korelasyonu (Pearson Correlation)	39
2.4.10	Dinamik Zaman Esnetme (Dynamic Time Warping, DTW)	40
3	VERİTABANLARI	41
3.1	ECG-ID Veritabanı	41
3.2	Heartprint Veritabanı	41
3.3	BMD101 EKG Sensör Modülüyle Elde Edilen Veritabanı	42
4	METODOLOJİ	45
4.1	Ön İşleme	45
4.2	Önerilen Yöntem: Öznitelik Çıkarımı ve i-vektör Temsili	46
4.2.1	Öznitelik Çıkarımı	46
4.2.2	i-vektörlerin Elde Edilmesi	47
4.3	EKG ile Doğrulama için Kullanılan Alternatif Yaklaşımlar	48
4.3.1	Öznitelik Çıkarımı ve Normalizasyon	49
4.3.2	Kullanıcı Bazlı Model Kurma ve Hiperparametre Arayışı	49
4.3.3	SVM Modelleme ve Hiperparametre Optimizasyonu	50
4.3.4	MLP Modelleme ve Hiperparametre Optimizasyonu	50
4.3.5	RF Modelleme ve Hiperparametre Optimizasyonu	52
4.3.6	CNN Modelleme ve Hiperparametre Optimizasyonu	53
4.3.7	RNN Modelleme ve Hiperparametre Optimizasyonu	55
4.3.8	Son Değerlendirme	56
4.4	Performans Değerlendirme Metrikleri	56
4.4.1	Doğru Kabul Oranı (TAR)	57
4.4.2	Yanlış Kabul Oranı (FAR)	57
4.4.3	Doğru Reddetme Oranı (TRR)	57
4.4.4	Yanlış Reddetme Oranı (FRR)	58
4.4.5	Doğruluk (ACC)	58
4.4.6	Eşit Hata Oranı (EER)	59
4.4.7	Alıcı İşletim Karakteristiği (ROC)	59
5	DENEYSEL SONUÇLAR	60
5.1	Veri Bölme Stratejisi	60

5.2	i-vektör Yönteminin Genel Adımları	61
5.2.1	Veri Görselleştirme	62
5.3	ECG-ID Veritabanı Performans Analizi	63
5.4	BMD101 Veritabanı Performans Analizi	71
5.5	Heartprint Veritabanı Performans Analizi	86
5.6	Sinyal Süresine Dayalı Performans Değerlendirmesi	95
5.7	Alternatif Yaklaşımların Performans Analizi	97
5.8	Benzerlik Ölçütleri Performans Analizi	98
5.9	Sonuçlar	98
6	SONUÇ	100
	KAYNAKÇA	102
	TEZDEN ÜRETİLMİŞ YAYINLAR	110

SİMGE LİSTESİ

B	Bant Geniřlięi
F	Birinci Dereceden Baum-Welch İstatistięi
ϕ	Faz Kayması
K	Genlik Kazancı
f_c	Merkez Frekansı
N	Sıfırncı Dereceden Baum-Welch İstatistięi
M	Süpervektör

KISALTMA LİSTESİ

ACC	Doğruluk (Accuracy)
ADC	Analog Dijital Dönüştürücü (Analog Digital Converter)
AUC	Eğrinin Altındaki Alan (Area Under the Curve)
BIH	Beth Israel Hastanesi (Beth Israel Hospital)
CNN	Konvolüsyonel Sinir Ağı (Convolutional Neural Network)
DCT	Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform)
DTW	Dinamik Zaman Esnetme (Dynamic Time Warping)
EER	Eşit Hata Oranı (Equal Error Rate)
EKG	Elektrokardiyogram
EM	Beklenti Maksimizasyonu (Expectation Maximization)
EMD	Deneyisel Mod Dekompozisyonu (Empirical Mode Decomposition)
ERB	Eşdeğer Dikdörtgen Bant Genişliği (Equivalent Rectangular Bandwidth)
FAR	Yanlış Kabul Oranı (False Acceptance Rate)
FFT	Hızlı Fourier Dönüşümü (Fast Fourier Transform)
FIR	Sonlu İmpuls Cevabı (Finite Impulse Response)
FRR	Yanlış Reddetme Oranı (False Rejection Rate)
GFCC	Gammatone Frekanslı Cepstrum Katsayıları (Gammatone Frequency Cepstrum Coefficients)
GMM	Gauss Karışım Modeli (Gaussian Mixture Model)
HT	Hilbert Dönüşümü (Hilbert Transform)
i-vektör	Kimlik Vektörü (Identity Vector)
kNN	k-En Yakın Komşu (k-Nearest Neighbors)
LDA	Doğrusal Diskriminant Analiz (Linear Discriminant Analysis)

LNA	Düşük Gürültülü Amplifikatör (Low Noise Amplifier)
MAP	Maksimum Posteriori (Maximum a Posteriori)
MFCC	Mel Frekansı Kepstrum Katsayıları (Mel Frequency Cepstrum Coefficients)
MIT	Massachusetts Teknoloji Enstitüsü (Massachusetts Institute of Technology)
MLP	Çok Katmanlı Algılayıcı (Multi-Layer Perceptron)
PT	Pan Tompkins Algoritması (Pan-Tompkins Algorithm)
PTB	Federal Fizik ve Teknoloji Enstitüsü (Physikalisch-Technische Bundesanstalt)
RBF	Radyal Baz Fonksiyonu (Radial Basis Function)
RF	Rastgele Orman (Random Forest)
RNN	Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
ROC	Alıcı İşlem Karakteristikleri (Receiver Operating Characteristic)
STFT	Kısa Zamanlı Fourier Dönüşümü (Short-Time Fourier Transform)
SVM	Destek Vektör Makinesi (Support Vector Machine)
TAR	Doğru Kabul Oranı (True Acceptance Rate)
TRR	Doğru Reddetme Oranı (True Rejection Rate)
t-SNE	Dağıtık Stokastik Komşu Gömme (t-distributed Stochastic Neighbor Embedding)
TV	Toplam Değişkenlik Uzayı (Total Variability Space)
UART	Evrensel Asenkron Alıcı/Verici (Universal Asynchronous Receiver/Transmitter)
UBM	Evrensel Arka Plan Modeli (Universal Background Model)
WCCN	Sınıf İçi Kovaryans Normalizasyonu (Within-Class Covariance Normalization)
WT	Dalgacık Dönüşümü (Wavelet Transform)

ŞEKİL LİSTESİ

Şekil 1.1	Biyometrik yöntemlerin sınıflandırılması [7]	4
Şekil 1.2	(a) 12 derivasyonlu sistemde elektrot yerleşimi, (b) 12 derivasyonlu EKG, (c) Einthoven üçgeni [16]	6
Şekil 1.3	Elektrokardiyogram	8
Şekil 1.4	KardioChip adlı EKG algılama modülü [17]	15
Şekil 1.5	AliveCore EKG mobil sensörü [2]	16
Şekil 1.6	EKG ölçüm cihazı [34]	17
Şekil 1.7	EKG ölçümü için giyilebilir saat [36]	17
Şekil 1.8	Nymi band kullanılarak EKG ölçümü [40]	19
Şekil 2.1	Pan-Tompkins algoritması	26
Şekil 2.2	Pan-Tompkins algoritması yardımıyla referans noktaların belirlenmesi [52]	27
Şekil 2.3	MFCC özniteliklerinin çıkarılması işlemi blok diyagramı	28
Şekil 2.4	GFCC özniteliklerinin çıkarılması işlemi blok diyagramı	29
Şekil 3.1	ReadMyHeart el tipi EKG cihazı [95]	42
Şekil 3.2	BMD101 EKG sensör modülü	43
Şekil 4.1	Bir EKG sinyalinin orijinal zaman serisi, spektrogramı ve güç spektrumu	45
Şekil 4.2	Ön işleme algoritma uygulaması	46
Şekil 4.3	i-vektör algoritması blok diyagramı	47
Şekil 5.1	Geliştirme seti: 20 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (ECG-ID)	64
Şekil 5.2	Eğitim-test seti: 20 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (ECG-ID)	64
Şekil 5.3	En yüksek doğruluğa dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 16, ECG-ID)	66
Şekil 5.4	Kimlik doğrulama eşliğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 16, ECG-ID)	67
Şekil 5.5	EER noktasına dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 32, ECG-ID)	69
Şekil 5.6	Kimlik doğrulama eşliğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 32, ECG-ID)	70

Şekil 5.7	Geliştirme seti: 22 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (BMD-1)	72
Şekil 5.8	Eğitim-test seti: 6 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (BMD-1)	72
Şekil 5.9	En yüksek doğruluğa dayalı ROC Eğrisi (Sinyal süresi: 4 s, Karışım sayısı: 64, BMD-1)	74
Şekil 5.10	Kimlik doğrulama eşiğine ilişkin FAR ve FRR performansları (Sinyal süresi: 4 s, Karışım sayısı: 64, BMD-1)	75
Şekil 5.11	EER noktasına dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 8, BMD-1)	78
Şekil 5.12	Kimlik doğrulama eşiğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 8, BMD-1)	78
Şekil 5.13	Geliştirme seti: 23 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (BMD-2)	79
Şekil 5.14	Eğitim-test seti: 10 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (BMD-2)	80
Şekil 5.15	En yüksek doğruluğa dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 8, BMD-2)	81
Şekil 5.16	Kimlik doğrulama eşiğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 8, BMD-2)	82
Şekil 5.17	EER noktasına dayalı ROC Eğrisi (Sinyal süresi: 4 s, Karışım sayısı: 8, BMD-2)	85
Şekil 5.18	Kimlik doğrulama eşiğine ilişkin FAR ve FRR performansları (Sinyal süresi: 4 s, Karışım sayısı: 8, BMD-2)	85
Şekil 5.19	Geliştirme seti: 108 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (Heartprint)	87
Şekil 5.20	Eğitim-test seti: 199 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (Heartprint)	87
Şekil 5.21	En yüksek doğruluğa ve EER noktasına dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 32, Heartprint)	94
Şekil 5.22	Kimlik doğrulama eşiğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 32, Heartprint)	94

TABLO LİSTESİ

Tablo 5.1	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (ECG-ID) - MFCC	65
Tablo 5.2	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (ECG-ID) - GFCC	66
Tablo 5.3	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (ECG-ID) - MFCC+GFCC . . .	67
Tablo 5.4	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (ECG-ID) - MFCC	68
Tablo 5.5	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (ECG-ID) - GFCC	69
Tablo 5.6	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (ECG-ID) - MFCC+GFCC . . .	70
Tablo 5.7	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-1) - MFCC	73
Tablo 5.8	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-1) - GFCC	74
Tablo 5.9	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-1) - MFCC+GFCC . . .	75
Tablo 5.10	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-1) - MFCC	76
Tablo 5.11	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-1) - GFCC	77
Tablo 5.12	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-1) - MFCC+GFCC . . .	77
Tablo 5.13	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-2) - MFCC	80
Tablo 5.14	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-2) - GFCC	81
Tablo 5.15	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-2) - MFCC+GFCC . . .	82
Tablo 5.16	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-2) - MFCC	83

Tablo 5.17	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-2) - GFCC	84
Tablo 5.18	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-2) - MFCC+GFCC . . .	84
Tablo 5.19	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (Heartprint) - MFCC	88
Tablo 5.20	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (Heartprint) - GFCC	89
Tablo 5.21	Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (Heartprint) - MFCC+GFCC . .	90
Tablo 5.22	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (Heartprint) - MFCC	91
Tablo 5.23	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (Heartprint) - GFCC	92
Tablo 5.24	Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (Heartprint) - MFCC+GFCC . .	93
Tablo 5.25	Heartprint veritabanındaki 199 bireyin önerilen yöntemin farklı kayıt ve doğrulama sürelerinde performans analizi (MFCC ve GFCC özniteliklerinin birleştirilmesi ve karışım sayısı: 32) . . .	95
Tablo 5.26	Heartprint veritabanındaki 108 bireyin önerilen yöntemin farklı kayıt ve doğrulama sürelerinde performans analizi (MFCC ve GFCC özniteliklerinin birleştirilmesi ve karışım sayısı: 32) . . .	96
Tablo 5.27	Heartprint veritabanı üzerinde EKG tabanlı kimlik doğrulama yöntemlerinin performansları	97
Tablo 5.28	i-vektörlerin farklı benzerlik ölçütleriyle karşılaştırılması	98
Tablo 5.29	En yüksek doğruluğa dayalı önerilen yöntemin özeti	98
Tablo 5.30	Eşit hata oranı (EER) için optimal çalışma noktasına dayalı önerilen yöntemin özeti	99
Tablo 5.31	Mobil platformlarda parmak üzerinden elde edilen EKG algoritmalarının karşılaştırılması	99

Düşük Çözünürlüklü Sensörlerle Biyometri

Fatma Saba KOÇKAN

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Doktora Tezi

Danışman: Doç. Dr. Bülent BOLAT

Kişisel veri güvenliğinin kritik önem taşıdığı dijital çağda, geleneksel biyometrik yöntemlerin mobil cihazlarda yaşadığı güvenlik kısıtları, daha güvenilir ve güçlü kimlik doğrulama yaklaşımlarına olan ihtiyacı artırmaktadır. Bu kapsamda gerçekleştirilen çalışma, mobil cihazlarda kullanılmak üzere, düşük çözünürlüklü sensörlerden elde edilen elektrokardiyogram (EKG) verilerine dayanan yenilikçi bir kimlik doğrulama yöntemi önermektedir.

EKG, kalp aktivitesinden elde edilen elektriksel sinyaller aracılığıyla bireye özgü biyometrik özellikler sunan bir tekniktir. Kalp atışının ritmik ve bireye has özellikleri, EKG'yi kimlik doğrulama ve insan tanıma uygulamaları için ideal bir veri kaynağı haline getirmektedir.

Önerilen yöntemde, son on yılda konuşmacı tanıma alanında başarılı sonuçlar elde eden i-vektör yaklaşımından yararlanılmaktadır. i-vektörler, veri sıkıştırma ve özellik çıkarımı süreçlerinde etkinlik sağlayarak, kimlik doğrulama ve tanıma sistemlerinin verimliliğini artırmaktadır. Çalışmada, EKG verilerinden elde edilen öznitelikler arasında Mel Frekansı Kepstral Katsayıları (MFCC) ve Gammatone Frekansı Kepstral Katsayıları (GFCC) kullanılmaktadır. MFCC, ses sinyalinin kısa süreli güç spektrumunu temsil ederken, GFCC, insan kulağının frekans çözünürlüğünü modelleyerek daha doğal bir özellik çıkarımını mümkün kılmaktadır.

Bireysel EKG sinyallerinden elde edilen öznitelikler kullanılarak oluşturulan i-vektörler, kosinüs mesafesi ölçümü ile puanlanmış ve bu sayede kimlik doğrulama

işlemi gerçekleştirilmiştir. Kosinüs mesafesi, vektörler arasındaki açısal farkı ölçerek benzerlik değerlendirmesi yapmada etkili bir metrik olarak öne çıkmaktadır.

Deneysel sonuçlar, önerilen yöntemin yüksek doğruluk oranlarıyla mobil cihazlar için pratik çözümler sunma potansiyelini ortaya koymakta; yöntem, güvenilirliğini ve uygulanabilirliğini doğrulamaktadır.

Bu tez, biyometrik kimlik doğrulama alanında EKG verilerinin kullanımını yaygınlaştırmayı amaçlamakta ve mobil güvenlik çözümlerine özgün yaklaşımlar kazandırmayı hedeflemektedir. Ayrıca, önerilen yöntemin gelecekte daha güvenli ve kullanıcı dostu biyometrik sistemlerin geliştirilmesine önemli katkılar sağlayacağı öngörülmektedir.

Anahtar Kelimeler: Biyometrik kimlik doğrulama, elektrokardiyogram, gammatone frekans kepstrum katsayısı (GFCC), i-vector, mel frekans kepstrum katsayısı (MFCC).

ABSTRACT

Biometrics with Low Resolution Sensors

Fatma Saba KOÇKAN

Department of Electronics and Communication Engineering

Doctor of Philosophy Thesis

Supervisor: Assoc. Prof. Dr. Bülent BOLAT

In the digital age, where personal data security is of critical importance, the security limitations of traditional biometric methods on mobile devices have increased the need for more reliable and robust identity authentication approaches. In this context, this study proposes an innovative identity verification method based on electrocardiogram (ECG) data acquired from low-resolution sensors, designed for use on mobile devices.

ECG is a technique that provides individual-specific biometric features through electrical signals generated by cardiac activity. The rhythmic and unique characteristics of heartbeats make ECG an ideal data source for identity verification and human recognition applications.

In the proposed method, the i-vector approach—which has achieved successful results in speaker recognition over the past decade—is utilized. I-vectors enhance the efficiency of authentication and identification systems by enabling effective data compression and feature extraction. In this study, Mel Frequency Cepstral Coefficients (MFCC) and Gammatone Frequency Cepstral Coefficients (GFCC) are employed as feature extraction techniques from ECG data. While MFCC represents the short-term power spectrum of audio signals, GFCC models the frequency resolution of the human ear, thereby enabling a more natural feature extraction process.

The i-vectors, derived from individual ECG signals, are scored using cosine distance measurement, thus facilitating the identity verification process. Cosine distance

stands out as an effective metric by quantifying the angular difference between vectors for similarity evaluation.

Experimental results demonstrate that the proposed method, with its high accuracy rates, reveals significant potential in providing practical solutions for mobile devices, thereby confirming its reliability and applicability.

This thesis aims to promote the widespread use of ECG data in the field of biometric authentication and to introduce innovative approaches to mobile security solutions. Furthermore, it is anticipated that the proposed method will contribute significantly to the development of safer and more user-friendly biometric systems in the future.

Keywords: Biometric authentication, electrocardiogram, gammatone frequency cepstrum coefficient (GFCC), i-vector, mel frequency cepstrum coefficient (MFCC).

1 GİRİŞ

Teknolojideki hızlı ilerlemeler, günlük yaşamımızda önemli dönüşümlere neden olarak mobil cihazların kullanımını küresel ölçekte yaygınlaştırmıştır. Mobil cihazlar yalnızca iletişim aracı olmaktan çıkmış; sosyal medya, finansal işlemler, sağlık ve eğitim gibi birçok alanda hayatımızın ayrılmaz bir parçası hâline gelmiştir. Akıllı telefonların kullanımının hızla artması ve kullanıcıların günlük hayatlarında bu cihazlara ayırdıkları sürenin giderek yükselmesi, mobil teknolojilerin insan yaşamını şekillendirmede ne derece etkili olduğunu açıkça göstermektedir.

Mobil cihazların artan kullanımı, kişisel ve hassas verilere yönelik tehditleri de artırmıştır [1]. Özellikle son dönemde mobil cihazları hedef alan siber saldırıların artması, kişisel veri güvenliğinin önemini ve korunması ihtiyacının kritik bir noktaya ulaştığını ortaya koymaktadır. Mobil cihazlarda geleneksel kimlik doğrulama yöntemleri (PIN, desen veya grafiksel şifreler), kullanıcı tarafından belirlenen şifrenin güvenlik seviyesine bağlı olarak farklılık göstermekle birlikte, günümüzün karmaşıklaşan tehditlerine karşı yetersiz kalmaktadır [2]. Bu nedenle kullanıcılar, daha güçlü ve güvenilir olan biyometrik doğrulama yöntemlerine yönelmiştir.

Biyometrik doğrulama yöntemleri, bireylerin benzersiz fizyolojik ve davranışsal özelliklerini temel alarak, geleneksel yöntemlere göre daha güvenli bir doğrulama sağlamaktadır [3]. Parmak izi, yüz veya iris tanıma gibi popüler yöntemlerin kolayca taklit edilebilme riskleri bulunmaktadır. Parmak izi yöntemleri yapay malzemeler kullanılarak, yüz tanıma yöntemleri ise fotoğraf veya video gibi basit yöntemlerle aldatılabilmektedir. Benzer şekilde, ses tanıma sistemlerinin kayıtlar aracılığıyla kandırılması mümkündür. Bu bağlamda, canlılık doğrulaması sunan; benzersiz elektrofizyolojik yapısı nedeniyle taklit edilmesi oldukça güç olan elektrokardiyogram (EKG) tabanlı biyometrik doğrulama yöntemleri ön plana çıkmaktadır.

Elektrokardiyogram (EKG), kalbin elektriksel aktivitesinden elde edilen ve

bireye özgü fizyolojik öznitelikleri içeren biyolojik sinyallerdir. Kalp atışlarının kişiye özgü ritmik yapısı nedeniyle EKG, evrensellik, eşsizlik, süreklilik ve elde edilebilirlik gibi temel biyometrik kriterleri karşılamaktadır. Son yıllarda yapılan çalışmalar, düşük maliyetli ve düşük çözünürlüklü sensörlerle bile kısa süreli EKG kayıtlarının mobil cihazlarda güvenilir kimlik doğrulama amacıyla kullanılabileceğini ortaya koymuştur. Bu tez çalışmasının temel amacı da, mobil cihazlarda kullanılmak üzere düşük çözünürlüklü sensörlerle kısa süreli kaydedilen EKG sinyallerinin biyometrik doğrulamadaki etkinliğini araştırmaktır.

Bu amaç doğrultusunda, EKG sinyallerindeki bireye özgü özniteliklerin temsilinde Mel Frekanslı Kepstral Katsayıları (MFCC) ve Gammatone Frekanslı Kepstral Katsayıları (GFCC) gibi gelişmiş sinyal işleme tekniklerinden yararlanılmıştır. MFCC yöntemi, sinyallerin kısa süreli güç spektrumunu temsil ederek öznitelik çıkarırken, GFCC yöntemi ise insan kulağının doğal frekans çözünürlüğüne yakın bir öznitelik çıkarımı sağlamaktadır. Bu yöntemlerin birlikte kullanılması, EKG sinyallerinin ayrıştırıcı gücünü belirgin biçimde artırmaktadır.

Çalışmada ayrıca, konuşmacı tanıma alanında başarıyla kullanılan ve biyometrik sistemlerde etkinliği kanıtlanmış olan i-vektör yaklaşımından yararlanılmıştır. Bu yöntem, kısa ve düşük çözünürlüklü EKG verilerinde dahi yüksek doğruluk sağlayarak, mobil cihazların sınırlı kaynakları açısından uygun, hafif, güvenilir ve hızlı bir doğrulama yöntemi sunmaktadır.

Sonuç olarak, bu tez kapsamında geliştirilen yöntemle, mobil cihazlarda düşük çözünürlüklü sensörlerle elde edilen kısa süreli EKG verileri kullanılarak, mevcut teknolojilere kıyasla daha güvenilir, kullanıcı dostu ve hızlı bir biyometrik doğrulama sistemi sunmak hedeflenmiştir. Yapılan deneysel çalışmalar da, önerilen yöntemin yüksek doğruluk ve pratik uygulanabilirlik sağlayabileceğini göstermiştir.

1.1 Biyometri ve Kavramsal Temeller

Biyometri, bireylerin ölçülebilir fizyolojik veya davranışsal özniteliklerine dayanarak kimlik tanımlama ve doğrulama yapan yöntemler bütünüdür. Bu yöntemler, bireye özgü, unutulması veya kaybedilmesi mümkün olmayan ve tahmin edilmesi güç yapılar sunar. Bu nedenle biyometri, güvenlik sistemlerinde yaygın olarak tercih edilen bir alan haline gelmiştir [4].

Ancak her insan özelliği biyometrik olarak değerlendirilemez. Bir özelliğin biyometrik öznitelik olarak kabul edilebilmesi için, aşağıdaki temel kriterlere sahip olması gerekmektedir:

- **Evrensellik:** Karakteristiğın tüm bireylerde bulunması,
- **Eşsizlik:** Her bireye özgü, birbirinden farklı olması,
- **Süreklilik:** Zaman içinde yeterince sabit kalması,
- **Elde Edilebilirlik:** Pratikte ölçülebilir ve kaydedilebilir olması [4–7].

Bunun yanı sıra, bir özelliğın biyometrik sistemlerde etkin bir şekilde kullanılabilmesi için şu ek gereklilikler de göz önünde bulundurulmalıdır:

- **Performans:** Özelliğın doğru, hızlı ve sağlam ölçümlere olanak tanınması; çevresel ve işlevsel etkilere karşı dayanıklı olması,
- **Kabul Edilebilirlik:** Bireylerin, özniteliklerin ölçümü ve kullanımı konusunda itirazda bulunmaması,
- **Kandırılmaya Karşı Dayanıklılık:** Özelliğın kolayca taklit edilememesi [6, 7].


Farklı insan özniteliklerinin daha iyi tanımlanabilmesi amacıyla, fizyolojik yöntemler, vücut üzerindeki konumlarına göre kategorize edilmektedir. Bu kategoriler aşağıdaki gibi sınıflandırılabilir:

- El bölgesi öznitelikleri,
- Yüz bölgesi öznitelikleri,
- Göz ve perioküler bölge öznitelikleri,
- Davranışsal öznitelikler,
- Mediko-kimyasal öznitelikler [7].

Şekil 1.1’de, biyometrik yöntemlerin sınıflandırılması şematik olarak sunulmaktadır.

1.2 Mobil Biyometrik Uygulamalar

Mobil cihazlarda, parmak izi, ses, iris, yüz, avuç izi, diş, yürüyüş ve imza tanıma gibi çeşitli biyometrik yöntemler kullanılmaktadır. Ancak bu yöntemler; uygulama alanı, donanım ihtiyacı, kararlılık ve doğruluk gibi kriterler açısından farklılıklar



Şekil 1.1 Biyometrik yöntemlerin sınıflandırılması [7]

göstermektedir. Dolayısıyla, kullanıcılar için yüksek tanıma performansı, kolay kullanım ve güvenilirlik sunan ideal bir biyometrik yöntemin belirlenmesi hâlen zorlu bir problem olarak karşımıza çıkmaktadır [8].

Özellikle, parmak izi tanıma, mobil cihazlarda en çok tercih edilen biyometrik yöntemlerden biri olarak öne çıkmaktadır. Bununla birlikte, parmak izinin bozulması ya da sahte parmak izi kullanılması gibi durumlar, kimlik doğrulama sürecinde hata oranlarını artırarak güvenlik açıklarına neden olabilmektedir. Ticari cep telefonlarında, parmak izi doğrulamasının bu tür zayıflıkları gözlemlenmiştir [2].

Mobil cihazlarda ek donanıma ihtiyaç duymadan çalışan yüz ve iris tanıma teknikleri de literatürde yaygın biçimde uygulanmaktadır. Ancak bu sistemlerin performansı, genellikle uygun ışık koşullarında elde edilen kaliteli görüntülere bağlı olarak değişiklik göstermektedir [8].

Ayrıca, ses tanıma yöntemleri çevresel gürültüye duyarlı olup, ses kayıtları yoluyla yanıltılma riski taşımaktadır [9]. Mobil yürüme tanıma sistemleri ise yerleşik ivmeölçer verilerine dayanarak gerçekleştirilmektedir; ancak bu sistemler henüz istenilen güvenilirlik düzeyine ulaşamamış olup, doğru şekilde eğitilmiş bir

saldırılan tarafından kandırılma ihtimali mevcuttur [10, 11].

Kalp, doğal ve güvenilir bir biyometrik öznitelik olarak kabul edilmektedir. Son zamanlarda, elektrokardiyogram (EKG) tabanlı biyometrik tanıma sistemleri, hem sinyallerin canlı bir vücuttan elde edilmesinden kaynaklanan güvenlik üstünlüğü hem de biyometrik bilgilerin kamufle edilebilme özelliği sayesinde önemli bir ilgi odağı haline gelmiştir. EKG sinyalleri, biyolojik işlevlere dayandığından, diğer biyometrik verilere kıyasla atlatılması veya taklit edilmesi çok daha güçtür [12]. Bu özellik, EKG tabanlı tanıma sistemlerinin, bireylerin kalp atışlarını benzersiz biyometrik öznitelik olarak kullanarak kimlik doğrulama ve tanımlama sağlamasında önemli bir rol oynamaktadır.


1.3 Elektrokardiyogram (EKG) ve Biyometrik Öznitelikler

Elektrokardiyogram (EKG), kalbin ritim, frekans, atım düzeni, yayılım ve tekrar eden elektriksel aktivitelerinin vücut yüzeyinden kaydedilmesiyle elde edilen biyolojik sinyallerdir. Bu yöntem, kalp ritmi, damar hastalıkları, kalp krizi ve kardiyak hipertrofi gibi durumların tespitinde değerli klinik bilgiler sunar.

Kalp kası (miyokard), kendi kendine kasılma özelliğine sahiptir. Kalbin sinüs düğümünden çıkan düzenli uyarılar, özel iletim yolları aracılığıyla kas hücrelerine aktarılır [13]. Dinlenme halindeki hücreler elektriksel olarak polarizeyken, gelen uyarılar nedeniyle depolarize olarak kasılır ve kısalır. Böylece, kalp odacıklarını çevreleyen miyokard, bütünsel bir büzülme yaşayarak içindeki kanı büyük ve küçük dolaşıma gönderir. Bu kasılma sürecine sistol denir; sistol sonrası hücreler hızla eski elektrik yüklerine kavuşarak yeniden polarize olur ve bu süreç, kalp atım sayısı kadar tekrarlanır.

Kalbin elektriksel faaliyeti sonucunda ortaya çıkan potansiyel farklar, çevre dokular ve özellikle kan aracılığıyla tüm vücuda yayılır. Vücut üzerinde yerleştirilen elektrotlar, bu farkları kaydederek elektrokardiyogram eğrileri oluşturur. Her bölgedeki potansiyel farklarının kaydedilmesi, ilgili bölgeye ait derivasyon (lead) kavramını ortaya çıkarır. Normal bir EKG, I, II, III, aVR, aVL, aVF, V1, V2, V3, V4, V5 ve V6 olmak üzere toplam 12 derivasyonu içerir [14, 15].

Şekil 1.2’de, 12 derivasyonlu EKG konfigürasyonu gösterilmiştir. Bu şema, elektrotların vücut üzerindeki yerleşimini ve her bir derivasyonun kalbin hangi bölgesini temsil ettiğini ayrıntılı biçimde sunar.



 ekil 1.2 (a) 12 derivasyonlu sistemde elektrot yerle imi, (b) 12 derivasyonlu EKG, (c) Einthoven   geni [16]

EKG derivasyonları genel olarak şu şekilde sınıflandırılır:

- **I, II, III derivasyonları:** Frontal düzlemde kalbin elektriksel aktivitesini ölçer.
- **aVR, aVL, aVF derivasyonları:** Ekstremité derivasyonları olarak bilinir; yine frontal düzlemde kalbin aktivitesini değerlendirir.
- **V1, V2, V3, V4, V5, V6 derivasyonları:** Göğüs (horizontal) düzlemde kalbin elektriksel aktivitesini kaydeder.

Her bir derivasyon, kalbin belirli bölgelerinden elde edilen sinyalleri temsil eder:

- **I derivasyonu:** Sol atriyum ve sol ventrikülün lateral duvarı,
- **II ve III derivasyonları:** Sağ atriyum ve sol ventrikülün inferior (alt) duvarı,
- **aVR:** Sağ atriyum,
- **aVL:** Sol ventrikülün lateral duvarı,
- **aVF:** Kalbin inferior (alt) duvarı,
- **V1 ve V2:** Sağ ventrikül ve septum,
- **V3 ve V4:** Anterior (ön) duvar,
- **V5 ve V6:** Sol ventrikülün lateral duvarı.


Einthoven üçgeni, EKG derivasyonlarının geometrik ilişkilerini açıklayan temel bir kavramdır. Üç elektrot arasındaki bağlantıları tanımlayan bu üçgen, derivasyon I, II ve III ile temsil edilmektedir:

- **Derivasyon I (Lead I):** Sol kol ile sağ kol arasındaki voltaj farkını ölçer ve kalbin sağ-sol (lateral) aktivitesini yansıtır.
- **Derivasyon II (Lead II):** Sağ kol ile sol bacak arasındaki voltaj farkını kaydeder; kalbin üst-alt (inferior) aktivitesini gösterir.
- **Derivasyon III (Lead III):** Sol kol ile sol bacak arasındaki voltaj farkını ölçer; kalbin inferior-lateral aktivitesini temsil eder.

Bu üç derivasyon, Einthoven üçgeninin temelini oluşturur ve kalbin elektriksel aktivitesini farklı açılardan değerlendirmeye olanak tanır.

Şekil 1.3'te, tipik bir EKG eğrisi yer almaktadır. EKG sinyalleri, temel olarak P, QRS ve T dalgalarından oluşmaktadır [2]. P dalgası, atriyumların kasılması sonucu ortaya çıkar; QRS kompleksi, atriyum kasılmasının sona erdiğini ve ventrikül kasılmasının başladığını; T dalgası ise ventriküllerin kasılmasının sona erdiğini ifade eder.

Bu dalga formları, insan anatomisinin benzersiz özelliklerine bağlı olarak ortaya çıktığından, EKG biyometrisi evrensellik, ölçülebilirlik, tekillik ve kalıcılık gibi temel kriterleri karşılamaktadır [17].



Şekil 1.3 Elektrokardiyogram

Normal bir EKG işareti için Şekil 1.3'te belirtilen öznel değerleri şöyledir [18, 19]:

- **RR intervali:** 0.6–1 s,
- **QRS kompleksi:** 0.06–0.10 s,
- **P dalga süresi:** 0.08–0.12 s,
- **PR intervali:** 0.12–0.2 s,
- **PR segmenti:** 0.05–0.12 s,
- **ST segmenti:** 0.08–0.12 s,
- **T dalga süresi:** 0.16 s,
- **QT intervali:** 0.35–0.4 s.

1.4 Tezin Amacı ve Kapsamı

Bu tez çalışmasının temel amacı, düşük çözünürlüklü sensörler kullanarak EKG tabanlı biyometrik kimlik doğrulamanın mümkün olup olmadığını araştırmaktır. Önerilen yöntem, mobil cihazlarda kullanım için optimize edilerek kullanıcı dostu ve güvenilir bir doğrulama çerçevesi sunmayı hedeflemektedir. EKG sinyallerinin benzersiz karakteristikleri sayesinde, kimlik doğrulama süreçlerinin güvenilirliğini artırmak ve geleneksel yöntemlere kıyasla daha sağlam bir güvenlik mekanizması sağlamak amaçlanmaktadır.

Mobil cihazlarda EKG tabanlı kimlik doğrulamada başlıca önem taşıyan parametreler arasında, elektrot sayısı, sensör kalitesi, kaydedilen sinyal süresi ile yanlış kabul oranı (FAR) ve doğru kabul oranı (TAR) gibi performans metrikleri bulunmaktadır. Özellikle yüksek maliyetli tıbbi cihazlar yerine, düşük maliyetli ve düşük çözünürlüklü sensörlere yönelik ilgi artmaktadır. Bu tezin temel odağı, düşük maliyetli sensörlerden alınan EKG verilerini kullanarak mobil cihazlar için güvenilir ve pratik biyometrik doğrulama yöntemleri geliştirmektir.

Mobil sağlık hizmetlerindeki ilerlemeler ve giyilebilir cihazların yaygınlaşması, kullanıcıların kalp atışı verilerini gerçek zamanlı olarak takip etmelerini kolaylaştırmıştır. Bu tez, giyilebilir cihazlar veya basit mobil EKG sensörleri aracılığıyla toplanan düşük çözünürlüklü verilerin kimlik doğrulama amacıyla kullanılma potansiyelini incelemekte ve oluşturulan küçük bir veritabanı üzerinde geliştirilen algoritmaların performansını değerlendirmektedir.

Literatürde, kısa süreli ve düşük çözünürlüklü EKG kayıtlarının mobil uygulamalar için biyometrik kimlik doğrulama amacıyla kapsamlı olarak incelenmediği görülmektedir. Bu tez çalışmasında, teorik ve uygulamalı yöntemler birlikte ele alınarak, mobil cihazlarda düşük maliyetli sensörlerden elde edilen kısa EKG kayıtları ile güvenilir ve pratik bir biyometrik doğrulama çerçevesi geliştirilmesi hedeflenmiştir. Böylece, mevcut literatürdeki önemli bir boşluk doldurulacak ve mobil biyometrik sistemlerin uygulanabilirliği artırılacaktır.

1.5 Literatür Özeti

Literatürde yer alan araştırmalar, EKG temelli kimlik doğrulamanın güvenilir bir biyometri metodu olduğunu göstermektedir. Bildiğimiz kadarıyla, Biel ve diğ. [20] tarafından, EKG biyometrisi için sinyal şekline dayalı bir yöntemi kullanan ilk yaklaşım sunulmuştur. Bu çalışmada, sınıflandırma için zaman, genlik ve eğimle ilgili öznitelikler çıkarılmış; sonuçlar, EKG kullanılarak belirlenmiş bir gruptan bir

kişinin tanınabileceğini göstermektedir. Ayrıca, yalnızca bir ölçüm kanalının EKG kimlik doğrulaması için yeterli olduğu sonucuna varılmıştır.

İsrail ve diğ. [13] tarafından yapılan bir çalışmada, kalp hızı değişikliklerinin EKG öznitelikleri üzerindeki etkisi incelenmiştir. Deneyler, farklı endişe durumlarında ve farklı elektrot yerleştirme pozisyonlarında 20 saniye süreyle 29 katılımcının EKG sinyalleri üzerinden gerçekleştirilmiştir. Sonuçlar, elektrotların konumlandırılmasından bağımsız olarak ve denekler çeşitli stres durumlarına maruz kalmış olsalar bile doğru bir sınıflamanın mümkün olduğunu göstermiştir. Ayrıca, kalp atış hızındaki değişimlerin EKG özniteliklerine etkisini azaltmak için doğrusal normalizasyonun kullanılabileceği analiz edilmiştir.

EKG biyometrisinin önemli bir sorunu, bir kaydın ne kadar süreyle geçerli kalabileceğidir. Bu endişeyi ele almak için, Wübbeler ve diğ. [21] tarafından, bir veritabanına dayalı EKG doğrulama şeması gerçekleştirilmiştir. Bu veritabanı, aydan yıla kadar değişen zaman aralıklarında kaydedilen verilerden oluşmakta ve 74 katılımcıya ait kayıtları içermektedir. Şablonları oluşturmak için Lead-I, Lead-II ve Lead-III sinyallerinin 10 saniyelik kayıtları birleştirilmiştir. Kimlik doğrulama işlemi, en yakın komşu algoritması kullanılarak gerçekleştirilmiş ve doğru kabul oranı %98,10 olarak elde edilmiştir. Sonuç olarak, bu çalışmada EKG biyometrisinin, oluşturulan bir kayıt şablonundan uzun yıllar sonra dahi geçerliliğini koruduğu ortaya konulmuştur.

Bir başka çalışma, Singh ve Singh tarafından sunulmuştur [22]. Bu çalışmada, her kalp atışından zaman, genlik ve açılara dayalı olarak 20 öznitelik çıkarılmıştır. Kayıt şablonu ile kimlik doğrulama şablonu arasındaki her öznitelik için Öklid uzaklığı hesaplanmıştır. Deney, en az 3 dakika boyunca 73 katılımcının kaydedilmiş verileriyle MIT-BIH Physionet veritabanından elde edilmiştir. Bu çalışmanın performansı, yanlış kabul oranı (FAR) %7 ve doğru kabul oranı (TAR) %82 olarak rapor edilmiştir. Elde edilen sonuçlar, EKG biyometrisinin, parmak izi ve yüz tanıma gibi yöntemlerle birleştirildiğinde daha da iyileştirilebileceğini göstermiş; multimodal sistem ise %99,00 doğru kabul oranı üretmiştir.

Aziz ve diğ. tarafından yapılan bir çalışmada [12], EKG tabanlı bir biyometrik kimlik doğrulama sistemi önerilmiştir. Önerilen yöntem, ham EKG sinyallerinden gürültüleri kaldırmak ve ilgi alanını belirlemek için deneysel mod dekompozisyonu (EMD) kullanmıştır. Zaman, frekans ve istatistiksel alan özniteliklerinin bir kombinasyonu ile farklı veri sınıflarını ayırt etmek amacıyla öznitelikler çıkarılmıştır. Seçilen öznitelikler, sekiz sınıflandırma yöntemi ile test edilmiş; sonuçlara göre, destek vektör makineleri (SVM-C) %98,72'lik bir sınıflandırma

doğruluğuna ulaşarak, 10 katlı çapraz doğrulama stratejisi ile en yüksek doğruluğu elde etmiştir. Bu çalışmanın veritabanı, 14 katılımcıdan elde edilmiştir. Deneyssel analiz, önerilen yöntemin diğer çalışmalarla karşılaştırıldığında güvenilir, doğru ve hesaplama açısından daha az maliyetli olduğunu ortaya koymuştur.

Pal ve diğ. [23] tarafından sunulan çalışmada, EKG analizi için etkili bir yöntem önerilmektedir. Bu yöntem, sinyali düzeltmek ve dalga formunun tüm temel özniteliklerini çıkarmak amacıyla geliştirilmiştir. Çalışmada, EKG sinyallerini gürültüden arındırmak için FIR yüksek geçişli bir filtre kullanılmış; R tepe noktaları Haar dalga dönüşümü ile belirlenmiştir. EKG dalga formunun baskın referans noktalarından biri olan, eğri altındaki alan adı verilen yeni bir öznitelik sınıfı, aralık öznitelikleri, genlik öznitelikleri ve açı öznitelikleri gibi diğer bilinen öznitelik sınıfları ile birlikte hesaplanmıştır. Pal ve diğ., QT veritabanında %99,49, PTB veritabanında %98,96 ve MIT-BIH aritmisi veritabanının alt kümesinde %98,48 kimlik doğrulama performansı rapor etmişlerdir.

Bu çalışma [24], AlexNet ve GoogleNet ağlarının önceden eğitilmiş versiyonlarının birleşimini kullanarak EKG verileri ile kişi tanımlamayı önermektedir. Ağları eğitmeden önce, tek boyutlu EKG verileri filtrelenip iki boyutlu bir formata dönüştürülmektedir. Bu çalışmada kullanılan veritabanı, MIT-BIH Aritmi veritabanından alınan on EKG sinyalini içermektedir. Performans değerlendirmesi, önerilen birleşim yönteminin, AlexNet ve GoogleNet'in bireysel performanslarını geride bırakarak ortalama %96,6 doğruluk oranına ulaştığını göstermektedir. Bu sonuçlar, konvolüsyonel sinir ağlarının (CNN'lerin) geleneksel makine öğrenme yöntemlerine kıyasla daha yüksek doğruluk ve üstün öznitelik çıkarımı sağladığını vurgulamaktadır. Bu araştırma, EKG sinyallerinin biyometrik doğrulamada kullanılmasının etkinliğini ve derin öğrenme yöntemlerinin bu alandaki potansiyelini ortaya koymaktadır.

Çalışmada [25], minimal ön işleme ile ham EKG verilerini işleyen yeni bir EKG tabanlı biyometrik tanımlama yöntemi önerilmiştir. Bu yöntem, çeşitli uygulama bağlamlarında yeterli doğruluğu sağlarken, hesaplama maliyetini düşük tutacak şekilde tasarlanmıştır. Deep-ECG olarak bilinen derin öğrenme modeli, minimal ön işleme yapılmış EKG sinyallerini işleyebilecek şekilde uyarlanmıştır. Çalışmada SHAREE veritabanı kullanılmış; bu veritabanı, kontrolsüz koşullar altında toplanmış 139 bireyin 24 saatlik Holter kayıtlarını içermektedir. Üç deney gerçekleştirilmiş ve bu deneylerde minimal ön işlemenin, son teknoloji yöntemlerle elde edilen tanımlama doğruluğu ve sonuçlarla karşılaştırılması yapılmıştır. Sonuçlar, minimal ön işlemenin hesaplama maliyetlerini önemli ölçüde azalttığını ve biyometrik tanımlama sistemlerinde yüksek etkinliği koruduğunu

göstermiştir.

2 saniyelik EKG segmentleri kullanılarak, yöntem bireysel uçlarda %80'in üzerinde ve birden fazla uçta %90'ın üzerinde doğruluk elde etmiştir. %80'in üzerinde doğruluk elde etmek için gerekli olan minimum eğitim örneği sayısının, bu EKG segmenti süresiyle kişi başına 100 olduğu bulunmuştur. Özetle, çalışma, önerilen yöntemin gerçek zamanlı uygulamalarda etkili bir şekilde uygulanabileceğini ve giyilebilir cihazlarda verimli kullanılabileceğini göstermektedir.

Bu çalışma [26], Covid-19 pandemisi nedeniyle fiziksel temasın kabul edilemez hale gelmesiyle artan sosyal mesafeyi koruma ihtiyacına cevap vermek üzere, EKG tabanlı biyometrik doğrulama yöntemlerinin güvenliğini araştırmaktadır. Saldırganın, kurbanın kısa bir EKG şablonunu yakalayarak sahte EKG sinyalleri oluşturduğu bir GAN tabanlı sunum saldırısı geliştirilmiştir. EKG-ID veritabanı kullanılarak gerçekleştirilen deneylerde, önerilen saldırı %91,70 ortalama tanımlama oranı ile başarılı bulunmuştur. Bu çalışma, EKG biyometrik sistemlerinin güvenliğini artırmak için sinir ağı mimarisi tabanlı yeni bir derin öğrenme çerçevesi de önermektedir.

Bu çalışma [27], bir EKG sinyalinin kısa bir segmentinin zaman-frekans alanı temsili, biyometrik tanıma için nasıl etkili bir şekilde kullanılabileceğini araştırmıştır. Mevcut derin öğrenme tabanlı tanıma sistemlerinde genellikle yüksek tanıma doğruluğu elde etmek için uzun EKG sinyal segmentleri kullanılırken, bu çalışmada R-dalgası etrafındaki 0.5 saniyelik kısa bir segment kullanılarak çok oturumlu verilerde mükemmel tanıma doğruluğu elde edilmiş ve mevcut yöntemler aşılmıştır.

Kısa bir EKG sinyal segmentinin zaman-frekans alanı temsili, tanıma yeteneğini artırmak için önemlidir ve daha az karmaşık CNN modellerinin biyometrik tanımda etkili olabileceğini göstermektedir. Araştırmacılara göre, bu yaklaşım ticari ve kamu uygulamaları için sağlam, güvenilir ve kabul edilebilir bir kimlik doğrulama sistemi geliştirmeye yardımcı olabilir. Ayrıca, EKG sinyalinin güvenilirliğini artırmak için daha büyük, çok oturumlu veri kümelerinde kısa segmentlerin performansını belirlemek üzere daha fazla araştırma gereklidir. Gelecekteki çalışmaların, farklı kardiyak koşullar altındaki tanıma performansını incelemeyi ve sinyaldeki değişikliklere karşı dayanıklı, daha sofistike derin öğrenme modelleri geliştirmeyi hedeflediği belirtilmiştir.

Bu çalışma [28], bireysel kimlik doğrulama için EKG sinyallerini kullanarak tek kalp atışı ile kimlik doğrulama sağlayan bir 1D konvolüsyonel sinir ağı (1D-CNN) çerçevesi önermektedir. MIT-BIH Normal Sinüs Ritmi (NSRDB),

MIT-BIH Aritmi (MIT-ARR), ECG-ID ve MIMIC-III veritabanları üzerinde yapılan deęerlendirmelerde; NSRDB (18 denek, doęruluk %99,26), MIT-ARR (27 denek, doęruluk %98,82), MIMIC-III (83 denek, doęruluk %98,71) ve ECG-ID (90 denek, doęruluk %95,69) veritabanlarında yksek doęruluk oranlarına ulaşılmıřtır.

Ayrıca, SMOTE algoritması kullanılarak dengelenmiř veritabanında NSRDB ve MIT-ARR veritabanlarında %100 doęruluk, kesinlik, duyarlılık ve F1-skoru elde edilmiřtir. Karıřık veritabanında (MIXED-1: 173 denek, %98,44 doęruluk; MIXED-2: 200 denek, %95,59 doęruluk; MIXED-3: 218 denek, %93,38 doęruluk) performans, %99,6'nın zerinde kalmıřtır. Bu sonular, nerilen erevenin biyometrik kimlik doęrulama iin yksek doęruluk ve gvenilirlik saęladığını gstermektedir.

Biyosinyal tabanlı kullanıcı tanıma teknolojileri, yz ve parmak izi tabanlı yntemlerin sınırlamalarına alternatif olarak geliřmekte olup, mevcut biosinyal veritabanlarının (DB) kısıtlamalarını ařmak amacıyla yeni nesil zmler sunmaktadır. oęu DB, veri eřitlilięi ve oturumlar arası deęiřkenlik analizini sınırlayan, tek oturumda az sayıda katılımcıdan veri toplama eęilimindedir. Bu alıřma, elektrokardiyogram (EKG) ve elektromiyogram (EMG) sinyallerini ieren, oklu oturumlarla kaydedilmiř ve denek sayısı aısından daha kapsamlı olan CSU_MBDB1 ve CSU_MBDB2 veritabanlarını tanıtmaktadır.

Denekler, birden fazla oturumda ve oturumlar arasında en az bir gn sreyle, rahat bir ortamda altı farklı jest yaparken kaydedilmiřtir. Bu DB'ler, eřitli uygulamalara uyum saęlayabilecek řekilde tasarlanmıř olup, deneyler sırasında %66,39 doęruluk oranı elde edilmiřtir. Bu sonular, sinyal iřleme ve geliřmiř aę tasarımları ile performansın artırılma potansiyelini gstermektedir. Ayrıca, bu veritabanları, EKG ve EMG'nin doęrusal olmayan zniteliklerini incelemek iin de deęerli bir kaynak olarak ne ıkmaktadır [29].

Bu alıřmada [30], biyometrik kimlik doęrulama iin elektrokardiyogram (EKG) sinyallerinin etkinlięi incelenmiřtir. ECG-BA-CNN (konvolsyonel sinir aęı kullanarak EKG tabanlı kimlik doęrulama) yntemi nerilmiřtir. Biosec1 veritabanında, CNN modeli %97, CNN+LSTM modeli %99 doęruluk elde ederken; Biosec2 veritabanında ise CNN modeli %95, CNN+LSTM modeli %97 doęruluk gstermiřtir. zel veritabanında, tek oturumda %98, iki oturumda ise %87,1 doęruluk saęlanmıřtır. EKG sinyalleri normalize edilip, CNN ekirdek tabanlı bir yaklařımla znitelikler ıkarılmıřtır. Sonular, EKG sinyallerinin biyometrik kimlik doęrulamada yksek doęruluk ve gvenlik saęladığını gstermiřtir. Bu bulgular, geliřmiř sinir aęı mimarileri ile entegre edilen EKG tabanlı sistemlerin

güvenilir kullanıcı kimlik doğrulama sağlayabileceğini vurgulamaktadır.

Uzaktan sağlık izleme (RHM), hasta kimliğinin ve sağlık kayıtlarının güvenliği açısından büyük önem taşımaktadır. Her bireyin benzersiz olan EKG deseni, biyometrik tanımlama için kullanılabilir. Bu çalışmada [31], dijital diferansiyel ve yumuşatma filtreleri ile işlenen ve CEEMDAN ile ayrıştırılan bir EKG tabanlı hasta tanımlama sistemi önerilmiştir. Ayrıca, LSTM tabanlı sınıflandırıcı kullanılarak sekiz ayrı EKG veritabanında testler gerçekleştirilmiş; ortalama doğruluk %99,59 olup, çoğu veritabanında %99,5'in üzerinde, AFDB'de ise %99,1 doğruluk raporlanmıştır. Çapraz oturum senaryolarında, CNN modeli %69,35, LSTM modeli ise %89,21 doğruluk göstermiştir. Gelecek çalışmalarda, zaman ve frekans analizleri ile doğruluğun artırılması hedeflenmektedir.

Tıbbi cihazlarda kullanılan EKG sensörleri, mobil biyometrik kimlik doğrulama uygulamaları için uygun değildir; çünkü bu cihazlar yüksek maliyetli ve büyük boyutludur. Bu nedenle, mobil cihazlarda düşük maliyetli ve düşük çözünürlüklü sensörlerin kullanılması önem taşımaktadır. Son dönemde, mobil sağlık cihazlarına olan ilgi artmış; bu bağlamda, giyilebilir cihazlar aracılığıyla elde edilen düşük çözünürlüklü EKG sinyallerinin kimlik doğrulama uygulamalarında kullanılması, mobil biyometri alanında önemli bir gelişme sağlamaktadır.

Bu çalışmada [32], elektrokardiyogram (EKG) sinyallerinin biyometrik kimlik doğrulama için potansiyelini değerlendiren bir araştırma sunmaktadır. Çalışmanın odak noktası, kalp biyometrisinin benzersizliğini ve kalıcılığını doğrulamak ve geniş, çok oturumlu bir veritabanı üzerinde bu süreci test etmektir. Veritabanı, hem ham EKG sinyallerini hem de demografik bilgileri içermekte olup, farklı demografik gruplar arasında tanıma performansını değerlendirmek amacıyla kullanılmıştır. Çalışmanın bulguları, özellik mühendisliğine dayalı kimlik doğrulama yöntemi ve derin öğrenme modelleri ile elde edilmiştir. Kimlik doğrulama sürecinde, eğitim ve test setlerinin farklı oturumlardan alınmasının performansı düşürdüğü; derin öğrenme modelinin ise çok oturumlu veritabanında yüksek tanıma başarısı sağladığı, ancak oturumlar arası zaman farkının bu başarıyı etkilediği belirlenmiştir. Sonuç olarak, EKG sinyallerinin biyometrik kimlik doğrulama ve tanımlama için uygun bir aday olduğu, uzun süreli oturumlar arasında dahi kabul edilebilir performans sergilediği sonucuna varılmıştır.

Tantinger ve diğ. [33], bir giysinin içine entegre edilmiş bir tekstil elektroduyla ölçülen bir EKG'nin insan kimliği için uygun olup olmadığını araştırmıştır. Almanya'nın Erlangen şehrindeki Fraunhofer IIS Entegre Devreler Enstitüsü'nde geliştirilen FitnessSHIRT, mobil EKG verilerini toplamak için kullanılmıştır. Bu

çalışmaya, ortalama yaşları 26,3; ortalama boyu 183,2 cm ve ortalama ağırlığı 78,8 kg olan sağlıklı 10 erkek katılmıştır.

Farklı ölçüm sistemlerinin etkisini dışlamak amacıyla, aynı FitnessSHIRT sistemi kullanılmış; üç ölçüm, 10 dakikalık sürelerle yapılmış ve her ölçüm arasında en az yedi günlük bir ara verilmiştir. Ön işlenmiş EKG segmentlerinden öznitelikleri çıkarmak için üç farklı yaklaşım kullanılmıştır (referans noktaları, otokorelasyon ve ayrık kosinüs dönüşümü kombinasyonu ile dalgacık dönüşümü). Araştırmacılar, stabil bir kimlik doğrulaması için QRS kompleksinin özniteliklerinin en önemli bilgileri içerdiği sonucuna varmışlardır.

Bu nedenle, dalgacık dönüşümü kullanılarak öznitelik çıkarma en iyi sonuçları sağlamıştır. Ancak, sınıflandırma sonuçlarının stabilitesi, EKG sinyalindeki bölümlerin zamansal farklılıkları (özellikle P ve T dalgalarının topolojisi) nedeniyle sınırlıdır. Ayrıca, üç seansta değişen elektrot pozisyonları doğrulama oranını düşürmüştür. Bu etkileri telafi etmek için daha fazla araştırma yapılması gerekmektedir.

Choi ve diğ. [17], Neurosky tarafından üretilen CardioChip sensöründen (Şekil 1.4) elde edilen gürültülü elektrokardiyogramlar kullanılarak biyometrik kimlik doğrulaması sunmuştur. Mobil sensörlerden alınan EKG verilerinde bulunan farklı sesleri azaltmak amacıyla bir kademeli filtre oluşturulmuş ve pratik uygulamalarda yeterli performans elde edilmiştir. Ayrıca, önerilen kimlik doğrulama yaklaşımı, birbirine karşı tek destek vektör makineleri (SVM) sınıflayıcılarının birleşiminden oluşan bir topluluk temelinde sunulmuştur. Sensörün belirsizliğine rağmen, önerilen yaklaşım, 175 birey üzerinde tek kalp atışı için %4,46 ve 15 saniyelik bir test aralığı için %1,87'lik bir eşit hata oranı (EER) üretmiştir.



Şekil 1.4 KardioChip adlı EKG algılama modülü [17]


Arteaga-Falconi ve diğ. [2] ise bir mobil biyometrik doğrulama algoritması önermiştir. Bu algoritma, bir mobil telefon kılıfındaki (Şekil 1.5) kalp monitörü aracılığıyla alınan EKG verilerine dayanmaktadır. Algoritma, on farklı zamanda ve koşulda on katılımcı ile test edilmiş ve ayrıca Physionet veritabanından 73 kayıtla da değerlendirilmiştir. Önerilen algoritmanın, 4 saniyelik sinyal alımı ile %1,41 yanlış kabul oranı (FAR) ve %81,82 doğru kabul oranı (TAR) sağladığı gözlemlenmiştir.



Şekil 1.5 AliveCore EKG mobil sensörü [2]

Chen ve Chen [34] tarafından sunulan çalışmada, yapay sinir ağı modelleri kullanılarak bir doğrulama yöntemi tanıtılmıştır. EKG sinyal kaydı, örnekleme hızı 512 Hz olan yerleşik bir BMD101 çipi (Şekil 1.6) ile gerçekleştirilmiş ve farklı fiziksel koşullar altında 50 bireyden toplanmıştır. Bu çalışma, kabul ve reddetme hata performansını dengeleyebilen iki yapay sinir ağı modeliyle iki aşamalı bir doğrulama algoritması önermektedir. Sadece 3 saniye içinde 3 atış kullanılarak yapılan doğrulama, 50 denekten oluşan bir grup için ortalama yanlış kabul oranı (FAR) ve yanlış reddetme oranı (FRR) değerlerini %10'un altına, kohortun küçük grupları (30'dan az) için ise %5,00'in altına düşürmektedir.

Zhang ve Wu [35] ise akıllı telefonlar gibi mobil cihazlar için uygun, pratik bir EKG tabanlı kimlik doğrulama yöntemi sunmuştur. İlk olarak, her kalp döngüsünden kalp atımları çıkarılmakta; ardından her kalp atımı, daha önce tespit edilen referanslar ile bölünmüş PQ, QRS ve JT segmentlerine ayrılarak düzeltilmektedir. Son olarak, öznelik boyutu, ayırık kosinüs dönüşümü ile 80'e indirilmektedir. Kullanıcılar, ilk kez EKG şablonlarını kaydetmek için sadece 20 saniye ve sonrasında doğrulamak için yaklaşık 4 saniye harcarlar. 85 sağlıklı katılımcının EKG kayıtları, Physionet'te yaygın olarak kullanılan veritabanlarından seçilmiştir. Doğrulama deneylerinde, 85 katılımcıdan elde edilen ortalama eşit hata oranı (EER) %1,57 olarak belirlenmiş; kimlik doğrulama deneylerinin doğruluk oranı, sinir ağı sınıflayıcısı ile %96,6 ve SVM ile %97,7 olarak hesaplanmıştır. Her katılımcının saklaması gereken şablon boyutu ise sadece 160 bayttır.



Şekil 1.6 EKG ölçüm cihazı [34]

EKG sinyalleri, mobil veya giyilebilir cihazlardan toplanabilir ve hareket, sinyal alım türü vb. nedenlerle gürültü tarafından bozulabilir. Bu durum, yakalanan sinyal kalitesi ile kullanım kolaylığı arasında bir denge oluşturur. Kang ve diğerleri [36], kayıt ve kimlik doğrulama aşamalarında çıkarılan şablonların çapraz korelasyonunun kullanımını önermiştir. Önerilen algoritmalar, doğrulama için giyilebilir bir saatte (Şekil 1.7) uygulanmıştır. Deneylerin sonunda, 3 saniyelik doğrulama süresi ve 30 saniyelik kayıt süresi kullanılarak, yanlış kabul oranı (FAR) %5,2 ve yanlış reddetme oranı (FRR) %1,9 olarak hesaplanmıştır.



Şekil 1.7 EKG ölçümü için giyilebilir saat [36]

Elektrokardiyogram (EKG) sinyalleri, akıllı ev ortamlarının güvenliğini artırmak için biyometrik doğrulamada kullanılmaktadır. Bu çalışma, EKG sinyallerinin benzersiz özniteliklerinden yararlanarak kullanıcı kimliğini doğrulamayı amaçlamaktadır. Giyilebilir sensörlerle toplanan EKG sinyallerinden öznitelikler çıkarılarak bir şablon oluşturulur ve bu öznitelik vektörü, kullanıcının kimliğini doğrulamak için kullanılır. EKG tabanlı biyometrik sistem, sahtecilik ve DDoS saldırılarına karşı dayanıklıdır ve akıllı evler için yüksek güvenlik sağlamaktadır. Sınıflandırma için destek vektör makinesi (SVM) algoritmaları kullanılmıştır. Bu yöntem, EKG sinyalleriyle akıllı ev IoT ortamlarının güvenliğini artırmada etkili olmuştur [37].

Bu çalışma [38] ise, giyilebilir cihazlarda kullanıcı kimliğini doğrulamak için PhotoPlethysmoGram (PPG) ve Elektrokardiyogram (EKG) sinyallerini kullanan SOMEONE topluluk öğrenme yöntemini sunmaktadır. Algoritma, bu sinyalleri işleyerek kullanıcıları tanımakta ve F1 skoru, hassasiyet, yanlış kabul oranı (FAR) ve yanlış reddetme oranı (FRR) gibi metriklerde üstün performans sergilemektedir. MIMIC veritabanındaki EKG sinyalleri için SOMEONE, %97,3 F1 skoru, %97,4 hassasiyet, %0,1 FAR ve %2,7 FRR elde etmiştir. CapnoBase veritabanındaki PPG sinyalleri için %80,1 F1 skoru, %80,7 hassasiyet, %0,4 FAR ve %19,3 FRR; CAPNO veritabanındaki EKG sinyalleri için %86 F1 skoru, %86,3 hassasiyet, %0,3 FAR ve %13,7 FRR; CAPNO veritabanındaki PPG sinyalleri için ise %94 F1 skoru, %94,1 hassasiyet, %0,1 FAR ve %5,9 FRR elde edilmiştir. Bu çalışma, PPG ve EKG sinyallerini kullanarak akıllı ev IoT ortamlarının güvenliğini artırmanın etkinliğini göstermektedir.

Bu çalışma [39] ise, tıbbi ve giyilebilir cihazlardan toplanan elektrokardiyogram (EKG) sinyallerini kullanarak çeşitli biyometrik doğrulama modellerinin performansını değerlendirmektedir. Önerilen yöntem, mobil cihazlar için önemli olan kısa kayıt süresiyle hızlı eğitim modellerine odaklanmaktadır. İki kamu veritabanı kullanılarak, farklı örnek uzunlukları ve eğitim seti boyutları ile çeşitli sınıflandırma modelleri araştırılmıştır. Sonuçlar, istatistiksel yöntemlerin hiper düzlem ayırıcılardan daha iyi performans gösterdiğini ortaya koymuştur. Naive Bayes (NB) sınıflandırıcısı en iyi eşit hata oranını (EER) elde ederken, Derin Öğrenme (DL) modeli, gerekli kayıt örneklerini ve doğrulama süresini azaltmada üstünlük sağlamıştır. DL modeli, E-HOL veritabanında %5,76 EER ve WeSAD veritabanında %7,07 EER elde etmiş ve sadece 5 saniyelik kayıt verisi ile bu sonuçlara ulaşmıştır. Bu sonuçlar, önerilen yöntemin kısa kayıt süreleriyle bile tıbbi ve giyilebilir EKG kaydediciler için sağlam kimlik doğrulama sağlayabileceğini göstermektedir. Çalışma, EKG biyometriğinin özellikle giyilebilir cihazlarda gelecekteki doğrulama yöntemleri için geçerli bir seçenek

olduğunu sonucuna varmaktadır.

Chun ve diğ. [40] ise, kişinin EKG atımlarını elde etmek için iki elektrodlu giyilebilir bir EKG sensörü (Nymi bandı) (Şekil 1.8) kullanmakta ve diğer EKG bilgilerine erişimi olmayan giyilebilir cihazlar için yeni bir EKG tabanlı kullanıcı doğrulama yöntemi önermektedir. Önerilen yöntem, karmaşık STFT (kısa süreli Fourier dönüşümü) ve basit Öklid uzaklığı kullanmaktadır. Çalışmada, giyilebilir EKG sensörlerinden alınan 15 bireyin EKG verileri üzerinde gerçekleştirilen testlerde, %0,9 EER elde edilmiş; halka açık ECG-ID veritabanındaki 89 birey için ise %2,2 EER sağlanmıştır.



Şekil 1.8 Nymi band kullanılarak EKG ölçümü [40]

Nawawi ve diğ. [41] ise, gerçek dünya senaryolarında biyometrik doğrulama için giyilebilir akıllı tekstil gömleklerden elde edilen EKG sinyallerinin güvenilirliğini araştırmıştır. Çalışmada, 22 katılımcıdan (18 erkek, 4 kadın) veri toplanmış ve bu veriler, düşük geçişli Butterworth filtreleri kullanılarak işlenmiştir. Öznitelikler, QRS segmentasyonu yöntemi kullanılarak çıkarılmış ve Q destek vektör makinesi (QSVM) sınıflandırıcısı ile analiz edilmiştir. Çalışma, beş farklı senaryoyu değerlendirmiştir:

- **Senaryo A:** Aynı oturumdan alınan eğitim ve test verileri kullanılarak gerçekleştirilen senaryoda, %99,27 doğruluk (ACC), %92,77 doğru kabul oranı (TAR) ve %0,40 yanlış kabul oranı (FAR) elde edilmiştir.
- **Senaryo B:** 30 gün arayla toplanan verilerle eğitim ve test yapılması durumunda %93,59 doğruluk, %30,81 TAR ve %2,84 FAR raporlanmıştır.
- **Senaryo C:** Bir oturumdan alınan verilerle eğitim yapıp, başka bir oturumdan alınan verilerle test yapılması durumunda %99,20 doğruluk, %90,32 TAR ve %0,27 FAR elde edilmiştir.
- **Senaryo D:** Bilinen aktivitelerle eğitim ve test yapılması durumunda %99,63 doğruluk, %97,14 TAR ve %0,14 FAR sonuçları elde edilmiştir.

- **Senaryo E:** Farklı aktivitelerle eğitim ve test yapılması durumunda %88,86 doğruluk, %44,56 TAR ve %6,05 FAR elde edilmiştir.

Bu bulgular, zamansal değişkenlik ve farklı aktivite koşullarına rağmen, giyilebilir cihazlarla kullanıldığında EKG biyometriğinin yüksek doğruluk sağlayabileceğini göstermektedir.

Bu çalışma [42] ise, mobil sensörler kullanarak düşük maliyetli ve yüksek performanslı bir EKG tabanlı biyometrik tanıma sistemi tasarlamayı amaçlamaktadır. Proje, sinyal alma, tanıma algoritması simülasyonu ve mobil uygulamada uygulanma olmak üzere üç aşamaya ayrılmıştır. MATLAB kullanılarak geliştirilen ve Physionet PTB veritabanındaki EKG sinyalleriyle test edilen yöntem, ön işleme, öznelilik çıkarma, boyut indirgeme ve sınıflandırma adımlarını içermektedir. Sonuçlar, %82 tanımlama oranı, %16,4 EER, %16 FAR ve %18 FRR ile umut verici sonuçlar göstermiştir. Bu sonuçlar, EKG sinyallerinin mobil cihazlarda biyometrik tanıma için etkili olabileceğini ortaya koymaktadır. Sistemin her adımının optimize edilmesi ve veritabanının genişletilmesi ile tanımlama oranının artırılabilirliği belirtilmektedir. Çalışma, mobil uygulamalar için EKG tabanlı biyometrik sistemlerin potansiyelini göstermekte ve daha fazla araştırma gerektirdiğini vurgulamaktadır.

1.5.1 Literatürde i-vektörlerin EKG ile Kullanımı

Konuşma ve konuşmacı tanımda i-vektörlerin başarısından ilham alınarak, EKG sinyallerinde hastaya özgü bilgileri göstermek amacıyla i-vektörler uygulanmıştır. AAMI (Association for the Advancement of Medical Instrumentation) önerisine göre, 15 kalp atışı tipi beş sınıfa ayrılır; normal sinüs atımları (N), supraventriküler ektopik atımlar (S), ventriküler ektopik atımlar (V), normalin füzyonu ve ventriküler ektopik vuruş (F) ve bilinmeyen vuruş tipi (Q). Bu çalışmada ANSI/AAMI EC57 standardının önerdiği gibi, iki aritmi sınıfının (Sınıf S ve V) sınıflandırma performansını değerlendirmeye odaklanılmıştır. İki farklı test uygulanmış; S sınıfı %99,1 ve %98,8, V sınıfı ise %99,7 ve %98,8 doğruluk (ACC) oranlarıyla sınıflandırılmıştır [43, 44].

Diğer bir çalışmada [45], i-vektör, normal/anormal kalp sesi sınıflandırma görevi için uyarlanmıştır. İlk olarak, MFCC öznelilik vektörleri kalp ses kayıtlarından çıkarılmış, daha sonra bireylerin kalp sesi karakteristiğine dayalı öznelilikler elde etmek için i-vektör yöntemi kullanılmıştır. Deneysel sonuçlar, önerilen yöntemin, Physionet 2016 veri kümesindeki temel sistemle karşılaştırıldığında modifiye doğruluk temelinde %16'lık bir performans artışı sağlayabildiğini göstermektedir.

Xian ve diğ. [46] ise, konuşmacı tanıma alanındaki başarıdan ilham alarak, EKG tanımlaması için i-vektör modellerinin kullanımını araştırmışlardır. Bu çalışma, değişkenlik sorunlarını ele almak amacıyla çeşitli telafi yöntemlerini kullanan i-vektör modellerinin performansını değerlendirmeye odaklanmıştır. Değerlendirme, beyazlatma, doğrusal diskriminant analizi (LDA), sınıf içi kovaryans normalizasyonu (WCCN) gibi farklı telafi yöntemlerini içeren tek yaklaşım ile WCCN-beyazlatma, LDA-beyazlatma, WCCN-LDA gibi sıralı yaklaşımlar için önyargısız protokol (protokol 1) ve tüm özne protokolü (protokol 2) kapsamında gerçekleştirilmiştir. Deneysel değerlendirme, 310 EKG kaydıyla 90 konuyu içeren Physionet'ten ECG-ID veritabanı kullanılarak yapılmıştır. Sonuçlar, sıralı yaklaşımın tek yaklaşıma göre üstün performans sergilediğini, ayrıca daha az Gauss bileşeni gerektirdiği için hesaplama süresini azalttığını göstermektedir.

Yukarıda özetlenen çalışmalar, EKG tabanlı biyometrik doğrulamanın güvenilirliğini kanıtlamakla birlikte, çoğu yüksek çözünürlüklü veriler veya belirli koşullar altında gerçekleştirilmiştir. Ayrıca, mobil cihazlarda gerçek zamanlı kullanım ve düşük çözünürlüklü sensörlerden alınan veriler üzerinde sınırlı sayıda çalışma bulunmaktadır. Bu bilgiler ışığında, kısa EKG kayıtlarıyla (örneğin 5 saniye) ve düşük maliyetli sensörlerle yüksek doğruluk oranı elde etmenin hâlen geniş kapsamlı bir araştırma boşluğunu oluşturduğu söylenebilir. Dolayısıyla, mevcut tez çalışması, mobil biyometrik doğrulamada ekonomik, hızlı ve güvenilir bir alternatif sunmayı hedeflemektedir.

1.6 Hipotez

Bu tezde, düşük çözünürlüklü sensörlerle elde edilen EKG verilerinin mobil cihazlarda biyometrik kimlik doğrulama amacıyla kullanılabileceği hipotezi test edilmektedir. Önerilen yaklaşım, Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC) gibi gelişmiş öznitelik çıkarma tekniklerini, i-vektör temsili ile bir araya getirerek yüksek doğruluk ve düşük işlem süresi sağlamayı amaçlamaktadır. Aşağıda, hipotezin dayanak noktaları özetlenmiştir:

Gelişmiş Öznitelik Çıkarımı (MFCC ve GFCC)

- MFCC, EKG sinyallerinin zamansal ve frekanssal bileşenlerini etkili şekilde temsil edebilir.
- GFCC, insan işitsel modeline benzer şekilde, düşük frekans bantlarında ayırım gücünü artırarak MFCC'yi tamamlar.

- İki yöntemin birlikte kullanımı, tek başına elde edilebilen öznitelik setinden daha güvenilir ve kapsamlı bir öznitelik uzayı sunar.

i-vektör Temsili ve Boyut İndirgeme

- Konuşmacı tanımada popüler olan i-vektör yaklaşımının, EKG sinyallerindeki kişiye özgü bilgiyi düşük boyutlu bir uzayda temsil edeceği öngörülmektedir.
- Evrensel arka plan modeli (UBM) ve toplam değişkenlik uzayının (TV) kullanımı, verideki karmaşık varyasyonları kapsayarak kimlik doğrulama performansını artırabilir.
- LDA veya WCCN gibi boyut indirgeme ve normalizasyon yöntemleri, i-vektör uzayında ek ayırım gücü sağlayacaktır.

Kosinüs Mesafesi ve Alternatif Benzerlik Ölçütleri

- i-vektörler arasındaki benzerlik için kosinüs mesafesinin, EKG verisinin karakteristik farklılıklarını yakalamada etkili olacağı öngörülmektedir.
- Öklid mesafesi, Manhattan mesafesi, Pearson korelasyonu veya dinamik zaman esnetme (DTW) gibi alternatif ölçütlerin de değerlendirilerek en uygun eşik ve benzerlik metriklerinin belirlenmesi hedeflenmektedir.

Mobil Kullanılabilirlik ve Düşük Çözünürlüklü Sensörler

- EKG kayıtlarının yalnızca 5 saniyeye indirgenmesi, mobil cihazlarda işlem ve hafıza kullanımını azaltarak gerçek zamanlı doğrulamanın önünü açar.
- Canlı kalp atışından elde edilen biyometrik veri, sahtecilik girişimlerine karşı yüksek direnç gösterir.
- Düşük maliyetli sensörlerin ürettiği kısıtlı çözünürlüklü verilerde dahi, uygun ön işleme ve zengin öznitelik çıkarma (MFCC+GFCC) süreçleriyle tatmin edici ayırıştırma yapılabileceği düşünülmektedir.

Alternatif Yaklaşımlar ve Karşılaştırmalı Değerlendirme

- Destek vektör makineleri (SVM), çok katmanlı algılayıcı (MLP), konvolüsyonel sinir ağları (CNN) ve tekrarlayan sinir ağları (RNN) gibi yöntemlerin de EKG tabanlı kimlik doğrulamada başarılı olduğu bilinmektedir.

- Önerilen i-vektör tabanlı yaklaşım, bu yöntemlerle karşılaştırılarak tez çalışmasının konumunu netleştirecektir.

Hipotezin temel varsayımı, kalp atışlarının bireylere özgü benzersiz desenler içerdiği ve MFCC ile GFCC gibi yöntemlerle bu desenlerin i-vektör uzayında yüksek doğrulukla ayrıştırılabileceğidir. Böylece, mobil cihazlarda düşük maliyetli sensörlerle gerçek zamanlı ve güvenilir kimlik doğrulama mümkün olacaktır. Ardından, kosinüs mesafesi tabanlı (veya alternatif ölçütlere dayalı) benzerlik analizi ile kısa EKG kayıtlarında dahi yüksek doğruluk oranıyla kimlik doğrulama yapılabileceği düşünülmektedir. Böylelikle, mobil cihazlarda düşük maliyetli sensörlerle gerçek zamanlı, pratik ve güvenilir bir biyometrik doğrulama mekanizması geliştirme hedefi gerçekleştirilebilecektir.



2

ELEKTROKARDİYOGRAM (EKG)

BİYOMETRİSİ: KİMLİK DOĞRULAMADA

TEMEL İLKELER VE YÖNTEMSEL

YAKLAŞIMLAR

Elektrokardiyogram (EKG) biyometrisi, kalbin elektriksel aktivitesinden elde edilen sinyaller kullanılarak bireylerin tanımlanmasını sağlayan yenilikçi bir yöntemdir. Her bireyin kalp atışlarındaki kendine has ritmik ve morfolojik öznitelikler, bu yöntemin diğer biyometrik tekniklerden ayrışmasını sağlar. Özellikle, EKG sinyallerinin canlılık garantisi sunması, sahteciliğe karşı ek bir güvenlik katmanı oluşturur. Ayrıca, sinyalin dinamik ve zamansal değişimleri, gelişmiş sinyal işleme ve makine öğrenimi teknikleriyle entegre edildiğinde yüksek doğruluklu tanımlama imkanı sağlar.

Mobil cihazlar ve giyilebilir teknolojiler, gerçek zamanlı uygulamalara uygun, ekonomik ve güvenilir çözümler sunarak, kişisel veri güvenliğinin kritik önem taşıdığı günümüz dijital dünyasında önemli bir rol oynar. Bu bağlamda, EKG biyometrisi, hem yüksek performansı hem de uygulama kolaylığı ile öne çıkmaktadır.

Bu bölümde, EKG biyometrisinin temel prensipleri ve kavramsal altyapısı ele alınacaktır. Sinyalin ön işleme, öznitelik çıkarma ve sınıflandırma süreçleri üzerinden; bu yöntemin hangi problemlere çözüm sunduğu ve hangi avantajları sağladığı kapsamlı biçimde incelenecektir. Böylece, EKG biyometrisinin tercih edilme nedenleri, sunduğu yenilikçi yaklaşımların hangi alanlarda fark yaratabileceği ve mevcut sistemlere kıyasla hangi açılardan üstünlük sağladığı ortaya konulacaktır.

Bir EKG tabanlı kimlik doğrulama algoritması genel olarak üç temel adımdan oluşur:

1. **Ön İşleme:** EKG sinyalindeki gürültülerin giderilmesi ve sinyal kalitesinin artırılması amaçlanır. Bu aşamada, taban hattı kayması, güç hattı girişimleri ve kas gürültüsü gibi etkenler çeşitli filtreleme yöntemleriyle (örneğin, bant geçiren filtreler, dalgacık dönüşümü) temizlenir.
2. **Öznitelik Çıkarma:** Ön işleme sonrası elde edilen temiz sinyalden, kimlik tanımlama için kritik morfolojik ve frekanssal öznitelikler çıkarılır. Örneğin, QRS kompleksi ve diğer dalga formlarının öznitelikleri bu adımda elde edilir.
3. **Sınıflandırma:** Çıkarılan öznitelikler kullanılarak, farklı bireylerin tanımlanması ve kimlik doğrulama işlemi gerçekleştirilir. Bu aşamada, k-en yakın komşu (kNN), destek vektör makineleri (SVM) veya diğer makine öğrenimi yöntemleri uygulanabilir.

Ayrıca, sinyal yakalama işlemi, mobil ve giyilebilir cihazların (örneğin, akıllı telefonlar, saatler, bileklikler vb.) arkasına veya önüne monte edilebilen, iki kuru lead-I tipi elektrottan alınan EKG sinyallerinin kaydedilmesiyle gerçekleştirilir.

2.1 Ön İşleme: Gürültü Giderme ve R-Peak Tespiti ile EKG Sinyal Segmentasyonu

EKG kaydında karşılaşılabilecek en önemli gürültü kaynakları; taban hattı kayması, güç hattı girişimi ve kas gürültüsüdür.

- **Taban hattı kayması:** EKG işareti kaydedilirken, kalp ile elektrot arasındaki kişinin hareketi, nefes alıp vermesi ve elektrotun vücut yüzeyine tam oturmaması sonucu oluşan değişimlerden kaynaklanır. Bu kayma, genellikle 1 Hz'in altındaki frekanslarda meydana gelir.
- **Güç hattı girişimleri:** 50/60 Hz şebeke frekansına bağlı olarak ortaya çıkan gürültülerdir.
- **Kas gürültüsü:** Yüksek frekanslı gürültü, kişinin hareketi ve iskelet kaslarının kasılmasıyla oluşur.

Ön işleme aşamasında, EKG sinyallerindeki gürültüyü gidermek için literatürde yaygın olarak bant geçiren filtreler ve dalgacık dönüşümü gibi teknikler kullanılmaktadır.

Ön işleme adımından sonra, EKG sinyalinin anlamlı bileşenlerinin ayrıştırılabilmesi için dalga formu segmentasyonu gerçekleştirilir. Bu işlem,


öncelikle R-tepe noktalarının tespiti ve sonrasında sinyalin normalizasyonuna dayanır. R-tepe noktası, gürültü kaynaklarından en az etkilenen ve sinyalin en belirgin noktasıdır. Bu noktaların tespiti için dalgacık dönüşümü (WT), Hilbert dönüşümü (HT) ve Pan-Tompkins algoritması (PT) gibi yöntemler sıklıkla kullanılmaktadır.

Belirlenen R tepeleri, sinyalin segmentlere ayrılmasını sağlar; bu segmentler üzerinden QRS kompleksi gibi morfolojik öznitelikler çıkarılarak tanımlama yapılır. QRS kompleksi, ventriküllerin kasılmasını yansıttığından ve kalp hastalıklarından kaynaklanan anormalliklere karşı nispeten stabil olduğundan, öznitelik çıkarımında en yaygın kullanılan bileşendir.

Dalgacık dönüşümü (WT), sinyalin zaman ve frekans alanındaki detaylarını ortaya çıkarmada güçlü bir araç olup, anlık değişikliklerin tespiti ve sinyalin sıkıştırılması için idealdir [47, 48]. Elektrokardiyogram gibi biyomedikal sinyallerin analizinde, WT sinyalin farklı frekans bileşenlerini ve bunların zaman içindeki evrimini ayrıntılı olarak sunar.

Hilbert dönüşümü (HT) ise, bir sinyalin analitik formunu elde etmek amacıyla kullanılır. HT, sinyalin genlik ve faz bileşenlerini ayırarak fazın zaman içindeki değişimini analiz etmeye olanak tanır [49, 50]. Bu özellik, özellikle QRS komplekslerinin tespitinde ve R-tepe noktalarının belirlenmesinde yararlı olmaktadır.

Pan-Tompkins algoritması, QRS komplekslerinin tespiti için geliştirilen ve genlik, genişlik ile eğim ölçütlerini temel alan pratik bir yöntemdir [51]. Algoritma; bant geçiren filtreleme, türev alma, kare alma, entegrasyon ve eşik belirleme adımlarını içerir. Şekil 2.1’de Pan-Tompkins algoritmasının akış şeması gösterilmektedir.




Şekil 2.1 Pan-Tompkins algoritması

Şekil 2.2’de, Pan-Tompkins algoritması kullanılarak veritabanımızdaki bir EKG sinyaline ait referans noktaların belirlenmesine ilişkin bir örnek yer almaktadır [52].

2.2 Öznitelik Çıkarma Yöntemleri

Öznitelik çıkarma algoritmaları, referans noktalara dayalı (fiducial-based) ve referans noktalara dayalı olmayan (non-fiducial-based) yöntemler olarak iki



Şekil 2.2 Pan-Tompkins algoritması yardımıyla referans noktaların belirlenmesi [52]


kategoride değerlendirilebilir. Referans noktalardan elde edilen öznitelikler, genellikle genlik, zaman, alan ve aç gibi bileşenleri içerirken; referans noktalara dayalı olmayan öznitelikler, EKG sinyalinin Fourier dönüşümü, dalgacık katsayıları, otokorelasyon katsayıları ve ayrık kosinüs dönüşümü kullanılarak elde edilir.

Bu çalışma kapsamında, Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC) kullanılarak öznitelik vektörleri oluşturulmuş; bu öznitelikler, Gauss karışım modeli (GMM) tabanlı evrensel arka plan modeli (UBM) kullanılarak i-vektörlere dönüştürülmüştür.

2.2.1 Mel Frekans Kepstrum Katsayıları (MFCC)

Mel Frekans Kepstral Katsayıları (MFCC), sinyal işleme alanında, özellikle konuşma tanımda yaygın olarak kullanılan güçlü bir algoritmadır. Temel olarak, kepsrum, konvolüsyondan toplamaya geçiş sağlayan bir homomorfik dönüşümdür. "Mel" terimi, kepsrum ekseninin, insan kulağına dayalı algısal bir işitsel ölçek olan Mel ölçeğinde ölçeklendirildiğini ifade eder [53]. MFCC hesaplaması şu adımları içerir: ön-vurgulama, çerçeveleme, pencereleme, Fourier Dönüşümü (FFT), Mel Filtre Bankası ve Ayrık Kosinüs Dönüşümü (DCT). MFCC özniteliklerinin çıkarılması için adımlar Şekil 2.3'te gösterilmektedir.

Başlangıçta, giriş sinyali $x[n]$ ön vurgulanmaktadır. "Ön vurgu" kavramı, yüksek frekanslı bileşenlerin güçlendirilmesi anlamına gelir; sinyal, yüksek geçiren bir



Şekil 2.3 MFCC özniteliklerinin çıkarılması işlemi blok diyagramı

filtreden geçirilir. Filtrenin çıktısı aşağıdaki gibidir:

$$p[n] = x[n] - 0.97 \times x[n-1]. \quad (2.1)$$

Çerçeveleme olarak adlandırılan bir sonraki adımda, ön-vurgulanan sinyal, aynı uzunlukta kısa süreli çerçevelere (örneğin, 25 ms) bölünür ve her çerçeveye sürekliliği sağlamak için bir pencereleme fonksiyonu uygulanır. Bu işlem şu şekilde yapılır:

$$h[n] = p[n] \times \left(0.54 - 0.46 \times \cos\left(\frac{2\pi n}{N-1}\right) \right), \quad 0 < n < N-1, \quad (2.2)$$

burada her çerçevedeki örnek sayısı N ile gösterilir. Daha sonra, her çerçevenin Hızlı Fourier Dönüşümü (FFT) alınarak frekans alanına dönüştürülür:

$$H[k] = \sum_{n=0}^{N-1} h[n] e^{-j\frac{2\pi kn}{N}}. \quad (2.3)$$

Bu adımda, Fourier dönüşümü alınmış sinyal, Mel-filtre bankası olarak adlandırılan bir dizi üçgen bant geçiren filtreden geçirilerek Mel spektrumu hesaplanır:

$$X[l] = \log \left(\sum_{k=k_{lu}}^{k_{lu}} |H[k]| W_l(k) \right), \quad l = 0, 1, \dots, L-1, \quad (2.4)$$

burada $H[k]$ karmaşık Fourier dönüşümünün mutlak değeri, $W_l(k)$ l 'nci üçgen filtredir ve k_{lu} ile k_{lu} sırasıyla l 'nci filtrenin alt ve üst kesme frekanslarıdır.

Mel ölçeği, yaklaşık olarak 1 kHz'nin altındaki frekans aralığında doğrusal, 1 kHz'nin üzerindeki frekans aralığında ise logaritmik bir ölçek sunar. Aşağıdaki denklem, hertz cinsinden verilen frekansı Mel ölçeğine dönüştürür:

$$F(\text{mel}) = 2595 \times \log_{10} \left(1 + \frac{f}{700} \right). \quad (2.5)$$

Son adım, MFCC üretmek için DCT'nin uygulanmasıdır [45]:

$$C[m] = \sum_{l=1}^L X[l] \cos \left[\frac{\pi m(l-0.5)}{L} \right], \quad m = 1, \dots, M-1. \quad (2.6)$$

2.2.2 Gammatone Frekansı Kepstrum Katsayıları (GFCC)

Gammatone filtre bankası, koklea simülasyonu için kullanılan bir filtre grubudur. Bir Gammatone filtresinin dürtü yanıtı, insan işitme filtresinin genlik karakteristiklerine oldukça benzer. Gammatone filtre bankası, insan kulağının önemli bir parçası olan baziler zarının filtreleme karakteristiklerini en iyi şekilde simüle edebilir.

Bir Gammatone filtresinin darbe cevabı aşağıdaki gibi tanımlanır:

$$g(t) = K t^{(n-1)} e^{-2\pi B t} \cos(2\pi f_c t + \phi), \quad (2.7)$$

burada K genlik kazancını, n filtre sırasını, B filtre bant genişliğini, f_c hertz (Hz) cinsinden merkezi frekansı ve ϕ faz kaymasını ifade eder [54, 55]. Merkez frekanslar, filtre bankasının sınırları arasında eşit aralıklı olarak eşdeğer dikdörtgen bant genişliği (ERB) ölçeğinde yer alır [56]. Gammatone filtresinin bant genişliği, $B = 1.019 \times ERB(f_c)$ şeklinde verilir ve herhangi bir frekans f (Hz) için ERB (Hz) şu şekilde hesaplanır:

$$ERB(f) = \left[\left(\frac{f}{EarQ} \right)^p + (B_{min})^p \right]^{1/p}, \quad (2.8)$$

burada $EarQ$ yüksek frekanslarda asimptotik filtre kalitesini, B_{min} düşük frekanslarda minimum bant genişliğini ve p genellikle 1 veya 2'yi ifade eder. Literatürde üç farklı ERB filtre modeli önerilmiştir: Greenwood, $p = 1$, $EarQ = 7.23$ ve $B_{min} = 22.85$ değerlerini; $p = 1$, $EarQ = 9.26$ ve $B_{min} = 24.7$ değerleri, Glasberg ve Moore parametreleri olarak bilinir; Lyon ise, düşük frekanslarda $p = 2$, $EarQ = 8$ ve $B_{min} = 125$ (daha geniş bant genişliği) parametreleriyle orta keskinlikte filtreler önermiştir [57, 58]. Çalışmamızda, Greenwood'un parametreleri kullanılmıştır.



Şekil 2.4 GFCC özneliklerinin çıkarılması işlemi blok diyagramı

GFCC, Şekil 2.4'te gösterildiği gibi, MFCC'nin bir modifikasyonu olarak

tanımlanabilir. İlk olarak, ses sinyalleri kısa çerçevelere bölünür. Daha sonra, her çerçeve için FFT uygulanarak çerçeve spektrumu analiz edilir. Ardından, Gammatone filtresi, sinyalin FFT'sine uygulanarak, algısal olarak anlamlı ses frekansları vurgulanır. Son adımda, log fonksiyonu ve ayrık kosinüs dönüşümü uygulanır. GFCC, aşağıdaki gibi hesaplanabilir:

$$GFCC_m = \sqrt{\frac{2}{N}} \sum_{n=1}^N \log_{10}(X_n) \cos \left[\frac{\pi n}{N} \left(m - \frac{1}{2} \right) \right], \quad 1 \leq m \leq M, \quad (2.9)$$

burada X_n sinyalin n 'inci spektral bandındaki enerjiyi, N Gammatone filtresinin sayısını ve m GFCC'nin sayısını ifade eder [54, 58].

GFCC ile MFCC arasındaki temel farklar, her iki yöntemin sinyal özneliklerini yakalama ve sıkıştırma yaklaşımlarında yatmaktadır. MFCC, insan baziler zarının tepkisini yaklaşık olarak modellemek amacıyla üçgen filtre bankaları kullanırken; GFCC, insan işitme sisteminin frekans seçiciliğini daha doğru simüle edebilmek için Gammatone filtre bankası kullanır. Ayrıca, MFCC sinyalin dinamik aralığını azaltmak amacıyla logaritmik sıkıştırma uygular; bu sıkıştırma, yüksek enerji bileşenlerinde doyuma neden olabilir ve özellikle EKG sinyallerinde (örneğin, 1–35 Hz aralığındaki QRS kompleksi gibi) ince spektral farklılıkları maskeleyebilir [59]. Buna karşın, GFCC yöntemi, kübik sıkıştırma kullanarak, doğrusal olmayan karakteristikleri ve ince amplitüd farklılıklarını daha iyi korur; böylece, sinyaldeki kritik detayların ayırt edilebilirliği artırılır [60, 61]. Her iki yöntemin hesaplama maliyetleri benzer düzeyde olmakla birlikte, GFCC'nin bu sıkıştırma stratejisi, özellikle EKG tabanlı biyometrik tanımlamada daha belirgin enerji geçişleri ve zengin spektral dağılım sağlayarak, bireysel özneliklerin korunmasına katkıda bulunabilir [54, 58].

2.3 i-vektör ve İlgili Yöntemler

i-vektör yaklaşımı başlangıçta konuşmacı tanıma uygulamaları için geliştirilmiş olsa da, son yıllarda dil tanımlama, müzik türü sınıflandırması, cinsiyet tanıma, yaş tahmini, duygu tanıma, ses sahnesi sınıflandırması, otomatik konuşmacı doğrulama sistemlerinde sahtekarlık tespiti ve imza doğrulama gibi farklı alanlarda da uygulanmaktadır [62].

Klasik faktör analizi teorisi, iki faktör ve bunlara karşılık gelen iki bağımsız uzaya dayanmaktadır. Ancak, i-vektör yöntemi bu iki ayrı alanı tek bir uzay kullanarak değiştirmektedir. Bu yöntem, bir örneğe ait öznelik vektörlerini, toplam değişkenlik uzayı (TV) adı verilen düşük boyutlu bir vektör uzayına eşler.

TV, kovaryans matrisindeki en büyük özdeğerlere karşılık gelen özvektörlerden oluşan bir matris tarafından tanımlanmaktadır [63].

Süpervektör M , konuşma sinyallerinin temsilinde önemli bir rol oynar. Bu vektör, konuşma sinyalinden elde edilen özniteliklerin, Evrensel Arka Plan Modeli (UBM) ile maksimum posteriori (MAP) adaptasyonu sonucunda elde edilen Gauss Karışım Modeli (GMM) ortalama vektörlerinin arka arkaya eklenmesiyle oluşturulur. Matematiksel olarak şu şekilde ifade edilir:

$$M = m + Tw, \quad (2.10)$$

burada m , UBM modelinin ortalama vektörlerinin arka arkaya eklenmesiyle elde edilen süpervektörü, T düşük ranklı ve sütunları konuşmacı farklılıklarını modelleyen bir matrisi, w ise sinyalden elde edilen i-vektörü temsil etmektedir.

UBM, genellikle Gauss Karışım Modeli (GMM) kullanılarak hesaplanır. GMM, bir veri kümesinin karmaşık dağılımını temsil etmek için kullanılan istatistiksel bir modeldir. UBM, konuşmacı tanıma sistemlerinde yaygın olarak kullanılan bir model olup, konuşma verilerinin genel özniteliklerini öğrenir ve temsil eder. UBM'nin matematiksel ifadesi şu şekildedir:

$$P(x \mid \lambda_{UBM}) = \sum_{k=1}^K \pi_k N(x \mid \mu_k, \Sigma_k), \quad (2.11)$$

$P(x \mid \lambda_{UBM})$, UBM tarafından modellenen verilerin olasılık yoğunluk fonksiyonunu temsil eder. Burada, Σ_k belirli bir bileşen (k) için konuşma özniteliklerinin varyansını ve öznitelikler arasındaki ilişkiyi tanımlar; μ_k ise bileşen k 'ya ait ortalama vektörü gösterir; π_k her bir Gauss bileşeninin ağırlığını ifade eder; $N(x \mid \mu_k, \Sigma_k)$ verilen μ_k ve Σ_k altında verinin gerçekleşme olasılığını belirten Gauss dağılımını temsil eder. Öznitelik vektörü x , UBM tarafından modellenen konuşma verisini ve λ_{UBM} UBM parametrelerini içeren bir parametre vektörünü ifade eder.

i-vektörlerin tahmini, Baum-Welch istatistiklerine (sıfırıncı dereceden N ve birinci dereceden F) dayanmaktadır. Bu istatistikler, verilen bir sinyal için UBM ve Mel Frekans Kepstral Katsayıları (MFCC) öznitelikleri kullanılarak çıkarılır:

$$N_c = \sum_t P(c \mid y_t, \lambda), \quad (2.12)$$

$$F_c = \sum_t P(c \mid y_t, \lambda)(y_t - \mu_c), \quad (2.13)$$

$c = 1, \dots, C$ GMM bileşen indeksleri; $P(c \mid y_t, \lambda)$, karışım bileşeni c 'nin vektör y_t 'yi üretme olasılığını; μ_c ise UBM karışım bileşeni c 'nin ortalamasını temsil eder. Verilen bir sinyal için i -vektör şu denklem kullanılarak elde edilir:

$$w = (I + T^t \Sigma^{-1} N T)^{-1} T^t \Sigma^{-1} N F, \quad (2.14)$$

burada I , $CF \times CF$ boyutunda birim matrisidir; N , $F \times F$ bloklarına sahip bir diagonal matristir ve her bir blok $N_c I$ ($c = 1, 2, \dots, C$) şeklindedir; Σ ise T tarafından yakalanamayan artık değişkenliği temsil eden kovaryans matrisidir [64].

UBM, biyometrik kimlik doğrulama sistemlerinde kullanılan bir referans modelidir [65]. Verilen bir veri kümesindeki tüm bireylerin ortak özniteliklerinin istatistiksel bir özetini sağlar. Diğer bir deyişle, EKG verilerinden elde edilen öznitelikler, her bireyin EKG verilerine özgü öznitelikleri kapsar. UBM, bu özniteliklerin genelleştirilmiş istatistiksel modelini oluşturarak, farklı bireyler arasındaki benzerlikleri ve farklılıkları belirler [66]. Bir kullanıcının öznitelikleri ile UBM arasındaki fark, kullanıcının benzersiz biyometrik özniteliklerini açıklar ve kimlik doğrulama sürecinde kullanılır. UBM'nin oluşturulması için, öznitelikler üzerinde Gauss Karışım Modeli-Beklenti Maksimizasyonu uygulanır. Dolayısıyla, T matrisi, özniteliklerin Baum-Welch istatistikleri kullanılarak hesaplanabilir [64].

Toplam değişkenlik uzayında, i -vektörlerin iki yaygın normalizasyon tekniği; sınıf içi kovaryans normalizasyonu (WCCN) ve doğrusal diskriminant analiz (LDA)'dır. WCCN, sınıf içi kovaryansın tersini kullanarak kosinüs çekirdeğini normalize eder. LDA ise, değişkenlik etkilerini en aza indirmek ve sınıflar arasındaki varyansı maksimize etmek için özniteliklerin lineer kombinasyonlarını hesaplamaya çalışır [64, 67, 68].

2.3.1 Doğrusal Diskriminant Analiz (LDA)

Doğrusal diskriminant analizi (LDA), sınıflandırma ve boyut indirgeme problemlerinde yaygın olarak kullanılan bir makine öğrenimi ve istatistiksel tekniktir. Temel amacı, veri kümesindeki sınıfları birbirinden ayırt edebilmek için en iyi öznitelik alt kümesini bulmaktır [69–71].

LDA, bir sınıflandırıcı olarak kullanıldığında, veri özniteliklerini kullanarak bir veya daha fazla sınıfa ait örnekleri ayırt etmek için bir karar sınıfı oluşturur. Bu, veri kümesindeki sınıflar arasındaki farklılıkları maksimize etmek amacıyla özniteliklerin lineer kombinasyonunu hesaplamak üzere kullanılan denetimli bir öğrenme yöntemidir.

LDA'nın bir diğ er  nemli kullanımı boyut indirgeme i lemidir. Boyut indirgeme, veri k mesinin boyutunu azaltarak verinin karma ıklı ını d    rmeyi ve modelin daha verimli  alı masını sa lamayı ama lar. LDA, veri k mesindeki  znitelikleri birbirinden ayırt etme yetene i sayesinde boyut indirgeme i in etkili bir ara tır.

LDA, veri k mesinin da ılımını ve sınıflar arasındaki ayrımları hesaba katarak, veri  zniteliklerini en iyi  ekilde temsil eden bir alt uzay bulur. Bu alt uzay, verinin sınıflar arasında maksimum ayırım sa layacak  ekilde optimize edilir.

2.3.2 Sınıf İ i Kovaryans Normalizasyonu (WCCN)

Sınıf i i kovaryans normalizasyonu (WCCN), veri k mesindeki sınıflar arasındaki varyasyonları dengelemek i in kullanılan bir tekniktir. WCCN, her sınıfın kovaryans matrisini hesaplar ve bu matrisleri birle tirerek toplu bir kovaryans matrisi olu turur. B ylece, sınıflar arasındaki kovaryans farkları azaltılır ve sınıflandırma algoritmaları daha tutarlı sonu lar verir [64, 71].

2.4 Sınıflandırma Y ntemleri ve Benzerlik  l   tleri

EKG tabanlı biyometrik do rulama sistemlerinde, sinyalin zamansal ve frekansal  zniteliklerinin etkili bi imde  ıkarılmasıyla elde edilen  znitelik vekt rleri  zerinden kimlik do rulama ger ekle tirilir. Bu do rulama i lemlerinde, sınıflandırma algoritmaları ve benzerlik  l   tleri kritik rol oynamaktadır.

Literat rde yaygın olarak kullanılan y ntemler arasında; destek vekt r makineleri (SVM),  ok katmanlı algılayıcı (MLP), rastgele orman (RF), konvol syonel sinir a ları (CNN) ve tekrarlayan sinir a ları (RNN) yer almaktadır. Bu y ntemler, hem do rusal hem de do rusal olmayan ili kilerin modellenmesinde; k   k ve b   k veri k melerinin i lenmesinde, ayrıca g r  t l  ve de i ken sinyal ko ullarında y ksek performans sunmaları nedeniyle tercih edilmektedir.

Bu  alı mada, EKG sinyallerinden elde edilen i-vekt rlerin benzerlik skorları temel alınarak biyometrik kimlik do rulama ger ekle tirilmi tir. Ana benzerlik  l   t  olarak kosin s mesafesi kullanılmı  ve ba arılı sonu lar elde edilmi tir. Bununla birlikte,  znitelik vekt rlerinin kar ıla tırılmasında daha kapsamlı bir de erlendirme yapmak amacıyla  klid, Manhattan, Pearson korelasyonu ve dinamik zaman esnetme (DTW) gibi alternatif benzerlik  l   tleri de incelenmi  ve performansları kar ıla tırılmı tır.

A a ıdaki b l mlerde, s z konusu sınıflandırma y ntemlerinin ve benzerlik

ölçütlerinin temel prensipleri, matematiksel ifadeleri ve EKG tabanlı biyometrik doğrulamadaki uygulama alanları detaylı olarak ele alınacaktır.

2.4.1 Destek Vektör Makineleri (SVM)

Destek vektör makineleri (Support Vector Machines, SVM), sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan güçlü bir denetimli öğrenme algoritmasıdır. SVM'nin temel amacı, veri noktalarını sınıflar arasında en iyi şekilde ayıracak bir karar sınırı (hiperdüzlem) belirlemektir. Bu hiperdüzlem, sınıfların en yakın veri noktalarına olan mesafeyi (marjin) maksimize edecek şekilde optimize edilir [72]. Matematiksel olarak, SVM'nin optimizasyon problemi şu şekilde ifade edilir:

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i, \quad (2.15)$$

burada:

- $\mathbf{w}$: Hiperdüzlemin ağırlık vektörünü ve sınıflar arasındaki ayrımı tanımlar.
- b : Hiperdüzlemin sabiti olup, hiperdüzleme olan kaymayı belirler.
- ξ_i : Hata terimlerini ifade eder; doğrusal olmayan sınıflandırmada marjine düşen veya yanlış sınıflandırılan veri noktalarını temsil eder.
- C : Hiperparametre olup, hata toleransı ile hiperdüzlemin marjin genişliği arasındaki dengeyi kontrol eder.
- N : Eğitim veri kümesindeki toplam örnek sayısını ifade eder [73].

Doğrusal olmayan veri kümeleri için, kernel fonksiyonları kullanılarak veriler daha yüksek boyutlu bir uzaya dönüştürülür; bu dönüşüm, karmaşık sınıflandırma problemlerinin daha basit biçimde çözülebilmesini sağlar. Kernel fonksiyonlarında x ve y terimleri, veri kümesindeki iki farklı veri noktası (öznitelik vektörleri) olarak ifade edilir. SVM'de yaygın olarak kullanılan kernel fonksiyonları şunlardır:

- **Doğrusal Kernel:** $K(x, y) = x^\top y$,
- **Polinomsal Kernel:** $K(x, y) = (x^\top y + r)^d$, burada r sabit, d ise polinomun derecesidir.
- **RBK Kernel (Radial Basis Function):** $K(x, y) = \exp(-\gamma \|x - y\|^2)$, burada γ kernel fonksiyonunun genişliğini kontrol eden bir parametredir [74].

Kernel fonksiyonları sayesinde SVM, doğrusal olmayan sınıflandırma problemlerinde de etkili çözümler sunar. SVM, özellikle sınırlı veritabanlarında yüksek doğruluk oranları sunması ve aşırı öğrenme (overfitting) riskini minimize etme yeteneği ile dikkat çekmektedir. Bununla birlikte, gürültülü veri kümelerinde kararlılık göstermesi, SVM'nin biyometrik kimlik doğrulama sistemlerinde güvenilir bir yöntem olarak kullanılmasını sağlamaktadır. Literatürde, parmak izi, yüz ve EKG gibi biyometrik sistemlerin yanı sıra, metin işleme, görüntü tanıma ve tıbbi veri analizi gibi farklı alanlarda da yaygın olarak tercih edilmektedir. Ayrıca, finans ve ekonomi alanında hisse senedi fiyat tahmini ve kredi risk analizi gibi problemlerde de etkili bir çözüm yöntemi sunmaktadır [75].

SVM'nin avantajları arasında doğrusal olmayan verilerdeki sınıflandırma başarısı, kernel fonksiyonlarının sağladığı esneklik ve küçük veritabanlarıyla etkili çalışabilmesi yer almaktadır. Bununla birlikte, büyük veritabanlarında eğitim süresinin uzaması, işlem maliyetinin yüksekliği ve hiperparametre optimizasyonunun zorlukları SVM'nin sınırlamaları arasında sayılabilir. Ayrıca, çok sınıflı problemler için birden fazla sınıflandırıcı kullanılması gerektiğinden, sınıflar arasında dengesizliğe yol açma riski bulunmaktadır. Bu nedenlerle, SVM'nin kullanım alanı, problem türüne ve veritabanının büyüklüğüne göre dikkatlice değerlendirilmelidir [76].

2.4.2 Çok Katmanlı Algılayıcı (MLP)

Çok katmanlı algılayıcı (Multi-Layer Perceptron, MLP), yapay sinir ağlarının temel yapı taşlarından biri olup, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan bir yöntemdir. MLP, ileri beslemeli bir yapıdadır ve giriş verilerinin katmanlar boyunca işlenmesiyle öğrenme gerçekleştirir. Temel olarak, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur [77].

MLP'nin çalışma prensibi, her bir nöronun giriş sinyallerini ağırlıklandırarak ve bir aktivasyon fonksiyonu kullanarak işlenmiş bir çıktı üretmesine dayanır. Bu işlem, aşağıdaki matematiksel ifade ile tanımlanabilir:

$$y = f \left(\sum_{i=1}^n w_i x_i + b \right), \quad (2.16)$$

burada:

- x_i : Girdi sinyalleri,
- w_i : Girdi sinyallerine atanan ağırlıklar,

- b : Bias terimi,
- f : Aktivasyon fonksiyonu.

Gizli katmanlarda yaygın olarak kullanılan aktivasyon fonksiyonları arasında sigmoid, tanh ve ReLU (Rectified Linear Unit) bulunmaktadır. Bu fonksiyonlar, doğrusal olmayan ilişkilerin modellenmesini sağlar.

MLP'nin eğitimi, geri yayılım (backpropagation) algoritması ve optimizasyon teknikleri kullanılarak gerçekleştirilir. Modelin hata fonksiyonu, problem türüne bağlı olarak çapraz entropi veya ortalama kare hata (MSE) olarak seçilir. Optimizasyon sürecinde ise genellikle Stokastik Gradyan İnişi (SGD) ve türevleri (örneğin, Adam, RMSProp) kullanılır [77].

Bununla birlikte, MLP'nin performansı genellikle hiperparametre optimizasyonuna (örneğin, katman sayısı, nöron sayısı, öğrenme hızı) bağlıdır. Ayrıca, büyük veritabanlarında eğitim süresi uzayabilir ve aşırı öğrenme (overfitting) riski artabilir. Bu durumları önlemek için düzenleme yöntemleri (örneğin, L2 cezası, dropout) kullanılmaktadır. MLP'nin avantajları arasında doğrusal olmayan ilişkileri modelleme kapasitesi, küçük veritabanlarında yüksek performans göstermesi ve geniş bir uygulama alanına sahip olması yer alır. Ancak, büyük veritabanlarında eğitim süresinin uzaması ve hiperparametre optimizasyonunun zorluğu gibi dezavantajları bulunmaktadır [78–80].

2.4.3 Rastgele Orman (RF)

Rastgele orman (Random Forest, RF), birden fazla karar ağacının (*decision tree*) topluluk (ensemble) yaklaşımıyla bir araya getirilmesiyle oluşturulan güçlü bir makine öğrenimi yöntemidir. Her bir karar ağacı, veri kümesinden tekrar seçmeli örnekleme (bootstrap) yöntemiyle oluşturulan alt veri kümesi üzerinde eğitilir. Böylece, farklı ağaçlar farklı parçalardan öğrenerek modelin aşırı öğrenme (overfitting) eğilimi azaltılır. Ayrıca, ağaçlardaki her düğümde rastgele seçilen bir alt öznitelik kümesi kullanılarak ağaçlar arasındaki benzerlik (korelasyon) düşürülür [81, 82]. Karar ağaçlarında en iyi bölünme noktası, çoğunlukla Gini indeksi veya bilgi kazancı (information gain) gibi metriklerle belirlenir. Örneğin, Gini indeksi şu şekilde ifade edilebilir:

$$G = \sum_{k=1}^K p_k(1 - p_k), \quad (2.17)$$

burada p_k , ilgili düğümdeki verilerin k sınıfına ait olma olasılığını gösterir. Topluluk içindeki tüm ağaçların çıktıları, sınıflandırma problemlerinde çoğunluk oylaması, regresyon problemlerinde ise ortalama alınması yoluyla birleştirilir. Ağaç sayısı, maksimum derinlik ve öznitelik alt kümesi boyutu gibi hiperparametreler, RF'nin performansında kritik rol oynar.

EKG tabanlı biyometrik doğrulamada, RF özellikle gürültülü veya değişken sinyal koşullarında yüksek doğruluk oranları sunmasıyla dikkat çekmektedir. Literatürde, dalgacık (wavelet) veya istatistiksel tabanlı öznitelik çıkarma yöntemlerinin ardından RF ile yapılan sınıflandırma deneylerinde başarılı sonuçlar elde edildiği rapor edilmiştir [83]. Öte yandan, birden çok karar ağacının eğitimi nedeniyle bellek ve hesaplama maliyeti artabilir; bu nedenle veri büyüklüğü ve hiperparametre seçimi bakımından titiz bir yaklaşım gereklidir.

2.4.4 Konvolüsyonel Sinir Ağları (CNN)

Konvolüsyonel sinir ağları (Convolutional Neural Networks, CNN), özellikle görüntü ve zaman serisi verilerinde otomatik öznitelik çıkarımı yapabilen derin öğrenme mimarilerinden biridir. CNN'nin temelinde, giriş verisiyle gerçekleştirilen evrişim (*convolution*) işlemi yer alır. 1-boyutlu (1D) bir evrişim örneği aşağıdaki gibi ifade edilebilir:

$$y_i = \sum_{k=0}^{K-1} x_{i+k} \cdot w_k + b, \quad (2.18)$$

burada x_{i+k} giriş verisinin $i + k$ konumundaki değeri, w_k öğrenilen filtre ağırlığını (kernel) ve b bias terimini ifade eder. Bu işlem, farklı konumlardaki örüntüleri yakalayıp modelin öğrenmesine katkı sağlar. Ardından, havuzlama (*pooling*) katmanları ile boyut küçültmesi yapılarak daha soyut öznitelik temsilleri elde edilir [84].

EKG sinyalleri gibi zaman serisi verilerinde, 1D konvolüsyon filtreleri dalga formu üzerinde kaydırılarak sinyalin farklı segmentlerindeki frekans ve şekil bileşenleri otomatik olarak öğrenilebilir. Literatürde, bu yöntemle el ile öznitelik çıkarma adımının büyük ölçüde azaltıldığı ve gürültüye karşı dayanıklı modeller oluşturulduğu rapor edilmiştir [85, 86]. Böylece, EKG tabanlı biyometrik doğrulamada CNN yaklaşımlarıyla yüksek doğruluklar elde edilmekte; farklı bireylerin kalp atış karakteristikleri konvolüsyon katmanlarında yakalanmaktadır.

2.4.5 Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağları (Recurrent Neural Networks, RNN), sıralı veriler arasındaki bağımlılıkları modellemek için tasarlanmış bir yapay sinir ağı türüdür. RNN’lerde, her zaman adımında hesaplanan gizli durum (*hidden state*) bir sonraki adıma aktarılır. Klasik bir RNN güncellemesi aşağıdaki basit denklemle ifade edilebilir:

$$h_t = \sigma(W_{xh} x_t + W_{hh} h_{t-1} + b_h), \quad (2.19)$$

burada h_t güncel gizli durum, x_t giriş vektörü, W_{xh} ve W_{hh} ağırlık matrisleri, b_h bias terimi ve $\sigma(\cdot)$ aktivasyon fonksiyonudur [87]. Ancak, klasik RNN yapıları uzun sekanslarda gradyan kaybolması (vanishing gradient) sorununa karşı hassastır.

Bu sorunu hafifletmek amacıyla LSTM (Long Short-Term Memory) ve GRU (Gated Recurrent Unit) gibi kapılı (gated) mekanizmalara sahip RNN modelleri geliştirilmiştir. EKG sinyalleri, zamana bağlı bir dizi halinde olduğundan, RNN tabanlı yaklaşımlar kalp atışı döngülerindeki ardışık yapıyı (örneğin, P-QRS-T komplekslerinin sıralaması) yakalamada etkilidir [88, 89]. Bu sayede, EKG tabanlı kimlik doğrulama sistemlerinde RNN ve türevleri, özellikle zaman içindeki kalp atışı örüntülerini dikkate alarak yüksek doğruluk sunabilmektedir.

2.4.6 Kosinüs Mesafesi (Cosine Distance)

i-vektörlerin sınıflandırılmasında, kosinüs çekirdek fonksiyonu etkili bir sınıflandırıcıdır [71]. Kosinüs mesafesi, iki vektör arasındaki açısal farkı ölçer ve benzerlikleri belirler. w_1 ve w_2 i-vektörleri arasındaki kosinüs çekirdek fonksiyonu şu şekilde tanımlanır:

$$\cos(w_1, w_2) = \frac{\langle w_1, w_2 \rangle}{\|w_1\| \cdot \|w_2\|} \quad (2.20)$$

Burada, $\langle w_1, w_2 \rangle$ iki vektörün iç çarpımını; $\|w_1\|$ ve $\|w_2\|$ ise vektörlerin normlarını temsil eder. İki verinin i-vektörleri aynı yönü gösteriyorsa, kosinüs mesafesi 1 değerini alır; zıt yönleri işaret ederse -1 değerini alır. Kosinüs mesafesi, özellikle yüksek boyutlu veri kümelerinde benzerlik ölçütü olarak etkili bir yöntemdir.

2.4.7 Öklid Mesafesi (Euclidean Distance)

Öklid mesafesi, iki i-vektör arasındaki düz çizgi uzaklığını ölçmek için kullanılan temel bir yöntemdir. Matematiksel olarak şu şekilde ifade edilir:

$$d_{\text{euclidean}}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (2.21)$$

burada $x = (x_1, x_2, \dots, x_n)$ ve $y = (y_1, y_2, \dots, y_n)$ i-vektörleridir; n ise i-vektörlerin boyutunu ifade eder [90]. Öklid mesafesi, iki vektör arasındaki genlik farklarını doğrudan hesaba katmasıyla genellikle etkili bir yöntem olarak kabul edilir. Ancak, yöntemin genlik ölçeğine duyarlı olması nedeniyle, farklı büyüklükteki i-vektörlerin karşılaştırılmasında normalizasyon gereklidir.

2.4.8 Manhattan Mesafesi (Manhattan Distance)

Manhattan mesafesi, iki i-vektör arasındaki her bir bileşen için mutlak farkların toplamını ölçen bir yöntemdir ve aşağıdaki formülle hesaplanır [91]:

$$d_{\text{manhattan}}(x, y) = \sum_{i=1}^n |x_i - y_i|. \quad (2.22)$$

Bu yöntem, özellikle aykırı değerlere karşı Öklid mesafesine kıyasla daha az duyarlı olmasıyla öne çıkar. Ayrıca, verilerin her bir bileşenini ayrı ayrı değerlendirme imkanı sunar. Ancak, farklı bileşenlerin ilişkili olduğu durumlarda bu yöntemin performansı sınırlı kalabilir.

2.4.9 Pearson Korelasyonu (Pearson Correlation)

Pearson korelasyonu, iki i-vektör arasındaki doğrusal ilişkiyi ölçmek için kullanılan bir yöntemdir ve şu şekilde ifade edilir [92]:

$$r_{\text{pearson}}(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (2.23)$$

burada $\bar{x}$ ve $\bar{y}$ sırasıyla x ve y vektörlerinin ortalamalarını temsil eder. Bu yöntem, vektörlerin büyüklük farklarını göz ardı ederek yönelim benzerliklerini ölçmesiyle dikkat çeker. Bu özelliği sayesinde, farklı ölçeklerdeki verilerin karşılaştırılmasına olanak tanır; ancak, doğrusal olmayan ilişkiler bu yöntemle yeterince değerlendirilemez.

2.4.10 Dinamik Zaman Esnetme (Dynamic Time Warping, DTW)

Dinamik zaman esnetme (DTW), iki zaman serisi veya vektör arasındaki benzerlikleri, zamanlama farklılıklarını dikkate alarak ölçen bir yöntemdir [93]. DTW, aşağıdaki maliyet fonksiyonu üzerinden hesaplanır:

$$DTW(X, Y) = \min \left(\sum_{k=1}^K d(x_{i_k}, y_{j_k}) \right). \quad (2.24)$$

Bu yöntemin en önemli avantajı, zamanlama kaymalarını telafi ederek sinyalleri hizalama yeteneğidir. Özellikle, zaman serileri arasında esnek karşılaştırmalar yapılmasını sağlar ve zamanlamaya duyarlı biyometrik sistemlerde etkili bir çözüm sunar. Ancak, hesaplama maliyetinin yüksek olması yöntemin önemli bir dezavantajıdır.

3

VERİTABANLARI

Bu çalışmada kullanılan veri kaynakları ve donanımlar detaylı bir şekilde açıklanmıştır. Üç ana veritabanı ve bunların elde edilmesi için kullanılan donanımlar tanımlanmıştır. İlk olarak, ECG-ID veritabanı tanıtılmış; daha sonra daha büyük bir veritabanı olan Heartprint sunulmuş; ardından BMD101 EKG sensör modülüyle elde ettiğimiz kayıtlarla oluşturduğumuz veritabanına geçilmiştir.

3.1 ECG-ID Veritabanı

ECG-ID Veritabanı, Tatiana Lugovaya tarafından oluşturulmuş ve PhysioBank'a katkıda bulunulmuştur [94]. Bu veritabanı, 90 gönüllüden alınan toplam 310 EKG kaydından oluşan bir settir. Lugovaya, bu EKG'leri yüksek lisans tezinde kullanmıştır.

Kayıtlar, 13 ile 75 yaşları arasındaki 44 erkek ve 46 kadın gönüllüden alınmıştır. Bu gönüllüler, yazarın öğrencileri, meslektaşları ve arkadaşlarıdır. Her birey için kayıt sayısı 2 ile 20 arasında değişmekte; bu kayıtlar, bir gün içinde toplanan iki kayıttan, altı ay boyunca periyodik olarak toplanan yirmiye kadar çeşitlilik göstermektedir. EKG kayıtları, 12-bit çözünürlükte ve 500 Hz örnekleme frekansında kaydedilmiş olup, her bir kayıt 20 saniye sürmektedir.

Bu çalışmada, önerilen yöntemi analiz etmek amacıyla, yeterli sayıda kayda sahip 20 bireyden alınan, her biri 10 kayıt içeren EKG verileri kullanılmıştır. Bu EKG kayıtları, rastgele olarak geliştirme, eğitim ve test verileri şeklinde bölünmüştür. Bu yaklaşım, veritabanının dengeli ve temsili bir örnekleme kullanıldığını sağlamıştır.

3.2 Heartprint Veritabanı

Heartprint [32], 2012 yılından itibaren, on yıl boyunca gerçekleştirilen çoklu oturumlar kapsamında, dinlenme ve okuma koşullarında elde edilen 1539 kayıttan

oluşan bir EKG biyometrik veritabanıdır. Veritabanı, 130 erkek ve 69 kadın olmak üzere toplam 199 bireyden elde edilmiş olup, çeşitli demografik sınıfları, cinsiyetleri, etnik kökenleri ve yaş gruplarını kapsamaktadır.

Heartprint veritabanı sinyalleri, Tayvan'ın Taoyuan şehrinde geliştirilen ve Şekil 3.1'de gösterilen DailyCare BioMedical, Inc. üretimi ReadMyHeart adlı el tipi bir EKG cihazı ile kaydedilmiştir. Bu cihaz, her iki elin başparmakları arasındaki potansiyel farkını ölçerek tek kanallı (lead I) EKG kaydı almakta ve sinyali 250 Hz frekansında örnekleme yapmaktadır. ReadMyHeart cihazı, iki kuru iletken elektrot kullanarak sinyali alır, dijitalleştirir ve EKG kaydını bilgisayara .txt uzantılı metin dosyası olarak aktarmaktadır.



Şekil 3.1 ReadMyHeart el tipi EKG cihazı [95]

3.3 BMD101 EKG Sensör Modülüyle Elde Edilen Veritabanı

Mobil ve giyilebilir cihazlar için tasarlanan BMD101 EKG sensör modülü kullanılarak EKG sinyalleri toplanmıştır. Bu sensör, NeuroSky'nin BMD101 yonga setine sahip 3. nesil biyo-sinyal algılama ve işleme sistem-on-chip kitidir. BMD101, taşınabilir uygulamalar için uygun, çok küçük form faktörüne ve düşük güç tüketimine sahip bir çözümdür.


BMD101, gelişmiş bir analog ön uç devresi ve esnek, güçlü bir dijital sinyal işleme yapısı ile tasarlanmıştır. Bu cihaz, düşük gürültülü amplifikatör (LNA) ve analog-dijital dönüştürücü (ADC) gibi ana bileşenler sayesinde, μV seviyesinden mV seviyesine kadar değişen biyo-sinyal girişlerini işleyebilir. BMD101, 16-bit yüksek çözünürlüklü bir ADC kullanarak bu biyo-sinyalleri

dijitale dönüştürebilmektedir.

BMD101'in düşük sistem gürültüsü ve programlanabilir kazancı, hassas biyo-sinyal verilerini güvenilir bir şekilde toplamak için idealdir. Ayrıca, UART (57600 Baud Rate) arabirimleri aracılığıyla iletişim kurabilir; bu da BMD101'in harici cihazlarla kolayca entegre edilebilmesini sağlar.

Şekil 3.2'de gösterilen Sichiray BMD101 EKG sensör modülü ile yapılan çalışmamızda, EKG verileri parmak uçlarından, lead I konfigürasyonunda kaydedilmiştir. Bu veritabanı, 23 farklı bireyden çeşitli zaman aralıklarında toplanan kayıtlardan oluşturulmuştur. Her bir bireyden alınan kayıtlar, farklı sayıda ve farklı sürelerde olup, bu da veritabanının çeşitliliğini ve kapsamını artırmaktadır. Bu veriler, 16-bit çözünürlükte, 512 Hz örnekleme frekansında ve 20 saniyelik EKG kayıt segmentleri şeklinde kullanılmıştır.

Bu veritabanı, çalışmamızın temelini oluşturmakta ve önerdiğimiz EKG biyometrik kimlik doğrulama algoritmasının geliştirilmesi ve test edilmesi için kullanılmaktadır. BMD101 sensörü ve elde edilen veriler, mobil güvenlik uygulamalarında biyometrik kimlik doğrulamanın pratik ve etkili bir yolunu sağlama potansiyeline sahiptir.



Şekil 3.2 BMD101 EKG sensör modülü


Bu çalışmada kullanılan üç farklı veritabanı, EKG tabanlı biyometrik kimlik doğrulamanın farklı senaryolarda nasıl performans gösterdiğini kapsamlı bir şekilde incelememize olanak tanımaktadır. ECG-ID veritabanı, bireylerin farklı zamanlardaki EKG varyasyonlarını analiz etmek için kullanılırken; Heartprint veritabanı, dinlenme ve okuma gibi kontrollü ortamlarda uzun süreli takip edilen bireylerin kimlik doğrulama performansını değerlendirmeye olanak sağlamaktadır. Öte yandan, BMD101 sensörü ile oluşturulan veritabanı, gerçek mobil ortamda kısa süreli ve düşük çözünürlüklü EKG kayıtlarıyla biyometrik kimlik doğrulamanın

pratik uygulanabilirliğini test etmeyi hedeflemektedir. Çeşitli zaman aralıklarında, farklı koşullarda toplanmış bu veritabanları, önerilen yöntemin doğruluğunu artırmak ve mobil cihazlar için güvenilir biyometrik kimlik doğrulama sistemlerinin geliştirilmesine katkı sağlamak amacıyla kullanılmaktadır.



4.1 Ön İşleme

EKG işaretleri, 0.1–100 Hz arasında bir frekans bandına ve 0 mV ile 1 mV arasında bir genlik değerine sahiptir. Medikal alanda etkili EKG bilgisi 0.7–40 Hz aralığında iken, biyometrik alanda bu aralık 1–35 Hz olarak kabul edilmektedir. Şekil 4.1’de, örneklendirilmiş bir EKG sinyalinin orijinal zaman serisi, bu sinyalin spektrogramı ve güç spektrumu görülmektedir.




Şekil 4.1 Bir EKG sinyalinin orijinal zaman serisi, spektrogramı ve güç spektrumu

EKG kayıtlarındaki gürültü kaynaklarıyla başa çıkmak için kayıtlar şu şekilde filtrelenmiştir:

- İlk olarak, taban hattı kaymasını ortadan kaldırmak için, kesme frekansı 1 Hz olan Chebyshev-I tipi bir yüksek geçiş filtresi kullanılmıştır.
- Güç hattı parazitini gidermek için, 50–60 Hz aralığında bir geçiş bandına sahip Chebyshev-II tipi bir bant durdurma filtresi kullanılmıştır.
- Kas gürültüsüyle başa çıkmak için, kesme frekansı 100 Hz olan eliptik bir düşük geçiş filtresi kullanılmıştır.
- Son adımda, bir yumuşatma işlemi gerçekleştirilmiştir.

Ön işleme algoritması uygulandıktan sonra, EKG sinyallerindeki taban hattı kayması ve diğer gürültülerin başarıyla azaltıldığı gözlemlenmiştir. Şekil 4.2’de, önerilen ön işleme algoritmasının bir EKG kaydı üzerindeki etkisi gösterilmektedir. Bu adımlar sonucunda, temizlenmiş ve daha analiz edilebilir EKG sinyalleri elde edilmiştir.



Şekil 4.2 Ön işleme algoritma uygulaması

4.2 Önerilen Yöntem: Öznitelik Çıkarımı ve i-vektör Temsili

4.2.1 Öznitelik Çıkarımı

Ön işleme sonrasında, öznitelik olarak kullanılmak üzere Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC)


türetilmektedir.

MFCC ve GFCC, veritabanına bağlı olarak 1 veya 0.5 saniyelik pencere boyutu ve 0.25 veya 0.1 saniyelik kayma ölçüsü kullanılarak EKG verilerinden elde edilmiştir. Spektral bant sayısı, veritabanına bağlı olarak MFCC için 20 veya 24, GFCC için ise 16, 20 veya 40 olarak ayarlanmıştır. Biyometrik bilgiyi yakalamak amacıyla, frekans aralığı 1–35 Hz ile sınırlandırılmıştır.

Sonuç olarak, veritabanına bağlı olarak MFCC ve GFCC için ayrı ayrı 13×77 veya 13×145 boyutlarında öznitelik vektörleri oluşturulmuş; ardından, ortalama ve varyans ayarlaması yapılarak öznitelik vektörleri normalize edilmiştir.

4.2.2 i-vektörlerin Elde Edilmesi

Şekil 4.3, önerilen i-vektör yönteminin blok diyagramını göstermektedir.



Şekil 4.3 i-vektör algoritması blok diyagramı

Geliştirme verilerinden öznitelik vektörleri elde edildikten sonra, GMM-EM algoritması farklı sayıda karışım (nmix = [8, 16, 32, 64, 128, 256]) uygulanmakta ve her karışım için bir UBM (Universal Background Model) elde edilmektedir. i-vektör modelinin Baum-Welch istatistikleri, geliştirme verilerinden elde edilen öznitelik vektörleri kullanılarak hesaplanmaktadır.

Çalışmanın başlangıcında, toplam değişkenlik alt uzayı T sırasıyla 100, 200, 300 ve 400 boyutları için öğrenilmiştir. Ancak, ilerleyen aşamalarda iki veritabanımızın sınırlı boyutu nedeniyle yalnızca 100 boyutunun, Heartprint veritabanı için ise 200 boyutunun kullanılması uygun görülmüştür. Daha sonra, Baum-Welch istatistikleri, UBM ve T matrisi kullanılarak i -vektörler hesaplanmaktadır.

Farklı sınıflar arasındaki ayrımı daha iyi sağlamak amacıyla, geliştirme verilerinden elde edilen i -vektörlere LDA uygulanmakta ve ortaya çıkan V matrisi, eğitim verilerinin i -vektörlerine uygulanarak bireysel i -vektör modelleri oluşturulmaktadır.

Test i -vektörleri ile eğitim verilerinden elde edilen modeller arasındaki benzerlik skoru, kosinüs mesafesi kullanılarak hesaplanmaktadır. Sisteme erişim başvurusunda bulunan kişinin, erişim izni olan bir birey olarak kabul edilip edilmeyeceği, belirlenen eşik değere göre tespit edilmektedir. En iyi eşik değeri, 0.95 ile 0.5 arasında deneme-yanılma yöntemiyle belirlenmektedir.

Her bir deney için, performans değerlendirme metriklerini elde etmek amacıyla farklı eğitim ve test verileri kullanılarak deneyler, Heartprint veritabanı için 4 kez, diğer veritabanları için 10 kez tekrarlanmaktadır.

4.3 EKG ile Doğrulama için Kullanılan Alternatif Yaklaşımlar

Bu bölümde, literatürde yaygın olarak kullanılan çeşitli makine öğrenimi ve derin öğrenme yöntemlerinin (SVM, MLP, RF, CNN ve RNN) EKG tabanlı doğrulama sistemlerine uygulanış süreçleri detaylı bir şekilde ele alınmaktadır. Amacımız, her bir yöntemin modelleme, öznitelik çıkarımı ve hiperparametre optimizasyonu aşamalarındaki adımlarını açıklayarak, önerilen i -vektör tabanlı yöntem ile karşılaştırılabilecek bir temel sağlamaktır. Performans analizleri, ilerleyen bölümlerde ele alınacaktır.

Bu kapsamda, tüm yöntemler için ortak bir veri hazırlama ve öznitelik çıkarımı süreci benimsenmiş; hiperparametre optimizasyonu ise Bayes optimizasyonu ile gerçekleştirilmiştir. Her bir yöntemde, MFCC ve GFCC öznitelikleri ayrı ayrı optimize edilip özniteliklere ait parametreler belirlendikten sonra, bu özniteliklerin birleştirilmesiyle elde edilen özniteliklerin yöntemlerdeki performansı analiz edilmiştir.

EKG sinyallerindeki taban hattı kayması, güç hattı paraziti ve kas gürültüsü gibi istenmeyen bileşenlerin azaltılması için uygulanan filtreler, Ön İşleme bölümünde açıklandığı şekilde burada da uygulanmıştır.

4.3.1 Öznitelik Çıkarımı ve Normalizasyon

EKG sinyallerinden 5 saniyelik kesitler alınarak, Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC) türetilmiştir. Bu süreçte, aşağıdaki parametre kombinasyonları geliştirme verisi üzerinde test edilmiştir:

- **Pencere süresi:** 0.5 s, 0.75 s, 1 s veya 2 s,
- **Kayma süresi:** 0.1 s, 0.25 s, 0.5 s veya 1 s,
- **Bant sayısı:** 20, 30 veya 40,
- **Bant genişliği:** 0.1, 1 veya 1.5.

Denemeler sonucunda, yanlış kabul oranı (FAR) temel alınarak en uygun öznitelik ayarları belirlenmiş ve bu ayarlar kullanılarak MFCC ile GFCC vektörleri birleştirilerek nihai öznitelik vektörleri oluşturulmuştur.

Elde edilen öznitelik vektörlerinin istatistiksel uyumu için, eğitim setinin ortalama ve standart sapması kullanılarak tüm veri (geliştirme ve test) z-skor normalizasyonu yöntemiyle aynı ölçeğe dönüştürülmüştür. Bu sayede, farklı kayıtlar arasındaki ölçek farkları azaltılmış ve özniteliklerin model performansına etkisi optimize edilmiştir.

4.3.2 Kullanıcı Bazlı Model Kurma ve Hiperparametre Arayışı

Bu çalışmada, kullanıcı bazlı bir modelleme yaklaşımı benimsenmiştir. Her bir katılımcının verileri “pozitif sınıf”, diğer katılımcıların verileri ise “negatif sınıf” olarak tanımlanmıştır. Negatif örnek sayısı, pozitif örnek sayısının belirli bir katı olacak şekilde sınırlandırılarak, veri dengesizliğinin olumsuz etkileri en aza indirilmiştir. Bu yapı, sistemin her bir kullanıcı için özelleştirilmiş doğrulama modelleri oluşturmasına olanak sağlamıştır.

Hiperparametre arayışı, geliştirme verisi üzerinde 3 katlı çapraz doğrulama (CV) yöntemi ile gerçekleştirilmiştir. Optimizasyon sürecinde, modellerin yanlış kabul oranı (FAR) değerini en düşük seviyeye indirmesi hedeflenmiştir. Her katılımcıya ait en iyi parametre kombinasyonları belirlendikten sonra, aynı parametreler kullanılarak eğitim verisi üzerinde nihai modeller oluşturulmuş ve test verisinde ACC, FAR, TAR ve EER gibi performans metrikleri raporlanmıştır.

4.3.3 SVM Modelleme ve Hiperparametre Optimizasyonu

Bu çalışmada, destek vektör makineleri (SVM) kullanılarak kişi bazlı EKG doğrulama modeli geliştirilmiştir. Modelleme sürecinde, EKG sinyallerinden türetilen Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC) kullanılmıştır. Öznitelik çıkarımı sürecinde yapılan optimizasyonlar sonucunda, SVM modeli için en uygun MFCC ve GFCC parametreleri aşağıdaki gibi belirlenmiştir:

- **MFCC Parametreleri:** Pencere süresi: 2 s, kayma süresi: 0.5 s, bant sayısı: 20, bant genişliği: 1.
- **GFCC Parametreleri:** Pencere süresi: 2 s, kayma süresi: 0.5 s, bant sayısı: 20, bant genişliği: 0.1.

Bu öznitelikler birleştirilerek nihai öznitelik vektörleri oluşturulmuş ve tüm veri, z-skor normalizasyonu yöntemiyle aynı ölçeğe getirilmiştir.

SVM hiperparametre optimizasyonu, kullanıcı bazlı bir yaklaşımla gerçekleştirilmiştir. Her kullanıcı için ayrı bir model oluşturulmuş ve Bayes optimizasyonu yardımıyla SVM'nin en uygun hiperparametreleri belirlenmiştir. Optimize edilen hiperparametreler şu şekildedir:

- **Kısıtlama Parametresi (C):** [0.1, 10]
- **Pozitif Sınıf Ağırlığı:** [50, 300]
- **Negatif Sınıf Ağırlık Çarpanı:** [2, 10]
- **Çekirdek Ölçeği (KernelScale):** [0.1, 10]
- **Polinom Derecesi (Polynomial çekirdek için):** [2, 10]

Yapılan testlerde, çekirdek fonksiyonları arasında polinomial çekirdek fonksiyonu, en düşük yanlış kabul oranı (FAR) değerleriyle diğer çekirdek fonksiyonlarına göre daha iyi performans göstermiştir. Bu nedenle, nihai analizlerde polinomial çekirdek fonksiyonu tercih edilmiştir.

4.3.4 MLP Modelleme ve Hiperparametre Optimizasyonu

Bu çalışmada, çok katmanlı yapay sinir ağları (MLP) kullanılarak kişi bazlı EKG doğrulama modeli geliştirilmiştir. Modelleme sürecinde, EKG sinyallerinden

türetilen Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC) kullanılmıştır. Öznitelik çıkarımı sürecinde yapılan optimizasyonlar sonucunda, MLP modeli için en uygun MFCC ve GFCC parametreleri aşağıdaki gibi belirlenmiştir:

- **MFCC Parametreleri:** Pencere süresi: 2 s, kayma süresi: 0.5 s, bant sayısı: 20, bant genişliği: 1.
- **GFCC Parametreleri:** Pencere süresi: 2 s, kayma süresi: 0.5 s, bant sayısı: 30, bant genişliği: 0.1.

Bu öznitelikler birleştirilerek nihai öznitelik vektörleri oluşturulmuş ve tüm veri, z-skor normalizasyonu yöntemiyle ölçeklendirilmiştir.

MLP hiperparametre optimizasyonu, kullanıcı bazlı bir yaklaşımla gerçekleştirilmiştir. Her kullanıcı için ayrı bir model oluşturulmuş ve Bayes optimizasyonu yardımıyla MLP'nin en uygun hiperparametreleri belirlenmiştir. Optimize edilen hiperparametreler şu şekildedir:

- **Gizli Katmanlardaki Nöron Sayısı:** [10, 500]
- **Katman Sayısı:** [1, 5]
- **Pozitif Sınıf Ağırlığı:** [50, 500]
- **Negatif Sınıf Ağırlık Çarpanı:** [5, 100]

MLP modeli, kullanıcı bazlı bir yapı ile tasarlanmıştır. Her bir kullanıcının verileri pozitif sınıf, diğer kullanıcıların verileri ise negatif sınıf olarak etiketlenmiştir. Veri dengesizliğini azaltmak amacıyla, negatif örnek sayısı, pozitif örnek sayısının belirli bir katıyla sınırlandırılmıştır. Model eğitimi için kullanılan MLP yapısı, belirlenen hiperparametrelerle her kullanıcıya özel olarak tasarlanmış olup, aşağıdaki bileşenlerden oluşmaktadır:

- Tam bağlantılı (fully connected) katmanlar,
- Sigmoid aktivasyon fonksiyonları,
- Çıkış katmanında iki sınıflı doğrulama için softmax aktivasyon fonksiyonu.

Test verisi üzerinde yapılan analizlerde, Yanlış Kabul Oranı (FAR), Doğru Kabul Oranı (TAR) ve Eşit Hata Oranı (EER) gibi performans metrikleri kullanılarak sonuçlar raporlanmıştır.

4.3.5 RF Modelleme ve Hiperparametre Optimizasyonu

Bu çalışmada, rastgele orman (RF) algoritması kullanılarak kişi bazlı EKG doğrulama modeli geliştirilmiştir. Modelleme sürecinde, EKG sinyallerinden türetilen Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC) kullanılmıştır. Öznitelik çıkarımı sürecinde yapılan optimizasyonlar sonucunda, RF modeli için en uygun MFCC ve GFCC parametreleri aşağıdaki gibi belirlenmiştir:

- **MFCC Parametreleri:** Pencere süresi: 2 s, kayma süresi: 0.5 s, bant sayısı: 20, bant genişliği: 1.
- **GFCC Parametreleri:** Pencere süresi: 2 s, kayma süresi: 0.5 s, bant sayısı: 20, bant genişliği: 0.1.

Bu öznitelikler birleştirilerek nihai öznitelik vektörleri oluşturulmuş ve tüm veri, z-skor normalizasyonu yöntemiyle ölçeklendirilmiştir.

RF hiperparametre optimizasyonu, kullanıcı bazlı bir yaklaşımla gerçekleştirilmiştir. Her kullanıcı için ayrı bir model oluşturulmuş ve Bayes optimizasyonu yardımıyla RF'nin en uygun hiperparametreleri belirlenmiştir. Optimize edilen hiperparametreler şu şekildedir:

- **Ağaç Sayısı (NumTrees):** [20, 200]
- **En Fazla Bölme Sayısı (MaxNumSplits):** [2, 50]
- **Örneklenmiş Değişken Sayısı (NumVariablesToSample):** [1, $nFeatures$]
- **Bölme Kriteri (SplitCriterion):** *gdi, deviance, twoing*
- **Pozitif Sınıf Ağırlığı:** [50, 300]
- **Negatif Sınıf Ağırlık Çarpanı:** [5, 50]

RF modeli, kullanıcı bazlı bir yapı ile tasarlanmıştır. Her bir kullanıcının verileri pozitif sınıf, diğer kullanıcıların verileri ise negatif sınıf olarak etiketlenmiştir. Veri dengesizliğini azaltmak amacıyla, negatif örnek sayısı, pozitif örnek sayısının belirli bir katı ile sınırlandırılmıştır. Model eğitimi için kullanılan RF yapısı, belirlenen hiperparametrelerle her kullanıcıya özel olarak optimize edilmiştir.

Test verisi üzerinde yapılan analizlerde, yanlış kabul oranı (FAR), doğru kabul oranı (TAR) ve eşit hata oranı (EER) gibi performans metrikleri kullanılarak

sonular raporlanmıřtır. Bayes optimizasyonu sonucunda elde edilen en iyi parametre kombinasyonlarının doėrulama performansı, RF modelinin kullanıcı bazlı doėrulama için uygun bir yöntem olduėunu göstermektedir.

4.3.6 CNN Modelleme ve Hiperparametre Optimizasyonu

Bu alıřmada, konvolüsyonel sinir aėı (CNN) tabanlı iki farklı model geliştirilmiřtir. CNN, katmanlar arasında öğrenilen filtreler aracılıėıyla giriş verilerindeki uzamsal ve zamansal iliřkileri öğrenmeye odaklanan derin öğrenme yöntemlerinden biridir. Bu yöntem, özellikle zaman serisi ve görüntü verilerinde yüksek performans göstermesiyle bilinmektedir. alıřmamızda, birinci modelde EKG sinyalleri doğrudan kullanılırken, ikinci modelde EKG sinyallerinden türetilen Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC) ile işlem yapılmıřtır.

4.3.6.1 1D-CNN Tabanlı Model

Bu yöntemde, EKG sinyalleri doğrudan giriş verisi olarak kullanılmıřtır. Eėitim, doėrulama ve test setleri, kiři bazlı veri bölme stratejisiyle oluřturulmuř ve negatif sınıf örnek sayısı, pozitif sınıfın beř katı olacak řekilde sınırlandırılmıřtır.

1D-CNN modeli, ardışık konvolüsyon katmanlarından oluřmaktadır. Her konvolüsyon katmanında filtreler yardımıyla sinyallerden öznitelikler çıkarılmıř, bu öznitelikler batch normalization, ReLU aktivasyonu ve max pooling işlemleriyle desteklenmiřtir. Modelin ıkış katmanında, iki sınıflı doėrulama işlemi için softmax aktivasyonu kullanılmıřtır. Hiperparametre optimizasyonunda, Yanlıř Kabul Oranı (FAR) minimize edilmiřtir. Optimize edilen parametreler řu řekilde belirlenmiřtir:

- **Filtre Sayısı (NumFilters):** [32, 128],
- **Çekirdek Boyutu (KernelSize):** [3, 7],
- **Konvolüsyon Katman Sayısı (NumLayers):** [2, 4],
- **Maksimum Epoch Sayısı (MaxEpochs):** [20, 50].

Model, test seti üzerinde Yanlıř Kabul Oranı (FAR), Doğru Kabul Oranı (TAR) ve Eřit Hata Oranı (EER) gibi metriklerle deėerlendirilmiř ve etkili sonular elde edilmiřtir.

4.3.6.2 MFCC ve GFCC Tabanlı 2D-CNN Modeli

Bu yöntemde, EKG sinyallerinden MFCC ve GFCC öznitelikleri çıkarılarak model girişine verilmiştir. Çıkarılan öznitelikler, zaman-frekans matrisleri olarak organize edilmiş ve iki kanalda birleştirilmiştir. Öznitelik çıkarımı sırasında kullanılan parametreler şu şekilde belirlenmiştir:

- **MFCC Parametreleri:** Pencere süresi 2 s, kayma süresi 0.5 s, bant sayısı 20, bant genişliği 1.
- **GFCC Parametreleri:** Pencere süresi 2 s, kayma süresi 0.5 s, bant sayısı 20, bant genişliği 0.1.

2D-CNN modeli, ardışık konvolüsyon katmanları ile yapılandırılmıştır. Model, batch normalization ve ReLU aktivasyonu ile desteklenen konvolüsyon katmanlarını, max pooling işlemleriyle birleştirerek öznitelikleri daha soyut bir temsil haline getirir. Global ortalama havuzlama yerine, öznitelikleri daha detaylı işleyebilmek amacıyla düzleştirme (flatten) ve tam bağlantılı (fully connected) katmanlar kullanılmıştır. Bu yapı, modelin derin öğrenme kapasitesini artırmaktadır. Hiperparametre optimizasyonunda Bayes optimizasyonu kullanılarak aşağıdaki parametreler optimize edilmiştir:

- **Filtre Sayısı (NumFilters):** [32, 128],
- **Çekirdek Boyutu (FilterSize):** [3, 5],
- **Konvolüsyon Katman Sayısı (NumConvs):** [2, 3],
- **Maksimum Epoch Sayısı (MaxEpochs):** [20, 50].

4.3.6.3 CNN Performans Değerlendirmesi

Her iki model, test verisi üzerinde Yanlış Kabul Oranı (FAR), Doğru Kabul Oranı (TAR) ve Eşit Hata Oranı (EER) metrikleri kullanılarak değerlendirilmiştir. 2D-CNN modeli, MFCC ve GFCC özniteliklerini entegre ederek zaman-frekans bilgisini daha etkili bir şekilde işlemiş; bu sayede 1D-CNN modeline kıyasla daha yüksek doğrulama başarısı elde edilmiştir.

Sonuç olarak, CNN tabanlı bu iki yöntem, EKG tabanlı kimlik doğrulama sistemlerinde güçlü performans sergilemiş ve özellikle MFCC ile GFCC özniteliklerinin entegrasyonu doğrulama başarı oranını önemli ölçüde artırmıştır. Bu bulgular, EKG sinyallerinin biyometrik kimlik doğrulama sistemlerinde etkin bir şekilde kullanılabileceğini ortaya koymaktadır.

4.3.7 RNN Modelleme ve Hiperparametre Optimizasyonu

Bu çalışmada, tekrarlayan sinir ağıları (RNN) tabanlı bir model kullanılarak kişi bazlı EKG doğrulama sistemi geliştirilmiştir. RNN, özellikle zaman serisi verilerindeki ardışık ilişkileri öğrenmek için güçlü bir derin öğrenme mimarisi olarak öne çıkmaktadır. Modelleme sürecinde, EKG sinyallerinden türetilen Mel Frekans Kepstral Katsayıları (MFCC) ve Gammatone Frekans Kepstral Katsayıları (GFCC) öznitelikleri çıkarılmış ve giriş verisi olarak kullanılmıştır. Kullanıcı bazlı bir yaklaşımla her katılımcıya özel modeller oluşturulmuş ve hiperparametre optimizasyonu Bayes optimizasyonu yöntemiyle gerçekleştirilmiştir.

Modelde giriş verisi olarak EKG sinyallerinden türetilen MFCC ve GFCC öznitelikleri kullanılmıştır. Öznitelik çıkarımı sırasında kullanılan parametreler aşağıdaki gibidir:

- **MFCC Parametreleri:** Pencere süresi: 2 s, kayma süresi: 0.5 s, bant sayısı: 20, bant genişliği: 1.
- **GFCC Parametreleri:** Pencere süresi: 2 s, kayma süresi: 0.5 s, bant sayısı: 30, bant genişliği: 0.1.

Elde edilen öznitelikler, her bir EKG sinyaline karşılık gelen zaman-frekans temsillerini oluşturmuş ve RNN modeli için giriş dizileri haline getirilmiştir. Eğitim, doğrulama ve test setleri, kişi bazlı veri bölme stratejisi ile oluşturulmuş ve tüm veri z-skor normalizasyonu yöntemiyle ölçeklendirilmiştir.

Bu çalışmada kullanılan çift yönlü Gated Tekrarlayan Birim (Bi-GRU; Bidirectional Gated Recurrent Unit) tabanlı RNN modeli şu bileşenlerden oluşmaktadır:

- **Birinci Bi-GRU Katmanı:** Gizli birim sayısı 50 ile 150 arasında optimize edilmiştir.
- **Dropout Katmanı:** İlk Bi-GRU katmanından sonra, 0 ile 0.3 arasında optimize edilen dropout oranı uygulanmıştır.
- **İkinci Bi-GRU Katmanı:** Gizli birim sayısı 50 ile 150 arasında optimize edilmiştir.
- **Dropout Katmanı:** İkinci Bi-GRU katmanından sonra tekrar dropout uygulanmıştır.
- **Tam Bağlantılı Katman (Fully Connected):** İki sınıflı doğrulama için iki nöron içerir.

- **Softmax Katmanı:** Çıkış katmanında, sınıf olasılıkları hesaplanmıştır.

Optimize edilen hiperparametreler şunlardır:

- **Birinci Bi-GRU Katmanındaki Gizli Birim Sayısı:** 50 ile 150 arasında.
- **İkinci Bi-GRU Katmanındaki Gizli Birim Sayısı:** 50 ile 150 arasında.
- **Öğrenme Oranı (Learning Rate):** 1×10^{-4} ile 1×10^{-3} arasında.
- **Maksimum Epoch Sayısı:** 50 ile 100 arasında.
- **Mini Batch Boyutu:** 16 ile 32 arasında.
- **Dropout Oranı:** 0 ile 0.3 arasında.

Çift yönlü GRU tabanlı RNN modeli, özellikle zaman serisi verilerinin öğrenilmesinde yüksek doğrulama başarısı göstermiştir. Bayes optimizasyonu ile belirlenen hiperparametreler, modelin genel doğrulama performansını artırmış ve EKG tabanlı biyometrik doğrulama sistemlerinde RNN'nin etkili bir yöntem olduğunu ortaya koymuştur.

4.3.8 Son Değerlendirme

Tüm bu yöntemler (SVM, MLP, RF, CNN ve RNN) ortak bir veri hazırlama ve öznitelik çıkarma çerçevesi üzerinde, farklı öğrenme mekanizmaları ve hiperparametre ayarları ile uygulanmıştır. Elde edilen sonuçlar, eşit hata oranı (EER), yanlış kabul oranı (FAR) ve doğru kabul oranı (TAR) gibi performans metrikleri kullanılarak değerlendirilmektedir. Özellikle Heartprint veri kümesi üzerinden gerçekleştirilen genellenebilirlik analizleri, önerilen yöntemlerin mobil biyometrik doğrulama sistemlerinde yüksek doğruluk ve güvenilirlik sağladığını göstermektedir. Bu kapsamlı değerlendirme, sistemin farklı koşullar altında nasıl performans gösterdiğini net bir şekilde ortaya koyarken, geliştirilen modellerin mobil ve giyilebilir cihazlarda pratik olarak uygulanabileceğini de kanıtlamaktadır.

4.4 Performans Değerlendirme Metrikleri

Biyometrik sistemlerin doğruluğu ve güvenilirliği, belirli performans metrikleri kullanılarak değerlendirilmektedir. Bu bölümde, biyometrik sistemlerde yaygın olarak kullanılan performans metrikleri ve bu metriklerin matematiksel formülleri ele alınmaktadır.

4.4.1 Doğru Kabul Oranı (TAR)

Doğru kabul oranı (TAR), biyometrik sistemin doğru bir şekilde tanıdığı gerçek pozitiflerin oranını ifade eder. Bu metrik, sistemin gerçek kullanıcıları tanıma başarısını gösterir:

$$TAR = \frac{\text{Doğru Kabul Edilen Doğru Pozitifler}}{\text{Toplam Doğru Pozitifler}} = \frac{TP}{TP + FN}. \quad (4.1)$$

Burada,

- TP (True Positives): Sistemin doğru bir şekilde kabul ettiği gerçek kullanıcılar.
- FN (False Negatives): Sistemin yanlış bir şekilde reddettiği gerçek kullanıcılar.

Yüksek bir TAR, sistemin gerçek kullanıcıları yüksek doğrulukla tanıdığını gösterir.

4.4.2 Yanlış Kabul Oranı (FAR)

Yanlış kabul oranı (FAR), biyometrik sistemin yanlış bir şekilde kabul ettiği yanlış pozitiflerin oranını ifade eder. Bu metrik, sistemin yetkisiz kişileri kabul etme eğilimini ortaya koyar:

$$FAR = \frac{\text{Yanlış Kabul Edilen Yanlış Pozitifler}}{\text{Toplam Yanlış Pozitifler}} = \frac{FP}{FP + TN}. \quad (4.2)$$

Burada,

- FP (False Positives): Sistemin yanlış bir şekilde kabul ettiği yetkisiz kullanıcılar.
- TN (True Negatives): Sistemin doğru bir şekilde reddettiği yetkisiz kullanıcılar.

Düşük bir FAR, sistemin yetkisiz kişileri düşük bir oranda kabul ettiğini gösterir.

4.4.3 Doğru Reddetme Oranı (TRR)

Doğru reddetme oranı (TRR), biyometrik sistemin doğru bir şekilde reddettiği gerçek negatiflerin oranını ifade eder. Bu metrik, sistemin yetkisiz kişileri tanımada

başarısını gösterir:

$$TRR = \frac{\text{Doğru Reddedilen Gerçek Negatifler}}{\text{Toplam Gerçek Negatifler}} = \frac{TN}{TN + FP}. \quad (4.3)$$

Yüksek bir TRR, sistemin yetkisiz kişileri yüksek doğrulukla reddettiğini gösterir.

4.4.4 Yanlış Reddetme Oranı (FRR)

Yanlış reddetme oranı (FRR), biyometrik sistemin yanlış bir şekilde reddettiği gerçek pozitiflerin oranını ifade eder. Bu metrik, sistemin gerçek kullanıcıları yanlış bir şekilde reddetme eğilimini gösterir:

$$FRR = \frac{\text{Yanlış Reddedilen Gerçek Pozitifler}}{\text{Toplam Gerçek Pozitifler}} = \frac{FN}{TP + FN}. \quad (4.4)$$

Düşük bir FRR, sistemin gerçek kullanıcıları yüksek doğrulukla kabul ettiğini gösterir.

4.4.5 Doğruluk (ACC)

Doğruluk (ACC), biyometrik sistemin genel performansını ölçer ve doğru tanımlanan toplam örneklerin oranını ifade eder. Bu metrik, sistemin hem gerçek kullanıcıları tanıma hem de yetkisiz kişileri reddetme başarısını gösterir:

$$ACC = \frac{\text{Doğru Tanımlanan Örnekler}}{\text{Toplam Örnekler}} = \frac{TP + TN}{TP + TN + FP + FN}. \quad (4.5)$$

Yüksek bir doğruluk, biyometrik sistemin genel performansının yüksek olduğunu gösterir.

Biyometrik sistemlerde performans değerlendirme metrikleri, sistemin doğruluğunu ve güvenilirliğini objektif bir şekilde ölçmek için kritik öneme sahiptir. Bu metrikler, sistemin hem gerçek kullanıcıları tanıma hem de yetkisiz kişileri reddetme başarısını değerlendirmek amacıyla kullanılır. Yüksek TAR, TRR ve ACC değerleri ile düşük FAR ve FRR değerleri, biyometrik sistemin güvenilir ve etkili olduğunu gösterir.

Eşit hata oranı (EER) ve alıcı işletim karakteristiği (ROC) eğrileri, biyometrik sistemlerin performansını değerlendirmede önemli diğer metriklerdir.

4.4.6 Eşit Hata Oranı (EER)

Eşit hata oranı (EER), biyometrik sistemin yanlış kabul oranı (FAR) ile yanlış reddetme oranının (FRR) eşit olduğu noktayı ifade eder. EER, bu iki hata türünün birbirine karşı hassasiyetini dengelemektedir. Biyometrik sistemin performansının yüksek olması için düşük bir EER değeri istenir. EER genellikle ROC eğrisi üzerinde FAR ve FRR oranlarının kesiştiği noktada bulunur.

4.4.7 Alıcı İşletim Karakteristiği (ROC)

ROC eğrisi, biyometrik sistemin farklı eşik değerlerine karşı yanlış kabul oranı (FAR) ile doğru kabul oranı (TAR) arasındaki ilişkiyi gösteren bir grafikdir. Bu eğri, biyometrik sistemin performansını görsel olarak değerlendirmede kullanılır. Eğer sistem, eğrinin sol üst köşesine daha yakınsa, o kadar iyi performans gösterir; bu durumda düşük FAR ve yüksek TAR elde edilir. Sistemin performansı, ROC eğrisinin altındaki alan (Area Under the Curve, AUC) ile de ölçülebilir. AUC değeri, ROC eğrisinin altında kalan alanın yüzdesini temsil eder; dolayısıyla daha yüksek bir AUC, sistemin daha iyi performans gösterdiğini ifade eder. AUC, ROC eğrisinin eşik değerlerinden bağımsız olarak genel performansı ölçmektedir.

5

DENEYSEL SONUÇLAR

Bu bölümde, önerilen EKG tabanlı biyometrik kimlik doğrulama sisteminin deneysel sonuçları sunulmaktadır. Öncelikle, i-vektör yaklaşımının yanı sıra SVM, MLP, RF, CNN ve RNN gibi alternatif yöntemler için kullanılan veri bölümlendirme stratejisi, ön işleme, öznitelik çıkarma ve modelleme adımları açıklanmıştır. ECG-ID ve BMD101 veritabanlarında elde edilen performans sonuçlarının yanı sıra, en kapsamlı karşılaştırma Heartprint veritabanı üzerinden yapılmıştır. Her veritabanı için ROC eğrileri, FAR, TAR ve ACC gibi metrikler analiz edilerek, sistemin başarımı farklı açılardan değerlendirilmiştir.

5.1 Veri Bölme Stratejisi

Her bir EKG veri kümesi, i-vektör yaklaşımının gereksinimlerini karşılamak ve veri sızıntısını önlemek amacıyla üç ayrı, örtüşmeyen alt kümeye ayrılmıştır.

- **Geliştirme Seti:** Global model parametrelerinin öğrenilmesi için kullanılır. Özellikle, evrensel arka plan modelinin (UBM) eğitimi ve toplam değişkenlik matrisinin (T) tahmini bu aşamada gerçekleştirilir. Böylece, tüm veri kümesinin genel niteliklerine dayalı sağlam bir temel oluşturulur.
- **Eğitim Seti:** Geliştirme setinden elde edilen global parametreler kullanılarak, her birey için özelleştirilmiş kullanıcı modelleri bu alt kümede eğitilir. Bu şekilde, her kullanıcının kendine özgü verisi kullanılarak kişiselleştirilmiş kimlik doğrulama modelleri oluşturulur.
- **Test Seti:** Modelin nihai performansını objektif bir şekilde ölçmek amacıyla, optimizasyon ve eğitim aşamalarında kullanılmayan verilerden oluşur. Test seti sayesinde, modelin genellenebilirliği ve gerçek hayata uyarlanabilirliği değerlendirilir.

Veri bölme işlemi, her deneyde rastgele olarak tekrarlanmış ve farklı dağılımlar

kullanılarak modellerin sonuçları üzerindeki olası rastlantısal etkiler en aza indirgenmeye çalışılmıştır. Bu yaklaşım, i-vektör yöntemi yanı sıra SVM, MLP, RF, CNN ve RNN gibi alternatif yöntemler için de aynı şekilde uygulanmıştır. Böylece, tüm yöntemler arasında adil ve tutarlı bir karşılaştırma olanağı sağlanmıştır.

Alternatif yöntemler (SVM, MLP, RF, CNN, RNN) için hiperparametre optimizasyonu geliştirme setinde gerçekleştirilmiş; en uygun kullanıcı bazlı parametreler, eğitim setinde model kurulumu için kullanılmıştır. Son olarak, her modelin gerçek performansı test seti üzerinde ölçülmüştür. Bu strateji, veri sızıntısını önler, verilerin dengeli kullanımını sağlar ve modellerin gerçek dünya performansını kapsamlı biçimde değerlendirir.

5.2 i-vektör Yönteminin Genel Adımları

Önerilen i-vektör yöntemi, tüm veri tabanlarında tutarlı bir biçimde uygulanmış ve aşağıdaki temel adımları izlemiştir:

1. Ön İşleme ve Öznitelik Çıkarma:

Her bir EKG sinyali, Bölüm 2 ve Bölüm 4'te ayrıntılı olarak açıklanan ön işleme adımlarından geçirilmiş ve sonrasında hem MFCC hem de GFCC öznitelikleri çıkarılmıştır.

2. GMM-EM ile UBM Eğitimi:

Geliştirme setinde, 8'den 256'ya kadar farklı karışım sayıları için Gauss karışım modelleri (GMM) eğitilerek evrensel arkaplan modeli (UBM) oluşturulmuştur.

3. Toplam Değişkenlik (T) Matrisi:

T matrisinin boyutları 100, 200, 300 ve 400 olarak denenmiş; daha küçük veri tabanlarında 100, Heartprint gibi daha geniş veri tabanlarında ise 200 boyutlu matris tercih edilmiştir.

4. i-vektör Çıkarımı ve LDA:

Baum-Welch istatistikleri yardımıyla i-vektörler elde edilmiş; sınıf ayrımını güçlendirmek amacıyla doğrusal diskriminant analizi (LDA) ile boyut indirgeme uygulanmıştır.

5. Puanlama:

Test aşamasında, elde edilen i-vektörler ile kayıtlı modeller arasındaki kosinüs benzerlik değerleri hesaplanmış ve 0.5–0.95 aralığında değişen eşik değerleri kullanılarak kabul/red kararları verilmiştir.

6. Tekrarlı Denemeler ve Nihai Ölçütler:

Her bir deney, farklı rastgele veri bölmeleriyle birden fazla kez (örneğin, 10 tekrar) yürütülmüştür. Elde edilen doğruluk (ACC), yanlış kabul oranı (FAR), doğru kabul oranı (TAR), yanlış reddetme oranı (FRR) ve eşit hata oranı (EER) ölçümlerinin ortalamaları alınarak, sistemin genellenebilir performansı daha sağlam bir biçimde tahmin edilmiştir.

7. Veri Toplama :

Tüm veri tabanlarında 3, 4 ve 5 saniyelik EKG kayıtları üzerinde deneyler gerçekleştirilmiştir. Bu sayede, yöntemin mobil veya kısıtlı kaynaklara sahip cihazlarda da uygulanabilirliği araştırılmıştır.

Bu yapı, i-vektör tabanlı yaklaşımın her veritabanında aynı iş akışıyla nasıl uygulandığını net bir şekilde göstermektedir. Her veritabanı için elde edilen deneysel sonuçlar ve performans analizleri, yukarıdaki adımlar üzerinden sunulmaktadır.

5.2.1 Veri Görselleştirme

i-vektör dağılımlarını elde etmek için kullanılan t-SNE (t-dağılımlı Stokastik Komşu Gömme) yöntemi, yüksek boyutlu verileri iki veya üç boyutlu düzlemde görselleştirmek amacıyla kullanılan doğrusal olmayan bir boyut indirgeme tekniğidir. Algoritmanın temel prensibi, yüksek boyutlu uzayda veri noktalarının birbirlerine olan benzerliklerini Gauss koşullu olasılıklarıyla ifade etmek ve düşük boyutlu uzayda ise ağır kuyruklu Student-t dağılımı kullanarak benzerlikleri modellemektir. Bu iki dağılım arasındaki fark, Kullback–Leibler sapması kullanılarak minimize edilir ve böylece noktaların düşük boyutlu uzaydaki konumları optimize edilir [96].

Yüksek boyuttaki yakın komşuluk yapısını düşük boyuta aktarırken ortaya çıkan "yığılma problemi" (crowding problem), Student-t dağılımının ağır kuyruklu yapısı sayesinde azaltılır; bu sayede, merkezden uzak veri noktalarına daha anlamlı olasılıklar atayarak, yüksek boyutta farklı olan noktaların düşük boyutta da ayrışması sağlanır. Bu nedenle t-SNE, biyomedikal sinyallerin (örneğin EKG) kümelenme ve sınıflandırma amaçlı görselleştirilmesinde sıklıkla tercih edilir.

Öte yandan, t-SNE çıktılarındaki eksenler doğrudan fiziksel veya matematiksel anlam taşımamakta; yalnızca veri noktaları arasındaki göreceli uzaklık ilişkilerini temsil etmektedir. Algoritmanın konveks olmayan optimizasyonu ve rastgele başlangıç koşullarına duyarlılığı nedeniyle, çıktı uzayının eksen yönelimleri ve

ölçekleri değişkenlik gösterebilir. Bu nedenle, t-SNE grafikleri yorumlanırken, eksenlerin mutlak değerleri yerine veri noktalarının göreceli konumları ve kümelerin yapısı esas alınmalıdır [97].

5.3 ECG-ID Veritabanı Performans Analizi

İlk olarak, bu çalışmada ECG-ID veritabanından seçilen 20 bireye ait 200 EKG kaydından (birey başına on kayıt) oluşturduğumuz veri seti kullanılmıştır. Her birey için 6 EKG kaydı geliştirme seti olarak seçilmiş ve UBM ile T matrisi hesaplanmıştır. Kalan 4 EKG kaydı ise sistemin performansını değerlendirmek için kullanılmıştır.


Değerlendirme sırasında, test edilecek bireyin kayıtlarının %75'i rastgele olarak eğitim verisi olarak seçilmiştir. Diğer bir deyişle, test edilecek bireye ait 3 EKG kaydı model oluşturmak için kullanılmış ve kalan kayıtlar (bu kayıtlardan biri test edilen bireye aittir) test verisi olarak değerlendirilmiştir.

ECG-ID veritabanı üzerinde gerçekleştirilen deneylerde, manuel optimizasyon sonucu aşağıdaki parametreler kullanılarak MFCC ve GFCC öznitelikleri çıkarılmıştır:


- **Pencere Boyutu:** 1 s,
- **Kayma:** 0.25 s,
- **MFCC/GFCC Bant Sayısı:** 20/20,
- **Frekans Aralığı:** 1–35 Hz,
- **Toplam Değişkenlik Boyutu:** 100,
- **Çalışma Sayısı (Tekrar Sayısı):** 10.

Şekil 5.1 ve Şekil 5.2, 20 bireyin sırasıyla geliştirme seti ile eğitim-test seti için MFCC ve GFCC uygulamalarına ait i-vektör dağılımlarını göstermektedir. Her birey farklı bir renk ile temsil edilmiş; her nokta ise tek bir i-vektöre karşılık gelmektedir. Grafiklerde, bireylere özgü kümelerin net biçimde ayrılabilirdiği gözlemlenmektedir.

Tablo 5.1, Tablo 5.2 ve Tablo 5.3 ile Tablo 5.4, Tablo 5.5 ve Tablo 5.6, farklı EKG kayıt sürelerinde elde edilen, sırasıyla en yüksek doğruluk (ACC) ve eşit hata oranı (EER) bazlı sonuçları temsil etmektedir.



Şekil 5.1 Geliştirme seti: 20 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (ECG-ID)



Şekil 5.2 Eğitim-test seti: 20 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (ECG-ID)


Tablo 5.1, Tablo 5.2 ve Tablo 5.3 incelendiğinde, en yüksek ACC ile en düşük FAR değerlerine ulaşmak için en uygun yapılandırmanın, hem MFCC hem de GFCC özniteliklerinin kullanıldığı, 5 saniyelik sinyal süresi ve 16 karışım sayısı olduğu görülmektedir. Bu durumu gösteren ROC eğrisi ve EER grafiği sırasıyla Şekil 5.3 ve Şekil 5.4'te verilmiştir.

Tablo 5.1 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (ECG-ID) - MFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	99.20	±0.062	94.00	±2.108	0.73	±0.072
	4	99.09	±0.075	93.00	±4.216	0.83	±0.125
	5	99.61	±0.068	77.50	±5.401	0.10	±0.035
16	3	98.94	±0.107	92.50	±2.635	0.98	±0.122
	4	99.03	±0.097	91.00	±4.595	0.87	±0.131
	5	99.28	±0.142	85.00	±5.774	0.53	±0.126
32	3	98.66	±0.093	84.00	±4.595	1.14	±0.094
	4	98.73	±0.093	80.50	±7.619	1.03	±0.132
	5	98.88	±0.102	57.50	±8.580	0.58	±0.068
64	3	98.81	±0.087	79.50	±5.986	0.93	±0.111
	4	98.96	±0.106	79.00	±6.146	0.78	±0.111
	5	99.45	±0.076	86.50	±5.798	0.38	±0.076
128	3	98.69	±0.071	77.50	±4.249	1.03	±0.055
	4	98.73	±0.115	71.50	±5.798	0.91	±0.122
	5	99.36	±0.074	84.00	±5.164	0.43	±0.034
256	3	98.46	±0.053	62.00	±7.888	1.06	±0.079
	4	98.64	±0.128	18.50	±8.182	0.30	±0.064
	5	99.03	±0.061	79.50	±4.972	0.72	±0.065

Tablo 5.2 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (ECG-ID) - GFCC


Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	99.06	± 0.134	72.00	± 7.888	0.58	± 0.127
	4	99.08	± 0.089	96.00	± 4.595	0.87	± 0.044
	5	99.33	± 0.092	92.50	± 5.401	0.58	± 0.068
16	3	99.05	± 0.126	80.00	± 5.270	0.70	± 0.124
	4	99.25	± 0.127	86.50	± 4.743	0.58	± 0.127
	5	99.12	± 0.116	73.00	± 5.375	0.53	± 0.109
32	3	99.04	± 0.051	86.00	± 3.944	0.79	± 0.000
	4	99.09	± 0.043	90.00	± 3.333	0.79	± 0.000
	5	99.10	± 0.048	90.50	± 3.689	0.79	± 0.000
64	3	99.11	± 0.119	82.50	± 6.346	0.67	± 0.107
	4	99.01	± 0.080	87.00	± 6.325	0.83	± 0.077
	5	99.06	± 0.147	72.00	± 10.328	0.58	± 0.127
128	3	98.95	± 0.096	73.50	± 5.798	0.72	± 0.122
	4	99.03	± 0.097	81.00	± 5.676	0.74	± 0.115
	5	99.08	± 0.133	67.50	± 8.250	0.51	± 0.108
256	3	98.94	± 0.102	78.00	± 7.888	0.79	± 0.000
	4	99.01	± 0.156	69.50	± 8.317	0.61	± 0.111
	5	99.15	± 0.112	87.00	± 5.869	0.69	± 0.071



Şekil 5.3 En yüksek doğruluğa dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 16, ECG-ID)

Tablo 5.3 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (ECG-ID) - MFCC+GFCC

Karışım Sayısı	s	ACC(%)	TAR(%)	FAR(%)
8	3	99.02 ±0.078	86.50 ±4.116	0.82 ±0.071
	4	99.15 ±0.037	94.50 ±2.838	0.79 ±0.000
	5	99.12 ±0.055	92.00 ±4.216	0.79 ±0.000
16	3	99.17 ±0.101	74.50 ±6.433	0.51 ±0.076
	4	99.17 ±0.118	82.00 ±5.375	0.61 ±0.111
	5	99.76 ±0.062	81.50 ±4.743	0.00 ±0.000
32	3	99.21 ±0.108	85.50 ±4.463	0.61 ±0.067
	4	99.27 ±0.110	94.50 ±4.575	0.67 ±0.121
	5	99.49 ±0.104	85.00 ±5.774	0.32 ±0.065
64	3	99.24 ±0.130	88.00 ±5.375	0.61 ±0.103
	4	99.07 ±0.075	88.50 ±5.798	0.79 ±0.000
	5	99.47 ±0.094	83.00 ±5.375	0.31 ±0.062
128	3	99.11 ±0.115	70.00 ±7.454	0.51 ±0.108
	4	99.08 ±0.143	77.00 ±7.528	0.63 ±0.104
	5	99.55 ±0.057	82.00 ±4.830	0.22 ±0.044
256	3	99.05 ±0.137	57.00 ±6.749	0.40 ±0.095
	4	98.93 ±0.082	81.50 ±7.472	0.84 ±0.111
	5	99.40 ±0.114	72.00 ±7.888	0.24 ±0.034



Şekil 5.4 Kimlik doğrulama eşğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 16, ECG-ID)


Benzer şekilde, Tablo 5.4, Tablo 5.5 ve Tablo 5.6 incelendiğinde, EER açısından en uygun çalışma noktalarının belirlendiği görülmektedir. En yüksek ACC ve en düşük FAR değerlerine ulaşmak için, hem MFCC hem de GFCC özniteliklerinin kullanıldığı, 5 saniyelik sinyal süresi ve 32 karışım sayısı en uygun yapılandırmayı sağlamaktadır. Bu durumu gösteren ROC eğrisi ve EER grafiği ise sırasıyla Şekil 5.5 ve Şekil 5.6’da sunulmuştur.

Tablo 5.4 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (ECG-ID) - MFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	98.55	±0.119	100.00	±0.000	1.47	±0.121
	4	96.66	±0.221	97.00	±2.582	3.34	±0.219
	5	95.02	±0.247	94.50	±2.838	4.97	±0.256
16	3	98.19	±0.105	100.00	±0.000	1.83	±0.107
	4	93.37	±0.275	94.50	±2.838	6.64	±0.267
	5	96.75	±0.256	97.50	±2.635	3.26	±0.276
32	3	96.82	±0.120	96.50	±4.116	3.17	±0.161
	4	92.29	±0.376	93.00	±4.216	7.72	±0.413
	5	97.44	±0.217	97.50	±2.635	2.56	±0.227
64	3	96.59	±0.098	98.50	±2.415	3.43	±0.107
	4	91.53	±0.427	89.00	±4.595	8.43	±0.470
	5	93.27	±0.184	93.00	±4.216	6.72	±0.164
128	3	96.66	±0.187	97.00	±2.582	3.35	±0.204
	4	91.66	±0.210	92.00	±4.830	8.35	±0.249
	5	96.74	±0.175	97.00	±2.582	3.26	±0.181
256	3	94.94	±0.173	90.50	±4.972	5.01	±0.182
	4	95.95	±0.231	96.50	±3.375	4.05	±0.224
	5	94.69	±0.091	94.00	±4.595	5.30	±0.104

Tablo 5.5 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (ECG-ID) - GFCC


Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	96.16	± 0.211	97.50	± 2.635	3.86	± 0.199
	4	97.50	± 0.160	97.50	± 2.635	2.50	± 0.167
	5	97.65	± 0.152	97.50	± 2.635	2.35	± 0.139
16	3	95.08	± 0.205	96.00	± 3.162	4.93	± 0.187
	4	95.30	± 0.179	95.50	± 4.378	4.70	± 0.202
	5	95.03	± 0.182	95.50	± 3.689	4.98	± 0.186
32	3	93.74	± 0.424	94.00	± 2.108	6.26	± 0.447
	4	97.06	± 0.155	97.00	± 3.496	2.93	± 0.162
	5	97.01	± 0.236	98.50	± 2.415	3.01	± 0.255
64	3	95.44	± 0.191	95.00	± 4.082	4.56	± 0.213
	4	98.54	± 0.063	98.50	± 2.415	1.46	± 0.081
	5	98.68	± 0.140	98.50	± 2.415	1.32	± 0.140
128	3	94.29	± 0.303	95.50	± 3.689	5.73	± 0.324
	4	95.47	± 0.227	97.00	± 2.582	4.55	± 0.229
	5	94.87	± 0.184	95.50	± 3.689	5.14	± 0.202
256	3	93.52	± 0.267	93.00	± 5.375	6.47	± 0.306
	4	94.58	± 0.182	93.50	± 3.375	5.40	± 0.192
	5	97.62	± 0.179	97.00	± 4.216	2.38	± 0.144



Şekil 5.5 EER noktasına dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 32, ECG-ID)

Tablo 5.6 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (ECG-ID) - MFCC+GFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	97.81	± 0.080	99.50	± 1.581	2.22	± 0.070
	4	98.60	± 0.070	99.50	± 1.581	1.41	± 0.064
	5	98.94	± 0.088	99.50	± 1.581	1.07	± 0.082
16	3	97.00	± 0.320	93.50	± 3.375	2.95	± 0.303
	4	94.10	± 0.250	94.50	± 2.838	5.91	± 0.232
	5	96.01	± 0.282	92.00	± 2.582	3.93	± 0.272
32	3	96.19	± 0.320	94.50	± 3.375	3.79	± 0.303
	4	99.24	± 0.250	97.00	± 2.838	0.73	± 0.232
	5	99.38	± 0.063	97.50	± 2.635	0.59	± 0.054
64	3	97.56	± 0.144	98.50	± 2.415	2.45	± 0.134
	4	98.53	± 0.034	98.00	± 2.582	1.46	± 0.042
	5	98.14	± 0.283	93.00	± 4.216	1.80	± 0.299
128	3	95.49	± 0.383	97.00	± 2.582	4.53	± 0.406
	4	97.55	± 0.118	97.00	± 2.582	2.45	± 0.102
	5	96.10	± 0.127	94.50	± 2.838	3.87	± 0.135
256	3	95.75	± 0.239	96.00	± 3.944	4.25	± 0.283
	4	94.84	± 0.357	93.00	± 4.216	5.14	± 0.410
	5	94.66	± 0.270	94.50	± 2.838	5.34	± 0.290



Şekil 5.6 Kimlik doğrulama eşğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 32, ECG-ID)

5.4 BMD101 Veritabanı Performans Analizi

Bu çalışmada, gönüllü katılımcılardan kişisel olarak topladığımız özel BMD101 veri kümesi üzerinde önerilen yöntem değerlendirilmiştir. BMD101 sensörü, mobil cihazlara entegre edilebilir yapısıyla gerçek dünya uygulanabilirliğini test etme amacımıza doğrudan katkı sağlasa da, bu çalışmada gerçek zamanlı testler gerçekleştirilmemiştir. Söz konusu veri kümesi, iki farklı senaryoda (BMD-1 ve BMD-2) yürütülen deneyleri desteklemiş; hem önerilen metodolojinin doğruluğunu hem de analiz bileşenlerinin, gerçekçi mobil uygulama koşullarına benzer ortamlarda etkinliğini değerlendirmemize imkân tanımıştır.


BMD101 veritabanı için manuel optimizasyonla elde edilen parametreler aşağıda listelenmiştir:

- **Pencere Boyutu:** 1 s
- **Kayma:** 0.25 s
- **MFCC/GFCC Bant Sayısı:** 20/16
- **Frekans Aralığı:** 1–35 Hz
- **Toplam Değişkenlik Boyutu:** 100
- **Çalışma Sayısı (Tekrar):** 10


Bu yaklaşım, BMD101 sensörünün taşınabilir cihazlara entegrasyon potansiyelini yansıtmakta ve deneysel sonuçların pratik kullanım senaryolarına ışık tutabilecek şekilde analiz edilmesine imkân tanımaktadır.

Çalışmanın ilk aşamasında oluşturulan veritabanında, farklı sayıda EKG kaydına sahip 22 birey bulunmaktadır. Geliştirme setinde, veritabanındaki bu 22 bireyin toplamda 170 EKG verisi kullanılarak UBM ve T matrisi hesaplanmaktadır. Bu hesaplamalar, sistemin genel yapısını ve performans parametrelerini belirlemede temel bir işlev görmektedir. Geriye, 10 EKG kaydı bulunan 6 birey kalmaktadır. Bu 6 bireyin EKG kayıtlarının %60'ı rastgele seçilerek bireye özgü modeller oluşturulmakta ve kalan %40'ı test seti olarak ayrılmaktadır. Bu ayrım, sistemimizin gerçek dünya koşullarında ne kadar etkili çalışabileceğini ölçme fırsatı sunmaktadır.

Şekil 5.7 ve Şekil 5.8, 22 bireyin sırasıyla geliştirme seti ve eğitim-test seti için MFCC ve GFCC uygulamalarının vektör dağılımlarını göstermektedir. Tablo 5.7,



Şekil 5.7 Geliştirme seti: 22 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (BMD-1)



Şekil 5.8 Eğitim-test seti: 6 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (BMD-1)

Tablo 5.8 ve Tablo 5.9, en yüksek doğruluk değerine; Tablo 5.10, Tablo 5.11 ve Tablo 5.12, eşit hata oranına (EER) dayalı sonuçları göstermektedir.


Tablo 5.7, Tablo 5.8 ve Tablo 5.9 incelendiğinde, en yüksek ACC ve en düşük FAR elde etmek için uygun yapılandırmanın, hem MFCC hem de GFCC özniteliklerinin, 4 saniyelik sinyal süresi ve 64 karışım sayısı ile kullanılmasıyla sağlandığı açıktır. ROC eğrisi ve EER grafiği sırasıyla Şekil 5.9 ve Şekil 5.10'da gösterilmektedir.

Tablo 5.7 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-1) - MFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	96.54	±0.478	67.92	±3.953	1.17	±0.360
	4	97.90	±0.455	71.67	±6.149	0.00	±0.000
	5	97.87	±0.270	71.67	±3.287	0.03	±0.105
16	3	96.51	±0.505	63.75	±5.215	0.87	±0.358
	4	96.17	±0.417	71.67	±6.455	1.87	±0.391
	5	95.62	±0.767	55.00	±8.517	1.13	±0.422
32	3	96.88	±0.608	74.58	±4.143	1.33	±0.588
	4	97.44	±0.438	65.42	±5.909	0.00	±0.000
	5	98.24	±0.545	87.50	±5.893	0.90	±0.316
64	3	97.22	±0.252	62.50	±3.402	0.00	±0.000
	4	97.10	±0.686	78.33	±3.829	1.40	±0.562
	5	97.35	±0.332	74.58	±4.585	0.83	±0.283
128	3	95.40	±0.513	42.92	±6.227	0.40	±0.263
	4	96.98	±0.631	65.00	±7.658	0.47	±0.172
	5	97.35	±0.362	74.17	±3.829	0.80	±0.172
256	3	94.69	±0.664	56.25	±4.910	2.23	±0.446
	4	95.93	±0.540	50.42	±6.038	0.43	±0.225
	5	95.59	±0.484	71.25	±4.585	2.47	±0.322

Tablo 5.8 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-1) - GFCC


Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	97.25	± 0.572	86.25	± 3.953	1.87	± 0.549
	4	98.36	± 0.358	83.75	± 4.988	0.47	± 0.233
	5	97.78	± 1.207	95.83	± 5.556	2.07	± 1.359
16	3	96.70	± 0.798	85.42	± 6.875	2.40	± 0.516
	4	97.75	± 0.293	87.50	± 5.556	1.43	± 0.274
	5	97.87	± 0.447	76.67	± 7.136	0.43	± 0.225
32	3	96.11	± 0.508	52.08	± 6.588	0.37	± 0.246
	4	97.53	± 0.784	69.58	± 10.025	0.23	± 0.274
	5	98.02	± 0.911	73.33	± 12.298	0.00	± 0.000
64	3	94.44	± 0.965	48.75	± 7.620	1.90	± 0.630
	4	95.65	± 0.397	56.67	± 5.270	1.23	± 0.353
	5	95.62	± 0.767	81.67	± 4.891	3.27	± 0.699
128	3	95.68	± 0.682	46.67	± 6.747	0.40	± 0.263
	4	96.76	± 0.671	56.25	± 9.054	0.00	± 0.000
	5	96.08	± 0.583	58.33	± 7.607	0.90	± 0.316
256	3	93.83	± 0.525	37.50	± 5.893	1.67	± 0.314
	4	93.40	± 0.417	15.83	± 4.730	0.40	± 0.263
	5	92.93	± 0.492	22.50	± 5.958	1.43	± 0.446



Şekil 5.9 En yüksek doğruluğa dayalı ROC Eğrisi (Sinyal süresi: 4 s, Karışım sayısı: 64, BMD-1)

Tablo 5.9 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-1) - MFCC+GFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	95.15	± 0.583	48.75	± 3.953	1.13	± 0.422
	4	95.96	± 1.083	79.58	± 6.350	2.73	± 1.098
	5	95.31	± 1.189	82.50	± 5.827	3.67	± 1.227
16	3	95.46	± 1.365	90.83	± 5.827	4.17	± 1.509
	4	96.73	± 1.110	97.92	± 2.946	3.37	± 1.356
	5	96.36	± 1.283	92.50	± 3.829	3.33	± 1.499
32	3	97.59	± 0.455	77.92	± 6.227	0.83	± 0.236
	4	98.27	± 0.260	82.50	± 3.287	0.47	± 0.233
	5	96.30	± 1.209	86.67	± 4.730	2.93	± 1.205
64	3	97.93	± 0.583	87.50	± 4.392	1.23	± 0.417
	4	98.43	± 0.397	78.75	± 5.361	0.00	± 0.000
	5	97.90	± 0.379	81.67	± 4.025	0.80	± 0.281
128	3	97.62	± 0.370	73.75	± 4.831	0.47	± 0.281
	4	97.84	± 0.356	80.00	± 4.730	0.73	± 0.306
	5	97.35	± 0.838	88.33	± 5.122	1.93	± 0.843
256	3	94.29	± 0.509	51.25	± 6.818	2.27	± 0.625
	4	96.79	± 0.441	62.92	± 6.646	0.50	± 0.176
	5	95.22	± 0.826	61.25	± 4.831	2.07	± 0.872



Şekil 5.10 Kimlik doğrulama eşliğine ilişkin FAR ve FRR performansları (Sinyal süresi: 4 s, Karışım sayısı: 64, BMD-1)

Benzer şekilde, Tablo 5.10, Tablo 5.11 ve Tablo 5.12 incelendiğinde, EER açısından en uygun çalışma noktalarının belirlendiği görülmektedir. En yüksek ACC ve en düşük FAR elde etmek için, GFCC özniteliklerinin 5 saniyelik sinyal süresi ve 8 karışım sayısı ile kullanılması uygun yapılandırmayı sağlamaktadır. ROC eğrisi ve EER grafiği ise Şekil 5.11 ve Şekil 5.12’de gösterilmektedir.

Tablo 5.10 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-1) - MFCC


Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	87.75	±0.743	87.08	±4.585	12.20	±0.849
	4	90.65	±0.824	91.67	±3.928	9.43	±0.771
	5	94.94	±1.359	92.50	±2.635	4.87	±1.390
16	3	87.99	±0.762	92.08	±5.361	12.33	±0.816
	4	91.70	±1.177	90.42	±4.414	8.20	±1.209
	5	88.43	±0.957	92.08	±5.710	11.87	±1.113
32	3	88.98	±1.574	91.25	±4.988	11.20	±1.657
	4	93.30	±0.977	91.25	±4.585	6.53	±0.971
	5	94.44	±0.651	95.42	±4.988	5.63	±0.949
64	3	85.28	±1.470	85.42	±5.642	14.73	±1.570
	4	90.19	±1.572	90.83	±3.287	9.87	±1.541
	5	93.43	±1.350	92.50	±4.303	6.50	±1.326
128	3	82.13	±1.737	86.25	±2.812	18.20	±1.827
	4	88.21	±1.424	87.50	±6.211	11.73	±1.530
	5	89.23	±1.264	91.67	±5.556	10.97	±1.418
256	3	85.46	±1.313	84.58	±3.953	14.47	±1.492
	4	89.32	±1.100	87.50	±3.402	10.53	±1.239
	5	91.57	±0.618	90.42	±5.909	8.33	±0.667

Tablo 5.11 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-1) - GFCC


Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	94.26	±1.660	92.92	±3.953	5.63	±1.829
	4	96.48	±1.311	95.83	±3.402	3.47	±1.239
	5	97.78	±1.207	95.83	±5.556	2.07	±1.359
16	3	91.79	±1.236	93.75	±6.875	8.37	±1.212
	4	96.57	±0.608	96.25	±3.648	3.40	±0.584
	5	96.60	±0.436	97.92	±2.196	3.50	±0.451
32	3	91.48	±2.149	90.00	±4.891	8.40	±2.148
	4	94.94	±0.945	93.33	±4.479	4.93	±1.131
	5	95.77	±1.294	94.17	±4.025	4.10	±1.516
64	3	88.27	±1.268	91.67	±5.893	12.00	±1.133
	4	91.20	±0.745	89.58	±2.946	8.67	±0.875
	5	92.07	±1.040	90.00	±4.025	7.77	±1.248
128	3	83.40	±1.371	89.17	±5.958	17.07	±1.447
	4	88.80	±0.943	87.50	±4.392	11.10	±1.218
	5	86.94	±2.314	90.00	±4.025	13.30	±2.570
256	3	81.94	±1.887	83.75	±5.361	18.20	±2.207
	4	82.50	±1.484	78.75	±6.038	17.20	±1.687
	5	78.12	±1.724	80.83	±5.625	22.10	±1.833

Tablo 5.12 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-1) - MFCC+GFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	91.20	±0.888	91.25	±4.143	8.80	±0.892
	4	95.19	±0.786	91.25	±3.648	4.50	±0.878
	5	94.66	±0.836	92.08	±3.074	5.13	±0.892
16	3	92.96	±0.858	92.92	±4.414	7.03	±0.962
	4	96.73	±1.110	97.92	±2.946	3.37	±1.356
	5	95.37	±0.965	95.83	±3.402	4.67	±1.227
32	3	90.86	±1.010	90.42	±2.812	9.10	±1.144
	4	95.12	±0.560	95.42	±3.074	4.90	±0.649
	5	94.29	±0.912	96.67	±3.829	5.90	±1.055
64	3	92.72	±0.851	93.75	±3.541	7.37	±0.808
	4	96.51	±0.461	96.25	±3.648	3.47	±0.613
	5	96.94	±1.002	95.00	±3.829	2.90	±1.187
128	3	93.70	±0.786	97.08	±3.953	6.57	±0.704
	4	95.19	±0.441	95.83	±2.778	4.87	±0.502
	5	96.02	±1.221	95.83	±2.778	3.97	±1.319
256	3	85.71	±1.350	80.83	±8.146	13.90	±1.633
	4	93.55	±0.981	89.58	±8.391	6.13	±1.135
	5	89.35	±1.582	92.92	±3.430	10.93	±1.684




Şekil 5.11 EER noktasına dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 8, BMD-1)



Şekil 5.12 Kimlik doğrulama eşğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 8, BMD-1)


İkinci senaryoda, veritabanındaki 23 bireyin 187 EKG verisi kullanılarak UBM ve T matrisi hesaplanmaktadır. Ardından, toplamda 100 veri içeren 10 bireyden alınan her biri 10 EKG kaydı ile sistemin performansı test edilmektedir. Test edilecek birey için verilerin %60'ı eğitim verisi olarak rastgele seçilmekte, kalanı ise test verisi olarak kullanılmaktadır.

Şekil 5.13 ve Şekil 5.14, 23 bireyin sırasıyla geliştirme seti ve eğitim-test seti için MFCC ve GFCC uygulamalarının vektör dağılımlarını göstermektedir. Tablo 5.13, Tablo 5.14 ve Tablo 5.15, en yüksek doğruluk değerlerini; diğer yandan Tablo 5.16, Tablo 5.17 ve Tablo 5.18 ise eşit hata oranı (EER) göz önünde bulundurularak oluşturulan sonuçları göstermektedir.



Şekil 5.13 Geliştirme seti: 23 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (BMD-2)

Tablo 5.13, Tablo 5.14 ve Tablo 5.15 incelendiğinde, en yüksek ACC elde etmek ve FAR değerini en aza indirmek için uygun yapılandırmanın, 5 saniyelik sinyal süresi ve 16 karışım sayısı ile GFCC özniteliklerinin kullanılmasını içerdiği ortaya çıkmaktadır. ROC eğrisi ve EER grafiği sırasıyla Şekil 5.15 ve Şekil 5.16'da gösterilmektedir.




Şekil 5.14 Eğitim-test seti: 10 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (BMD-2)

Tablo 5.13 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-2) - MFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	96.66	±0.182	27.75	±3.426	0.28	±0.108
	4	97.47	±0.316	55.25	±4.158	0.66	±0.279
	5	97.55	±0.270	54.00	±4.743	0.51	±0.159
16	3	96.77	±0.214	27.00	±4.684	0.13	±0.102
	4	97.73	±0.101	57.00	±3.873	0.46	±0.110
	5	97.41	±0.159	59.00	±3.575	0.88	±0.133
32	3	96.82	±0.117	35.25	±2.486	0.44	±0.091
	4	97.01	±0.162	37.75	±2.993	0.36	±0.137
	5	97.83	±0.280	73.50	±4.116	1.09	±0.195
64	3	96.52	±0.449	45.50	±5.986	1.21	±0.294
	4	97.02	±0.395	52.75	±6.396	1.01	±0.243
	5	97.70	±0.202	60.00	±2.887	0.62	±0.159
128	3	96.19	±0.212	22.25	±3.217	0.52	±0.139
	4	96.73	±0.279	35.00	±4.410	0.52	±0.166
	5	97.09	±0.262	37.00	±3.873	0.24	±0.126
256	3	96.62	±0.172	35.75	±2.899	0.68	±0.133
	4	96.62	±0.239	42.25	±4.632	0.97	±0.223
	5	96.90	±0.406	45.50	±7.246	0.81	±0.174

Tablo 5.14 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-2) - GFCC


Karışım Sayısı	s	ACC(%)	TAR(%)	FAR(%)
8	3	97.07 ±0.326	45.25 ±6.816	0.62 ±0.217
	4	97.45 ±0.301	60.25 ±3.810	0.90 ±0.192
	5	96.79 ±0.172	43.50 ±3.764	0.84 ±0.107
16	3	97.20 ±0.266	41.00 ±5.676	0.30 ±0.105
	4	97.94 ±0.208	62.25 ±3.810	0.48 ±0.129
	5	98.52 ±0.137	65.25 ±3.217	0.00 ±0.000
32	3	97.62 ±0.152	56.25 ±3.773	0.54 ±0.110
	4	97.20 ±0.293	62.50 ±5.137	1.26 ±0.223
	5	97.99 ±0.215	66.00 ±5.297	0.59 ±0.229
64	3	96.90 ±0.106	30.00 ±3.118	0.12 ±0.063
	4	97.18 ±0.267	50.00 ±4.714	0.72 ±0.218
	5	97.87 ±0.256	58.50 ±3.944	0.38 ±0.175
128	3	96.85 ±0.225	41.50 ±3.375	0.69 ±0.172
	4	97.09 ±0.289	43.50 ±4.595	0.53 ±0.164
	5	97.13 ±0.313	54.25 ±4.091	0.97 ±0.246
256	3	96.19 ±0.212	10.50 ±4.972	0.00 ±0.000
	4	96.90 ±0.272	45.00 ±4.249	0.79 ±0.243
	5	96.34 ±0.208	29.00 ±3.944	0.67 ±0.117



Şekil 5.15 En yüksek doğruluğa dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 8, BMD-2)

Tablo 5.15 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (BMD-2) - MFCC+GFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	98.40	± 0.235	69.25	± 5.007	0.30	± 0.129
	4	98.41	± 0.177	62.75	± 4.158	0.00	± 0.000
	5	98.35	± 0.202	64.75	± 4.480	0.16	± 0.094
16	3	97.67	± 0.277	53.00	± 4.684	0.34	± 0.110
	4	98.12	± 0.213	62.50	± 4.249	0.30	± 0.091
	5	98.39	± 0.177	65.50	± 4.684	0.14	± 0.075
32	3	96.88	± 0.392	49.25	± 5.780	1.00	± 0.203
	4	97.93	± 0.293	57.00	± 5.503	0.26	± 0.139
	5	97.72	± 0.266	56.00	± 5.676	0.42	± 0.146
64	3	97.07	± 0.226	31.25	± 5.303	0.00	± 0.000
	4	97.70	± 0.280	68.75	± 5.035	1.01	± 0.212
	5	97.98	± 0.365	75.75	± 5.534	1.03	± 0.174
128	3	97.15	± 0.206	42.25	± 4.923	0.41	± 0.118
	4	97.84	± 0.213	52.25	± 4.322	0.13	± 0.088
	5	97.84	± 0.181	59.25	± 4.866	0.44	± 0.117
256	3	96.59	± 0.345	44.75	± 4.923	1.11	± 0.240
	4	97.83	± 0.196	55.50	± 3.689	0.29	± 0.078
	5	98.03	± 0.289	60.25	± 6.816	0.29	± 0.078



Şekil 5.16 Kimlik doğrulama eşliğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 8, BMD-2)

Tablo 5.16 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-2) - MFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	89.55	± 0.732	87.00	± 3.689	10.33	± 0.764
	4	92.21	± 0.513	90.50	± 3.873	7.71	± 0.540
	5	91.62	± 0.361	91.75	± 3.736	8.39	± 0.324
16	3	85.52	± 1.034	87.00	± 3.689	14.54	± 1.038
	4	87.46	± 0.986	88.00	± 3.689	12.57	± 0.979
	5	90.52	± 0.817	89.25	± 4.572	9.42	± 0.806
32	3	89.43	± 0.704	87.00	± 2.838	10.47	± 0.789
	4	91.81	± 0.476	92.00	± 1.972	8.20	± 0.554
	5	91.63	± 0.497	91.75	± 1.687	8.38	± 0.532
64	3	84.90	± 0.575	87.75	± 4.480	15.22	± 0.595
	4	90.13	± 0.684	86.50	± 5.426	9.71	± 0.640
	5	90.53	± 0.440	88.50	± 3.764	9.38	± 0.436
128	3	89.70	± 0.648	88.50	± 4.441	10.24	± 0.599
	4	90.62	± 0.704	92.75	± 3.623	9.48	± 0.644
	5	89.87	± 0.486	92.75	± 3.623	10.26	± 0.527
256	3	88.32	± 1.045	85.00	± 2.887	11.53	± 1.085
	4	88.12	± 0.999	92.00	± 3.073	12.06	± 1.052
	5	88.54	± 1.057	92.00	± 3.689	11.61	± 1.090


Tablo 5.16, Tablo 5.17 ve Tablo 5.18, eşit hata oranı (EER) için en uygun çalışma noktalarını göstermektedir. En yüksek ACC elde etmek ve FAR değerini en aza indirmek için uygun yapılandırmanın, hem MFCC hem de GFCC öznitelikleri kullanılarak 4 saniyelik sinyal süresi ve 8 karışım sayısı ile sağlandığı görülmektedir. ROC eğrisi ve EER grafiği sırasıyla Şekil 5.17 ve Şekil 5.18’de gösterilmektedir.

Tablo 5.17 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-2) - GFCC


Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	88.82	±0.881	90.25	±4.480	11.24	±0.744
	4	89.79	±0.514	92.75	±3.623	10.34	±0.493
	5	91.74	±0.577	93.00	±2.297	8.31	±0.641
16	3	86.29	±0.885	83.00	±3.689	13.57	±0.965
	4	87.63	±0.667	90.25	±4.480	12.49	±0.609
	5	88.51	±0.806	92.50	±3.727	11.67	±0.806
32	3	87.53	±0.597	87.25	±2.189	12.46	±0.630
	4	87.81	±0.598	89.25	±3.129	12.26	±0.658
	5	91.36	±0.762	89.25	±5.007	8.54	±0.814
64	3	83.80	±1.572	85.50	±3.689	16.28	±1.757
	4	87.81	±1.129	92.50	±2.887	12.40	±1.190
	5	92.90	±0.512	91.75	±3.344	7.04	±0.497
128	3	84.95	±0.795	81.25	±6.264	14.89	±0.913
	4	88.23	±0.720	86.25	±4.751	11.68	±0.743
	5	88.37	±0.715	89.00	±3.375	11.66	±0.729
256	3	84.01	±1.207	80.50	±3.291	15.83	±1.241
	4	85.18	±0.932	79.50	±3.873	14.57	±0.988
	5	85.48	±0.743	87.25	±3.426	14.60	±0.752

Tablo 5.18 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (BMD-2) - MFCC+GFCC

Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	88.79	±0.862	92.25	±2.486	11.37	±0.861
	4	94.43	±0.414	89.75	±3.810	5.37	±0.549
	5	93.63	±0.559	92.25	±3.217	6.31	±0.615
16	3	86.91	±0.716	90.25	±5.197	13.23	±0.690
	4	91.38	±0.723	90.50	±4.534	8.58	±0.755
	5	92.59	±0.484	92.75	±3.426	7.42	±0.494
32	3	91.07	±0.495	91.75	±2.648	8.96	±0.535
	4	92.29	±0.306	95.75	±3.344	7.87	±0.339
	5	94.15	±0.410	91.75	±4.091	5.74	±0.457
64	3	89.50	±0.675	86.50	±2.934	10.37	±0.667
	4	93.89	±0.577	90.25	±4.480	5.94	±0.577
	5	93.62	±0.620	91.25	±5.035	6.28	±0.572
128	3	88.38	±0.506	91.00	±2.415	11.73	±0.565
	4	89.51	±0.405	93.25	±2.372	10.66	±0.427
	5	92.64	±0.511	89.25	±3.736	7.21	±0.481
256	3	85.94	±0.663	87.25	±2.751	14.12	±0.723
	4	88.79	±0.671	92.25	±3.623	11.37	±0.646
	5	91.90	±0.643	91.50	±3.375	8.08	±0.673



Şekil 5.17 EER noktasına dayalı ROC Eğrisi (Sinyal süresi: 4 s, Karışım sayısı: 8, BMD-2)



Şekil 5.18 Kimlik doğrulama eşğine ilişkin FAR ve FRR performansları (Sinyal süresi: 4 s, Karışım sayısı: 8, BMD-2)

5.5 Heartprint Veritabanı Performans Analizi

Heartprint veritabanı, bu araştırmanın son aşamasında kullanılan geniş ve kapsamlı bir biyometrik veri setidir. Bu veritabanı, 199 bireye ait toplam 1539 EKG kaydını içermektedir. Yüksek katılımcı sayısı ve çeşitliliği sayesinde, sistem performansı güvenilir bir şekilde ölçülebilmektedir.


Veri kümesinde katılımcıların kayıt sayılarındaki farklılıklar göz önünde bulundurularak, katılımcılar iki ana gruba ayrılmıştır. Kaydı en az 10 olan 108 katılımcı “yeterli veri” kategorisinde, kaydı 10’dan az olan 91 katılımcı ise “verisi kısıtlı” kategorisinde ele alınmıştır. Yeterli veriye sahip her bir katılımcının 6 EKG kaydı geliştirme (optimizasyon) verisi olarak ayrılmış, kalan kayıtlar ise %80 eğitim ve %20 test oranında bölünmüştür. Verisi kısıtlı olan 91 katılımcıya ait tüm kayıtlar doğrudan test verisine dahil edilmiştir. Bu strateji, modellerin genellenebilirliğini kapsamlı bir şekilde değerlendirmeyi ve sistem tasarımında dengeli veri kullanımını sağlamayı amaçlamaktadır.

Heartprint veritabanı için i-vektör yöntemi, aşağıdaki parametreler manuel olarak optimize edilerek kullanılmıştır:


- **Pencere boyutu:** 0.5 s
- **Kayma:** 0.1 s
- **MFCC/GFCC bant sayısı:** 24/40
- **Frekans aralığı:** 1–35 Hz
- **Toplam değişkenlik boyutu:** 200
- **Çalışma sayısı (tekrar):** 4

Şekil 5.19 ve Şekil 5.20, Heartprint veritabanı için sırasıyla geliştirme seti ve eğitim-test seti üzerinde uygulanan MFCC ve GFCC özniteliklerinin i-vektör dağılımlarını göstermektedir. Tablo 5.19, Tablo 5.20 ve Tablo 5.21 en yüksek doğruluk değerlerini, Tablo 5.22, Tablo 5.23 ve Tablo 5.24 ise eşit hata oranını (EER) göz önünde bulunduran sonuçları ortaya koymaktadır.

Tablo 5.19’den Tablo 5.24’e kadar yer alan tüm tablolar, detaylı olarak incelendiğinde, en yüksek ACC elde etmek ve FAR değerini en aza indirmek için en uygun yapılandırmanın iki durum içinde, 5 saniyelik bir sinyal süresi ve karışım sayısı 32 olarak uygulanmasıyla hem MFCC hem de GFCC özniteliklerinin



Şekil 5.19 Geliştirme seti: 108 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (Heartprint)



Şekil 5.20 Eğitim-test seti: 199 bireyin i-vektörlerinin 2 boyutlu t-SNE projeksiyonu (Heartprint)

Tablo 5.19 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (Heartprint) - MFCC

MFCC							
Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	99.80	±0.005	11.46	±2.216	0.00	±0.001
	4	99.80	±0.003	12.96	±2.105	0.00	±0.002
	5	99.80	±0.004	14.12	±2.088	0.00	±0.001
16	3	99.79	±0.012	24.88	±4.266	0.03	±0.005
	4	99.81	±0.002	31.48	±2.420	0.03	±0.006
	5	99.82	±0.009	32.64	±2.891	0.03	±0.005
32	3	99.80	±0.008	24.88	±2.311	0.03	±0.002
	4	99.82	±0.007	29.63	±0.845	0.02	±0.005
	5	99.83	±0.007	30.44	±1.576	0.02	±0.003
64	3	99.79	±0.004	9.26	±2.299	0.00	±0.000
	4	99.81	±0.013	29.63	±3.317	0.03	±0.005
	5	99.82	±0.010	31.02	±1.134	0.03	±0.006
128	3	99.80	±0.005	20.37	±1.134	0.02	±0.004
	4	99.81	±0.010	24.19	±3.056	0.02	±0.003
	5	99.82	±0.004	27.08	±0.802	0.02	±0.002
256	3	99.79	±0.005	12.04	±1.813	0.01	±0.002
	4	99.79	±0.002	16.44	±0.964	0.02	±0.003
	5	99.81	±0.005	19.91	±0.378	0.01	±0.003

Tablo 5.20 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (Heartprint) - GFCC

GFCC							
Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	99.79	±0.005	8.45	±2.342	0.00	±0.001
	4	99.79	±0.005	9.03	±2.686	0.00	±0.001
	5	99.80	±0.005	20.83	±1.464	0.02	±0.002
16	3	99.81	±0.005	21.76	±2.299	0.02	±0.002
	4	99.81	±0.006	23.61	±2.803	0.02	±0.001
	5	99.83	±0.003	28.47	±1.626	0.01	±0.002
32	3	99.80	±0.007	15.51	±2.841	0.01	±0.003
	4	99.81	±0.009	33.68	±2.683	0.04	±0.003
	5	99.83	±0.009	38.43	±3.295	0.03	±0.003
64	3	99.80	±0.004	16.90	±1.712	0.00	±0.003
	4	99.81	±0.004	19.10	±1.788	0.00	±0.001
	5	99.81	±0.014	38.66	±3.433	0.05	±0.007
128	3	99.80	±0.004	14.47	±2.049	0.01	±0.002
	4	99.81	±0.004	28.94	±1.225	0.03	±0.003
	5	99.81	±0.006	29.17	±1.000	0.03	±0.005
256	3	99.79	±0.002	9.14	±1.433	0.00	±0.001
	4	99.79	±0.005	11.34	±2.345	0.00	±0.000
	5	99.80	±0.005	11.92	±2.402	0.00	±0.001

Tablo 5.21 Sinyal edinim süresine göre elde edilen en yüksek doğruluk değerlerinde sistem performansı (Heartprint) - MFCC+GFCC

MFCC+GFCC							
Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	99.80	±0.004	23.96	±2.216	0.03	±0.003
	4	98.41	±0.177	29.40	±1.439	0.03	±0.004
	5	99.82	±0.002	32.64	±1.712	0.03	±0.006
16	3	99.80	±0.007	13.43	±3.185	0.00	±0.001
	4	99.80	±0.005	14.70	±3.171	0.00	±0.002
	5	99.80	±0.004	17.13	±1.773	0.01	±0.001
32	3	99.81	±0.004	15.86	±1.866	0.00	±0.001
	4	99.82	±0.005	37.85	±1.530	0.04	±0.005
	5	99.84	±0.007	42.82	±2.891	0.04	±0.001
64	3	99.81	±0.007	16.09	±3.410	0.00	±0.000
	4	99.82	±0.007	20.83	±3.423	0.00	±0.001
	5	99.83	±0.004	46.18	±2.248	0.05	±0.004
128	3	99.79	±0.007	11.46	±2.117	0.00	±0.002
	4	99.80	±0.006	15.28	±2.536	0.00	±0.001
	5	99.81	±0.003	19.79	±1.027	0.01	±0.004
256	3	99.79	±0.008	11.81	±3.219	0.01	±0.002
	4	99.80	±0.004	16.09	±2.216	0.01	±0.003
	5	99.81	±0.004	20.60	±2.088	0.01	±0.003

Tablo 5.22 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (Heartprint) - MFCC


MFCC							
Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	89.04	±0.182	88.77	±3.989	10.96	±0.186
	4	89.52	±0.114	90.39	±3.730	10.49	±0.122
	5	90.14	±0.150	91.90	±2.088	9.87	±0.153
16	3	90.09	±0.149	88.43	±3.163	9.91	±0.151
	4	90.60	±0.149	91.90	±2.284	9.41	±0.153
	5	91.05	±0.121	93.40	±2.342	8.96	±0.124
32	3	89.93	±0.060	90.97	±3.059	10.08	±0.065
	4	90.64	±0.068	92.71	±2.402	9.36	±0.070
	5	94.32	±0.069	91.32	±3.613	5.68	±0.073
64	3	88.79	±0.156	91.20	±1.927	11.22	±0.159
	4	89.81	±0.070	92.13	±1.773	10.19	±0.074
	5	93.93	±0.085	91.55	±3.033	6.06	±0.089
128	3	90.05	±0.054	92.82	±3.636	9.96	±0.060
	4	91.03	±0.089	93.17	±5.284	8.97	±0.097
	5	91.54	±0.059	94.56	±4.316	8.47	±0.059
256	3	88.46	±0.180	86.23	±3.238	11.54	±0.177
	4	89.03	±0.125	87.38	±3.368	10.97	±0.127
	5	89.12	±0.123	90.51	±3.733	10.89	±0.127

Tablo 5.23 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (Heartprint) - GFCC


GFCC							
Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	89.94	±0.039	88.89	±3.799	10.06	±0.041
	4	90.58	±0.040	91.67	±3.185	9.43	±0.043
	5	91.00	±0.106	92.94	±3.410	9.01	±0.111
16	3	88.64	±0.151	88.77	±2.787	11.37	±0.154
	4	89.28	±0.108	91.44	±1.712	10.73	±0.109
	5	89.82	±0.126	92.01	±1.027	10.19	±0.126
32	3	89.49	±0.083	87.62	±3.431	10.51	±0.089
	4	90.14	±0.073	92.36	±2.220	9.86	±0.074
	5	94.00	±0.084	91.09	±3.009	6.00	±0.088
64	3	88.93	±0.044	89.58	±1.389	11.08	±0.043
	4	89.76	±0.066	92.13	±1.648	10.25	±0.069
	5	90.34	±0.142	93.29	±0.964	9.67	±0.140
128	3	87.46	±0.105	90.51	±2.345	12.55	±0.104
	4	93.03	±0.036	89.93	±2.961	6.97	±0.035
	5	93.39	±0.039	88.89	±3.230	6.60	±0.032
256	3	91.74	±0.098	71.53	±3.675	8.22	±0.099
	4	91.69	±0.082	73.38	±2.522	8.28	±0.085
	5	91.79	±0.111	80.32	±2.018	8.19	±0.114

Tablo 5.24 Sinyal edinim süresine göre elde edilen eşit hata oranı (EER) değerlerinde sistem performansı (Heartprint) - MFCC+GFCC

MFCC+GFCC							
Karışım Sayısı	s	ACC(%)		TAR(%)		FAR(%)	
8	3	88.13	±0.097	91.55	±1.866	11.88	±0.100
	4	88.60	±0.117	91.09	±2.490	11.40	±0.121
	5	92.42	±0.103	91.32	±2.372	7.58	±0.107
16	3	87.89	±0.128	88.43	±1.927	12.11	±0.131
	4	91.65	±0.061	88.08	±2.709	8.35	±0.062
	5	91.89	±0.034	88.66	±2.988	8.10	±0.037
32	3	90.38	±0.100	92.25	±4.095	9.63	±0.103
	4	94.30	±0.046	92.82	±2.739	5.70	±0.051
	5	94.39	±0.069	93.17	±4.095	5.61	±0.077
64	3	92.35	±0.071	91.09	±2.656	7.65	±0.076
	4	92.67	±0.073	93.06	±1.927	7.33	±0.073
	5	92.79	±0.040	94.79	±0.876	7.22	±0.042
128	3	89.69	±0.038	85.88	±3.263	10.30	±0.035
	4	89.55	±0.091	87.04	±2.105	10.44	±0.094
	5	89.26	±0.076	91.55	±2.937	10.75	±0.074
256	3	88.72	±0.151	81.25	±3.790	11.27	±0.154
	4	87.93	±0.146	85.07	±1.433	12.07	±0.146
	5	87.47	±0.205	90.51	±2.791	12.55	±0.200



Şekil 5.21 En yüksek doğruluğa ve EER noktasına dayalı ROC Eğrisi (Sinyal süresi: 5 s, Karışım sayısı: 32, Heartprint)



Şekil 5.22 Kimlik doğrulama eşğine ilişkin FAR ve FRR performansları (Sinyal süresi: 5 s, Karışım sayısı: 32, Heartprint)

kullanılmasını içerdği ortaya çıkmaktadır. ROC eğrisi ve EER grafiği Şekil 5.21 ve Şekil 5.22’de gösterilmektedir.

Bu çeşitlendirilmiş eğitim ve test seti yapısı, geniş ve değişken bir veritabanında algoritmanın performansını ölçerek biyometrik doğrulama sistemlerinin güvenilirliğini ve etkinliğini artırmada kritik bir rol oynamaktadır. Özellikle, insan biyometrisinin değişkenliği ve çevresel faktörler göz önüne alındığında, bu deney sistemimizin farklı senaryolara nasıl tepki verdiğini anlamamıza olanak tanımaktadır. Elde edilen bilgiler, sistemin daha da optimize edilmesi ve daha geniş ölçekte uygulanabilirliğinin artırılması açısından değerlidir.

Ayrıca, bu çalışma, EKG verilerine dayalı biyometrik kimlik doğrulama sistemlerinin geliştirilmesi ve optimize edilmesi için önemli veriler sunmakta; kısa süreli kayıtların bile yüksek doğruluk oranlarıyla kullanılabileceğini göstermektedir.

5.6 Sinyal Süresine Dayalı Performans Değerlendirmesi

Heartprint veritabanında, EER noktasına dayalı olarak kayıt ve doğrulama sinyal sürelerinin performans analizi yapılmıştır. Tablo 5.24’de sunulan sonuçlara göre, en yüksek doğruluk ve en düşük yanlış kabul oranını elde etmek için en uygun yapılandırma noktası referans alınarak, sinyal edinim sürelerinin değiştirilmesiyle sistem performansı değerlendirilmiştir.

Tablo 5.25 Heartprint veritabanındaki 199 bireyin önerilen yöntemin farklı kayıt ve doğrulama sürelerinde performans analizi (MFCC ve GFCC özniteliklerinin birleştirilmesi ve karışım sayısı: 32)

Kayıt Uzunluğu (s)	Doğrulama Uzunluğu (s)	ACC (%)	TAR (%)	FAR (%)
15	15	95.94	96.30	4.06
15	10	95.74	97.72	4.27
15	5	95.58	94.56	4.42
10	10	95.32	97.69	4.68
10	5	95.14	94.79	4.86
5	5	94.39	93.17	5.61

Tablo 5.25’da gösterildiği üzere, kayıt ve doğrulama sürelerinin arttıkça sistemin doğruluğu artmakta ve yanlış kabul oranı azalmaktadır. Ancak, pratik uygulamalar ve mobil cihazlarda kullanıcı konforu ile işlem süresi gibi faktörler göz önünde bulundurulduğunda, 5 saniyelik sürelerin kabul edilebilir olduğu sonucuna varılmıştır.

Bu bölümde, Heartprint veritabanı yapılandırması detaylı olarak yeniden ele

Tablo 5.26 Heartprint veritabanındaki 108 bireyin önerilen yöntemin farklı kayıt ve doğrulama sürelerinde performans analizi (MFCC ve GFCC özniteliklerinin birleştirilmesi ve karışım sayısı: 32)

Kayıt Uzunluğu (s)	Doğrulama Uzunluğu (s)	ACC (%)	TAR (%)	FAR (%)
15	15	96.16	96.30	3.84
15	10	95.92	97.22	4.10
15	5	95.69	94.56	4.31
10	10	95.47	97.69	4.56
10	5	95.21	94.79	4.79
5	5	94.36	93.17	5.64

alınmakta ve sistem performansının kapsamlı bir değerlendirmesi sunulmaktadır. Veritabanı, 199 bireye ait toplam 1539 EKG kaydını içermekte olup, bu bireylerden 108'inin 10 ve üzeri kayda sahip olması nedeniyle bu 108 birey hem geliştirme hem de eğitim setlerinde kullanılmıştır. Kalan 91 bireyin tüm EKG kayıtları ise test seti olarak değerlendirilmiştir. Bu yapılandırma, çalışmanın kapsamını ve performans ölçümünde kullanılan yöntemlerin ayrıntılarını net bir şekilde ortaya koymaktadır.

Tablo 5.25 ve Tablo 5.26, önerilen yöntemin farklı veri bölme stratejileri altında, 199 ve 108 birey üzerinden elde edilen performans sonuçlarını karşılaştırmalı olarak sunmaktadır. Her iki tabloda da, MFCC ve GFCC özniteliklerinin birleştirilmesi ile 32 karışım sayısı kullanılarak, farklı kayıt ve doğrulama sürelerindeki sistem performansı detaylı olarak incelenmiştir.

Özellikle Tablo 5.25, geliştirme ve eğitim setlerinde yer alan 108 bireyin yanı sıra, test aşamasına eklenen 91 yeni birey üzerinden elde edilen sonuçları ortaya koyarak, sistemin daha önce karşılaşılmamış bireylerle performansını değerlendirmemize olanak tanımaktadır. Tablo 5.26 ise, sadece geliştirme ve eğitim setlerinde kullanılan 108 birey üzerinden test yapılan sonuçları sunmaktadır.

Yapılan karşılaştırmalar, 108 bireylik küçük veri seti ile 199 bireylik genişletilmiş veri seti arasında, özellikle yanlış kabul oranı (FAR) üzerinde küçük ancak anlamlı bir farklılık olduğunu göstermektedir. Bu durum, sisteme daha önce tanımadığı 91 yeni bireyin eklenmesinden kaynaklanmakta olup, genişletilmiş veri setinin sistemin genelleştirme yeteneğini yansıttığını göstermektedir. Bu bulgular, biyometrik doğrulama sistemlerinin yeni bireylerle etkileşimini ve genelleştirme kabiliyetini daha iyi anlamamıza olanak sağlamaktadır.

5.7 Alternatif Yaklaşımların Performans Analizi

Kimlik doğrulama sistemlerinde, EKG (Elektrokardiyogram) verilerinin benzersiz biyometrik öznelikler sunması, önemli bir potansiyel sağlamaktadır. Bu çalışmada, EKG verilerine dayalı olarak geliştirdiğimiz yöntemin performansını, diğer makine öğrenmesi ve derin öğrenme teknikleriyle karşılaştırdık. Destek Vektör Makinesi (SVM), Çok Katmanlı Algılayıcı (MLP), Rastgele Orman (RF), Bir Boyutlu Konvolüsyonel Sinir Ağları (CNN 1D), İki Boyutlu Konvolüsyonel Sinir Ağları (CNN 2D) ve Tekrarlayan Sinir Ağları (RNN) gibi yöntemler, Heartprint veritabanı üzerinde test edilmiştir. Bu karşılaştırmada, doğruluk (ACC), gerçek kabul oranı (TAR), yanlış kabul oranı (FAR) ve eşit hata oranı (EER) gibi kritik metrikler temel alınmıştır. Tablo 5.27, elde edilen sonuçları özetlemektedir.

Tablo 5.27 Heartprint veritabanı üzerinde EKG tabanlı kimlik doğrulama yöntemlerinin performansları

Yöntem	ACC(%)		TAR(%)		FAR(%)		EER(%)	
Önerilen Yön.	94.39	±0.07	93.17	±4.09	5.61	±0.08	6.22	±2.01
SVM	90.80	±1.00	94.80	±1.90	9.20	±1.50	7.00	±1.70
MLP	72.17	±2.56	75.28	±4.57	27.84	±2.55	26.28	±3.53
RF	88.50	±1.20	91.70	±2.50	11.50	±1.20	9.90	±1.70
CNN 1D	84.57	±1.17	84.29	±1.31	15.43	±1.17	15.56	±1.23
CNN 2D	87.56	±0.02	87.76	±0.02	12.43	±0.02	12.33	±0.02
RNN	86.43	±0.81	86.41	±0.82	13.57	±0.81	13.58	±0.82

Tablo 5.27’de özetlenen sonuçlar, önerilen yöntemin Heartprint veritabanı üzerinde %94.39 doğruluk (ACC) ve %93.17 gerçek kabul oranı (TAR) ile öne çıktığını göstermektedir. Ayrıca, %5.61 yanlış kabul oranı (FAR) ve %6.22 eşit hata oranı (EER) elde edilmiştir; bu da yöntemin hem yüksek doğruluk hem de düşük hata oranları açısından son derece güvenilir olduğunu ortaya koymaktadır.

Karşılaştırma sonuçları, SVM, MLP, RF, 1D-CNN, 2D-CNN ve RNN gibi alternatif yaklaşımların performanslarıyla birlikte sunulmuştur. Önerilen yöntemin ACC ve TAR değerleri, diğer yöntemlere kıyasla daha üstün performans sergilemekte; özellikle MLP ve CNN 1D gibi yöntemlerde gözlemlenen daha yüksek hata oranları, önerilen yaklaşımın avantajını vurgulamaktadır.

Bu veriler, önerilen yöntemin yalnızca yüksek doğruluk sağlamakla kalmayıp, aynı zamanda sistemin genel hata oranlarını düşürmede de etkili olduğunu göstermektedir. Elde edilen bulgular, i-vektör tabanlı öznelik çıkarım yöntemlerinin EKG tabanlı biyometrik kimlik doğrulamada sağlam bir temel oluşturduğunu ve gelecekteki çalışmalar için, bu yöntemlerin diğer yaklaşımlarla entegrasyonunun sistem performansını daha da artırabileceğini ortaya koymaktadır.

5.8 Benzerlik Ölçütleri Performans Analizi

Bu çalışmada, i-vektörlerin farklı benzerlik ölçütleriyle karşılaştırılması yoluyla, kimlik doğrulama sistemine etkileri incelenmiştir. Kosinüs mesafesi, Öklid mesafesi, Manhattan mesafesi, Pearson korelasyonu ve dinamik zaman esnetme (DTW) kullanılarak hesaplanan benzerlik skorlarının, doğruluk (ACC), yanlış kabul oranı (FAR) ve yanlış reddetme oranı (FRR) metrikleri üzerindeki etkileri Tablo 5.28’de sunulmuştur.

Tablo 5.28 i-vektörlerin farklı benzerlik ölçütleriyle karşılaştırılması

Benzerlik Ölçütü	ACC	FAR	FRR
Kosinüs Mesafesi	94.39	5.61	6.83
Öklid Mesafesi	96.21	3.78	10.30
Manhattan Mesafesi	94.65	5.34	11.57
Pearson Korelasyonu	93.10	6.90	7.64
DTW (Dynamic Time Warping)	97.99	1.92	43.75

Bu sonuçlar, farklı benzerlik ölçütlerinin i-vektör karşılaştırmalarında farklı performans sergilediğini göstermekte ve doğrulama sisteminin gereksinimlerine uygun ölçütün dikkatle seçilmesinin önemini ortaya koymaktadır.

5.9 Sonuçlar

Tablo 5.29 ve Tablo 5.30’ de tüm deneylerin sırasıyla en yüksek doğruluk ve eşit hata oranı (EER) için en uygun çalışma noktalarını özetlenmektedir.

Tablo 5.29 En yüksek doğruluğa dayalı önerilen yöntemin özeti

öznitelik	Veritabanı Birey Sayısı	Test Birey Sayısı	FAR (%)	FRR (%)	ACC (%)	Süre (s)
MFCC	22	6	0.90	12.50	98.24	5
GFCC	22	6	0.00	26.67	98.02	5
MFCC+GFCC	22	6	0.00	21.25	98.43	4
MFCC	23	10	1.09	26.50	97.83	5
GFCC	23	10	0.00	34.75	98.52	5
MFCC+GFCC	23	10	0.00	37.25	98.41	4
MFCC	20	20	0.10	22.50	99.61	5
GFCC	20	20	0.58	7.50	99.33	5
MFCC+GFCC	20	20	0.00	18.50	99.76	5
MFCC	199	199	0.02	69.56	99.83	5
GFCC	199	199	0.03	61.57	99.83	5
MFCC+GFCC	199	199	0.04	57.18	99.84	5

Deneysel bulgular, MFCC ve GFCC özniteliklerinin tek başına kullanıldığında tatmin edici sonuçlar sağladığını göstermiştir. Ancak, bu özniteliklerin EKG

Tablo 5.30 Eşit hata oranı (EER) için optimal çalışma noktasına dayalı önerilen yöntemin özeti

öznitelik	Veritabanı Birey Sayısı	Test Birey Sayısı	FAR (%)	FRR (%)	ACC (%)	Süre (s)
MFCC	22	6	4.87	7.50	94.94	5
GFCC	22	6	2.07	4.17	97.78	5
MFCC+GFCC	22	6	2.9	5	96.94	5
MFCC	23	10	7.71	9.50	92.21	4
GFCC	23	10	6.32	9.50	93.54	4
MFCC+GFCC	23	10	5.37	10.25	94.43	4
MFCC	20	20	1.47	0	98.55	3
GFCC	20	20	1.32	1.50	98.68	5
MFCC+GFCC	20	20	0.59	2.50	99.38	5
MFCC	199	199	5.68	8.68	94.32	5
GFCC	199	199	6.0	8.91	94.0	5
MFCC+GFCC	199	199	5.61	6.83	94.39	5

doğrulama sürecinde entegre edilmesi, doğruluk oranını (ACC) artırırken, yanlış kabul oranını (FAR) düşürmede daha etkili olmuştur.

Elde edilen sonuçlar, mobil platformlarda EKG doğrulaması üzerine yapılan son çalışmalarla karşılaştırılmış ve parmak tabanlı EKG doğrulaması ile ilgili bulgular Tablo 5.31’de özetlenmektedir.

Tablo 5.31 Mobil platformlarda parmak üzerinden elde edilen EKG algoritmalarının karşılaştırılması

Algoritma	Birey Sayısı	FAR (%)	FRR (%)	Doğrulama Uzunluğu (s)	Kayıt Uzunluğu (s)
Artega-Falconi ve diğ. [2]	10	1.41	18	4	30
Chen ve Chen [34]	10	2.7	3	≤3	N/A
Önerilen Alg. (Lab.)	6	2.07	4.17	5	5
Önerilen Alg. (Lab.)	10	5.37	10.25	4	4
Önerilen Alg.	20	0.59	2.5	5	5
Önerilen Alg.	199	5.61	6.83	5	5
Kang ve diğ. [36]	28	5.2	1.9	5	30
Chen ve Chen [34]	30	6	6	3	N/A
Artega-Falconi ve diğ. [2]	73	1.29	15.07	4	30

Önerilen yöntem, literatürdeki çalışmalara kıyasla mobil platformlarda güvenliği artıran ve kullanıcı dostu bir deneyim sunan umut verici sonuçlar ortaya koymaktadır. Düşük FAR, yetkisiz erişimlerin minimize edilmesiyle mobil güvenliği artırırken; düşük FRR, gerçek kullanıcıların hatalı reddedilme olasılığını azaltarak memnuniyeti desteklemektedir. Ayrıca, yöntemin 4-5 saniyelik doğrulama ve kayıt süreleri, mobil cihazlar için ideal bir performans sağlamaktadır. Bu bulgular, sistemimizin mobil biyometrik doğrulamada güvenilir ve kullanıcı odaklı bir çözüm sunabileceğini göstermektedir.

Bu çalışma, EKG biyometrik kimlik doğrulama algoritmasının mobil güvenlik uygulamalarında kullanılabilirliğini ve etkinliğini kapsamlı bir şekilde değerlendirmiştir. Hem ECG-ID hem de Heartprint veritabanlarının yanı sıra, özgün ölçümler alınarak oluşturulan veri setleri üzerinde gerçekleştirilen deneyler, önerilen yöntemin yüksek başarıyla uygulanabileceğini göstermektedir. Yüksek doğruluk oranları ve kısa sinyal edinme süreleri, bu yöntemin mobil cihazlarda etkili bir çözüm sunduğunu açıkça ortaya koymaktadır. Bu bulgular, yöntemin mobil güvenlik alanında önemli bir yenilik ve pratik bir çözüm olarak öne çıkabileceğini vurgulamaktadır.

Deney sonuçları, önerilen EKG biyometrik kimlik doğrulama algoritmasının güvenilirliğini ve etkinliğini güçlü bir şekilde desteklemektedir. ECG-ID ve Heartprint veritabanları üzerindeki testlerin yanı sıra, özel veri setiyle elde edilen sonuçlar, algoritmanın farklı veri kaynaklarında tutarlı ve yüksek performans sergilediğini doğrulamaktadır. Bu durum, yöntemin sadece teorik olarak değil, pratik uygulamalarda da başarılı olduğunu kanıtlamaktadır.

Çalışmada kullanılan makine öğrenmesi ve derin öğrenme yöntemlerinin karşılaştırmalı analizi, her bir yöntemin güçlü ve zayıf yönlerini ortaya koymuştur. Önerilen yöntemin bazı metriklerde diğer yöntemlere göre daha iyi sonuçlar verdiği gözlemlense de, performans farklarının sınırlı olduğu durumlar da dikkat çekmiştir. Bu durum, EKG tabanlı kimlik doğrulama süreçlerinde daha karmaşık öznelilik çıkarım tekniklerinin kullanımına duyulan ihtiyacı göstermektedir. Özellikle, i-vektör tabanlı yaklaşımların derin öğrenme modelleriyle sentezlenmesi, hem sınıflandırma hem de genel doğruluk performansını artırma potansiyeline sahiptir.

Çalışma sürecinde, parametre optimizasyonu ve yeterli EKG kaydını içeren veri setlerine erişim en büyük engeller arasında yer almıştır. Kişisel EKG kayıtlarının yeterliliği ve parametrelerin manuel ayarlanması, çalışmanın ilerlemesindeki önemli zorluklardı. Bu durum, algoritmaların otomatik hiperparametre

optimizasyonu ve daha geniş, çeşitlilik arz eden veri setlerinin kullanılmasını gerektirmektedir. Bu doğrultuda, gelecekte yapılacak çalışmalar bu sınırlamaların üstesinden gelmeye odaklanabilir.

Önerilen yöntemin kısa sinyal edinme süreleri, mobil cihazlarda hafızada minimal yer kaplamasını sağlar. Bu özellik, kullanıcıların cihazlarına hızlı ve kolay erişim sağlamalarına olanak tanıyarak günlük kullanımda büyük pratiklik sunar ve kullanıcı deneyimini olumlu yönde etkiler. Ayrıca, mobil cihazlarda saldırı sayısının genellikle sınırlı olması, veri setinin boyutunu makul seviyelerde tutmayı mümkün kılmaktadır. Ancak, algoritmanın daha geniş ve çeşitli veri setleri üzerinde test edilmesi, genelleştirilebilirlik ve güvenilirlik açısından önemlidir. Aynı zamanda, i-vektörler gibi ileri düzey tekniklerin mevcut yöntemlerle birleştirilmesi, yalnızca doğruluk oranlarının artırılmasına değil, aynı zamanda hata oranlarının da daha düşük seviyelere çekilmesine yardımcı olabilir. Böyle bir entegrasyon, EKG tabanlı kimlik doğrulamanın hem teorik hem de pratik performansını daha ileriye taşıyabilir.

Bu geliştirmeler, EKG biyometrik kimlik doğrulama teknolojisinin mobil güvenlik alanında daha da etkili hale gelmesine katkı sağlayacaktır. Gelecekte, algoritmanın geliştirilmesi ve daha geniş çapta benimsenmesiyle mobil cihazların güvenlik seviyelerinin artması ve kullanıcı deneyiminin iyileştirilmesi mümkün olacaktır. Bu çalışma, EKG biyometrik kimlik doğrulamanın mobil güvenlikte önemli bir yenilik ve pratik çözüm sunabileceğini net bir şekilde ortaya koymaktadır.

- [1] A. V. Lyamin E. N. Cherepovskaya, “An evaluation of biometric identification approach on low-frequency ECG signal,” *2017 IEEE 15th International Symposium on Applied Machine Intelligence and Informatics (SAMI)*, IEEE, 2017, ss. 000 137–000 142.
- [2] J. Arteaga-Falconi, H. Al Osman A. El Saddik, “ECG Authentication for Mobile Devices,” *IEEE Transactions on Instrumentation and Measurement*, c. 65, ss. 1–10, Ara. 2015. doi: 10.1109/TIM.2015.2503863.
- [3] E. Çelik, “Görüntü işlemeye dayalı avuç içi izinin yapay sinir ağı ile tanınması,” dok. tezi, Marmara Üniversitesi (Turkey), 2011.
- [4] N. Firtina, N. Firtına, G. Silahtaroglu G. Silahtaroglu, “Kulaktan Kişi ve Kimlik Tespiti için Örnek Bir Uygulama,” *Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, c. 7, no. 2, ss. 21–46, 2014.
- [5] Ü. Kaçar, “ARM Tabanlı Gömülü Sistemlerde Kulak Tanıma Sisteminin Gerçeklenmesi,” dok. tezi, Fen Bilimleri Enstitüsü, 2013.
- [6] B. Ergen A. Çalışkan, “Biyometrik Sistemler ve El Tabanlı Biyometrik Tanıma Karakteristikleri,” *6th International Advanced Technologies Symposium (IATS’11)*, 2011, ss. 16–18.
- [7] J. Unar, W. C. Seng A. Abbasi, “A review of biometric technology along with trends and prospects,” *Pattern recognition*, c. 47, no. 8, ss. 2673–2688, 2014.
- [8] B. Arslan Ş. Sağiroğlu, “Mobil Cihazlarda Biyometrik Sistemler üzerine Bir inceleme,” *Politeknik Dergisi*, c. 19, no. 2, ss. 101–114, 2016.
- [9] S. Wang J. Liu, “Biometrics on mobile phone,” *Recent Application in Biometrics*, ss. 3–22, 2011.
- [10] M. O. Derawi, C. Nickel, P. Bours C. Busch, “Unobtrusive user-authentication on mobile phones using biometric gait recognition,” *2010 Sixth International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, IEEE, 2010, ss. 306–311.
- [11] G. D. Clark J. Lindqvist, “Engineering gesture-based authentication systems,” *IEEE Pervasive Computing*, c. 14, no. 1, ss. 18–25, 2015.
- [12] S. Aziz, M. U. Khan, Z. A. Choudhry, A. Aymin A. Usman, “ECG-based biometric authentication using empirical mode decomposition and support vector machines,” *2019 IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, IEEE, 2019, ss. 0906–0912.

- [13] S. A. Israel, J. M. Irvine, A. Cheng, M. D. Wiederhold B. K. Wiederhold, "ECG to identify individuals," *Pattern recognition*, c. 38, no. 1, ss. 133–142, 2005.
- [14] J. Hampton J. Hampton, *The ECG Made Easy E-Book: The ECG Made Easy E-Book*. Elsevier Health Sciences, 2019.
- [15] S. K. Berkaya, A. K. Uysal, E. S. Gunal, S. Ergin, S. Gunal M. B. Gulmezoglu, "A survey on ECG analysis," *Biomedical Signal Processing and Control*, c. 43, ss. 216–235, 2018.
- [16] S. K. Saini R. Gupta, "Artificial intelligence methods for analysis of electrocardiogram signals for cardiac abnormalities: State-of-the-art and future challenges," *Artificial Intelligence Review*, c. 55, no. 2, ss. 1519–1565, 2022.
- [17] H.-S. Choi, B. Lee S. Yoon, "Biometric Authentication Using Noisy Electrocardiograms Acquired by Mobile Sensors," *IEEE Access*, c. 4, ss. 1266–1273, 2016. doi: 10.1109/ACCESS.2016.2548519.
- [18] J. L. Kowalak C. Turkington, *ECG interpretation*. Lippincott Williams & Wilkins, 2007.
- [19] E. Möngü, "Bilgisayar Destekli Qrs Deteksiyonu Ve Ekg Parametrelerinin Hesaplanması," dok. tezi, Fen Bilimleri Enstitüsü, 2003.
- [20] L. Biel, O. Pettersson, L. Philipson P. Wide, "ECG analysis: a new approach in human identification," *IEEE transactions on instrumentation and measurement*, c. 50, no. 3, ss. 808–812, 2001.
- [21] G. Wübbeler, M. Stavridis, D. Kreiseler, R.-D. Bousseljot C. Elster, "Verification of humans using the electrocardiogram," *Pattern Recognition Letters*, c. 28, no. 10, ss. 1172–1175, 2007.
- [22] Y. Singh S. Singh, "Evaluation of Electrocardiogram for Biometric Authentication," *Journal of Information Security*, c. 03, Ocak 2012. doi: 10.4236/jis.2012.31005.
- [23] A. Pal Y. N. Singh, "Biometric recognition using area under curve analysis of electrocardiogram," *International Journal of Advanced Computer Science and Applications*, c. 10, no. 1, 2019.
- [24] S. K. TR P. TL, "ECG Authentication Reinforced by Pretrained Convolutional Neural Networks," *2023 International Conference on Network, Multimedia and Information Technology (NMITCON)*, 2023, ss. 1–6. doi: 10.1109/NMITCON58196.2023.10275834.
- [25] Z. Mizgalewicz ve diğ., "Minimal Preprocessing of ECG Signals for Deep Learning-Based Biometric Systems," *2024 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, 2024, ss. 1–5. doi: 10.1109/CIVEMSA58715.2024.10586617.
- [26] A. Garg N. Karimian, "ECG Biometric Spoofing Using Adversarial Machine Learning," *2021 IEEE International Conference on Consumer Electronics (ICCE)*, 2021, ss. 1–5. doi: 10.1109/ICCE50685.2021.9427645.

- [27] D. A. AlDuwaile M. S. Islam, "Using convolutional neural network and a single heartbeat for ECG biometric recognition," *Entropy*, c. 23, no. 6, s. 733, 2021.
- [28] A. R. Yuniarti, S. Rizal K. M. Lim, "Single heartbeat ECG authentication: a 1D-CNN framework for robust and efficient human identification," *Frontiers in Bioengineering and Biotechnology*, c. 12, s. 1 398 888, 2024.
- [29] J. S. Kim ve diğ., "Multi-Session Electrocardiogram–Electromyogram Database for User Recognition," *Applied Sciences*, c. 14, no. 6, s. 2607, 2024.
- [30] S. MADDULURI T. K. KUMAR, "ELECTROCARDIOGRAM PLETHYSMOGRAPHIC ELECTROMYOGRAMS BASED BIOMETRIC AUTHENTICATION MODELS," *Journal of Theoretical and Applied Information Technology*, c. 102, no. 13, 2024.
- [31] D. Saxena P. Patel, "SMHeart ID: smart ID based on ECG and long short term memory for remote health monitoring," *Multimedia Tools and Applications*, ss. 1–28, 2024.
- [32] M. S. Islam, H. AlHichri, Y. Bazi, N. Ammour, N. Alajlan R. M. Jomaa, "Heartprint: A Multisession ECG Dataset for Biometric Recognition," Haz. 2022. doi: 10 . 6084 / m9 . figshare . 20105354 . v3. erişim adresi: [https : / / figshare . com / articles / dataset / Heartprint _ A _ Multisession _ ECG _ Dataset _ for _ Biometric _ Recognition / 20105354](https://figshare.com/articles/dataset/Heartprint_A_Multisession_ECG_Dataset_for_Biometric_Recognition/20105354).
- [33] D. Tantinger ve diğ., "Human authentication implemented for mobile applications based on ECG-data acquired from sensorized garments," *2015 Computing in Cardiology Conference (CinC)*, 2015, ss. 417–420. doi: 10 . 1109/CIC.2015.7408675.
- [34] Y. Chen W. Chen, "Finger ECG-based authentication for healthcare data security using artificial neural network," *2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom)*, 2017, ss. 1–6. doi: 10.1109/HealthCom.2017.8210804.
- [35] Y. Zhang J. Wu, "Practical human authentication method based on piecewise corrected Electrocardiogram," *2016 7th IEEE International Conference on Software Engineering and Service Science (ICSESS)*, IEEE, 2016, ss. 300–303.
- [36] S. J. Kang, S. Y. Lee, H. I. Cho H. Park, "ECG authentication system design based on signal analysis in mobile and wearable devices," *IEEE Signal Processing Letters*, c. 23, no. 6, ss. 805–808, 2016.
- [37] J. Ocheni, I. J. J, G. J. Leelipushpam, G. J. W. Kathrine, S. Silas S. K. S, "Electrocardiogram Based Authentication Scheme for Smart Home Security," *2023 International Conference on Circuit Power and Computing Technologies (ICCPCT)*, 2023, ss. 663–666. doi: 10 . 1109 / ICCPCT58313.2023.10245657.
- [38] L. Bastos ve diğ., "Ensemble Learning Method for Human Identification in Wearable Devices," *2022 International Wireless Communications and Mobile Computing (IWCMC)*, 2022, ss. 1052–1057. doi: 10 . 1109 / IWCMC55113.2022.9824669.

- [39] H. S. Bıçakcı, M. Santopietro, M. Boakes R. Guest, "Evaluation of Electrocardiogram Biometric Verification Models Based on Short Enrollment Time on Medical and Wearable Recorders," *2021 International Carnahan Conference on Security Technology (ICCST)*, 2021, ss. 1–6. doi: 10.1109/ICCST49569.2021.9717372.
- [40] S. Y. Chun, J.-H. Kang, H. Kim, C. Lee, I. Oakley S.-P. Kim, "ECG based user authentication for wearable devices using short time Fourier transform," *2016 39th international conference on telecommunications and signal processing (tsp)*, IEEE, 2016, ss. 656–659.
- [41] M. M. M. Nawawi, K. A. Sidek A. W. Azman, "ECG in Real World Scenario: Time Variability in Biometric Using Wearable Smart Textile Shirts," *Journal of Advanced Research in Applied Sciences and Engineering Technology*, c. 40, no. 2, ss. 36–49, 2024.
- [42] M. Zemzemi ve diğ., "Toward A Low Cost, High Performance ECG Based Biometrics: A Preliminary Work," *2018 15th International Multi-Conference on Systems, Signals & Devices (SSD)*, 2018, ss. 55–59. doi: 10.1109/SSD.2018.8570470.
- [43] S. S. Xu, M.-W. Mak C.-C. Cheung, "Patient-specific Heartbeat Classification based on i-vector adapted Deep Neural Networks," *2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, IEEE, 2018, ss. 784–787.
- [44] S. S. Xu, M.-W. Mak C.-C. Cheung, "I-vector-based patient adaptation of deep neural networks for automatic heartbeat classification," *IEEE journal of biomedical and health informatics*, c. 24, no. 3, ss. 717–727, 2019.
- [45] M. Adiban, B. BabaAli S. Shehnepoor, "I-vector based features embedding for heart sound classification," *arXiv preprint arXiv:1904.11914*, 2019.
- [46] T. R. Xian, N. S. Ibrahim D. A. Ramli, "i-vector Evaluation of Electrocardiogram (ECG) Biometric Identification System based on Sequential Compensation Approach," *Procedia Computer Science*, c. 176, ss. 233–240, 2020.
- [47] S. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, c. 11, no. 7, ss. 674–693, 1989. doi: 10.1109/34.192463.
- [48] I. Daubechies, *Ten lectures on wavelets*. SIAM, 1992.
- [49] B. Boashash, "Estimating and interpreting the instantaneous frequency of a signal. I. Fundamentals," *Proceedings of the IEEE*, c. 80, no. 4, ss. 520–538, 1992. doi: 10.1109/5.135376.
- [50] M. Le Van Quyen ve diğ., "Comparison of Hilbert transform and wavelet methods for the analysis of neuronal synchrony," *Journal of neuroscience methods*, c. 111, no. 2, ss. 83–98, 2001.
- [51] J. Pan W. Tompkins, "A real-time QRS detection algorithm. IEEE Transaction on biomedical Engineering, vol," *BME*, c. 32,
- [52] F. S. Koçkan B. Bolat, "Ekg Sinyalleri Kullanılarak Kimlik Doğrulama," *4. Uluslararası Bilimsel Araştırmalar Kongresi*, 2019, ss. 299–305.

- [53] S. A. Alodia Yusuf R. Hidayat, "MFCC Feature Extraction and KNN Classification in ECG Signals," *2019 6th International Conference on Information Technology, Computer and Electrical Engineering (ICITACEE)*, 2019, ss. 1–5. doi: 10.1109/ICITACEE.2019.8904285.
- [54] J.-M. Liu ve diğ., "Cough signal recognition with Gammatone Cepstral Coefficients," *2013 IEEE China Summit and International Conference on Signal and Information Processing*, 2013, ss. 160–164. doi: 10.1109/ChinaSIP.2013.6625319.
- [55] A. Adiga, M. Magimai C. S. Seelamantula, "Gammatone wavelet Cepstral Coefficients for robust speech recognition," *2013 IEEE International Conference of IEEE Region 10 (TENCON 2013)*, 2013, ss. 1–4. doi: 10.1109/TENCON.2013.6718948.
- [56] B. Ayoub, K. Jamal Z. Arsalane, "Gammatone frequency cepstral coefficients for speaker identification over VoIP networks," *2016 International Conference on Information Technology for Organizations Development (IT4OD)*, 2016, ss. 1–5. doi: 10.1109/IT4OD.2016.7479293.
- [57] A. Krobba, M. Debyeche S.-A. Selouani, "Mixture linear prediction Gammatone Cepstral features for robust speaker verification under transmission channel noise," *Multimedia Tools and Applications*, c. 79, ss. 18 679–18 693, 2020.
- [58] X. Valero F. Alias, "Gammatone Cepstral Coefficients: Biologically Inspired Features for Non-Speech Audio Classification," *IEEE Transactions on Multimedia*, c. 14, no. 6, ss. 1684–1689, 2012. doi: 10.1109/TMM.2012.2199972.
- [59] F. S. Koçkan B. Bolat, "ECG Biometrics on Mobile Devices: High-Accuracy Authentication Using i-Vectors and Cepstral Coefficients," *IEEE Access*, 2025. doi: 10.1109/ACCESS.2025.3553423.
- [60] M. A. Islam, "GFCC-based robust gender detection," *2016 International Conference on Innovations in Science, Engineering and Technology (ICISSET)*, 2016, ss. 1–4. doi: 10.1109/ICISSET.2016.7856507.
- [61] X. Zhao D. Wang, "Analyzing noise robustness of MFCC and GFCC features in speaker identification," *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, 2013, ss. 7204–7208. doi: 10.1109/ICASSP.2013.6639061.
- [62] M. Adiban, B. BabaAli S. Shehnepoor, "Statistical feature embedding for heart sound classification," *Journal of Electrical Engineering*, c. 70, no. 4, ss. 259–272, 2019.
- [63] W. Wang, W. Song, C. Chen, Z. Zhang Y. Xin, "I-vector features and deep neural network modeling for language recognition," *Procedia computer science*, c. 147, ss. 36–43, 2019.
- [64] N. Dehak, P. J. Kenny, R. Dehak, P. Dumouchel P. Ouellet, "Front-End Factor Analysis for Speaker Verification," *IEEE Transactions on Audio, Speech, and Language Processing*, c. 19, no. 4, ss. 788–798, 2011. doi: 10.1109/TASL.2010.2064307.

- [65] Đ. Grozdić, S. Jovičić, Z. Saric I. Subotić, “Comparison of GMM/UBM and i-vector based speaker recognition systems,” *Ekim* 2015, s. 274.
- [66] P. Matějka ve diğ., “Full-covariance UBM and heavy-tailed PLDA in i-vector speaker verification,” *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2011, ss. 4828–4831. doi: 10 . 1109/ICASSP.2011.5947436.
- [67] M. Li S. Narayanan, “Simplified supervised i-vector modeling with application to robust and efficient language identification and speaker verification,” *Computer Speech & Language*, c. 28, no. 4, ss. 940–958, 2014.
- [68] A. W. Zewoudie, “Discriminative features for GMM and i-vector based speaker diarization,” 2017.
- [69] T. Hastie, R. Tibshirani, J. H. Friedman J. H. Friedman, *The elements of statistical learning: data mining, inference, and prediction*. Springer, 2009, c. 2.
- [70] R. A. Fisher, “The use of multiple measurements in taxonomic problems,” *Annals of eugenics*, c. 7, no. 2, ss. 179–188, 1936.
- [71] N. Dehak, R. Dehak, J. R. Glass, D. A. Reynolds, P. Kenny ve diğ., “Cosine similarity scoring without score normalization techniques,” *Odyssey*, c. 15, 2010.
- [72] C. Cortes V. Vapnik, “Support-vector networks,” *Machine learning*, c. 20, ss. 273–297, 1995.
- [73] S. Xu ve diğ., “The applications of deep learning in automatic ECG classification,” 2020.
- [74] Z. Golrizkhatami, “Classification of ECG Signal by Using Wavelet Transform and SVM,” dok. tezi, Eastern Mediterranean University (EMU)-Doğu Akdeniz Üniversitesi (DAÜ), 2015.
- [75] S. Ayhan Ş. Erdoğan, “Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi,” *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, c. 9, no. 1, ss. 175–201, 2014.
- [76] O. Eray, “Destek vektör makineleri ile ses tanıma uygulaması,” yük. lis. tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, 2008.
- [77] A. H. Abd-elaziem, T. H. Soliman ve diğ., “A Multi-Layer Perceptron (MLP) Neural Networks for Stellar Classification: A Review of Methods and Results,” *International Journal of Advances in Applied Computational Intelligence*, c. 3, no. 10.54216, 2023.
- [78] A. H.-F. Syam Ahmad Jamil, J. A. Kadir, J. M. Jamil, F. R. Hashim, S. Shaharuddin N. F. Makmor, “Multilayer Perceptron Optimization of ECG Peaks for Cardiac Abnormality Detection,” *2022 IEEE 12th International Conference on Control System, Computing and Engineering (ICCSCE)*, 2022, ss. 37–41. doi: 10.1109/ICCSCE54767.2022.9935642.
- [79] M. Boussaa, I. Atouf, M. Atibi A. Bennis, “ECG signals classification using MFCC coefficients and ANN classifier,” *2016 International Conference on Electrical and Information Technologies (ICEIT)*, IEEE, 2016, ss. 480–484.

- [80] W. Wang, J. Guan, X. Che W. Wang, "MS-MLP: Multi-scale Sampling MLP for ECG Classification," *2022 30th European Signal Processing Conference (EUSIPCO)*, 2022, ss. 1288–1292. doi: 10 . 23919 / EUSIPCO55093 . 2022 . 9909814.
- [81] L. Breiman, "Random forests," *Machine learning*, c. 45, ss. 5–32, 2001.
- [82] A. Cutler, D. R. Cutler J. R. Stevens, "Random forests," *Ensemble machine learning: Methods and applications*, ss. 157–175, 2012.
- [83] R. Tan M. Perkowski, "ECG biometric identification using wavelet analysis coupled with probabilistic random forest," *2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA)*, IEEE, 2016, ss. 182–187.
- [84] R. Avanzato F. Beritelli, "Automatic ECG diagnosis using convolutional neural network," *Electronics*, c. 9, no. 6, s. 951, 2020.
- [85] Y. Wu, F. Yang, Y. Liu, X. Zha S. Yuan, "A comparison of 1-D and 2-D deep convolutional neural networks in ECG classification," *arXiv preprint arXiv:1810.07088*, 2018.
- [86] U. R. Acharya ve diğ., "A deep convolutional neural network model to classify heartbeats," *Computers in biology and medicine*, c. 89, ss. 389–396, 2017.
- [87] I. Goodfellow, *Deep learning*, 2016.
- [88] Z. Ebrahimi, M. Loni, M. Daneshtalab A. Gharehbaghi, "A review on deep learning methods for ECG arrhythmia classification," *Expert Systems with Applications: X*, c. 7, s. 100 033, 2020.
- [89] Ö. Yıldırım, P. Pławiak, R.-S. Tan U. R. Acharya, "Arrhythmia detection using deep convolutional neural network with long duration ECG signals," *Computers in biology and medicine*, c. 102, ss. 411–420, 2018.
- [90] S. A. A. Yusuf R. Hidayat, "MFCC feature extraction and KNN classification in ECG signals," *2019 6th International Conference on Information Technology, Computer and Electrical Engineering (ICITACEE)*, IEEE, 2019, ss. 1–5.
- [91] C. Pummer, "Continuous biometric authentication using electrocardiographic (ECG) data," dok. tezi, Ph. D. thesis, MSc thesis, 2016, Hagenberg, 2016.
- [92] V. Randazzo, E. Puleo, A. Paviglianiti, A. Vallan E. Pasero, "Development and Validation of an Algorithm for the Digitization of ECG Paper Images," *Sensors*, c. 22, no. 19, s. 7138, 2022.
- [93] S. Y. Chun, "Single pulse ECG-based small scale user authentication using guided filtering," *2016 international conference on biometrics (ICB)*, IEEE, 2016, ss. 1–7.
- [94] T. S. Lugovaya, "Biometric human identification based on ECG," *PhysioNet*, 2005.
- [95] *ReadMyHeart - Handheld ECG Recording Device*. erişim adresi: https://dailycare.en.ec21.com/ReadMyHeart_-_Handheld_ECG_Recording--976239_976240.html.

- [96] L. Van der Maaten G. Hinton, “Visualizing data using t-SNE.,” *Journal of machine learning research*, c. 9, no. 11, 2008.
- [97] M. Wattenberg, F. Viégas I. Johnson, “How to use t-SNE effectively,” *Distill*, c. 1, no. 10, e2, 2016.



TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. Koçkan S.F., Bolat B., "ECG Biometrics on Mobile Devices: High-Accuracy Authentication Using i-Vectors and Cepstral Coefficients" in IEEE Access, 2025, doi: 10.1109/ACCESS.2025.3553423.

Konferans Bildirisi

1. Koçkan S.F., Bolat B., "Ekg Sinyalleri Kullanılarak Kimlik Doğrulama", 4. Uluslararası Bilimsel Araştırmalar Kongresi - UBAK, 2019.