

BURSA TEKNİK ÜNİVERSİTESİ ❖ FEN BİLİMLERİ ENSTİTÜSÜ

**EVRIŞİMSEL SİNİR AĞLARI KULLANILARAK EKG VE YÜZ TABANLI
BİYOMETRİK TANIMA**



YÜKSEK LİSANS TEZİ

Ayça HANİLÇİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

TEMMUZ 2019

BURSA TEKNİK ÜNİVERSİTESİ ❖ FEN BİLİMLERİ ENSTİTÜSÜ

**EVRIŞİMSEL SİNİR AĞLARI KULLANILARAK EKG VE YÜZ TABANLI
BİYOMETRİK TANIMA**

YÜKSEK LİSANS TEZİ

**Ayça HANILÇI
(161082313)**

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Hakan GÜRKAN

TEMMUZ 2019

BTÜ, Fen Bilimleri Enstitüsü'nün 161082313 numaralı Yüksek Lisans Öğrencisi Ayça HANİLÇİ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "EVİRİŞİMSEL SINIR AĞLARI KULLANILARAK EKG VE YÜZ TABANLI BİYOMETRİK TANIMA" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Hakan GÜRKAN**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Ersen YILMAZ**
Bursa Uludağ Üniversitesi

Dr. Öğr. Üyesi Gökay BAYRAK
Bursa Teknik Üniversitesi

Savunma Tarihi : 5 Temmuz 2019

FBE Müdürü : **Doç. Dr. Murat ERTAŞ**
Bursa Teknik Üniversitesi /...../.....

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Ayça HANILÇI

İmzası :

X X X X X



Çok Değerli Eşime,

ÖNSÖZ

Bursa Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans Programı'nda gerçekleştirmiş olduğum bu tez çalışmamın planlama, araştırma ve yürütülmesi süresince yardım ve yönlendirmelerini esirgemeyen öncelikle Sayın Hocam Doç. Dr. Hakan GÜRKAN'a ve tüm Bölüm Öğretim Üyeleri'ne teşekkürlerimi sunarım.

Temmuz 2019

Ayça HANILÇI



İÇİNDEKİLER

Sayfa

ÖNSÖZ	v
İÇİNDEKİLER	vi
KISALTMALAR	viii
SEMBOLLER	ix
ŞEKİL LİSTESİ	xi
ÖZET	xiii
SUMMARY	xv
1. GİRİŞ	17
1.1 Tezin Amacı	17
1.2 Hipotez	18
2. BİYOMETRİK SİSTEM.....	19
2.1 Tekli Biyometrik Sistemler	19
2.2 Çoklu Biyometrik Sistemler	21
2.3 Elektrokardiyogram (EKG).....	22
3. LİTERATÜR ARAŞTIRMASI	25
3.1 EKG Tabanlı Biyometrik Tanıma Yöntemleri	25
3.2 Yüz Tabanlı Biyometrik Tanıma Yöntemleri	27
3.3 EKG ve Yüz Çoklu Biyometrik Tanıma Yöntemleri.....	28
4. EVRİŞİMSEL SİNİR AĞLARI (ESA)	30
4.1 Biyolojik Nöronların Matematiksel Modellenmesi.....	30
4.2 Derin Sinir Ağları (Derin Öğrenme)	31
4.3 Evrişimsel Sinir Ağları.....	33
5. MATERYAL VE YÖNTEM.....	37
5.1 Veri Tabanları	37
5.1.1 EKG veri tabanı	37
5.1.2 Yüz veri tabanı	37
5.2 Önerilen Yöntem-1: Evrişimsel Sinir Ağı Tabanlı EKG Biyometrik Tanıma Yöntemi.....	38
5.2.1 Ön işleme	38
5.2.2 Veri çoğullama	40
5.2.3 Öznitelik çıkarımı ve sınıflandırma	40
5.3 Önerilen Yöntem-2: Evrişimsel Sinir Ağı Tabanlı EKG ve Yüz Çoklu Biyometrik Tanıma Yöntemi (FACECG)	44
5.3.1 Ön işleme	45
5.3.2 Öznitelik çıkarımı ve sınıflandırma	45
5.3.3 Skor birleştirme	48
5.3.4 Öznitelik birleştirme	48
5.4 Performans Kriterleri.....	48
6. DENEYSEL SONUÇLAR.....	52
6.1 Donanım	52

6.2 Başarım Sonuçları	52
6.2.1 Önerilen Yöntem-1: Evrişimsel Sinir Ağı tabanlı EKG biyometrik tanıma yöntemi başarım sonuçları	52
6.2.2 Önerilen Yöntem-2: Evrişimsel Sinir Ağı tabanlı EKG ve Yüz çoklu biyometrik tanıma yöntemi (FACECG) başarım sonuçları	58
6.2.2.1 Önerilen Yöntem-2'nin EKG işaretlerine göre kişi tanıma başarım sonuçları	58
6.2.2.2 Önerilen Yöntem-2'nin yüz imgelerine göre kişi tanıma başarım sonuçları	63
6.3 Önerilen Yöntem-2'nin EKG İşaretleri ve Yüz İmgelerine Göre Kişi Tanıma Başarımı Sonuçları	66
7. TARTIŞMA VE ÖNERİLER	68
KAYNAKLAR	70
ÖZGEÇMİŞ.....	76



KISALTMALAR

AİK	: Alıcı İşletim Karakteristiği
CNN	: Convolutional Neural Network
DBNN	: Decision-Based Neural Network
DCT	: Discrete Cosine Transform
DNN	: Deep Neural Network
DSA	: Derin Sinir Ağı
EKG	: Elektrokardiyogram
ESA	: Evrimsel Sinir Ağı
fmap	: Feature map
GMM	: Gaussian Mixture Model
KTO	: Kişi Tanıma Oranı
LDA	: Linear Discriminant Analysis
LPC	: Linear Predictive Coding
MSD	: Mean Square Deviation
PAR	: Pulse Active Ratio
PCA	: Principles Component Analysis
RBNN	: Radial Basis Neural Network
ReLU	: Rectified Linear Unit
ROC	: Receiver Operating Characteristic
SVM	: Support Vector Machine

SEMBOLLER

x_i	: Giriş Sinyali
w_i	: Ağırlık Katsayıları
α	: Öğrenme Hızı



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : EKG ve yüz işaretlerinin birlikte kullanıldığı çoklu biyometrik sistemler. KTO: Kişi Tanıma Oranı, D: Doğruluk.....	29
Çizelge 4.1 : Derin Sinir Ağı - DSA Tarihsel Gelişimi	32
Çizelge 4.2 : Bir evrişimsel katman için parametre tanımlamaları	35
Çizelge 5.1 : Önerilen Yöntem-1 için geliştirilen ESA Mimarisine ait parametre çizelgesi.....	43
Çizelge 5.2 : Önerilen Yöntem-2 için geliştirilen ESA Mimarisine ait parametre çizelgesi.....	47
Çizelge 5.3 : Öznitelik birleştirme işleminde sınıflandırma için kullanılan sinir ağı mimarisine ilişkin parametre çizelgesi.....	48
Çizelge 5.4 : Hata matrisi.	49
Çizelge 6.1 : Önerilen Yöntem-1 için sınıflandırma başarımları.	57
Çizelge 6.2 : Önerilen Yöntem-2'nin EKG işaretlerine göre sınıflandırma başarımları.	66
Çizelge 6.3 : Önerilen Yöntem-2'nin yüz imgelerine göre sınıflandırma başarımları. .	66
Çizelge 6.4 : EKG ve yüz işaretlerinin birlikte kullanıldığı çoklu biyometrik sistemler karşılaştırma çizelgesi. KTO: Kişi Tanıma Oranı, D: Doğruluk.....	67

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Biyometrikler : (a) Fiziksel biyometriklere örnek: parmak izi, retina, yüz (b) Davranışsal biyometriklere örnek: imza, klavye vuruş dinamiği, ses.	19
Şekil 2.2 : Biyometrik sistem için eğitim ve test (doğrulama ve tanımlama) bölümleri.	21
Şekil 2.3 : EKG dalga formunun oluşum aşamaları.	23
Şekil 2.4 : EKG sinyalinin ölçüm yöntemleri : (a) 12-Kanallı EKG (b) Holter cihazı (c) Pratik yöntemler.	24
Şekil 4.1 : Beyindeki bir nöronun bağlantıları.	30
Şekil 4.2 : Bir nöronun matematiksel modellenmesi.	31
Şekil 4.3 : Temel bir sinir ağı örnek blok diyagramı.	32
Şekil 4.4 : Yapay Zeka-Derin Öğrenme ilişkisi.	32
Şekil 4.5 : Derin ESA mimarisi.	33
Şekil 4.6 : 2-boyutlu evrişim işlemi.	35
Şekil 4.7 : Maksimum ortaklama katmanı örnek gösterimi.	36
Şekil 5.1 : AR Face veri tabanına ait örnek resimler.	37
Şekil 5.2 : Önerilen Yöntem-1 olarak adlandırılan ESA tabanlı EKG biyometrik tanıma sistemine ilişkin blok diyagram.	38
Şekil 5.3 : EKG işareti.	39
Şekil 5.4 : QRS belirleme.	39
Şekil 5.5 : QRS bölütleme.	39
Şekil 5.6 : 256x256x1 boyutlu QRS imgesi.	40
Şekil 5.7 : Aktivasyon fonksiyonları : (a) ReLU (b) Sigmoid.	41
Şekil 5.8 : Önerilen Yöntem-1 için geliştirilen ESA Mimarisi.	42
Şekil 5.9 : ESA tabanlı çoklu EKG ve yüz biyometrik tanıma sistemi blok diyagramı.	44
Şekil 5.10 : ESA tabanlı çoklu EKG ve yüz biyometrik tanıma sistemi blok diyagramı.	44
Şekil 5.11 : Önerilen Yöntem-2 için geliştirilen ESA mimarisi.	46
Şekil 5.12 : Örnek bir AİK eğrisi.	50
Şekil 6.1 : Önerilen Yöntem-1 için 1. Kat model doğruluk eğrisi.	53
Şekil 6.2 : Önerilen Yöntem-1 için 2. kat model doğruluk eğrisi.	53
Şekil 6.3 : Önerilen Yöntem-1 için 3. kat model doğruluk eğrisi.	54
Şekil 6.4 : Önerilen Yöntem-1 için 1. kat model kayıp eğrisi.	55
Şekil 6.5 : Önerilen Yöntem-1 için 2.kat model kayıp eğrisi.	55
Şekil 6.6 : Önerilen Yöntem-1 için 3. kat model kayıp eğrisi.	56
Şekil 6.7 : Önerilen Yöntem-1 için 1. kat hata matrisi.	56
Şekil 6.8 : Önerilen Yöntem-1 için Alıcı İşletim Karakteristiği eğrisi.	57
Şekil 6.9 : Önerilen Yöntem-2 için birinci deneyde elde edilen 1. kat model doğruluk eğrisi.	59

Şekil 6.10 : Önerilen Yöntem-2 için birinci deneyde elde edilen 2. Kat model doğruluk eğrisi.	59
Şekil 6.11 : Önerilen Yöntem-2 için birinci deneyde elde edilen 3. kat model doğruluk eğrisi.	60
Şekil 6.12 : Önerilen Yöntem-2 için birinci deneyde elde edilen 1. kat model kayıp eğrisi.....	61
Şekil 6.13 : Önerilen Yöntem-2 için birinci deneyde elde edilen 2. kat model kayıp eğrisi.....	61
Şekil 6.14 : Önerilen Yöntem-2 için birinci deneyde elde edilen 3. kat model kayıp eğrisi.....	62
Şekil 6.15 : Önerilen Yöntem-2 için birinci deneyde elde edilen 1. kat hata matrisi.	62
Şekil 6.16 : Önerilen Yöntem-2 için birinci deneyde elde edilen Alıcı İşletim Karakteristiği eğrisi.....	63
Şekil 6.17 : Önerilen Yöntem-2 için ikinci deneyde elde edilen 1. kat model doğruluk eğrisi.	64
Şekil 6.18 : Önerilen Yöntem-2 için ikinci deneyde elde edilen 1. kat model kayıp eğrisi.....	65
Şekil 6.19 : Önerilen Yöntem-2 için ikinci deneyde elde edilen 1. kat hata matrisi.	65

EVRIŞİMSEL SİNİR AĞLARI KULLANILARAK EKG VE YÜZ TABANLI BİYOMETRİK TANIMA

ÖZET

Bu tezde, günümüzde makine öğrenmesi yöntemlerinin içinde en güncel derin öğrenme yöntemlerinden birisi olan evrişimsel sinir ağları ile çoklu biyometrik kişi tanıma problemi ele alınmıştır. Bu amaçla elektrokardiyogram işaretleri ve yüz imgeleri kullanılarak kişi tanıma çalışmaları yapılmıştır. Bu çalışmalar iki aşamadan oluşmaktadır. Birinci aşamada sadece evrişimsel sinir ağı (ESA) yöntemi kullanılarak elektrokardiyogram (EKG) işaretleri üzerinden biyometrik kişi tanıma işlemi gerçekleştiren bir yöntem (Önerilen Yöntem-1) sunulmuştur. Bu yöntemde bir boyutlu EKG işaretlerinden iki boyutlu QRS imgeleri oluşturulmuş ve bu QRS imgeleri veri çoğullama yöntemi kullanılarak çoğaltılmıştır. Daha sonra veri sayısına ve veri boyutuna uygun olarak geliştirilen bir evrişimsel sinir ağı mimarisinin girişine uygulanmıştır.

İkinci aşamada ise ESA yöntemi kullanılarak hem EKG işaretleri hem de yüz imgeleri üzerinden biyometrik kişi tanıma işlemi gerçekleştiren çoklu biyometrik tanıma yöntemi (Önerilen Yöntem-2, FACECG) sunulmuştur. Bu yöntemde de hem EKG işaretleri hem de yüz imgelerinden iki boyutlu QRS imgeleri ve normalize yüz imgeleri elde edilmiştir. Daha sonra elde edilen bu QRS ve yüz imgeleri herhangi bir veri çoğullama sürecinden geçirilmeden veri sayısına ve boyutlarına uygun olarak geliştirilen ve paralel olarak çalışan birbirine eş iki ESA mimarisinin girişine ayrı ayrı uygulanmıştır. Bu iki ESA mimarisinin parametreleri QRS imgeleri ve yüz imgeleri kullanılarak optimize edilmiştir. Önerilen Yöntem-2’de kullanılan bu iki ESA mimarisinin gerek EKG işaretleri için gerekse yüz imgeleri için ürettiği öznitelikler ve skorlar hem skor seviyeli hem de öznitelik seviyeli birleştirme teknikleri kullanılarak birleştirilmiştir. Bu sayede, sadece EKG işaretleri kullanan veya sadece yüz imgelerini kullanan tekli biyometrik tanıma sistemlerine göre kişi tanıma performansının artırılması ve EKG işaretlerinin canlılık özelliğinden yararlanarak yanıtma saldırılarına karşı daha güvenilir bir sistemin geliştirilmesi hedeflenmiştir.

Önerilen Yöntem-2’nin kişi tanıma başarımını ölçmek amacıyla EKG işaretleri için MIT-BIH Arrhythmia veri kümesi ve yüz imgeleri için AR-Face veri kümesi kullanılmıştır. Bu amaçla, her iki veri kümesinden seçilen 30 kişi eşleştirilerek EKG ve yüz imgelerinden oluşan 30 kişilik yapay bir veri kümesi oluşturulmuştur. Önerilen Yöntem-2’nin başarımının değerlendirilmesinde veri yanlılığı problemini ortadan kaldırmak için 3 kat çapraz doğrulama yöntemi kullanılmıştır. Yapılan deneyler sonucunda sadece EKG işaretleri kullanılarak ortalama %98.33 doğruluk değeri sağlanırken sadece yüz imgeleri kullanarak %98.60 doğruluk değeri elde edilmiştir. Hem öznitelik hem de skor seviyeli birleştirme yöntemlerinin ayrı ayrı kullanılması sonucunda ise Önerilen Yöntem-2’nin kişi tanıma başarımı doğruluk değeri açısından %100 olarak elde edilmiştir.

Literatür arařtırmasında bulabildiđimiz kadarıyla EKG iřaretlerini ve yüz imgelerini birlikte kullanarak biyometrik tanıma yapan sadece üç çalıřma olduđu belirlenmiřtir. Bu çalıřmalar yöntem olarak geleneksel yöntemleri kullanmaktadır. Bu açıdan tez çalıřmasında sunulan Önerilen Yöntem-2 (FACECG), 2 boyutlu evriřimsel sinir ađı yöntemini kullanarak hem EKG iřaretlerini hem de yüz imgelerini birlikte deđerlendirerek biyometrik tanıma iřlemini gerçekteřtiren ilk çalıřma olma özelliđine sahiptir. Ayrıca deneysel sonuçlar Önerilen Yöntem-2'nin (FACECG) literatürde bulunan üç çalıřmada sunulan kiři tanıma başarımlarına göre dođruluk deđerleri açısından daha yüksek başarımlarını verdiđini göstermektedir.

Anahtar kelimeler: evriřimsel sinir ađı, kiři tanıma, derin sinir ađı, elektrokardiogram, yüz tanıma, çoklu kiři tanıma sistemi.



ECG AND FACE BASED BIOMETRIC RECOGNITION USING CONVOLUTIONAL NEURAL NETWORKS

SUMMARY

In this thesis, multi-modal biometric recognition problem using convolutional neural networks which is the state-of-the-art machine learning technique is considered. To this end, biometric person recognition studies are carried out using electrocardiogram signals and face images. These studies consist of two stages. In the first stage, biometric recognition method using convolutional neural networks (CNN) based on only electrocardiogram (ECG) signals is proposed (Proposed Method-1). In this method, two-dimensional QRS images are obtained from one-dimensional ECG signals and the number of two-dimensional QRS images are then increased using a data augmentation method. Later, these augmented data is applied as the input to the proposed convolutional neural network architecture depending on the number of data and the size of the QRS images.

In the second stage, multi-modal biometric recognition approach using the convolutional neural network method which uses both ECG signals and face images is proposed (Proposed Method-2 FACECG). In this method, two-dimensional QRS images and normalized face images were obtained from both ECG signals and face images. Then the QRS images and normalized face images are separately applied to the two similar CNN architectures developed depending on the amount of data and the size of the images in parallel. The parameters of these two CNN architectures are optimized using QRS images and face images, respectively. The features and scores generated using these two CNN architectures used in Proposed Method-2 for ECG signals and face images are then fused using score-level and feature-level fusion techniques. Thus, it is aimed to improve the performance of single biometric recognition systems using stand-alone ECG signals or face images and develop a trustworthy biometric recognition systems robust against spoofing attacks with the help of liveness features of ECG signals.

MIT-BIH Arrhythmia dataset for ECG signals and AR-Face database for face images are used in order to measure the recognition performance of the Proposed Method-2. For this purpose, 30 persons selected from both data sets were matched and an artificial data set consisting of ECG and face images was formed. 3-fold cross-validation method was used to eliminate biasing effect problem in the evaluation of Proposed Method-2 performance. As a result of the experiments, 98.43% accuracy value was obtained using only ECG signals and 98.60% accuracy value was obtained using only face images. As a result of using both feature and score level fusing methods separately, the recognition performance of the Proposed Method-2 was obtained as 100% in terms of accuracy value.

To the best of our knowledge, there exist only three previous studies in literature which use both ECG signals and face images for biometric recognition. These studies utilize standard methods as recognition techniques. In this manner, the Proposed

Method-2 (FACECG) is the first study using both ECG signals and face images based on 2-dimensional convolutional neural networks. Besides, experimental results show that the Proposed Method-2 (FACECG) yields better recognition accuracy than the three studies found in the literature.

Keywords: convolutional neural network, biometric, deep neural network, electrocardiogram, face recognition, multimodal biometric system.



1. GİRİŞ

Biyometri, bireyleri ayırt etmeye yarayan, ölçülebilen fiziksel veya davranışsal özellikler için yapılan genel bir tanım olup bu özellikler parmak izi, yüz, el izi, avuç izi, retina, elektrokardiyogram, konuşma, yürüme biçimi, klavye vuruş dinamiği, imza, el yazısı olarak örneklendirilebilir [1]. Biyometrik tanıma sistemleri günümüzde yaygın olarak kullanılan bu biyometrilerin bir ya da daha fazlası kullanılarak kişi tanımanın gerçekleştirildiği yapılardır. Bankacılık işlemlerinde, bina giriş çıkışlarında, hastane yönetim sistemlerinde, güvenli bölgelere erişimde ve mobil cihazların kontrolünde bu sistemler sıklıkla kullanılmakta olup kullandıkları yöntem ve verilere göre üstünlükleri ve zayıf noktaları mevcuttur. Bu üstün ve zayıf yönler dikkate alınarak ihtiyaca yönelik en iyi sistem başarımını gerçekleyecek mimariler tasarlanabilmekte ve oldukça yüksek başarımlar vermektedir.

1.1 Tezin Amacı

Literatürde yüz veri kümeleri kullanılarak hem geleneksel hem de günümüzde sıkça kullanılan yapay zeka yöntemleri ile pek çok çalışma gerçekleştirilmiş olup bu çalışmalar yüksek kişi tanıma oranlarına erişebilmektedir. Parmak izi, yüz, retina gibi biyometrilerin kullanıldığı sistemlerin kolayca yanıltılabildiği fark edildikten sonra daha güvenli biyometrilerin ve/veya daha güvenli sistemlerin geliştirilmesi için de çalışmalar yapılmaktadır.

EKG işaretleri, medikal uygulamalarda çeşitli sınıflandıma yöntemleri kullanılarak kalp hastalıklarının teşhis edilmesinde ve sınıflandırılmasında başarılı bir şekilde uygulanmaktadır. Ayrıca, EKG işaretleri yaş, cinsiyet ve kalbin yapısı gibi çeşitli kişisel özelliklere bağlı olmak üzere kişileri birbirinden ayırt edebilecek önemli özellikler de barındırmaktadır. Bu işaretlerin hem taklit edilmesinin neredeyse imkansız olması hem de canlılık işareti olması EKG işaretlerinin önemli üstünlükleri arasında sayılabilir. Bu sebeplerden dolayı EKG işaretlerinin kişi tanıma sistemleri için uygun bir seçenek olabileceği düşünülmektedir.

Literatür arařtırmasında, EKG iřaretleri ile yüz imgelerini birlikte kullanan sadece 3 adet biyometrik tanıma yöntemi belirlenmiřtir. Bu yöntemlerin tamamı geleneksel yöntemler kullanılmaktadır. Bu nedenle, bu tez çalıřmasında, yüz verilerinin ve EKG iřaretlerinin birlikte kullanılması ile yanılma saldırılarına karřı daha gürbüz, canlılık özelliđini barındıran ve daha yüksek kiři tanıma bařarımına sahip bir evriřimsel sinir ađı tabanlı bir biyometrik kiři tanıma yönteminin gerçekenmesi amaçlanmaktadır.


1.2 Hipotez

Bu tez çalıřmasında, geleneksel kiři tanıma yöntemlerinin dıřında bir yöntem olan derin sinir ađları yöntemi kullanılarak güvenilir, canlılık tespitini de içinde barındıran, yanılma saldırılarına karřı dayanıklı bir biyometrik tanıma yöntemi geliřtirilmesi hedeflenmektedir. Böyle bir yöntemin geliřtirilmesi için derin sinir ađı mimarilerinden evriřimsel sinir ađı mimarisi seçilmiřtir. Bu çalıřmada iki farklı biyometrik veri (elektrokardiyogram ve yüz) kullanılarak yeni bir kiři tanıma yöntemi geliřtirilecektir. Bu özelliđi ile önerilen yöntem literatürde ilk evriřimsel sinir ađı tabanlı EKG ve yüz imgeleri kullanan biyometrik tanıma yöntemi olacaktır.

İki farklı biyometrik büyüklük ve iki farklı birleřtirme yöntemi kullanılarak geliřtirilecek olan biyometrik tanıma yönteminin bařarımının sadece EKG iřaretleri veya sadece yüz imgeleri kullanan yöntemlere göre daha yüksek olması beklenmektedir. Ayrıca önerilecek olan evriřimsel sinir ađı mimarisi tabanlı biyometrik tanıma yöntemi, çok büyük hacimli veri kümeleri yerine az sayıda veri kümesi ile eđitilecek ve mevcut donanım altyapısının verdiđi izinler dođrultusunda önerilen yöntemin bařarımı deđerlendirilecektir. Önerilecek yöntemin bařarımının az sayıda veri kümesi ile yüksek kiři tanıma bařarımı göstermesi beklenmektedir.

2. BİYOMETRİK SİSTEM

Biyometri, bireyleri ayırt etmeye yarayan ve ölçülebilen fiziksel veya davranışsal özellikler için yapılan genel bir tanımlamadır. Biyometrik ise, kişilerin fiziksel ve davranışsal biyometri özelliklerine dayanarak kim olduklarının otomatik olarak tespit edilmesi olarak ifade edilir. Bu fiziksel özellikler, parmak izi, yüz, el izi, retina, elektrokardiyogram; davranışsal olarak ise konuşma, yürüme biçimi, klavye vuruş dinamiği, imza, el yazısı olarak değerlendirilmektedir [1]. Şekil 2.1’de bu biyometriklerden bazıları gösterilmektedir.



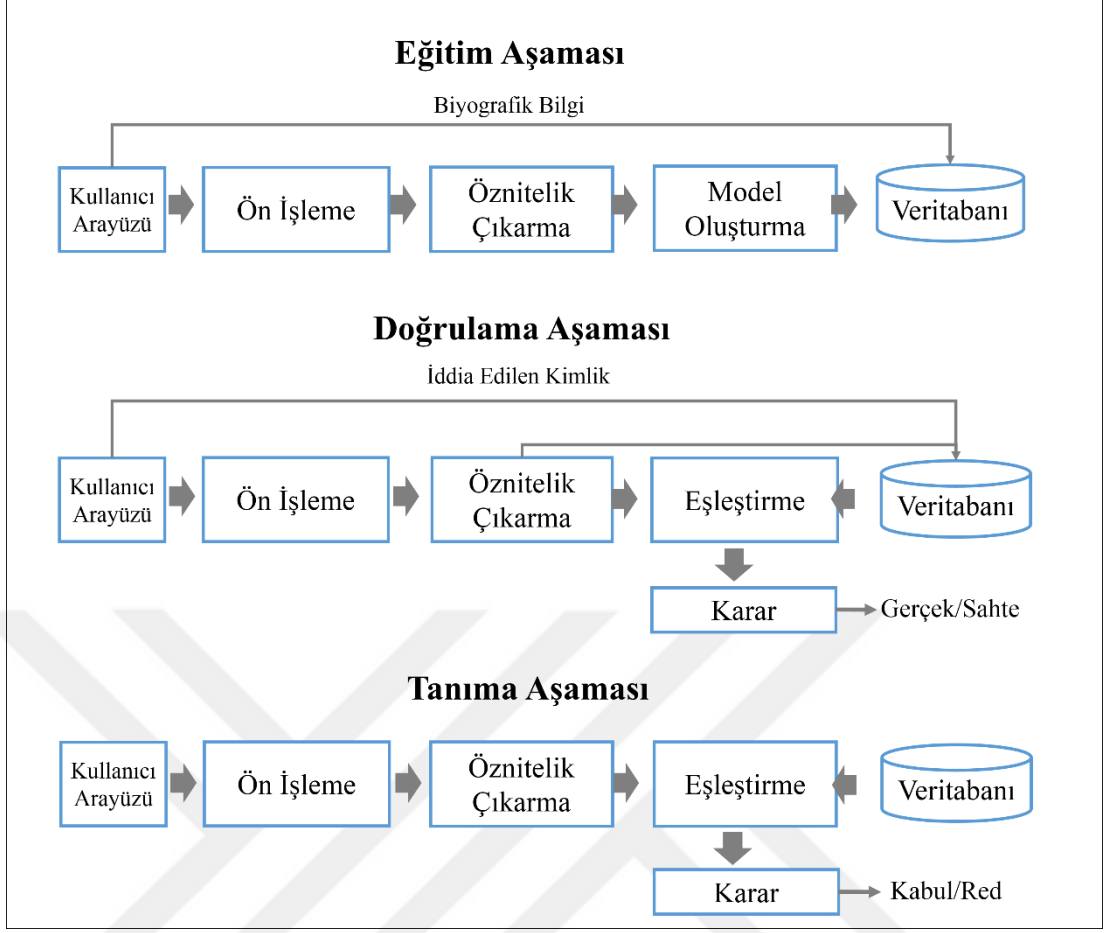
Şekil 2.1 : Biyometrikler : (a) Fiziksel biyometriklere örnek: parmak izi, retina, yüz (b) Davranışsal biyometriklere örnek: imza, klavye vuruş dinamiği, ses.

2.1 Tekli Biyometrik Sistemler

Genel olarak bir biyometrik sistem eğitim ve test olmak üzere iki aşamadan oluşmaktadır. Eğitim aşamasında, bilinen kişilere ait biyometrik özellikler (yüz resmi, konuşma sinyali vb.) kullanılarak her bir kişiyi temsil eden bir model (şablon) oluşturulur ve veri tabanına kaydedilir. Test aşamasında ise bilinmeyen kişiye ait biyometrik özellik veri tabanında yer alan kişilere ait modeller ile kıyaslanarak bir benzerlik skoru (genellikle olasılık) hesaplanır ve bu benzerlik skoruna göre karar verme işlemi gerçekleştirilir. Temel olarak bir biyometrik sistemin eğitim ve test aşamaları birkaç ana modülden meydana gelmektedir. Bu modüller kullanılarak

eđitim ve test ařamaları gerekleřtirilebilir. Eđitim ařamasında ncelikle bireylerden/kiřilerden genellikle bir sensr kullanılarak (kamera, mikrofon, parmak izi tarayıcı vb.) kullanıcı arayz modl aracılıđı ile biyometrik bilgiler alınır. Alınan bu biyometrik veriler daha sonra niřleme (preprocessing) modl kullanılarak ham veri zerinde bir takım iřlemler (grlt giderme ve normalizasyon gibi) gerekleřtirilir. niřleme modlnn ıkıřından elde edilen veriler, kiřileri karakterize eden ve ayırt etmeye yardımcı olacak znelik ıkarma modlne giriř olarak verilir. Her bir kiřiye ait eđitim znelikleri kullanılarak ilgili kiřiye temsil eden bir model (řablon) oluřturularak kullanıcı veri tabanına kaydedilir. Test ařamasında ise bilinmeyen kullanıcıya/kiřiye ait biyometrik veriler kullanıcı arayz modl tarafından alındıktan sonra eđitim ařamasında olduđu gibi sırası ile niřleme ve znelik ıkarma modllerine uygulanır. Bilinmeyen kiřiye ait znelikler, eđitim ařamasında oluřturulan ve kullanıcı veri tabanında yer alan modeller (řablonlar) ile kıyaslanarak bir benzerlik (eřleřtirme) skoru hesaplanır. Hesaplanan bu benzerlik skoruna gre bilinmeyen kiřinin kimliđi hakkında sistem bir karar verme iřlemi gerekleřtirir [2].

Biyometrik sistemler, uygulama ve karar verme yapısına gre tanıma ve dođrulama olmak zere iki řekilde gerekleřtirilir. Bu iki sistem arasındaki tek fark karar verme ařamasında ortaya ıkmaktadır. Tanıma sistemlerinde test ařamasında elde edilen bilinmeyen kiřiye ait znelikler, veri tabanında yer alan kullanıcılara ait modellerin her biri ile karřılařtırılır ve bilinmeyen kiřinin en byk benzerlik skorunu veren modelin ait olduđu kiři olduđuna karar verilir. Dođrulama sisteminde ise bilinmeyen kiři biyometrik zellik sađlarken aynı zamanda bir de kimlik iddiasında bulunur. Test ařamasında, bilinmeyen kiřiye ait znelikler ile sadece iddia ettiđi kiřinin modeli kullanılarak bir karar skoru hesaplanır. Hesaplanan bu karar skoru belirli bir eřik deđerin zerinde ise kimlik iddiası dođru olarak kabul edilirken, eřik deđerden kk ise kimlik iddiası reddedilir [2].



Şekil 2.2 : Biyometrik sistem için eğitim ve test (doğrulama ve tanımlama) bölümleri.

Şekil 2.2’de bir biyometrik sistem için tanımlanmış eğitim ve test aşamalarının blok diyagramları gösterilmektedir. Eğitim aşamasında veri kümeleri kullanılarak çeşitli yöntemler ile elde edilen kişiye özgü şablonlar veri tabanına kaydedilir. Eğer test aşamasında bir doğrulama modeline ihtiyaç var ise eğitim aşamasında veri tabanına kaydedilen şablonlar ile iddia edilen kimliğe ait doğrulama aşamasında elde edilen öznitelikler karşılaştırılarak Gerçek/Sahte cevaplarından biri üretilir. Eğer test aşamasında bir tanıma modeline ihtiyaç var ise eğitim aşamasında veri tabanına kaydedilen şablonların tamamı ile kimliğe ait tanıma aşamasında elde edilen öznitelikler karşılaştırılarak bilinmeyen kişinin veri tabanında bulunan hangi kişi olduğu cevabı üretilir [2].

2.2 Çoklu Biyometrik Sistemler


Bir biyometrik sistemin sahip olduğu birtakım sınırlar vardır. Bunlar, kullanıcı arayüzü ile toplanan verilerdeki gürültü, sınıflar arası benzerlikler, sınıf içi

çeşitlilikler, genelleştirilemeyen modeller ve yanıltma saldırıları olarak söylenebilir. Yüksek bir sınıflandırma başarımına veya güvenli bir sisteme bu limitler nedeni ile ulaşamayabilmektedir. Bu sebeple farklı kaynaklardan alınacak bilgiler, örneğin parmak izi ve iris kombinasyonu, bu tür problemlere çözüm olabilir. Bu kombinasyonlar kişilere ait daha fazla bilgi depolamamızı sağlayacaktır. Bu bilgilerin kombinasyonu birleştirme (fusion) olarak adlandırılır. Bu birleştirme işlemi birkaç farklı şekilde yapılabilmektedir. Skor seviyeli birleştirme, öznitelik (şablon) seviyeli birleştirme ve karar seviyeli birleştirme en yaygın olarak kullanılan tekniklerdir. Farklı kaynaklardan elde edilen biyometrikler kullanılarak geliştirilen çoklu biyometrik sistemlerin eşleştirme skorlarını artırması, yanıltma saldırılarına karşı daha güçlü olması beklenir [2].

2.3 Elektrokardiyogram (EKG)

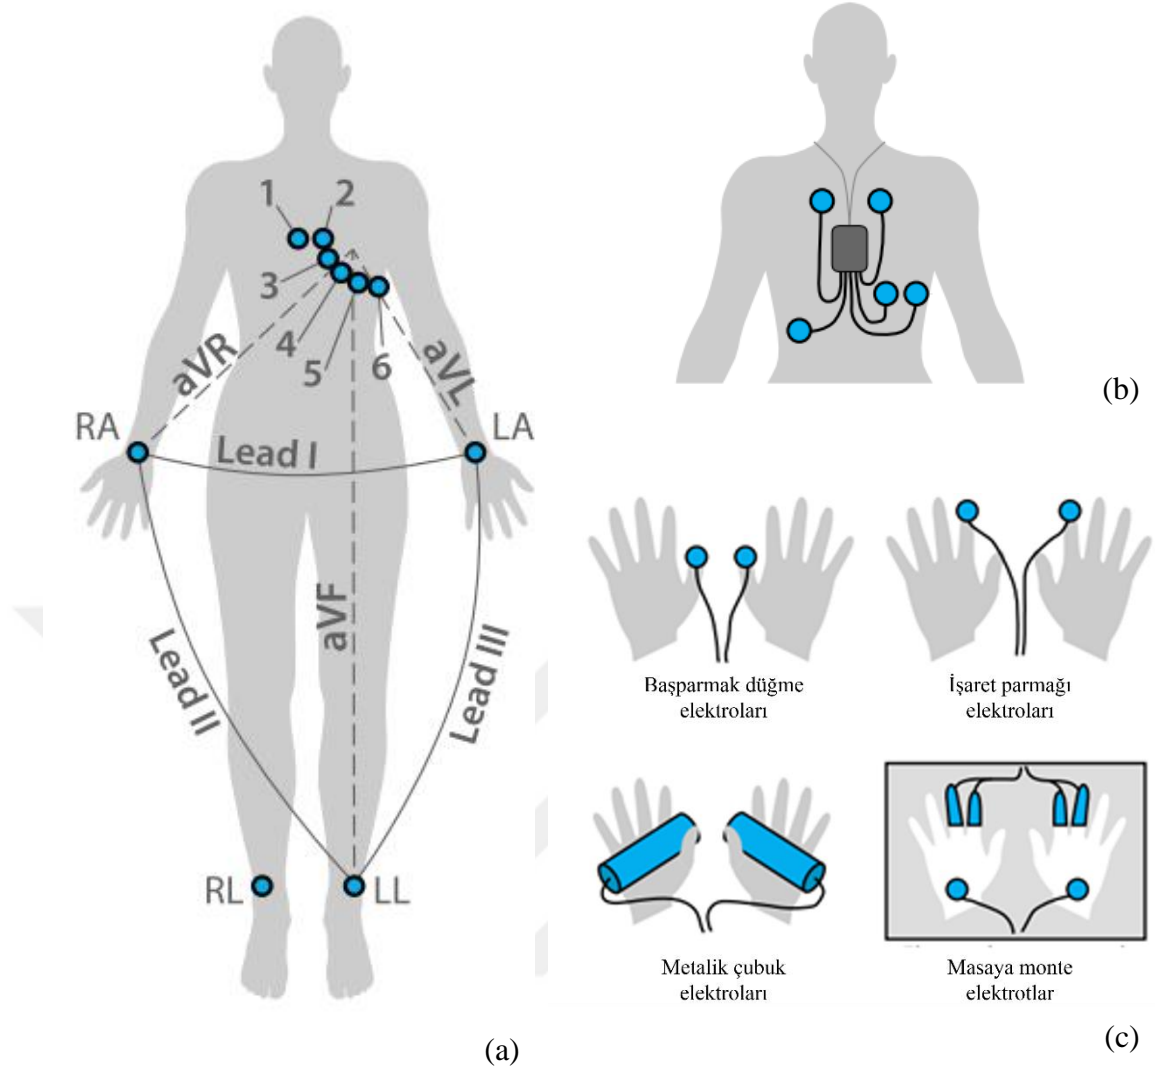
Elektrokardiyogram (EKG) işareti, kalbin kasılıp gevşeme hareketleri sonucu ortaya çıkan her kişinin anatomik yapısı ile ilişkili olan ve bu nedenle ayırt edici özelliğe sahip olan fizyolojik bir biyometrik işarettir [3]. EKG dalga formu, hastalıkların teşhisinde kullanılması için faydalı bir referanstır. Bunun yanı sıra kişi tanıma sistemlerinde kullanılmak üzere birçok çalışma yapılmıştır ve hala yapılmaya devam edilmektedir [4]. EKG işaretinin biyometrik özellik olarak tercih edilme sebepleri, evrensel olması, basit bir biçimde elde edilebilir olması ve doğası gereği yaşam işareti olmasıdır. Fakat bununla birlikte bir takım zayıf yanları da bulunmaktadır. Bunlar, EKG işaretinin elde edilebilmesi için temas gerektirmesi ve zaman içinde değişkenlik gösterebilmesidir [3]. EKG işareti bazı özel durumlardan etkilenebilen bir işarettir. Bu özel durumlar gürültü (sinyali algılayan sensörlerin konumlandırıldığı yer, bilgilerin toplandığı kanaldaki girişimler, ölçüm yapan elektrotların konumlandırıldığı yerden sapmaları, kullanılan ölçüm aletleri vb.), kişisel değişkenlikler (kişinin sağlık durumu, kalp hızındaki değişkenlik, egzersiz, duygusal durum, kullanılan ilaçlar vb.), kalp yapısı ve dokusu gibi sebepler nedeniyle ortaya çıkmaktadır [4]. Kalbin kasılıp gevşeme hareketleri sonucu ortaya çıkan elektriksel akımlar EKG işaretini ortaya çıkarır ve vücuttaki elektrotlar aracılığı ile ölçülebilir. Bu elektriksel işaret birkaç farklı dalgadan (P,Q,R,S ve T dalgaları) meydana gelmektedir ve normal koşullarda bu dalgalar periyodik olarak birbirini tekrar etmektedir. Şekil 2.3'te P, Q, R, S ve T dalgalarının kalbin fizyolojik

olarak depolarizasyon ve repolarizasyon aşamaları nedeni ile ortaya çıktığı gösterilmektedir [3].



Şekil 2.3 : EKG dalga formunun oluşum aşamaları [3].

EKG işaretini kalp hastalıklarının teşhisinde kullanmak için genellikle 12-Kanallı EKG ölçümü kullanılır. Bu standart ölçümde 10 adet elektrot kullanılarak 12 farklı yöndeki potansiyel farkları vektörel olarak toplanır. Standart 12-kanallı ölçümün yanında daha az elektrotta sahip ve hareket limiti problemini ortadan kaldıran ölçüm cihazı olarak Holter cihazı kullanılmaktadır. Holter cihazının sahip olduğu elektrot sayısının 12-Kanallı EKG ölçümüne kıyasla daha az sayıda olması tıbbi ölçümler için kolaylık sağlamak ve tercih sebebi olmaktadır. Ancak bu cihazda kullanılan elektrot sayısının yeterince az olmaması sebebi ile bu yöntem biyometrik uygulamalar için pratikte pek elverişli olmamaktadır. Bu sebeple elektrot sayısı az olan, kullanımı basit, yeni ölçüm yöntemleri geliştirilmiştir. Bu yeni yöntemlerde, öncekilerde kullanılan ıslak elektrotlar yerlerini kuru elektrotlara bırakmıştır ve elektrot sayıları iki veya üç elektroda kadar düşürülmüştür. Bu elektrotlar bilekler, el ve parmaklardan ölçümler alabilmektedir [3]. Bahsedilen üç farklı EKG ölçüm yöntemlerine ilişkin görseller Şekil 2.4'te gösterilmiştir.



Şekil 2.4 : EKG sinyalinin ölçüm yöntemleri : (a) 12-Kanallı EKG (b) Holter cihazı (c) Pratik yöntemler [3].

3. LİTERATÜR ARAŞTIRMASI

3.1 EKG Tabanlı Biyometrik Tanıma Yöntemleri

EKG işaretinin sınıflandırılması probleminde farklı öznitelik çıkarımı ve sınıflandırma yöntemleri üzerine çalışmalar yapılmıştır. Bu çalışmalarda zaman ve genlik belirten öznitelikler [5,6], şablon eşleşme metodu ile çıkarılan özilinti katsayılarından oluşan öznitelikler [7,8], her bir kalp döngüsünden elde edilen öznitelikler [9], iki boyutlu kalp vektöründen elde edilen öznitelikler [10], EKG bölütlerine ilişkin özilinti dizilerine Ayrık Kosinüs Dönüşümü'nün (Discrete Cosine Transform-DCT) uygulanması ile elde edilen öznitelikler [11,12,53,54], Dalgacık Dönüşümü (Wavelet Transform) kullanılarak elde edilen öznitelikler [13,14], EKG işaretinin Doğrusal Tahmini Kodlama (Linear Predictive Coding-LPC) spektrumundan elde edilen öznitelik setleri [15], veri madenciliği ile elde edilen öznitelikler [16], Darbe Aktif Oranı (Pulse Active Ratio-PAR) yöntemi ile elde edilen öznitelikler [17], kepstum (cepstrum) öznitelikleri [12], Hermite Polynomial Expansion (Hermite Polinom Katsayıları) [18], Güç Spektrum (Cepstral Features) özellikleri [18] kullanılmıştır. Ayrıca sınıflandırma yöntemi olarak Çok Değişkenli Analiz (Multivariate Analysis) yöntemi [5], Sinir Ağı Tabanlı Karar Verme yöntemi (Decision-Based Neural Network-DBNN) [7], Doğrusal Ayrıcı Analizi (Linear Discriminant Analysis-LDA) [9,53,54], Ortalama Karesel Hata [8], Temel Bileşenler Analizi (Principles Component Analysis-PCA) [19], Destek Vektör Makineleri (Support Vector Machine-SVM) [18], Gauss Karışım Dağılımı (Gaussian Mixture Model-GMM) [18], Derin Sinir Ağı (Deep Neural Network-DNN) [14] kullanılmıştır.

Makine öğrenmesi çalışmalarının yaygınlaşmaya başlaması ile çeşitli yapay zeka çözümleri, EKG işaretinden öznitelik şablonlarının oluşturulması ve sınıflandırılması probleminin çözümünde başarılı sonuçlar vermiştir. Lei vd. tarafından 2016 yılında yapılan çalışmada, 100 kişiden elde edilmiş EKG sinyallerinden Evrişimsel Sinir Ağı (ESA) mimarisi (1B-ESA) ve 1 adet frekans domeni öznitelik çıkarım modülü kullanılarak öznitelik vektörleri elde edilmiştir. 1x160 uzunluğunda elde edilen

birleştirilmiş öznitelik vektörü kullanılarak lineer olmayan SVM sınıflandırıcısı ile sınıflandırma başarımı %99.33 olarak hesaplanmıştır [20]. 2017 yılında Zhang vd. tarafından sınıf sayısı 18 ile 47 arasında değişen farklı EKG veritabanları kullanılarak 1B-ESA mimarisi ile bir çalışma gerçekleştirilmiştir. EKG işaretlerine dalgacık dönüşümü ve özilinti fonksiyonu uygulanmasının ardından 4 adet evrimsel katmanın N adet paralel bağlantısı ve 1 adet tam bağlantılı katmandan oluşan mimari girişine verilmiştir ve ortalama kişi tanıma oranı % 93.5 hesaplanmıştır [21]. 2017 yılında Eduardo vd. tarafından yapılan çalışmada, 709 kişiden oluşan bir veritabanı kullanılarak EKG işaretine ait öznitelikler derin otokodlayıcı (deep autoencoder) ile çıkarılmış olup sınıflandırma problemi için K-En Yakın Komşu (K-Nearest Neighbourhood, K-NN) yöntemi kullanılmıştır. Çalışma sonucunda tanıma hatası %0.91'e ulaşmıştır [22]. Salloum vd. tarafından 2017 yılında yapılan çalışmada, öznitelik ve sınıflandırma yöntemi olarak Tekrarlı Sinir Ağı (Recurrent Neural Networks-RNNs) kullanılmış olup ECG-ID ve MIT-BIH Arrhythmia (MITDB) veri tabanları üzerinde sistem testi gerçekleştirilmiştir. Bu veritabanlarındaki 47 ve 90 sayıdaki sınıflar için modelin test başarımı neredeyse %100'e ulaşmıştır [23]. 2017 yılında Zhang vd. tarafından yapılan çalışmada, 1 boyutlu EKG işareti 2 boyuta dönüştürülerek 200x200 boyutlarında imgeler (yörüngeler) elde edilmiş, 3 adet evrimsel katman ve 2 adet tam bağlantılı katmandan oluşan mimari ile 10 kişinin sınıflandırma başarımı %98.4 olarak hesaplanmıştır. Veri yanlılığı problemini ortadan kaldırmak için ise 10 katlamalı çapraz doğrulama kullanılmıştır [24]. 2018 yılında Luz vd. tarafından sunulan çalışmada, 2 farklı model ile elde edilen sonuçlar skor seviyeli birleştirme tekniği ile birleştirilmiş ve %14 eşit hata oranı (equal error rate) elde edilmiştir. Bu çalışmada EKG işareti R noktalarına göre hizalanarak 1 boyutlu QRS işaretleri elde edilirken diğer taraftan bu QRS işaretlerinin spektogramı alınmış ve bu giriş verileri sırası ile 1B-ESA ve 2B-ESA modellerine verilmiştir [25]. Labati vd. tarafından yapılan çalışmada, 52 kişi için daha önceki bazı yöntemlerde olduğu gibi EKG işaretinden QRS bölümleri elde edilmiş ve bu işaretler arasındaki özilinti katsayıları hesaplanmıştır. Bu katsayılar referans alınarak bazı QRS işaretleri seçilerek ardarda eklenilmiş ve tek boyutlu bir özilinti vektörü elde edilmiştir. Giriş olarak kullanılan bu vektör, geliştirilen 1-B ESA mimarisine giriş olarak verilmiş ve %100 oranında kişi tanıma başarımı elde edilmiştir [26]. 2018 yılında Abdeldayem vd. tarafından yapılan çalışmada, EKG işaretine Kısa Süreli Fourier Dönüşümü (Short-Time Fourier Transform-STFT) ve Sürekli Zaman Dalgacık Dönüşümü

(Continuous Wavelet Transform-CWT) uygulanarak geliştirilen 2B-ESA mimarisine giriş olarak verilmiştir. STFT ve CWT imgeleri için sırası ile sistemin ortalama tanıma oranı %97.85 ve %97.50'dir [27]. 2019 yılında Hammad vd. tarafından sunulan çalışmada ise EKG işareti ve parmak izi imgeleri kullanılarak biyometrik tanıma sistemi performansı değerlendirilmiştir. Bu çalışmada, 1-B ESA mimarisi ile EKG işaretleri tek boyutlu olarak kullanılarak öznelik çıkarımı gerçekleştirilmiş olup parmak izi işaretleri için ise 2B-ESA mimarisi kullanılmıştır. Her iki biyometrik işaretten elde edilen öznelik vektörleri Q-Gauss Çok Sınıflı Destek Vektör Makinesi sınıflandırıcısı (Q-Gaussian Multi-Class Support Vector Machine-QG-MSVM) kullanılarak sınıflandırılmış, skor birleştirme yöntemi ile birleştirilmiş ve sistem doğruluk oranı %99.99 olarak hesaplanmıştır [28].

3.2 Yüz Tabanlı Biyometrik Tanıma Yöntemleri

Yüz tanıma probleminde derin öğrenme tekniklerinin kullanılmaya başlanmasından önce bu problemin çözümü için birçok çalışma yapılmıştır [29]. Bu yöntemler, Geometrik Karakteristik Yöntemi (Geometrical Characteristic Method) [30], Altuzay Analiz Yöntemi (Subspace Analysis Method) [31], Elastik Grafik Eşleştirme Yöntemi (Elastic Graph Matching Method) [32], Saklı Markov Modeli (Hidden Markov Model) [33] yöntemleridir. 1960'lerden sonra yüz tanıma problemine uygulanan en yaygın modellere örnek olarak Radyal Temelli Fonksiyon Sinir Ağı (Radial Basis Function - RBF) [34], Evrişimsel Sinir Ağları [35], Derin Bayes Ağı (Deep Belief Network-DBN) [36] ve Yığın Gürültü Giderici Otokodlayıcı (Stacked Denoising Autoencoder- SDAE) [37] verilebilir [29]. Yapay zeka tekniklerinin yüz tanıma problemine uygulanmaya başlaması ile farklı sinir ağı mimarileri geliştirilmiştir. 2012 yılında Krizhevsky vd. tarafından Evrişimsel Sinir Ağları yönteminden AlexNet Mimarisini kullanarak 1000 farklı sınıfa ait 1.2 milyon yüksek çözünürlüklü resim kullanılmış, ağ eğitilmiş ve test edilmiştir. Büyük hacimli ESA'ların kullanılmasındaki en büyük problemlerden biri olan ezber sorununun önüne geçmek için ise veri çoğullama yöntemi kullanılmış ve mimariye seyreltme katmanı eklenmiştir. Sistemin test kümesine ait hata oranı %37.5 olarak hesaplanmıştır [38]. 2015 yılında Simonyan vd. tarafından gerçekleştirilen bir çalışmada ise 1000 sınıfın tanımlı olduğu veritabanı (ILSVRC-2012) kullanılarak çok sayıda evrişim katmanı içeren evrişimsel ağ modeli eğitilmiş, ILSVRC 2014 yarışmasında bu geliştirilen

VGGNet modeli ile hata oranı %25.5'e ulaşılmıştır [39]. 2017 yılında, An vd. tarafından yapılan çalışmada sınıflandırma ve yer tespiti işlemlerini gerçekleştiren iki kanallı ESA modeli geliştirilmiştir. Kaskat ve iki kanallı Evrişimsel Sinir Ağı (Convolutional Neural Network-CNN) modeli, 25 kişiye ait 48 video bölümünden elde edilen 800x600 boyutlarındaki 64.204 yüz imgesi kullanılarak eğitilmiş ve test edilmiştir. Bu çalışma sonucunda %91.0 test doğruluk oranına ulaşılmıştır [40].

3.3 EKG ve Yüz Çoklu Biyometrik Tanıma Yöntemleri

Literatürde EKG ve yüz verilerinin birlikte kullanıldığı çoklu biyometrik tanıma çalışmaları oldukça sınırlı sayıdadır. Bu çalışmalardan, 2003 yılında Israel vd. tarafından EKG ve yüz işaretlerini birlikte kullanan geleneksel bir biyometrik tanıma sistemi önerilmiştir. 15 sınıfa ait öznitelik vektörlerinin birleştirilmesi ile modellenen sisteme ait başarımlar sonucu %99'dur. [41]. 2011 yılında Boumbarov vd. tarafından önerilen EKG ve yüz tanıma sisteminde ise 19 kişi için çoklu biyometrik tanıma sistemi geliştirilmiştir. Bu çalışmada R noktalarına göre hizalanmış olan EKG işaretinin sınıflandırılmasında Radyal Bazlı Sinir Ağı (Radial Basis Neural Network) kullanılırken, yüz imgelerinin sınıflandırılması için ise Destek Vektör Makinası (Support Vector Machine-SVM) sınıflandırıcısı kullanılmıştır. Her iki sınıflandırıcının birleşimi ise Çarpım Kuralı (Product Rule) ile yapılmış olup %99.5 sınıflandırma başarımları elde edilmiştir [42]. EKG ve yüz verilerinin birlikte kullanıldığı en yeni çalışma Chakraborty vd. tarafından 2017 yılında sunulan çoklu biyometrik tanıma sistemidir. Ortalama Karesel Sapma (Mean Square Deviation-MSD) algoritmasına dayanan bu çalışma EKG ve yüz imgelerinden oluşan veri kümeleri üzerinde test edilmiş ve ayrı ayrı olmak üzere %95 oranında tanıma başarımları elde edilmiştir. 40 kişiye ait EKG ve yüz imgelerinden elde edilen öznitelik şablonlarının kombinasyonu kullanılarak %97.5 oranında tanıma oranı elde edilmiştir [43]. Bahsedilen üç çalışmaya ait karşılaştırma, Çizelge 3.1'de gösterilmiştir.


Çizelge 3.1 : EKG ve yüz işaretlerinin birlikte kullanıldığı çoklu biyometrik sistemler [3]. KTO: Kişi Tanıma Oranı, D: Doğruluk.

Yazar	Yıl	EKG Veritabanı	Yüz Veritabanı	Sınıf Sayısı	Sınıflandırıcı	Birleştirme	Sonuçlar
Israel vd. [41]	2003	SAIC's laboratuvarında bireysel olarak oluşturulmuştur.	Digital Kamera ile yapılan çekimler ile oluşturulmuştur.	15	Öklit Mesafesi (Euclidian Distance)	Öznitelik Karar Skor	KTO %99
				15			KTO %94
				15			KTO %66
Boumbarow vd. [42]	2011	Laboratuvarında bireysel olarak oluşturulmuştur.	Caltech-CV-Group, 1999	19	EKG: Radyal Temelli Sinir Ağı (Radial Basis Neural Network); Yüz: Destek Vektör Makineleri (Support Vector Machine)	Skor	D %99.5
Chakraborty vd. [43]	2017	İki kanallı BiopacMP 45 kullanılarak oluşturulmuştur.	Digital Kamera ile çekilen profil fotoğraflarında n oluşmaktadır.	40	Ortalama Karesel Sapma (Mean Square Deviation)	Öznitelik	D %97.5

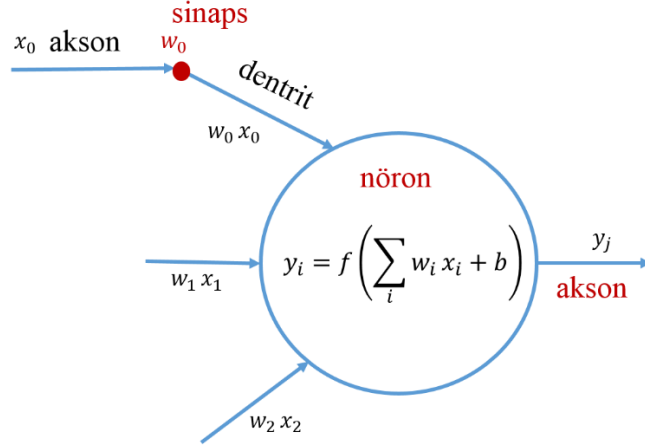
4. EVRİŞİMSEL SİNİR AĞLARI (ESA)

4.1 Biyolojik Nöronların Matematiksel Modellenmesi

Araştırmacılar tarafından temel işlem biriminin nöronlar olduğu savunulmakta ancak hala henüz tam olarak detayları açıklanamamaktadır. Biyolojik nöronların sahip olduğu dentrit ve akson olarak isimlendirilmiş bölümleri birbirleri ile haberleşmektedirler (Şekil 4.1). Bir nöronun dentrit bölümü tarafından algılanan işaret nöronda değerlendirildikten sonra elde edilen çıkış işareti akson tarafından diğer bir nöronun dentrit bölümüne iletilir. Yani bir nöron genel olarak giriş kanalları dendritler, çıkış kanalı ise akson olan basit bir sistem olarak düşünülebilir. Bu dentrit ve akson dalları arasındaki bağlantı noktalarına ise sinaps adı verilir. Sinapsın temel özelliği gelen x_i sinyalini ölçekleyebilmesidir. Bu ölçeklendirme w_i ağırlık katsayıları olarak modellenmektedir (Şekil 4.2). İnsan beyninin bu sinir hücrelerindeki sinaps noktalarındaki ağırlıklarda meydana gelen değişiklikler neticesinde öğrenmeyi gerçekleştirdiği kabul edilmektedir [44].



Şekil 4.1 : Beyindeki bir nöronun bağlantıları [45].




Şekil 4.2 : Bir nöronun matematiksel modellenmesi [44].

İnsan beyninin yaklaşık 86 milyar nöron ve 500 trilyondan fazla bağlantıya sahip olduğu araştırmacılar tarafından belirtilmiştir [45]. Bugün en büyük yapay zeka ağları bile bu sayıdan daha az nörona sahiptirler. Yapay sinir ağlarını oluşturan ana birim olan nöronlar beynin sahip olduğu biyolojik nöronların yapısı ve işleyişi modellenerek oluşturulmuştur. Bu yapay nöronlar, biyolojik nöronlarda olduğu gibi girdilere ve dönüşüm fonksiyonlarına sahiptirler [45]. Sinir ağları temelde nöronların gerçekleştirdiği, giriş değerlerinin ağırlıklandırılmış toplamı esasına dayanır. Ayrıca bu ağırlıklandırılmış toplamlara basit bir dönüşüm fonksiyonu (Örneğin, Sigmoid, Hyperbolic Tangent, ReLU, Leaky ReLU, Exponential LU) uygulanır [44].

4.2 Derin Sinir Ağları (Derin Öğrenme)

Şekil 4.3'te görüldüğü üzere temel bir sinir ağı giriş katmanı, çıkış katmanı ve bir veya birden çok gizli katmandan oluşmaktadır. Bu gizli katman(lar)dan elde edilen ağırlıklandırılmış öznitelikler çıkış katmanına iletilir. Sinir ağlarının bir altkümüsi olan derin sinir ağları birden çok gizli katmanın yer aldığı yapay sinir ağları olarak tanımlanmıştır ve gizli katman sayısı güncel uygulamalarda 5 ile 1000'ler arasında değişmektedir. Ağda çok sayıda gizli katmanın bulunması sebebiyle de derin sinir ağları daha yüksek karmaşıklığa sahip üst seviye özellikleri öğrenebilme yeteneğine sahiptir [44].



Şekil 4.3 : Temel bir sinir ağı örnek blok diyagramı.

Derin Öğrenme - Yapay Zeka ilişkisi Şekil 4.4'te gösterilmiştir. Derin Öğrenme Makine Öğrenmesinin alt kümesi iken, Makine Öğrenmesi de Yapay Zeka'nın bir altkümesidir [45].



Şekil 4.4 : Yapay Zeka-Derin Öğrenme ilişkisi [44].

Derin Sinir Ağları'nın tarihsel gelişimi Çizelge 4.1'de sunulmuştur [44].

Çizelge 4.1 : Derin Sinir Ağı - DSA Tarihsel Gelişimi [44].

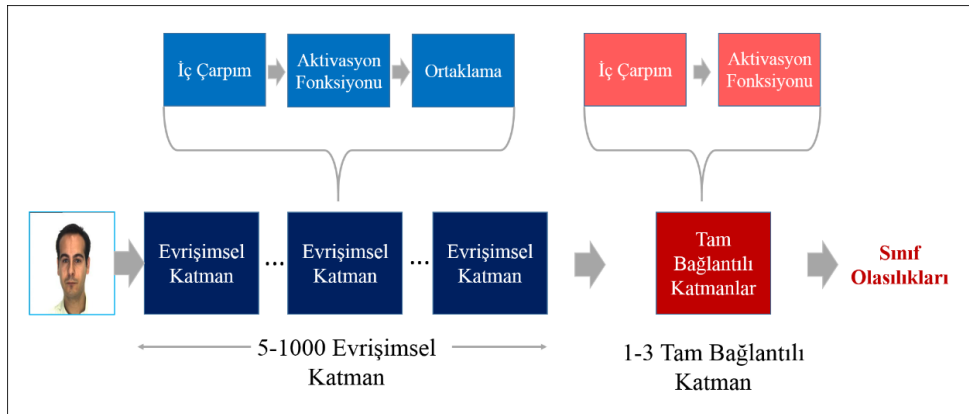
Yıl	Gelişim
1940' lar	Sinir Ağları'nın önerilmesi
1960' lar	Derin Sinir Ağları'nın önerilmesi
1989	Rakam Tanıma için Sinir Ağı tanımlanması (LeNet)
1990' lar	Basit sinir ağları için donanım geliştirilmesi (Intel ETANN)
2011	Derin Sinir Ağı Tabanlı konuşma tanınmanın bulunması
2012	Derin Sinir Ağları yaklaşımının geleneksel yöntemlerin yerini alması (AlexNet)
2014+	Derin Sinir Ağları araştırmalarının artışı (Neuflow, DianNao...)

4.3 Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (ESA) geniş kullanım alanlarına (imge tanıma, ses tanıma, robotik vb.) sahip olan, bir veya birden fazla gizli katmana sahip olabilen ve böylelikle de yüksek seviyede öznelikler üretebilen mimarilerdir. Bu yüksek seviyeli özneliklere öznelik haritası (feature map-fmap) adı verilmektedir [44].

ESA'ların sahip olduğu katmanlardaki nöronlar klasik sinir ağlarında olduğu gibi öğrenme kabiliyetine sahip ağırlık katsayılarına sahiptirler. Şekil 4.1'de olduğu gibi her bir nöron giriş değerlerini ve ağırlık katsayılarını iç çarpım işlemine tabi tutup sonuca doğrusal olmayan bir fonksiyon (aktivasyon fonksiyonu) uygular. Tüm ağ katmanları birer skor fonksiyonuna sahiptir ve çıkış katmanı (tam bağlantılı katman) ise kayıp fonksiyonuna sahiptir [46].

ESA'larda girişler 2 veya 3 boyutlu verilerden oluşmaktadır ve katmanlar genişlik, yükseklik ve derinlik boyutlarında düzenlenmiş nöronlara sahiptirler. Nöronlar kendinden önceki katmanın sadece küçük bir bölümü ile ilişkilendirilir ve eğer sınıflandırma da ESA ile gerçekleştirilecek ise ağın son katmanı sınıf sayısı kadar nöron içermektedir. ESA'lar katman dizilerinden oluşmaktadır ve her katmanda işlem hacmi dönüştürülmektedir. ESA mimarisinde yer alan katman çeşitleri Evrişimsel katman, Maksimum Ortaklama katmanı ve Tam Bağlantılı katmandır. Genel bir ESA mimarisi Şekil 4.5'te gösterilmiştir [46].



Şekil 4.5 : Derin ESA mimarisi [44].

Özetle Evrişimsel Ağlar'da katmanlar aracılığı ile orijinal imgelerden sonuç sınıf olasılıkları hesaplanmaktadır. Bu işlem temel olarak Şekil 4.5'te gösterilen katmanlar aracılığı ile gerçekleştirilir ve evrişimsel katmanlarda 3 boyutlu hacme sahip katman girişlerinden yine 3 boyutlu katman çıkışları elde edilir. Ayrıca Evrişimsel ve Tam


Bağlantılı katmanlar bazı parametrelere sahiptir. Ancak aktivasyon katmanları ve maksimum ortaklama katmanları herhangi bir parametreye sahip değildir. Evrişimsel ve Tam Bağlantılı katmanlarda nöronların sahip olduğu parametreler Dereceli Azalma (Gradient Descent) algoritması ile güncellenmektedir. Böylece evrişimsel ağa ait sınıf skorları her bir imgeye ait eğitim setindeki etiketlere uygun hesaplanabilmektedir. ESA'lardaki evrişimsel katmana ait parametreler öğrenilebilir parametrelerdir [46].

Eğitim kümesindeki doğru sınıflara ait skorların maksimumda tutulması ve yine yanlış sınıflara ait skorların minimumda tutulması ESA mimarilerinin görevidir. Bu görev ağırlık katsayılarının, w_i , iyileştirilmesi ile gerçekleştirilmektedir. Ağı eğitirken eğitim örneklerine ait doğru etiketler bilindiği için, ESA tarafından (mevcut ağırlık katsayıları ile) tahmin edilen etiketler ile eğitim kümesinde tanımlı gerçek sınıf etiketleri arasındaki fark, kayıp (loss) fonksiyonu ile hesaplanır. Böylece tüm eğitim kümesinin ortalama kayıp değerini minimuma çekecek ağırlık katsayıları bulunur. Bu ağırlıklar genellikle Dereceli Azalma algoritması ile güncellenmektedir. Dereceli Azalma algoritması iteratif bir algoritma olup, ağırlık katsayılarının güncellenme işlemi denklem 4.1'de belirtildiği şekilde gerçekleştirilir.

$$w_{ij}^{t+1} = w_{ij}^t - \alpha (dL/dw_{ij}), \alpha = \text{öğrenme hızı} \quad (4.1)$$

Burada, w_{ij} , i. katmandaki j. nöronun ağırlık katsayısını, t iterasyon adımını, α öğrenme hızını, L ise kayıp fonksiyonunu belirtmektedir. Denklem 4.1'de görüldüğü gibi Dereceli Azalma algoritması kayıp fonksiyonunu minimum yapacak en iyi ağırlık katsayılarını bulmaya çalışmaktadır. Her bir iterasyonda parametrelerin güncellenme işlemi ise o andaki ağırlık katsayısının değerinden kayıp fonksiyonunun türevinin küçük bir sayı ile (öğrenme hızı) çarpılarak çıkarılması şeklinde gerçekleştirilmektedir. Öğrenme hızı parametresi, ne kadar büyük adımlarla en iyi parametrelerin bulunacağını kontrol etmekte olup genellikle küçük değerler seçilmesi gerekmektedir. Aksi takdirde kayıp fonksiyonunun minimum noktasına ulaşmak yerine (yakınsama) iraksama ihtimali ortaya çıkmaktadır.

Evrişimsel katmanda ise Şekil 4.6'da gösterildiği gibi pencereleme işlemi kullanılarak 2 boyutlu evrişim (konvolüsyon) işlemi gerçekleştirilir. Giriş işaretinin ilgili alanına uygulanan süzgeç ile ağırlıklandırılmış bir toplam elde edilir ve çıkış işareti olarak kaydedilir [44].



Şekil 4.6 : 2-boyutlu evrişim işlemi.

ESA’larda her bir süzgeç 2 boyuta sahiptir ve giriş hacminin derinliği ile aynı derinliktedir. İlk evrişimsel katmanın girişine $W \times W \times 3$ boyutunda RGB seviyeli bir imge verildiği zaman, katmanda tanımlı süzgeç seti giriş hacminin genişliği ve yüksekliği boyunca tüm konumlarında kaydırılarak iç çarpım işlemi gerçekleştirilir. Ayrıca bu katmandaki süzgeç sayısı K olarak tanımlanmış ise bu katman K adet 2 boyutlu çıkış özneteliği oluşturacaktır [46]. Bir evrişimsel katmanda gerekli olan parametre tanımları Çizelge 4.2’de özetlenmiştir.

Çizelge 4.2 : Bir evrişimsel katman için parametre tanımlamaları [46].

Parametre	Açıklama
$(W1 \times H1 \times D1)$	Giriş işareti boyutları
$(W2 \times H2 \times D2)$	Çıkış işareti boyutları
F	Uygulanan 2 boyutlu süzgecin 1 boyutu
S	Uygulanan süzgeçlerin imge üzerinde kaydırma miktarı
P	Giriş işaretinin kenarlarına “0” elemanı ekleme miktarı
K	Uygulanan süzgeç sayısı
$C=D1$	Uygulanan süzgecin kanal sayısı (3. boyutu)

Çizelge 4.2’deki parametreler kullanılarak evrişimsel katman çıkışı boyutu hesaplanabilmektedir. Buradan yola çıkarak katman çıkışının boyutları denklem 4.2, 4.3, 4.4 ile ifade edilmektedir [46].

$$W_2 = (W_1 - F + 2P)/S + 1 \quad (4.2)$$

$$H_2 = (H_1 - F + 2P)/S + 1 \quad (4.3)$$

$$D_2 = K \quad (4.4)$$

Bir evrişimsel katmanda kullanılan bir süzgecin parametre sayısı denklem 4.5 ile ifade edilirken, aynı zamanda evrişimsel katmandaki nöron sayısı olarak da tanımlanır. K tane tanımlı süzgeç için bu sayı denklem 4.6 ile hesaplanabilir [46].


$$F.F.D_1 \quad (4.5)$$

$$(F.F.D_1).K \quad (4.6)$$

Evrişimsel katmana ait bir süzgecin parametre sayısı denklem 4.5 ile ifade edilirken katmana ait tüm parametrelerin sayısı denklem 4.7 ile hesaplanır [46].

$$A = W_2.H_2.D_2(F.F.D_1 + 1) \quad (4.7)$$

Ortaklama katmanı genel olarak evrişimsel katmanlarının arasında konumlandırılır. Bu katman ağı işlem hacmini ve parametre sayısını dolayısıyla ezber sorununu azaltır. Bu katman, giriş verisinin belirlenmiş bölgesinin en büyük değere sahip değerini seçip giriş hacmini yarıya indirgeyerek ortaklama işlemini gerçekleştirir [46]. $(W_1 \times H_1 \times D_1)$ boyutlarında giriş verisine sahip bir maksimum ortaklama katmanında süzgeç boyutu $F \times F$, kaydırma S olarak tanımlanmış ise, katman çıkışı boyutu $((W_1-F)/S + 1, (H_1-F)/S + 1, D_1)$ olarak hesaplanır. Genellikle $F=2$ ve $S=2$ değerleri kullanılır. Bu değerler için ortaklama işlemi Şekil 4.7’de gösterilmiştir [46].



Şekil 4.7 : Maksimum ortaklama katmanı örnek gösterimi.

Tam Bağlantılı katman girişlerinde, 3 boyutlu giriş işareti 1 boyutlu vektör haline dönüştürülür. Bu işleme düzleştirme denir. Böylelikle son evrişimsel katmanın çıkış boyutunu $(W_1 \times H_1 \times D_1)$, nöron sayısını ise K olarak ifade edersek, evrişimsel katman(lar)dan sonra ilk gelen tam bağlantılı katman girişi boyutu $(1, W_1.H_1.D_1)$, katman çıkışı boyutu ise $(1, K)$ olarak gösterilir.

Eğer evrişimsel katmana ait P ve S parametreleri ile karşılaştıracak olursak Tam Bağlantılı Katman parametreleri $P = 0, S = 1$ olarak ifade edilebilir [46].

5. MATERYAL VE YÖNTEM

5.1 Veri Tabanları


5.1.1 EKG veri tabanı

Bu çalışmada, 47 farklı kişiye ait 48 tane EKG işaretinden oluşan MIT-BIH Arrhythmia veri tabanı kullanılmıştır. Bu veri tabanında her bir EKG işareti 30 dakika uzunluğuna sahip olup 360 Hz frekansında örneklenmiştir. Bu veri tabanı yaşları 32 ile 89 arasında değişen 25 erkek, yaşları 23 ile 89 arasında değişen 22 kadından oluşmaktadır. Bu veritabanında 201 ve 202 numaralı kayıtlar aynı kişiye aittir [47,48,49].

Bu çalışmada önerilen her iki yöntemde de MIT-BIH Arrhythmia veri tabanındaki 47 kişi içerisindeki 108 numaralı hariç tutularak (veri yetersizliği nedeni ile) 46 kişi kişiden alınmış işaretler kullanılmış ve sunulan modelin sistem performansı değerlendirilmiştir.

5.1.2 Yüz veri tabanı


Bu çalışmada 70 erkek ve 56 kadına ait toplam 126 kişinin renkli resim verilerini içeren AR Face veri tabanı kullanılmıştır. Bu veri tabanında her bir kişi için 26 adet renkli resim verileri bulunmaktadır. Bu veritabanındaki resimler kişilerin farklı yüz ifadeleri, ışık koşulları, güneş gözlüğü veya şal aksesuarları kullanılarak çeşitlendirilmiştir. Her bir kişi için 26 resim kaydedilmiştir. Bu resimlerin ilk 13 tanesi kaydedildikten 14 gün sonra diğer 13 resim kaydedilmiştir [50].



Şekil 5.1 : AR Face veri tabanına ait örnek resimler [50].

5.2 Önerilen Yöntem-1: Evrişimsel Sinir Ağı Tabanlı EKG Biyometrik Tanıma Yöntemi

Bu çalışmada önerilen birinci yöntem Evrişimsel Sinir Ağı (ESA) tabanlı EKG biyometrik tanıma yöntemidir. Bu yöntem biyometrik tanıma amacıyla sadece EKG işaretlerini kullanmaktadır. Önerilen yöntemin blok diyagramı Şekil 5.2’de gösterilmiştir. Şekil 5.2’de verilen blok diyagramdan görüldüğü gibi önerilen yöntem boyut dönüşümü ve normalizasyon işlemlerini içeren ön işleme süreci, veri çoğullama süreci ve ESA tabanlı öznitelik çıkarımı ve sınıflandırma sürecinden oluşmaktadır.



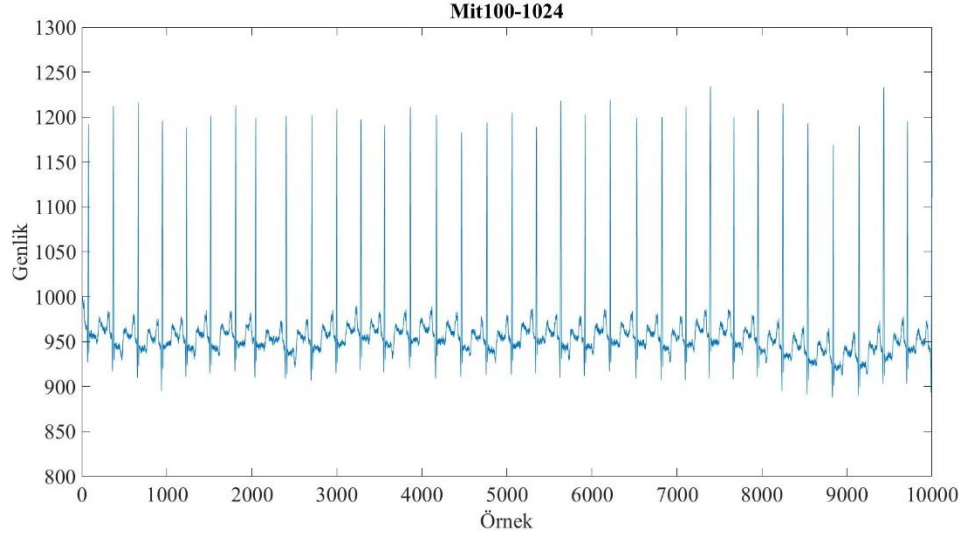
Şekil 5.2 : Önerilen Yöntem-1 olarak adlandırılan ESA tabanlı EKG biyometrik tanıma sistemine ilişkin blok diyagram

5.2.1 Ön işleme

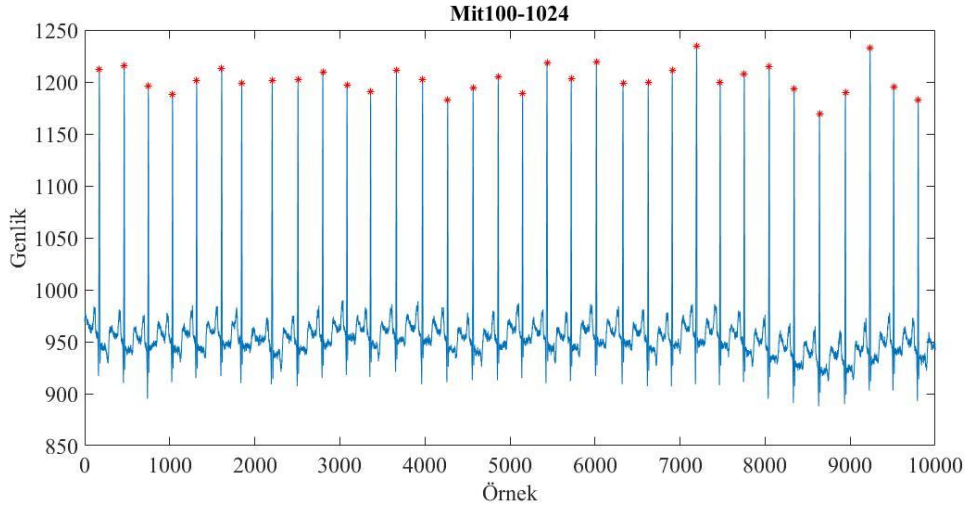
EKG işaretlerini daha başarılı bir şekilde sınıflandırabilmek için bu işaretleri gürültü bileşenlerinden arındırmak son derece önemlidir. Bu nedenle ön işleme sürecinin en başında EKG işaretlerini, şebeke gürültüsünden (50Hz), yüksek frekans gürültülerinden ve taban kayması (baseline wander) gürültüsünden temizlemek amacıyla 1-40 Hz frekans bandına sahip 4. dereceden sayısal Butterworth bant geçiren süzgeç kullanılmıştır. Daha sonra tek boyutlu EKG işaretlerinin Pan-Tompkins QRS belirleme yöntemi [51] ile R noktaları tespit edilmiş ve R noktalarına göre hizalanmış 1x256 boyutunda QRS bölütleri elde edilmiştir. Ardından Şekil 5.3-5.6’da görüldüğü gibi bu tek boyutlu QRS bölütleri %50 örtüşmeli olacak şekilde 256x256x1 boyutunda QRS imgelerine dönüştürülmüştür.

Son olarak her bir QRS imgesinin genlik değerleri denklem 5.1’de ifade edilen Minimum-Maksimum Yöntemi kullanılarak normalize edilmiştir.

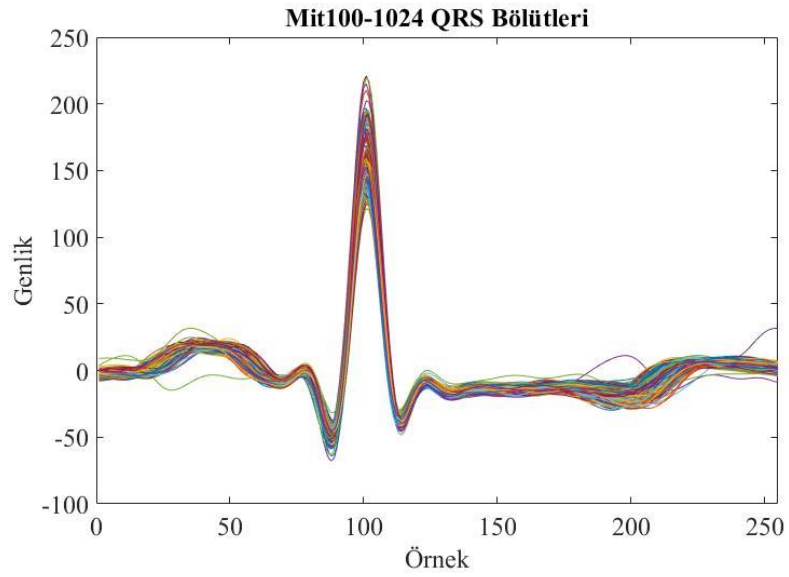
$$y = \frac{x - \max(x)}{\max(x) - \min(x)} \quad (5.1)$$




Şekil 5.3 : EKG işareti.



Şekil 5.4 : QRS belirleme.



Şekil 5.5 : QRS bölütleme.



Şekil 5.6 : 256x256x1 boyutlu QRS imgesi.

5.2.2 Veri çoğullama

Veri eğitim ve test kümelerinin yetersiz olması durumunda yaygınca kullanılan bir yöntem olan veri çoğaltma yöntemi, eğitilen modeli ezberleme problemine karşı korumaktadır [28]. Bu nedenle Önerilen Yöntem-1 için ön işleme süreci sonunda elde edilen 2 boyutlu QRS imgeleri dikey ve yatay aynalama yöntemi kullanılarak 4 kat çoğaltılmıştır.

5.2.3 Öznitelik çıkarımı ve sınıflandırma

Ön işleme süreci sonunda elde edilen QRS imgelerinden öznitelik çıkarımı ve sınıflandırma yapmak amacıyla sınıf sayısı ve veri boyutlarına uygun bir ESA mimarisi geliştirilmiştir. Geliştirilen ESA mimarisinin blok diyagramı Şekil 5.7’de sunulmuştur. Geliştirilen ESA Mimarisi, 4 adet evrişimsel katman, 3 adet tam bağlantılı katman ve 1 adet sınıflandırıcı katmanından oluşurken, her evrişimsel katman ve tam bağlantılı katman çıkışında birer adet maksimum ortaklama ve seyreltme katmanları kullanılmıştır. Evrişimsel katmanlarda doğrultulmuş doğrusal birim (Rectified Linear Unit-ReLU), tam bağlantılı katmanlarda Sigmoid, sınıflandırıcı olarak ise softmax aktivasyon fonksiyonları kullanılmıştır. Şekil 5.8’de gösterilen Sigmoid ve ReLU aktivasyon fonksiyonları sırası ile denklem 5.2 ve denklem 5.3’te görüldüğü biçimde tanımlanır. Denklem 5.2’de ifade edilen Sigmoid aktivasyon fonksiyonu tam bağlantılı katmanlarda, Denklem 5.3’te ifade edilen ReLU aktivasyon fonksiyonu evrişimsel katmanlarda kullanılmıştır.

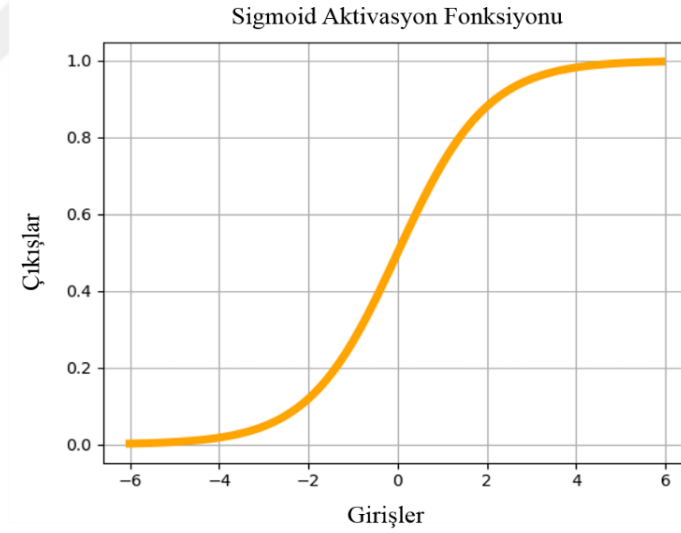
$$y = \frac{1}{1 + e^{-x}} \quad (5.2)$$

$$y = \max(0, x) \quad (5.3)$$

Bu denklemlerde belirtilen belirtilen x deęerleri katman giriř deęerlerini (öznitelikler), y deęerleri ise katmanlardaki nöron çıkıřlarını ifade etmektedir.




(a)



(b)

řekil 5.7 : Aktivasyon fonksiyonları : (a) ReLU (b) Sigmoid.



Şekil 5.8 : Önerilen Yöntem-1 için geliştirilen ESA Mimarisi.


Çizelge 5.1’de geliştirilen ESA mimarisine ait her bir katman için katman tipi, aktivasyon fonksiyonu, süzgeç boyutları, çıkış boyutu ve parametre sayıları verilmiştir.

Çizelge 5.1 : Önerilen Yöntem-1 için geliştirilen ESA Mimarisine ait parametre çizelgesi.


	Katman	Aktivasyon Fonksiyonu	Süzgeç Boyutu	Çıkış Boyutu	Parametre Sayısı
1	Evrişimsel	ReLU	3x3	256x256,32	320
2	Maks. Ortaklama	-	2x2	128x128,32	0
3	Seyreltme (0.2)	-	-	128x128,32	0
4	Evrişimsel	ReLU	3x3	128x128,64	18496
5	Maks. Ortaklama	-	2x2	64x64,64	0
6	Seyreltme (0.2)	-	-	64x64,64	0
7	Evrişimsel	ReLU	3x3	64x64,128	73856
8	Maks. Ortaklama	-	2x2	32x32,128	0
9	Seyreltme (0.2)	-	-	32x32,128	0
10	Evrişimsel	ReLU	3x3	32x32,256	295168
11	Maks. Ortaklama	-	2x2	16x16,256	0
12	Seyreltme (0.2)	-	-	16x16,256	0
13	Düzleştirme	-	-	65536	0
14	Tam Bağlantılı	Sigmoid	-	256	16777472
15	Seyreltme (0.2)	-	-	256	0
16	Tam Bağlantılı	Sigmoid	-	256	65792
17	Seyreltme (0.2)	-	-	256	0
18	Tam Bağlantılı	Sigmoid	-	256	65792
19	Seyreltme (0.2)	-	-	256	0
20	Çıkış	Softmax	-	46	11822
Toplam Parametre Sayısı					17308718

5.3 Önerilen Yöntem-2: Evrimsel Sinir Ağı Tabanlı EKG ve Yüz Çoklu Biyometrik Tanıma Yöntemi (FACECG)

Bu çalışmada önerilen ikinci yöntem ise ESA tabanlı EKG ve Yüz Çoklu Biyometrik Tanıma Yöntemidir. Bu yönteme ait oluşturulan Model 2 blok diyagramı Şekil 5.9'da sunulmuştur. Bu yöntem biyometrik tanıma amacıyla hem EKG işaretlerini hem de yüz imgelerini birlikte kullanmaktadır. Önerilen yöntemin blok diyagramı iki farklı birleştirme yöntemi için Şekil 5.9 ve Şekil 5.10'da ayrı ayrı gösterilmiştir. Şekil 5.9'da verilen blok diyagramdan görüldüğü gibi Önerilen Yöntem-2, EKG ve yüz imgelerini ön işleme sürecinden ve ESA tabanlı öznelik çıkarımı ve sınıflandırma sürecinden geçirdikten sonra elde edilen skorları skor birleştirme yöntemi ile birleştirerek biyometrik tanıma işlemini gerçekleştirmektedir. Şekil 5.10'da ise EKG ve yüz imgeleri ön işleme sürecinden ve ESA tabanlı öznelik çıkarma sürecinden geçirildikten sonra elde edilen öznelikler, öznelik birleştirme yöntemi kullanılarak birleştirilmiş ve biyometrik tanıma işlemi gerçekleştirilmiştir.



Şekil 5.9 : ESA tabanlı çoklu EKG ve yüz biyometrik tanıma sistemi blok diyagramı.



Şekil 5.10 : ESA tabanlı çoklu EKG ve yüz biyometrik tanıma sistemi blok diyagramı.

Her iki yöntemde, kişi tanıma amacıyla EKG işaretlerini kullandığı için aynı zamanda canlılık tespitini de gerçekleştirmektedir. Önerilen Yöntem-2'nin Önerilen


Yöntem-1'e göre üstünlüğü ise iki farklı biyometrik kullanılmasıdır. Böylece sistemin doğruluğu ve güvenilirliği daha yüksek olmaktadır.

5.3.1 Ön işleme

Önerilen Yöntem-2'de EKG ve yüz imgeleri için iki farklı ön işleme süreci uygulanmıştır. EKG işaretleri için Bölüm 5.2.1'de açıklanan ön işleme süreci uygulanmış ve QRS imgeleri oluşturulmuştur. Yüz imgeleri için kullanılan ön işleme süreci ise sadece normalizasyon işlemini içermektedir.

5.3.2 Öznitelik çıkarımı ve sınıflandırma

Önerilen Yöntem-2'de hem QRS imgelerinden hem de yüz imgelerinden öznitelik çıkarımı ve sınıflandırma işlemini gerçekleştirmek amacıyla sınıf sayısı ve veri boyutlarına uygun bir ESA mimarisi geliştirilmiştir. Geliştirilen ESA mimarisinin blok diyagramı Şekil 5.11'de sunulmuştur. Geliştirilen ESA Mimarisi, 4 adet evrişimsel katman, 3 adet tam bağlantılı katman ve 1 adet sınıflandırıcı katmanından oluşurken, her evrişimsel katman ve tam bağlantılı katman çıkışında birer adet maksimum ortaklama ve seyreltme katmanları kullanılmıştır. Evrişimsel katmanlarda doğrultulmuş doğrusal birim (Rectified Linear Unit-ReLU), tam bağlantılı katmanlarda Sigmoid, sınıflandırıcı olarak ise softmax aktivasyon fonksiyonları kullanılmıştır.



Şekil 5.11 : Önerilen Yöntem-2 için geliştirilen ESA mimarisi.

Çizelge 5.2’de geliştirilen ESA mimarisine ait her bir katman için katman tipi, aktivasyon fonksiyonu, süzgeç boyutları, çıkış boyutu ve parametre sayıları verilmiştir.

Çizelge 5.2 : Önerilen Yöntem-2 için geliştirilen ESA Mimarisine ait parametre çizelgesi.

	Katman	Aktivasyon Fonksiyonu	Süzgeç Boyutu	Çıkış Boyutu	Parametre Sayısı
1	Evrişimsel	ReLU	3x3	256x256,16	160
2	Maks. Ortaklama	-	2x2	128x128,16	0
3	Seyreltme (0.2)	-	-	128x128,16	0
4	Evrişimsel	ReLU	3x3	128x128,32	4640
5	Maks. Ortaklama	-	2x2	64x64,32	0
6	Seyreltme (0.2)	-	-	64x64,32	0
7	Evrişimsel	ReLU	3x3	64x64,64	18496
8	Maks. Ortaklama	-	2x2	32x32,64	0
9	Seyreltme (0.2)	-	-	32x32,64	0
10	Evrişimsel	ReLU	3x3	32x32,128	73856
11	Maks. Ortaklama	-	2x2	16x16,128	0
12	Seyreltme (0.2)	-	-	16x16,128	0
13	Düzleştirme	-	-	32768	0
14	Tam Bağlantılı	Sigmoid	-	128	4194432
15	Seyreltme (0.2)	-	-	128	0
16	Tam Bağlantılı	Sigmoid	-	128	16512
17	Seyreltme (0.2)	-	-	128	0
18	Çıkış	Softmax	-	30	3870
Toplam Parametre Sayısı					4311966

5.3.3 Skor birleştirme

Önerilen Yöntem-2’de birbiri ile paralel olarak çalışan iki ESA mimarisi sonucunda elde edilen skorlar ortalama skor birleştirme yöntemi kullanılarak birleştirilmiştir. Böylece QRS imgeleri üzerinden elde edilen kişi tanıma skorları ve yüz imgeleri üzerinde elde edilen kişi tanıma skorları birleştirilerek Önerilen Yöntem-2 için kişi tanıma başarımları elde edilmiştir.

5.3.4 Öznitelik birleştirme

Önerilen Yöntem-2, skor birleştirme yerine öznitelik birleştirme süreci kullanılacak şekilde yeniden yapılandırılmıştır. Bu durumda, eşit sayıda QRS ve yüz imgelerinin kullanıldığı paralel ESA mimarisindeki sınıflandırma katmanları öncesinde tanımlı tam bağlantılı katman çıkışlarındaki öznitelik vektörleri, bir başka deyişle softmax katmanları öncesinde elde edilen 1x128 boyutlu öznitelik vektörleri, ardarda eklenerek her bir eğitim ve test sayısı için tek bir 1x256 boyutlu öznitelik vektörü elde edilmiştir. Bu noktadan sonra birleştirilmiş öznitelik vektörleri Çizelge 5.3’te gösterilen sinir ağı mimarisi kullanılarak sınıflandırılmıştır.

Çizelge 5.3’te ise sadece sınıflandırma işlemi için önerilen sinir ağı mimarisine ait her bir katman için katman tipi, aktivasyon fonksiyonu, süzgeç boyutları, çıkış boyutu ve parametre sayıları verilmiştir.

Çizelge 5.3 : Öznitelik birleştirme işleminde sınıflandırma için kullanılan sinir ağı mimarisine ilişkin parametre çizelgesi.

	Katman	Aktivasyon Fonksiyonu	Çıkış Boyutu	Parametre Sayısı
1	Tam Bağlantılı	Sigmoid	64	16448
2	Seyreltme (0.2)	-	64	0
3	Çıkış	Softmax	30	1984
	Toplam Parametre Sayısı			18432

5.4 Performans Kriterleri

Sistem performansını değerlendirmek, geliştirilen sistemin sınıflandırma işlemini ne kadar doğru gerçekleştirdiğini anlamak için önemlidir. Bu çalışmada referans alınan

temel araç Hata Matrisi'dir. Hata matrisi, gerçek sınıf etiketleri ile tahmin edilen sınıf etiketlerinin sayılarını içeren, satır ve sütunlardan oluşan bir matristir. Bu matris ile hangi test sonucunun doğru sınıfa atandığı ve yanlış sınıfa atandığı açıkça görülmektedir [45]. Çizelge 5.4 ikili sınıflandırma için tanımlanmış hata matrisini göstermektedir.

Çizelge 5.4 : Hata matrisi.

	Tahmin Edilen (Pozitif)	Tahmin Edilen (Negatif)
Gerçek Sınıf (Pozitif)	Doğru Pozitif	Yanlış Negatif
Gerçek Sınıf (Negatif)	Yanlış Pozitif	Doğru Negatif

Hata matrisinde Doğru Pozitif (DP) gerçek sınıf etiketi pozitif olan ve pozitif olarak tahmin edilen örnek sayısını; Yanlış Pozitif (YP) gerçek sınıf etiketi negatif olan ve pozitif olarak tahmin edilen örnek sayısını; Doğru Negatif (DN) gerçek sınıf etiketi negatif olan ve negatif olarak tahmin edilen örnek sayısını; Yanlış Negatif (YN) gerçek sınıf etiketi pozitif olan ve negatif olarak tahmin edilen örnek sayısını temsil etmektedir [45].

Hata matrisinden yola çıkarak sistemin Doğruluk, Hassasiyet, Duyarlılık, F-Skor değerleri hesaplanabilmektedir.

Doğruluk değeri, denklem 5.4'te görüldüğü gibi doğru olarak tanınan sınıma sayısının toplam sınıma sayısına oranı olarak tanımlanır. Eğer modelde kullanılan sınıf sayıları arasında eşitsizlik mevcutsa ve fark sayısı fazla ise Doğruluk değeri sistem performansını değerlendirirken yanıltıcı olabilir [45].

$$Doğruluk = (DP + DN)/(DP + YP + DN + YN) \quad (5.4)$$

Pozitif tahmin değeri olarak da tanımlanan, hassasiyet değeri aynı koşullar altında tekrarlanan ölçümlerin derecesi olarak tanımlanır ve denklem 5.5 ile hesaplanır.

$$Hassasiyet = DP/(DP + YP) \quad (5.5)$$

Duyarlılık (Doğru Pozitif Oranı), pozitif bir sınıfın hangi sıklıkla doğru sınıf olarak tahmin edildiğini gösterir ve denklem 5.6 ile hesaplanır.

$$Duyarluluk = DP / (DP + YN) \quad (5.6)$$

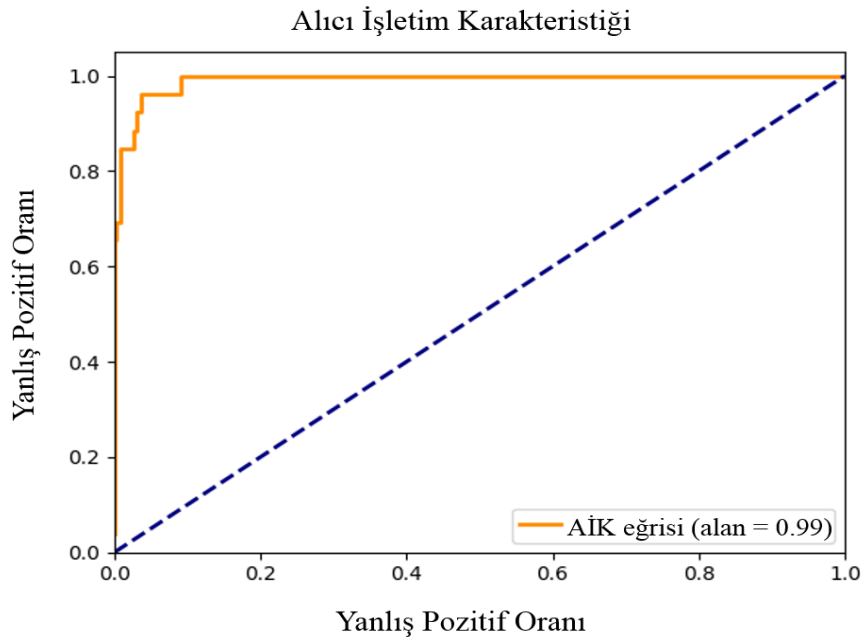
F-Skor değeri, önceki bölümlerde açıklanan Hassasiyet ve Duyarlılık değerlerinin harmonik ortalaması olarak tanımlanır [45] ve denklem 5.7 ile hesaplanır.

$$F - Skor = (2xDP) / (2xDP + YN + YP) \quad (5.7)$$

Sınıflandırma başarımını gösteren bir diğer ölçüt ise Alıcı İşletim Karakteristiği (AİK) eğrisidir. Bu eğri, doğru pozitif oranının (duyarlılık) yanlış pozitif oranına göre değişimini göstermektedir. Yanlış pozitif oranı ise denklem 5.8'de verilen formül ile elde edilir.

$$Yanlış Pozitif Oranı = YP / (DN + YP) \quad (5.8)$$

AİK eğrisi grafiğinin sol alt bölümünden sağ üst bölümüne doğru bir eğim gösterirken, eğer iyi bir model için çizdirilmiş ise grafik sol kısımda dik bir eğim gösterir [52]. Örnek bir AİK eğrisi Şekil 5.12'de gösterilmiştir. AİK eğrisinin altında kalan alan sistemin genel performansının bir ölçüsü olarak değerlendirilmektedir. İdeal bir sistemde AİK eğrisinin altında kalan alan 1 iken, bu alanın 1'e yaklaştıkça sistem başarımı artmaktadır.



Şekil 5.12 : Örnek bir AİK eğrisi.

Bu alıřmada, oklu sınıf performans deęerlendirmesi gerekleřtirildięinden Doęruluk, Duyarlılık, Hassasiyet deęerleri her sınıf iin ayrı ayrı hesaplanmış, F-skor deęeri ise sınıf ortalaması olarak ifade edilmiřtir. Modellere ait AİK eęrileri de tm sınıfların ortalamaları alınarak izdirilmiřtir.



6. DENEYSEL SONUÇLAR

6.1 Donanım


Bu çalışmada gerçekleştirilen tüm benzetimler, Intel Core i5 CPU, 2.80 Ghz işlemci hızı, ve 32 GB hafızaya (RAM) sahip bilgisayar üzerinde gerçekleştirilmiştir. Ön işleme aşamasında GNU Octave programı kullanılmıştır. Evrişimsel sinir ağıları deneyleri Python programlama dilinde Keras kütüphanesi kullanılarak gerçekleştirilmiştir.

6.2 Başarım Sonuçları

6.2.1 Önerilen Yöntem-1: Evrişimsel Sinir Ağı tabanlı EKG biyometrik tanıma yöntemi başarım sonuçları


Önerilen Yöntem-1'in kişi tanıma başarımını değerlendirmek amacıyla tasarlanan deneyde MIT-BIH Arrhythmia veri tabanı kullanılmıştır. Bu veri tabanında bulunan 46 kişinin EKG işaretleri Bölüm 5.2.1'de açıklanan ön işleme sürecinden geçirilerek 256x256x1 boyutlu toplam 1045 adet QRS imgesi oluşturulmuştur. Daha sonra bu QRS imgeleri Bölüm 5.2.2'de açıklanan veri çoğullama yöntemi kullanılarak çoğullanmış ve 4180 (1045 + 3x1045) adet 256x256x1 boyutlu QRS imgeleri elde edilmiştir. Bu QRS imgelerinden rasgele seçilen 3345 adedi (toplam veri sayısının %80'i) Evrişimsel Sinir Ağları modelini eğitmek için kullanılırken, geri kalan 835 adedi (toplam veri sayısının %20' si) sistem başarımını değerlendirmek için kullanılmıştır.

Önerilen Yöntem-1'in kişi tanıma başarımını değerlendirmede yanlılık (biasing effect) etkisini azaltmak için 3 katlamalı çapraz doğrulama (3-fold cross validation) yöntemi kullanılmıştır. Bu sebeple 3 farklı eğitim ve test kümesi oluşturulmuştur. Her bir kat için eğitim ve test kümelerinin model doğruluk (accuracy) eğrileri 100 eğitim adımı (epoch) için sırası ile Şekil 6.1, Şekil 6.2 ve Şekil 6.3'te sunulmuştur.



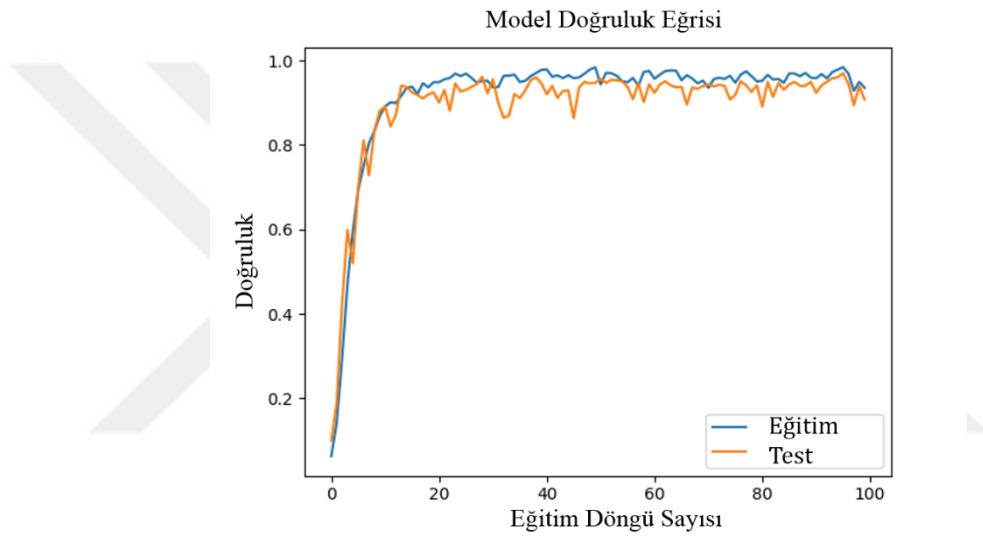
Şekil 6.1 : Önerilen Yöntem-1 için 1. Kat model doğruluk eğrisi.

Şekil 6.1 - 6.3’de görüldüğü üzere her bir kat için eğitim adım sayısı arttıkça doğruluk değeri de beklendiği üzere artmaktadır. Çünkü başlangıçta model parametreleri (katmanlar arası geçiş ağırlıkları, süzgeç ağırlıkları vb.) rasgele belirlenirken her eğitim adımında bu parametreler güncellenerek en iyi değerlere yakınsamaktadır. Bu yakınsama Şekil 6.1 - 6.3’de gösterilen doğruluk eğrilerinden de görüldüğü gibi doğruluk değeri belirli bir adımdan sonra çok fazla değişmemektedir. 1. ve 2. katlar için yaklaşık olarak 40 adımdan sonra doğruluk değeri maksimum değere ulaşırken ve bu adımdan sonra çok küçük değişimler görülmektedir. Buna karşın 3. kat için model doğruluk eğrisi yaklaşık 20 adımda en iyi değere yakınsamaktadır.



Şekil 6.2 : Önerilen Yöntem-1 için 2. kat model doğruluk eğrisi.

Şekil 6.1 - 6.6'da verilen doğruluk eğrilerinden görüldüğü üzere, genel olarak eğitim ve test kümeleri için doğruluk değerleri farklılık göstermektedir. Bu beklenen bir durumdur. Çünkü eğitim ve test veri kümeleri ayrık (birbiri ile örtüşmeyen) kümeler olması sebebi ile bu kümeler üzerinde elde edilen başarımlar da doğal olarak farklı olacaktır. Önerilen Yöntem-1, eğitim kümesi ile optimize edildiğinden genel olarak eğitim kümesinin başarımı test kümesinden daha fazladır. Ancak eğrilerden de görüldüğü gibi bu başarımlar arasında ciddi farklar bulunmamaktadır. Bu da Önerilen Yöntem-1'in aşırı öğrenme problemi ile karşılaşmadığının göstergesi olarak düşünülebilir.




Şekil 6.3 : Önerilen Yöntem-1 için 3. kat model doğruluk eğrisi.

EKG işaretleri ile biyometrik kişi tanıma deneylerine ilişkin her bir kat için eğitim ve test kümeleri üzerinde elde edilen kayıp değerlerinin eğitim adım sayısına göre değişimi Şekil 6.4-6.6'da gösterilmektedir.


Şekil 6.4 – 6.6 ile gösterilen kayıp eğrilerinden görüldüğü üzere adım sayısı arttıkça hem eğitim hem de test kümeleri üzerinde elde edilen kayıp değerleri azalmaktadır. Doğruluk eğrilerine benzer şekilde (Şekil 6.1 – 6.3) belirli bir adım sayısından itibaren kayıp değerleri çok küçük değişimler göstermektedir. Bütün katlar için genel olarak 40 adımdan itibaren kayıp değerlerindeki değişim oldukça küçük olmaktadır.

Her bir kat için verilen kayıp eğrilerden (Şekil 6.4 - 6.6) görüldüğü üzere belirli bir adım sayısından itibaren eğitim ve test kümeleri üzerinde elde edilen kayıp değerleri birbirine çok yakın olmakla birlikte genel olarak eğitim kümesi için hesaplanan kayıp

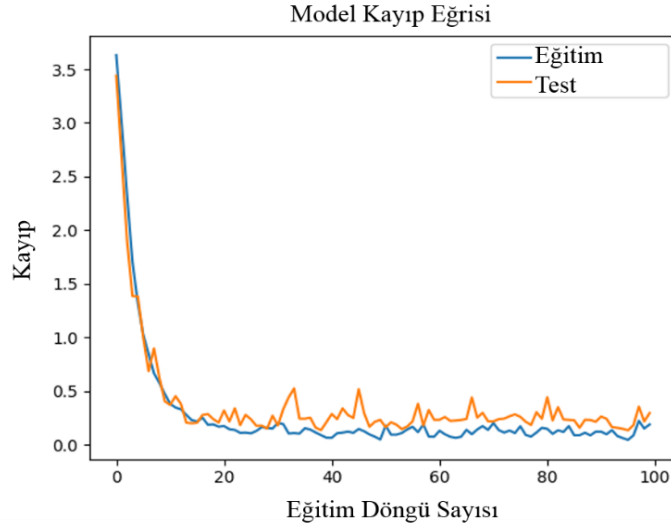
değerleri test kümesi için hesaplanan değerlerden daha düşüktür. Eğitim ve test kümeleri için hesaplanan kayıp değerlerinin de belirli bir adım sayısından itibaren birbirine çok yakın çıkması aşırı öğrenme (over-fitting) problemi ile karşılaşmadığının bir göstergesidir.



Şekil 6.4 : Önerilen Yöntem-1 için 1. kat model kayıp eğrisi.

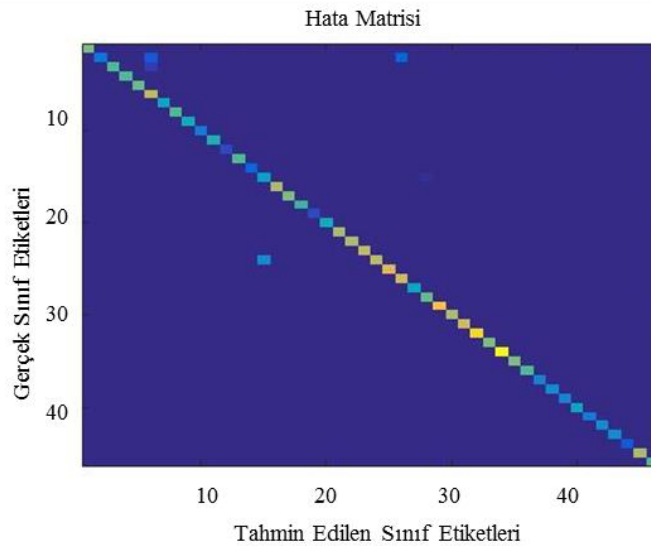


Şekil 6.5 : Önerilen Yöntem-1 için 2. kat model kayıp eğrisi.



Şekil 6.6 : Önerilen Yöntem-1 için 3. kat model kayıp eğrisi.

Sınıflandırma problemleri için temel performans göstergelerinden biri olan hata matrisi (confusion matrix) 1. kat test veri kümesi için Şekil 6.7’de gösterilmiştir. Hata matrisinin köşegen elemanları doğru olarak karar verilen sınıma sayılarını, köşegen dışındaki elemanlar ise yanlış olarak karar verilen sınımların sayısını göstermektedir. 46 kişi için sınıflandırmanın gerçekleştirildiği Önerilen Yöntem-1’de toplam 835 adet test sayısından 22 adedi (hata matrisinde köşegen dışında kalan eleman sayılarının toplamı) Önerilen Yöntem-1 tarafından yanlış kişiye atanmıştır.



Şekil 6.7 : Önerilen Yöntem-1 için 1. kat hata matrisi.

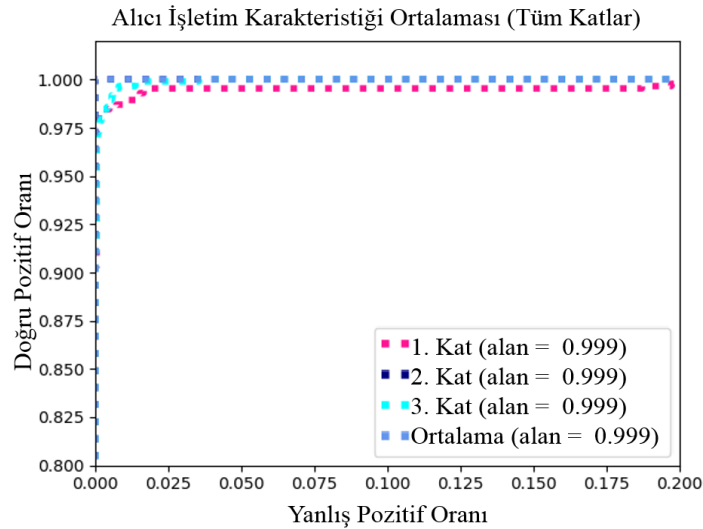
EKG işaretleri ile biyometrik kişi tanıma sisteminin başarımının her bir kat için farklı başarım ölçütleri ile analizi detaylı olarak Çizelge 6.1’de gösterilmiştir. Çizelgedeki

sonuçlardan görüldüğü üzere her bir kat için her bir başarıml ölçütü açısından oldukça iyi performans elde edilmiştir. Çizelgedeki kat 1, kat 2 ve kat 3 veri kümelerinin her bir ölçüt açısından birbirine yakın sonuçlar vermesi sistemin veri yanlı olmadığını göstermektedir. Çizelgenin son satırında ise bütün katların ortalamaları alındığında elde edilen başarıml oranları verilmiştir ve ortalama sistem test doğruluğu %98.08 olarak hesaplanmıştır.

Çizelge 6.1 : Önerilen Yöntem-1 için sınıflandırma başarımları.

Kat	Doğruluk	Duyarlılık	Hassasiyet	F-Ölçütü
Kat 1	%97.36	%97.29	%98.17	%97.98
Kat 2	%99.88	%99.86	%99.91	%99.89
Kat 3	%97.00	%97.39	%97.54	%97.46
Ortalama	%98.08	%98.34	%98.54	%98.44

EKG işaretleri ile biyometrik kişi tanıma deneylerinde son olarak her bir kat için ve bütün katların ortalaması alındığında elde edilen Alıcı İşletim Karakteristiği (Receiving Operation Characteristic) Eğrileri elde edilmiştir. Alıcı işlem karakteristiği eğrileri bir tanıma sisteminin yanlış pozitif oranının doğru pozitif oranına göre çizdirilmesi ile elde edilip bu iki oranın birbirine göre değişimlerini gözlemlemek adına önemli bir performans göstergesidir. ROC eğrisinin altında kalan alan sistemin genel performansının bir ölçüsü olarak değerlendirilmektedir. Şekil 6.8’de Önerilen Yöntem-1 için her bir kata ait ROC eğrileri gösterilmektedir.



Şekil 6.8 : Önerilen Yöntem-1 için Alıcı İşletim Karakteristiği eğrisi.


Şekilde verilen grafiklerden de görüldüğü gibi her bir kat için elde edilen ROC eğrilerinin altında kalan alan birbirine eşit olup, ortalama ROC eğrisi altında kalan alan da eşittir ve 1 değerine oldukça yakındır.

6.2.2 Önerilen Yöntem-2: Evrişimsel Sinir Ağı tabanlı EKG ve Yüz çoklu biyometrik tanıma yöntemi (FACECG) başarımları

6.2.2.1 Önerilen Yöntem-2'nin EKG işaretlerine göre kişi tanıma başarımları


Önerilen Yöntem-2'nin kişi tanıma başarımlarını değerlendirmek için tasarlanan birinci deneyde 46 farklı kişinin EKG işaretlerini içeren MIT BIH Arrhythmia veri kümesi kullanılmıştır. Bu veri kümesinde bulunan MIT-BIH Arrhythmia veritabanında bulunan 46 kişi içerisinde toplam QRS imgeleri sayısı en az 20 adet olan kişiler seçilerek 30 kişiye ait toplam 600 adet 256x256x1 boyutunda QRS imgeleri ile EKG işaretlerinden biyometrik kişi tanıma deneyi gerçekleştirilmiştir. Her bir kişi için seçilen 20'şer adet imgeden 16 adedi eğitim verisi olarak 4 adedi ise test verisi olarak hazırlanmıştır. Özetle toplamda 480 adet 256x256x1 boyutunda QRS eğitim imgesi, 120 adet ise test imgesi kullanılmıştır.

Önerilen Yöntem-2'nin EKG işaretlerine göre kişi tanıma başarımlarını değerlendirmede yanlışlık etkisini azaltmak için 3 katlamalı çapraz doğrulama yöntemi kullanılmıştır. Bu sebeple 3 farklı eğitim ve test kümesi hazırlanmıştır. Her bir kat için eğitim ve test kümelerinin model doğruluk eğrileri 100 eğitim adımı için sırasıyla Şekil 6.9 - 6.11'de sunulmuştur.




Şekil 6.9 : Önerilen Yöntem-2 için birinci deneyde elde edilen 1. kat model doğruluk eğrisi.

Şekil 6.9-6.11’de verilen doğruluk eğrilerinden anlaşılacağı gibi, Önerilen Yöntem-2 yaklaşımı EKG işaretlerinden kişi tanıma probleminde oldukça yüksek başarımlar göstermektedir. Bu başarımın tesadüf olmadığı da farklı katların doğruluk eğrileri kıyaslandığında açıkça görülmektedir. Katlardan bağımsız olarak eğitim döngü sayısı arttıkça doğruluk değeri artmaktadır ve belirli bir adımdan sonra en iyi noktaya yakınsamaktadır. Daha önceki bulgulardan da gözlemlendiği üzere yaklaşık olarak 40 eğitim döngü sayısı kullanmak en iyi performansı elde etmek için yeterlidir.




Şekil 6.10 : Önerilen Yöntem-2 için birinci deneyde elde edilen 2. Kat model doğruluk eğrisi.

Doğruluk eğrileri (Şekil 6.9 - 6.11) incelendiğinde, daha önce gözlenen sonuçlara benzer olarak eğitim ve test kümeleri üzerinde elde edilen doğruluğun birbirine yakın fakat farklı olduğu gözlemlenmektedir. Ayrıca, test kümesi üzerinde elde edilen doğruluk değerlerindeki değişimin eğitim kümesine nazaran daha fazla olduğu dikkat çekmektedir. Bu beklenen bir durumdur çünkü eğitim kümesi ile model parametreleri her adımda optimize edildiğinden dolayı doğruluk değerleri yüksek oranda değişim göstermemektedir. Ancak test kümesi eğitim kümesinden farklı veriler içerdiğinden dolayı test kümesi için elde edilen doğruluk değerlerinde her eğitim döngüsünde değişim ortaya çıkmaktadır.




Şekil 6.11 : Önerilen Yöntem-2 için birinci deneyde elde edilen 3. kat model doğruluk eğrisi.

Önerilen Yöntem-2’de kullanılan evrimsel sinir ağı yaklaşımı ile EKG işaretlerinden kişi tanıma deneyinde 3 katlamalı çapraz doğrulamada her bir kat için eğitim döngü sayısına bağlı olarak kayıp fonksiyonu değişimi Şekil 6.12-6.14’de gösterilmiştir. Daha önceki bulgulara benzer şekilde her bir kat için kayıp fonksiyonu benzer bir değişim göstermekte ve yine belirli bir döngüden itibaren en iyi değere yakınsamaktadır.




Şekil 6.12 : Önerilen Yöntem-2 için birinci deneyde elde edilen 1. kat model kayıp eğrisi.

Kayıp eğrileri incelendiğinde her bir kat için eğitim ve test kümelerindeki kayıp değerlerinin benzer bir değişim gösterdiği ve eğitim ve test kümeleri için hesaplanan kayıp değerlerinin birbirine yakın olduğu dikkat çekmektedir. Bu da Önerilen Yöntem-2’de kullanılan evrişimsel sinir ağı yapısının aşırı öğrenme problemi ile karşı karşıya kalmadığını göstermektedir.



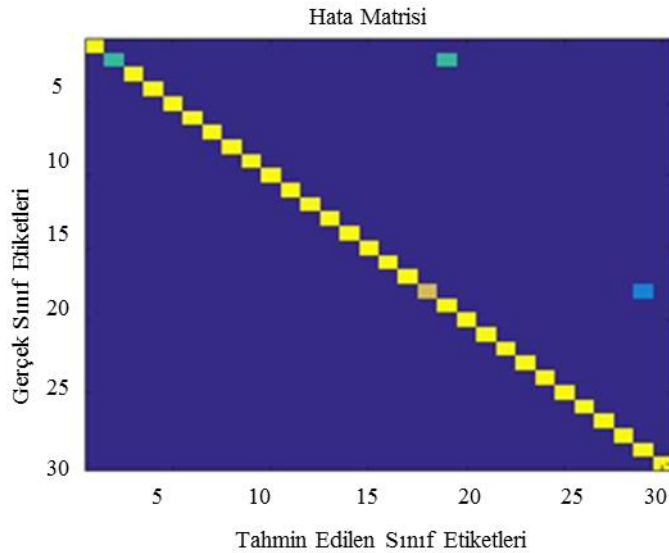
Şekil 6.13 : Önerilen Yöntem-2 için birinci deneyde elde edilen 2. kat model kayıp eğrisi.

Doğruluk eğrilerinden farklı olarak kayıp eğrileri dikkate alındığında ise yaklaşık 60 eğitim döngüsünden sonra önerilen yöntemin en iyi değere yakınsadığı görülmektedir.



Şekil 6.14 : Önerilen Yöntem-2 için birinci deneyde elde edilen 3. kat model kayıp eğrisi.

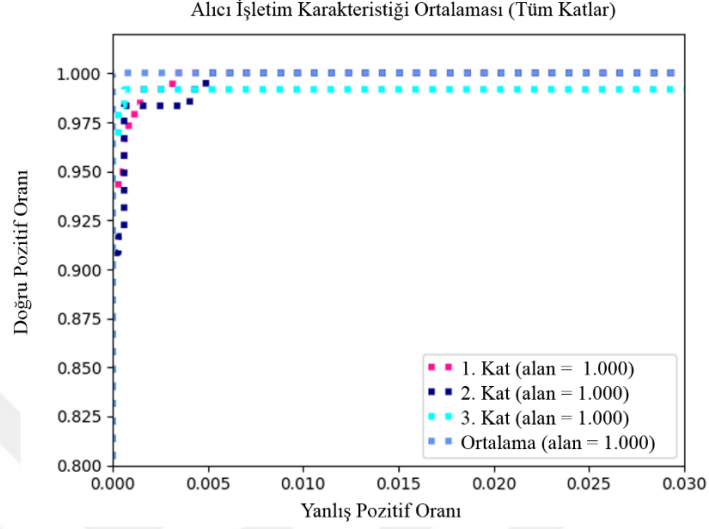
Bu deneyde 1. kat veri kümesi için hesaplanan hata matrisi Şekil 6.15'te gösterilmiştir. 30 kişi için sınıflandırmanın gerçekleştirildiği deneyde toplam 120 adet test sayısından 3 adedi (hata matrisinin köşegen elemanları dışında kalan elemanların sayısı) Önerilen Yöntem-2 tarafından yanlış kişiye atanmıştır. Dolayısı ile yaklaşık olarak %97.5 doğruluk değeri elde edilmiştir.



Şekil 6.15 : Önerilen Yöntem-2 için birinci deneyde elde edilen 1. kat hata matrisi.

Şekil 6.16'da Önerilen Yöntem-2'nin EKG işaretlerine göre kişi tanıma başarımının incelendiği bu deney için her bir kata ait elde edilen ROC eğrileri gösterilmektedir. Şekilde verilen grafiklerden de görüldüğü gibi her bir kat için elde edilen ROC eğrilerinin altında kalan alan birbirine eşit olup, ortalama ROC eğrisi altında kalan

alan da bu değerlere eşittir ve 1 değerine sahiptir. Bu da Önerilen Yöntem-2 nin EKG işaretlerine göre kişi tanıma probleminde oldukça yüksek başarımlar gösterdiğini ortaya koymaktadır.




Şekil 6.16 : Önerilen Yöntem-2 için birinci deneyde elde edilen Alıcı İşletim Karakteristiği eğrisi.

6.2.2.2 Önerilen Yöntem-2'nin yüz imgelerine göre kişi tanıma başarımlar sonuçları

Önerilen Yöntem-2'nin kişi tanıma başarımlarını değerlendirmek için tasarlanan ikinci deneyde AR Face veri kümesi kullanılarak Önerilen Yöntem-2'nin yüz imgelerine göre kişi tanıma başarımlarını incelenmiştir. Bu amaçla, bu deneyde AR Face veri kümesinde bulunan 126 kişi içerisinde birinci deneyde kullanılan kişi sayısı ile aynı sayıda kişi (30 kişi) seçilmiş ve yine aynı sayıda eğitim ve test yüz imgesi (kişi başına 20 adet) kullanılmıştır. Böylece 30 kişiye ait toplam 600 adet 256x256x3 boyutunda yüz imgesi eğitim ve test aşamaları için kullanılırken, her bir kişi için rasgele seçilen 20 adet yüz imgesinden 16 adedi eğitim, geri kalan 4 adedi ise test verisi olarak kullanılmıştır. Özetle toplamda 480 adet 256x256x3 boyutunda yüz imgesi eğitim aşamasında, 120 adet imge ise test aşamasında kullanılmıştır. Daha önceki deneylerde olduğu gibi bu deneyde de 3 katlamalı çapraz doğrulama yöntemi kullanılmıştır.

Önerilen Yöntem-2'nin yüz imgelerine göre kişi tanıma başarımlarının incelendiği bu deneyde seçilen örnek bir kat için eğitim ve test kümelerinin model doğruluk eğrileri

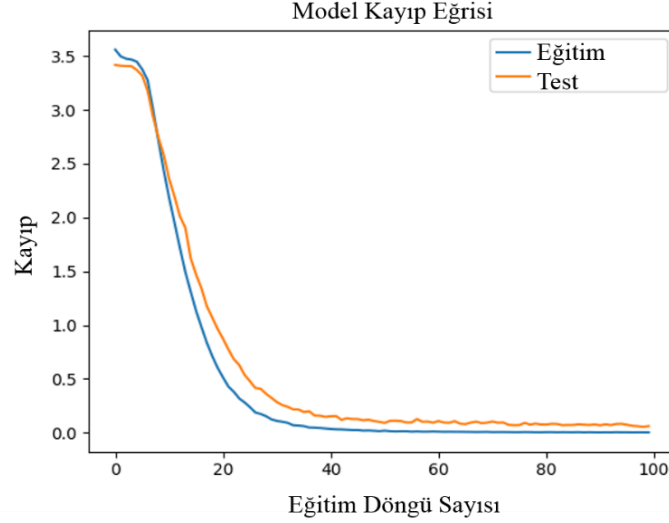
100 eğitim adımı için Şekil 6.17’de gösterilmektedir. Diğer katlar için de benzer eğriler gözlemlenmiş olup yapılan tüm yorumlar diğer katlar için de geçerlidir.



Şekil 6.17 : Önerilen Yöntem-2 için ikinci deneyde elde edilen 1. kat model doğruluk eğrisi.

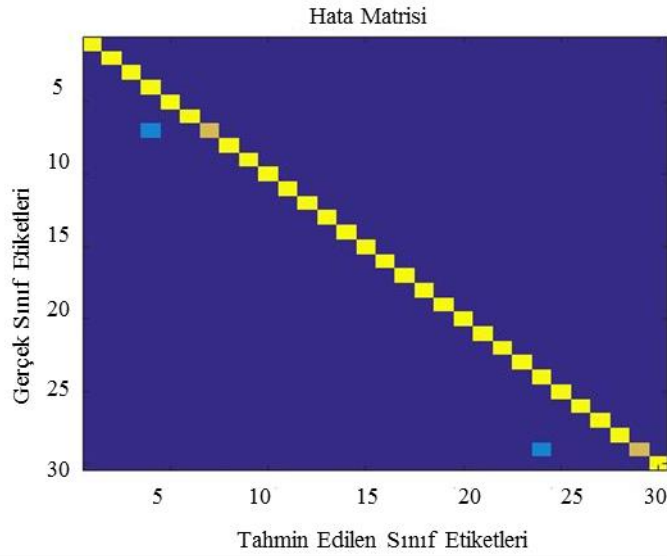
Bu deneyde elde edilen doğruluk eğrileri göz önünde bulundurulduğunda Önerilen Yöntem-2 için yapılan birinci deneyde olduğu gibi belirli bir eğitim adımından itibaren doğruluk değerinde ciddi bir değişiklik meydana gelmemekle birlikte, eğitim kümesine ait doğruluk oranı %100 değerine yakınsamaktadır. Bununla birlikte, farklı katlar için test kümesi üzerinde elde edilen doğruluk oranı değeri eğitim kümesi üzerinde elde edilen doğruluk değerinden çok az bir farkla daha düşük olduğu gözlemlenmiştir. Bu da beklenen bir durumdur. Çünkü evrimsel sinir ağı model parametreleri eğitim kümesi ile optimize edilmiştir. Bu nedenle test kümesinin değerlendirilmesinde farklar ortaya çıkmaktadır.

Bu deneyde seçilen örnek bir kat için eğitim ve test kümelerinin 100 eğitim döngü sayısına göre elde edilen kayıp eğrisi ve hata matrisi sırasıyla Şekil 6.18 ve Şekil 6.19’da gösterilmiştir. Şekil 6.18’den görüldüğü gibi eğitim döngü sayısı arttıkça kayıp değeri sistematik olarak azalmakta olup belirli bir döngü sayısından itibaren azalma miktarı oldukça küçülerek kayıp fonksiyonu belirli bir değere yakınsamaktadır.



Şekil 6.18 : Önerilen Yöntem-2 için ikinci deneyde elde edilen 1. kat model kayıp eğrisi.

Şekil 6.19’da verilen hata matrisi incelendiğinde ise 30 kişi için elde edilen 120 adet test sayısından sadece 2 tanesinin Önerilen Yöntem-2 tarafından yanlış kişiye atandığı görülmektedir.



Şekil 6.19 : Önerilen Yöntem-2 için ikinci deneyde elde edilen 1. kat hata matrisi.

Önerilen Yöntem-2’nin kişi tanıma başarımını incelemek amacıyla 3 katlamalı çapraz doğrulama şeklinde gerçekleştirilen EKG işaretleri üzerinden kişi tanıma ve yüz imgeleri üzerinden kişi tanıma deneyleri neticesinde elde edilen sınıflandırma başarımları her bir kat için Çizelge 6.2 ve 6.3’te sırasıyla sunulmuştur. Çizelgelerde sunulan sonuçlar incelendiğinde Önerilen Yöntem-2’nin kişi tanıma başarımının her iki deneyde de oldukça yüksek ve birbirine yakın olduğu gözlenmektedir. Önerilen

Yöntem-2'nin ortalama doğruluk değeri (3 katın ortalaması alınarak hesaplanan) ise EKG işaretlerine göre kişi tanıma için %98.33 iken yüz imgelerine göre kişi tanıma için %98.60 olarak elde edilmiştir.

Çizelge 6.2 : Önerilen Yöntem-2'nin EKG işaretlerine göre sınıflandırma başarımı.

Kat	Doğruluk	Duyarlılık	Hassasiyet	F-Ölçütü
Kat 1	%97.50	%97.50	%98.22	%97.85
Kat 2	%98.33	%98.33	%98.88	%98.61
Kat 3	%99.16	%99.16	%99.33	%99.24
Ortalama	%98.33	%98.33	%98.81	%98,56

Çizelge 6.3 : Önerilen Yöntem-2'nin yüz imgelerine göre sınıflandırma başarımı.

Kat	Doğruluk	Duyarlılık	Hassasiyet	F-Ölçütü
Kat 1	%98.33	%98.33	%98.66	%98.49
Kat 2	%99.16	%99.16	%99.33	%99.24
Kat 3	%98.33	%98.33	%98.66	%98.49
Ortalama	%98.60	%98.60	%98.88	%98.74

6.3 Önerilen Yöntem-2'nin EKG İşaretleri ve Yüz İmgelerine Göre Kişi Tanıma Başarımı Sonuçları

Önerilen Yöntem-2'nin EKG işaretlerini ve yüz imgelerini birlikte kullanarak kişi tanıma başarımının incelenmesi için skor birleştirme ve öznitelik birleştirme olmak üzere iki farklı birleştirme yöntemi kullanılmıştır.

Skor birleştirme işlemi, Önerilen Yöntem-2'nin EKG işaretlerine ve yüz imgelerine göre ayrı ayrı kişi tanıma başarımının incelenmesi için tasarlanan birinci ve ikinci deneyde kullanılan kat-1 test verilerine ait skor değerleri üzerinden gerçekleştirilmiştir. Ortalama skor birleştirme yöntemi kullanılarak yapılan bu skor birleştirme işlemi sonucunda Önerilen Yöntem-2'nin EKG işaretlerine göre %97.50 ve yüz imgelerine göre %98.33 olarak elde edilmiş olan doğruluk değerleri %100 olarak iyileştirilmiştir.

Öznitelik birleştirme işlemi, Önerilen Yöntem-2'nin EKG işaretlerine ve yüz imgelerine göre ayrı ayrı kişi tanıma başarımının incelenmesi için tasarlanan birinci ve ikinci deneyde kullanılan kat-1 test verileri için elde edilen öznitelik vektörleri kullanılarak gerçekleştirilmiştir. Daha önce Bölüm 5.3.4'te açıklandığı üzere Önerilen Yöntem-2'de kullanılan ESA mimarisinde yer alan softmax katmanı öncesinde hem EKG işaretleri için hem de yüz imgeleri için elde edilen 1x128 boyutlu öznitelik vektörleri arka arkaya eklenerek öznitelik birleştirme işlemi

gerçekleştirilmiş ve 1x256 boyutlu yeni öznitelik vektörleri oluşturulmuştur. Bu birleştirilmiş öznitelik vektörleri detayları Çizelge 5.3'te özetlenen sinir ağı mimarisi kullanılarak sınıflandırılmıştır. Bu işlemler sonucunda Önerilen Yöntem-2'nin EKG işaretlerine göre %97.50 ve yüz imgelerine göre %98.33 olarak elde edilmiş olan doğruluk değerleri %100 olarak iyileştirilmiştir.

EKG ve yüz veri kümeleri kullanılarak oluşturulan çoklu biyometrik tanıma sistemleri ile bu tez çalışmasında önerilen ve Önerilen Yöntem-2 (FACECG) olarak isimlendirilen biyometrik tanıma yönteminin başarımları doğruluk ve kişi tanıma oranlarına göre Çizelge 6.4'te karşılaştırmalı olarak incelenmiştir. Çizelge 6.4'te görüldüğü gibi Önerilen Yöntem-2 hem skor birleştirme yöntemi hem de öznitelik birleştirme yöntemi kullanılarak %100 doğruluk sağlamakta ve literatürde yayınlanmış olan diğer 3 çalışmadan da daha iyi sonuç vermektedir.

Çizelge 6.4 : EKG ve yüz işaretlerinin birlikte kullanıldığı çoklu biyometrik sistemler karşılaştırma çizelgesi [3]. KTO: Kişi Tanıma Oranı, D: Doğruluk.

Yazar	Yıl	EKG Veritabanı	Yüz Veritabanı	Sınıf Sayısı	Sınıflandırıcı	Birleştirme	Sonuçlar
Israel vd. [41]	2003	SAIC's laboratuvarında bireysel olarak oluşturulmuştur.	Digital Kamera ile yapılan çekimler ile oluşturulmuştur	15 15 15	Öklit Mesafesi (Euclidian Distance)	Öznitelik Karar Skor	KTO %99 KTO %94 KTO %66
Boumbarow vd. [42]	2011	Laboratuvar da bireysel olarak oluşturulmuştur.	Caltech-CV-Group, 1999	19	EKG: Radyal Temelli Sinir Ağı (Radial Basis Neural Network); Yüz: Destek Vektör Makineleri (Support Vector Machine)	Skor	D %99.5
Chakraborty vd. [43]	2017	İki kanallı BiopacMP45 kullanılarak oluşturulmuştur.	Digital Kamera ile çekilen profil fotoğraflarından oluşmaktadır.	40	Ortalama Karesel Sapma (Mean Square Deviation)	Öznitelik	D %97.5
Önerilen Yöntem-2 (FACECG)	2019	MIT-BIH Arrhythmia [49]	AR Face veri tabanı [50]	30	Evrişimsel Sinir Ağı, Çok Katmanlı Algılayıcı	Öznitelik Skor	D %100 D %100

7. TARTIŞMA VE ÖNERİLER

Bu tez çalışmasında bireylere ait ayırt edici özellikler barındıran elektrokardiyogram işaretleri (EKG) ve yüz imgeleri kullanılarak evrışimsel sinir ağı (ESA) tabanlı çoklu biyometrik tanıma sistemi gerçekleştirilmiştir. Gerçekleştirilen sistem tasarımında biyometrik veri olarak basit ve maliyeti düşük bir sensör (kamera) ile bilgisi alınabilen yüz imgeleri ve sisteme kişinin canlı olup olmadığı bilgisini sağlayabilecek olan EKG işareti tercih edilmiştir. Bu sayede birden fazla biyometrik veri kullanılarak sistem başarımı yüksek ve yanıltma saldırılarına karşı dayanıklı bir kişi tanıma sisteminin geliştirilmesi hedeflenmiştir. Günümüzde 2 boyutlu veri kümelerini sınıflandırmada başarılı sonuçlar üreten 2 boyutlu evrışimsel sinir ağı (ESA) mimarisi, bu tez çalışmasında 1 boyutlu EKG işaretlerinden elde edilen 2 boyutlu QRS imgelerinden ve RGB seviyeli yüz imgelerinden öznitelik çıkarma ve çıkarılan bu özniteliklerin sınıflandırılması aşamalarında kullanılmıştır. Hem QRS imgelerinin tek başına sınıflandırıldığı Önerilen Yöntem-1’de, hem de QRS ve yüz imgelerinin birlikte sınıflandırıldığı Önerilen Yöntem-2’de deneyler 3 katlı çapraz doğrulama şeklinde gerçekleştirilmiş ve yüksek başarımlarına ulaşılmıştır. Bu çalışmada Önerilen Yöntem-2 (FACECG) olarak sunulan yöntemle EKG ve yüz veri kümeleri ayrı ayrı sınıflandırıldığında sırası ile ortalama %98.33 ve %98.60 doğruluk değerleri elde edilmiştir. Bu iki farklı biyometrik verinin iki tür bilgi birleştirme (öznitelik ve skor seviyeli birleştirme) yöntemi ile birlikte kullanılması sonucunda her iki birleştirme yöntemi için de %100 doğruluk değerinin elde edildiği gösterilmiştir. Bu tez çalışması sonucunda elde edilen deneysel sonuçlar göstermektedir ki sadece EKG işaretini kullanarak veya sadece yüz imgelerini kullanarak elde edilen doğruluk değerleri bu iki büyüklüğün birlikte kullanılması sonucu önemli ölçüde iyileşmiş ve %100 doğruluk değerine ulaşmıştır.

Literatür aşamasında bulabildiğimiz kadarıyla EKG işaretlerini ve yüz imgelerini birlikte kullanarak biyometrik tanıma yapan sadece 3 çalışma olduğu belirlenmiştir. Bu 3 çalışma yöntem olarak Çizelge 6.4’ten görülebileceği gibi geleneksel yöntemleri kullanmaktadır. Bu anlamda bu tez çalışmasında sunulan Önerilen

Yöntem-2 (FACECG), 2 boyutlu evrişimsel sinir ağı yöntemini kullanarak hem EKG işaretlerini hem de yüz imgelerini birlikte değerlendirerek biyometrik tanıma işlemini gerçekleştiren ilk çalışma olma özelliğine sahiptir. Ayrıca Önerilen Yöntem-2 (FACECG) literatür araştırmasında bulunan 3 çalışmada sunulan kişi tanıma başarımlarına göre doğruluk değeri açısından daha yüksek başarımlarını vermektedir.

Deneysel çalışmalarda hem EKG hem de yüz tanıma sistemi için kullanılan veri kümesinde 30 farklı kişiye ait veriler kullanılmıştır. Daha fazla kişi barındıran veri tabanları kullanılarak burada önerilen çoklu biyometrik tanıma yöntemlerinin veya sistemlerinin geliştirilmesi ve sonuçların gözlenmesi gelecek çalışmalar olarak planlanmaktadır. Böylece önerilen yöntemin genelleştirilebilirliği ve daha fazla veri durumundaki performansı analiz edilebilecektir.

KAYNAKLAR

- [1] **Jain, A. K., Flynn, P., & Ross, A. A. (Eds.).** (2007). *Handbook of biometrics*. Springer Science & Business Media.
- [2] **Arun, A. R., Karthik, N., & Anil, K. J.** (2006). Handbook of multibiometrics.
- [3] **Pinto, J. R., Cardoso, J. S., & Lourenço, A.** (2018). Evolution, current challenges, and future possibilities in ECG biometrics. *IEEE Access*, 6, 34746-34776.
- [4] **Merone, M., Soda, P., Sansone, M., & Sansone, C.** (2017). ECG databases for biometric systems: A systematic review. *Expert Systems with Applications*, 67, 189-202.
- [5] **Biel, L., Pettersson, O., Philipson, L., & Wide, P.** (2001). ECG analysis: a new approach in human identification. *IEEE Transactions on Instrumentation and Measurement*, 50(3), 808-812.
- [6] **Shen, T. W. D., Tompkins, W. J., & Hu, Y. H.** (2010). Implementation of a one-lead ECG human identification system on a normal population. *Journal of Engineering and Computer Innovations*, 2(1), 12-21.
- [7] **Shen, T. W., Tompkins, W. J., & Hu, Y. H.** (2002). One-lead ECG for identity verification. In Proceedings of the Second Joint 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society][Engineering in Medicine and Biology (Vol. 1, pp. 62-63). IEEE.
- [8] **Shen, T.** (2005). Biometric identity verification based on electrocardiogram. *PhD thesis*.
- [9] **Israel, S. A., Irvine, J. M., Cheng, A., Wiederhold, M. D., & Wiederhold, B. K.** (2005). ECG to identify individuals. *Pattern recognition*, 38(1), 133-142.
- [10] **Wübbeler, G., Stavridis, M., Kreiseler, D., Bousseljot, R. D., & Elster, C.** (2007). Verification of humans using the electrocardiogram. *Pattern Recognition Letters*, 28(10), 1172-1175.
- [11] **Wang, Y., Agrafioti, F., Hatzinakos, D., & Plataniotis, K. N.** (2007). Analysis of human electrocardiogram for biometric recognition. *EURASIP journal on Advances in Signal Processing*, 2008(1), 148658.
- [12] **Gürkan, H., Guz, U., & Yarman, B. S.** (2013, July). A novel biometric authentication approach using electrocardiogram signals. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 4259-4262). IEEE.
- [13] **Chiu, C. C., Chuang, C. M., & Hsu, C. Y.** (2008, April). A novel personal identity verification approach using a discrete wavelet transform of the ECG signal. In *2008 International Conference on Multimedia and Ubiquitous Engineering (mue 2008)* (pp. 201-206). IEEE.

- [14] **Chamatidis, I., Katsika, A., & Spathoulas, G.** (2017, October). Using deep learning neural networks for ecg based authentication. In *2017 International Carnahan Conference on Security Technology (ICCST)* (pp. 1-6). IEEE.
- [15] **Loong, J. L. C., Subari, K. S., Besar, R., & Abdullah, M. K.** (2010). A new approach to ECG biometric systems: a comparative study between LPC and WPD systems. *World Academy of Science, Engineering and Technology*, 68(20), 759-764.
- [16] **Sufi, F., & Khalil, I.** (2011). Faster person identification using compressed ECG in time critical wireless telecardiology applications. *Journal of Network and Computer Applications*, 34(1), 282-293.
- [17] **Safie, S. I., Soraghan, J. J., & Petropoulakis, L.** (2011). Electrocardiogram (ECG) biometric authentication using pulse active ratio (PAR). *IEEE Transactions on Information Forensics and Security*, 6(4), 1315-1322.
- [18] **Li, M., & Narayanan, S.** (2010, August). Robust ECG biometrics by fusing temporal and cepstral information. In *2010 20th International Conference on Pattern Recognition* (pp. 1326-1329). IEEE.
- [19] **Irvine, J. M., Israel, S. A., Scruggs, W. T., & Worek, W. J.** (2008). eigenPulse: Robust human identification from cardiovascular function. *Pattern Recognition*, 41(11), 3427-3435.
- [20] **Lei, X., Zhang, Y., & Lu, Z.** (2016, October). Deep learning feature representation for electrocardiogram identification. In *2016 IEEE International Conference on Digital Signal Processing (DSP)* (pp. 11-14). IEEE.
- [21] **Zhang, Q., Zhou, D., & Zeng, X.** (2017). HeartID: A multiresolution convolutional neural network for ECG-based biometric human identification in smart health applications. *IEEE Access*, 5, 11805-11816.
- [22] **Eduardo, A., Aidos, H., & Fred, A. L.** (2017, February). ECG-based Biometrics using a Deep Autoencoder for Feature Learning-An Empirical Study on Transferability. In *ICPRAM* (pp. 463-470).
- [23] **Salloum, R., & Kuo, C. C. J.** (2017, March). ECG-based biometrics using recurrent neural networks. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 2062-2066). IEEE.
- [24] **Zhang, Q., Zhou, D., & Zeng, X.** (2017, October). PulsePrint: Single-arm-ECG biometric human identification using deep learning. In *2017 IEEE 8th Annual Ubiquitous Computing, Electronics and Mobile Communication Conference (UEMCON)*(pp. 452-456). IEEE.
- [25] **da Silva Luz, E. J., Moreira, G. J., Oliveira, L. S., Schwartz, W. R., & Menotti, D.** (2017). Learning deep off-the-person heart biometrics representations. *IEEE Transactions on Information Forensics and Security*, 13(5), 1258-1270.
- [26] **Labati, R. D., Muñoz, E., Piuri, V., Sassi, R., & Scotti, F.** (2018). Deep-ECG: Convolutional neural networks for ECG biometric recognition. *Pattern Recognition Letters*.
- [27] **Abdeldayem, S. S., & Bourlai, T.** (2018, December). ECG-based Human Authentication using High-level Spectro-temporal Signal Features. In *2018 IEEE International Conference on Big Data (Big Data)* (pp. 4984-4993). IEEE.

- [28] **Hammad, M., & Wang, K.** (2019). Parallel score fusion of ECG and fingerprint for human authentication based on convolution neural network. *Computers & Security*, 81, 107-122.
- [29] **Guo, S., Chen, S., & Li, Y.** (2016, August). Face recognition based on convolutional neural network and support vector machine. In *2016 IEEE International Conference on Information and Automation (ICIA)* (pp. 1787-1792). IEEE.
- [30] **Olstad, B., & Torp, A. H.** (1996). Encoding of a priori information in active contour models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(9), 863-872.
- [31] **Turk, M., & Pentland, A.** (1991). Eigenfaces for recognition. *Journal of cognitive neuroscience*, 3(1), 71-86.
- [32] **Wiskott, L., Fellous, J. M., Krüger, N., & Von Der Malsburg, C.** (1997, September). Face recognition by elastic bunch graph matching. In *International Conference on Computer Analysis of Images and Patterns* (pp. 456-463). Springer, Berlin, Heidelberg.
- [33] **Othman, H., & Aboulnasr, T.** (2003). A separable low complexity 2D HMM with application to face recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 25(10), 1229-1238.
- [34] **Er, M. J., Wu, S., Lu, J., & Toh, H. L.** (2002). Face recognition with radial basis function (RBF) neural networks. *IEEE transactions on neural networks*, 13(3), 697-710.
- [35] **Lawrence, S., Giles, C. L., Tsoi, A. C., & Back, A. D.** (1997). Face recognition: A convolutional neural-network approach. *IEEE transactions on neural networks*, 8(1), 98-113.
- [36] **Ko, K. E., & Sim, K. B.** (2010, October). Development of a Facial Emotion Recognition Method based on combining AAM with DBN. In *2010 International Conference on Cyberworlds* (pp. 87-91). IEEE.
- [37] **Xia, R., Deng, J., Schuller, B., & Liu, Y.** (2014, May). Modeling gender information for emotion recognition using denoising autoencoder. In *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 990-994). IEEE.
- [38] **Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- [39] **Simonyan, K., & Zisserman, A.** (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [40] **An, Y., Wu, J., & Yue, C.** (2017). CNNs for Face Detection and Recognition. California: Stanford University.
- [41] **Israel, S. A., Scruggs, W. T., Worek, W. J., & Irvine, J. M.** (2003, October). Fusing face and ECG for personal identification. In *32nd Applied Imagery Pattern Recognition Workshop, 2003. Proceedings.* (pp. 226-231). IEEE.

- [42] **Boumbarov, O., Velchev, Y., Tonchev, K., & Paliy, I.** (2011). Face and ECG based multi-modal biometric authentication. In *Advanced biometric technologies*. IntechOpen.
- [43] **Chakraborty, S., Mitra, M., & Pal, S.** (2016). Biometric analysis using fused feature set from side face texture and electrocardiogram. *IET Science, Measurement & Technology*, 11(2), 226-233.
- [44] **Sze, V., Chen, Y. H., Yang, T. J., & Emer, J. S.** (2017). Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, 105(12), 2295-2329.
- [45] **Patterson, J., & Gibson, A.** (2017). *Deep learning: A practitioner's approach*. " O'Reilly Media, Inc."
- [46] **Karpathy, A., & Li, F. F.** (2018). Stanford CS class CS231n: Convolutional Neural Networks for Visual Recognition. Course Notes, Link: <http://cs231n.github.io>. Accessed, 27.
- [47] **Moody, G. B., & Mark, R. G.** (2001). The impact of the MIT-BIH arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45-50.
- [48] **Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., ... & Stanley, H. E.** (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 101(23), e215-e220.
- [49] **Physionet MIT-BIH Arrhythmia Database**. Eriřim: 9 Ekim 2018, <https://physionet.org/physiobank/database/mitdb/>
- [50] **AR Face Database**. Eriřim: 10 Ekim 2018, <http://www2.ece.ohio state.edu/~aleix/ARdatabase.html>
- [51] **Pan, J., & Tompkins, W. J.** (1985). A real-time QRS detection algorithm. *IEEE Trans. Biomed. Eng*, 32(3), 230-236.
- [52] **Manning, C., Raghavan, P., & Schütze, H.** (2010). Introduction to information retrieval. *Natural Language Engineering*, 16(1), 100-103.
- [53] **Güven, G., Gürkan, H., & Guz, U.** (2018). Biometric identification using fingertip electrocardiogram signals. *Signal, Image and Video Processing*, 12(5), 933-940.
- [54] **Güven, G.** (2016). *Fingertip ECG signal based biometric recognition system* (Master's thesis, Iřık Üniversitesi).

EKLER

EK A: Sözlük

3 Katlamalı Çapraz Doğrulama	: 3-Fold Cross Validation
Ağırlık Katsayısı	: Weight Coefficient
Alıcı İşletim Karakteristiği	: Receiver Operating Characteristic (ROC)
Ayrık Kosinüs Dönüşümü	: Discrete Cosine Transform (DCT)
Birleştirme	: Fusion
Çarpım Kuralı	: Product Rule
Çok Değişkenli Analiz Yöntemi	: Multivariate Analysis
Çok Katmanlı Algılayıcı	: Multi Layer Perceptron (MLP)
Dalgacık Dönüşümü	: Wavelet Transform
Darbe Aktif Oranı	: Pulse Active Ratio (PAR)
Dereceli Azalma	: Gradient Descent
Derin Öğrenme	: Deep Learning
Derin Sinir Ağı	: Deep Neural Network (DNN)
Destek Vektör Makineleri	: Support Vector Machine (SVM)
Doğru Negatif	: True Negative
Doğru Pozitif	: True Positive
Doğru Pozitif Oranı	: True Positive Rate
Doğruluk	: Accuracy
Doğrusal Ayırıcı Analizi	: Linear Discriminant Analysis (LDA)
Doğrusal Tahmini Kodlama	: Linear Predictive Coding (LPC)
Duyarlılık	: Sensitivity, Recall
Düzleştirme	: Flatten
Evrişimsel	: Convolutional
Evrişimsel Sinir Ağı	: Convolutional Neural Network (CNN)
F-Ölçütü	: F-Score
Gauss Karışım Dağılımı	: Gaussian Mixture Model (GMM)
Gizli Katman	: Hidden Layer
Güç Spektrum	: Cepstral Features
Hassasiyet	: Precision
Hata Matrisi	: Confusion Matrix
Hermite Polynomial Expansion	: Hermite Polinom Katsayıları
İç çarpım, konvolüsyon	: Convolution
İterasyon adımı	: İteration Step
Kayıp Fonksiyonu	: Loss Function
Kepstrum	: Cepstrum
Makine Öğrenmesi	: Machine Learning
Maksimum Ortaklama	: Max Pooling
Ortalama Karesel Hata	: Mean Square Error
Ortalama Karesel Sapma	: Mean Square Deviation (MSD)
Öğrenme Hızı	: Learning Rate
Öklit Mesafesi	: Euclidian Distance

Ön İşleme	: Preprocessing
Özilinti	: Autocorrealtion
Öznitelik	: Feature
Öznitelik Haritası	: Feature Map (fmap)
Radyal Bazlı Sinir Ağı	: Radial Basis Neural Network (RBNN)
Seyreltme	: Dropout
Sinir Ağı Tabanlı Karar Verme	: Decision-Based Neural Network (DBNN)
Sinir Ağları	: Neural Networks
Tam Bağlantılı	: Fully Connected
Temel Bileşenler Analizi	: Principles Component Analysis (PCA)
Veri Madenciliği	: Data Mining
Yanlılık Etkisi	: Biasing Effect
Yanlış Negatif	: False Negative
Yanlış Pozitif	: False Positive
Yapay Zeka	: Artificial Intelligence



ÖZGEÇMİŞ



Ad-Soyad : Ayça HANILÇI
Doğum Tarihi ve Yeri : 04.05.1988 Fatih
E-posta : ycgktrk@gmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2010, Uludağ Üniversitesi, Mühendislik - Mimarlık Fakültesi, Elektronik Mühendisliği Bölümü
- **Yüksek Lisans** : 2019, Bursa Teknik Üniversitesi, Elektrik Elektronik Mühendisliği Anabilim Dalı

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- Hanilci, A , Gürkan, H . (2019). ECG Biometric Identification Method based on Parallel 2-D Convolutional Neural Networks. *Journal of Innovative Science and Engineering (JISE)*, 3 (1), 11-22. Retrieved from <http://jise.btu.edu.tr/issue/44666/559236>
- Gürkan, H., & Hanilçi, A. (2019). Evrişimsel sinir ağı ve QRS imgeleri kullanarak EKG tabanlı biyometrik tanıma yöntemi. (Değerlendirme aşamasında)