T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÇOKLU-BİYOMETRİK YÖNTEMLERLE KİMLİK DOĞRULAMA

KADİR SERCAN BAYRAM

DOKTORA TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI
HABERLEŞME PROGRAMI

DANIŞMAN
DR.ÖĞR.ÜYESİ BÜLENT BOLAT

İSTANBUL, 2018

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ÇOKLU-BİYOMETRİK YÖNTEMLERLE KİMLİK DOĞRULAMA

Kadir Sercan BAYRAM tarafından hazırlanan tez çalışması 19.06.2018 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Dr.Öğr.Üyesi Bülent BOLAT

Yıldız Teknik Üniversitesi

Jüri Üyeleri

Dr.Öğr.Üyesi Bülent BOLAT

Yıldız Teknik Üniversitesi _____

Dr.Öğr.Üyesi Nihan KAHRAMAN

Yıldız Teknik Üniversitesi _____

Dr.Öğr.Üyesi Soner ÖZGÜNEL

Haliç Üniversitesi _____

Prof.Dr. Ufuk TÜRELİ

Yıldız Teknik Üniversitesi _____

Doç.Dr. Mürvet KIRCI

İstanbul Teknik Üniversitesi _____

ÖNSÖZ

Bu tez çalışmasında, günümüzde kullanılan şifreleme yöntemlerinin güvenlik problemlerinden dolayı daha güvenli üç adet biyometri kullanarak kimliklendirme yapan çözüm önerilmiştir. Bununla beraber bu biyometrilerden herhangi birisinin elde edilme aşamasında sorun ile karşılaşılsa dahi diğer iki biyometri yardımıyla bu sorunun ortadan kaldırılması amaçlanmıştır.

Öncelikle tez çalışmamda bütün bilgi ve birikimini benimle paylaşan, desteğini hiç esirgemeyen tez danışmanım Dr.Öğr.Üyesi Bülent BOLAT'a teşekkürlerimi sunarım. Bu tez çalışmasında bana destek veren Prof.Dr. Tamer YILMAZ'a, tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen her zaman yanımda olan aileme teşekkür ederim.

Bu zorlu tez döneminde sabrını ve sevgisini her daim hissettiğim sevgili eşim Betül ANNAÇ BAYRAM'a teşekkürlerimi bir borç bilirim. Son olarak tezimin son döneminde dünyaya gelerek bize dünyaları veren canım oğlum Bertan BAYRAM hoş geldin hayatımıza.

Haziran, 2018

Kadir Sercan BAYRAM

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ vi

KISALTMA LİSTESİ viii

ŞEKİL LİSTESİ ix

ÇİZELGE LİSTESİ x

ÖZET xi

ABSTRACT xiii

BÖLÜM 1

GİRİŞ 1

1.1 Literatür Özeti 1
1.2 Tezin Amacı 6
1.3 Hipotez 7

BÖLÜM 2

BİYOMETRİ, ÇOKLU-BİYOMETRİ VE BİRLEŞTİRME İŞLEMİ 8

2.1 Çoklu-Biyometri 10
2.1.1 Çoklu-Biyometrik Karakteristik 11
2.1.2 Çoklu-Algoritma 11
2.1.3 Çoklu-Örnek 12
2.1.4 Çoklu-Sensör 12
2.2 Birleştirme İşlemi 13
2.2.1 Sensör-Seviyesi Birleştirme (S-SB) 13
2.2.2 Öznitelik Seviyesi Birleştirme (Ö-SB) 13
2.2.3 Eşleştirme Skoru-Seviyesi Birleştirme (ES-SB) 14
2.2.4 Karar-Seviyesi Birleştirme (K-SB) 14

BÖLÜM 3

KULLANILAN YÖNTEMLER 16

3.1 Öznitelik Çıkartımı Metotları 16
3.1.1 Temel Bileşenler Analizi 16
3.1.2 Yerel İkili Örüntü 18
3.1.3 Gri Seviye Eş-Oluşum Matrisi 20
3.2 Öznitelik Seçim Metodu 21
3.3 Sınıflandırma Metotları 22
3.3.1 Çok Katmanlı Algılayıcı 22
3.3.2 Karar Ağacı 24
3.3.3 Destek Vektör Makineleri 26
3.3.4 Olasılıksal Sinir Ağları 27

BÖLÜM 4

KULLANILAN VERİ SETİ VE DENEYSEL SONUÇLAR 29

4.1 Kullanılan Veri Seti 29
4.2 Deneysel Sonuçlar ve Yorumlanması 30

BÖLÜM 5

SONUÇ VE ÖNERİLER 44

KAYNAKLAR 46

ÖZGEÇMİŞ 51

SİMGE LİSTESİ

I	Veri seti içindeki görüntüler
N	Matris boyutu – piksel sayısı
Γ	Görüntü vektörü
M	Toplam görüntü sayısı
ψ	Ortalama görüntü vektörü
A	Veri seti
Φ	Veri setinin elemanları
C	Kovaryans matrisi
x_c,y_c	Piksel koordinatları
$LBP_{P,R}$	Yerel ikili operatörü
i_c,i_p	Merkez pikselin gri seviye değerleri
s(x)	LBP'nin ikili çıkışlar için fonksiyon
d	Pikseller arası uzaklık
θ	Pikseller arası açı
i,j	Piksellerin gri seviye değerleri
P	Eş-oluşum matrisi
σ	Standart sapma
μ	Ortalama
f_{log}	Lojistik bir fonksiyon
w_0	Başlangıç ağırlık değeri
$\vec{w}$	Güncellenmiş ağırlık değeri
$\vec{x}$	Ağırlıklara göre güncellenmiş giriş değerleri
p(x)	Verilerin sınıfına ait yüzde
H	Entropi
S	Orijinal veri seti
D	Bu veri setinin bölünmüş parçası
V	Orijinal veri setinin alt kümesi
k	Örnek sayısı
x_i	i. giriş vektörü
y_i	Sınıfın etiketi
b	Bias değeri
$K(x_i,x_j)$	Kernel fonksiyonu

$F_n(x)$	Olasılık yoğunluk fonksiyonu
P_1,P_2	Sınıfların görülme olasılıkları
L_1,L_2	Yanlış sınıflandırılma oranları
m	Giriş uzayının boyutu
i	Örüntü numarası
n	Eğitim verisi sayısı
σ	Ayarlanabilir yumuşatma terimi(denklem 3.15)

KISALTMA LİSTESİ

BBA	Bağımsız Bileşenler Analizi
DDA	Doğrusal Diskriminant Analizi
DT	Karar Ağacı
DVM	Destek Vektör Makinaları
EER	Eşit Hata Oranı
ES-SB	Eşleştirme Skoru Seviyesi Birleştirme
FAR	Hatalı Kabul Oranı
FDDA	Fisher Doğrusal Diskriminant Analizi
FER	Kayıt Hatası Oranı
FRR	Hatalı Red Oranı
GA	Genetik Algoritmalar
GLCM	Gri Seviye Eş-oluşum Matrisi
IR	Infrared
K-SB	Karar Seviyesi Birleştirme
LBP	Yerel İkili Örüntü
M3	Çoklu-Biyometri, Çoklu-Cihaz and Çokludil
MLP	Çok Katmanlı Algılayıcı
Ö-SB	Öznitelik Seviyesi Birleştirme
PNN	Olasılıksal Sinir Ağları
ROC	Alıcı İşlem Karakteristikleri
SPRT	Aşamalı Olasılık Oran Testi
S-SB	Sensör Seviyesi Birleştirme
TBA	Temel Bileşenler Analizi

ŞEKİL LİSTESİ

Sayfa

Şekil 2. 1 FAR, FRR ve EER grafik gösterimi 9
Şekil 2. 2 Çoklu-biyometrik sistem[49] 11
Şekil 2. 3 Çoklu-algoritma[51] 11
Şekil 2. 4 Çoklu-örnek[51] 12
Şekil 2. 5 Çoklu-sensör[51] 12
Şekil 2. 6 Sensör seviyesi birleştirme blok diyagramı 13
Şekil 2. 7 Öznitelik seviyesi birleştirme blok diyagramı 14
Şekil 2. 8 Eşleştirme skoru seviyesi birleştirme blok diyagramı 14
Şekil 2. 9 Karar seviyesi birleştirme blok diyagramı 15
Şekil 3. 1 Basit LBP operatörünün çalışması 19
Şekil 3. 2 Örnek LBP operatörleri (8,1) – (16,2) – (24,3) 19
Şekil 3. 3 Eş-oluşum matris örneği 20
Şekil 3. 4 İleriye doğru öznitelik seçim algoritması 22
Şekil 3. 5 Çok katmanlı algılayıcı modeli 23
Şekil 3. 6 Örnek karar ağacı modeli 24
Şekil 3. 7 Doğrusal sınıflandırma eğrileri 26
Şekil 3. 8 Optimum hiper düzlem 26
Şekil 3. 9 Verinin yüksek boyuta dönüştürme işlemi 27
Şekil 4. 1 Yüz görüntü örneği 29
Şekil 4. 2 Termal yüz görüntü örneği 30
Şekil 4. 3 Kulak görüntü örneği 30

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2. 1 Biyometrik karakteristikler ve parametreler 10
Çizelge 4. 1 Eşleştirme skoru seviyesi birleştirme – öznitelikleri (30 adet) kullanarak 31
Çizelge 4. 2 Eşleştirme skoru seviyesi birleştirme – öznitelikleri (40 adet) kullanarak 31
Çizelge 4. 3 Eşleştirme skoru seviyesi birleştirme – öznitelikleri (50 adet) kullanarak 31
Çizelge 4. 4 Öznitelik seviyesi birleştirme – öznitelikleri kullanarak..... 32
Çizelge 4. 5 Eşleştirme skoru seviyesi birleştirme(karar ağacı algoritması için) 33
Çizelge 4.6 Eşleştirme skoru seviyesi birleştirme(destek vektör makineleri için)..... 34
Çizelge 4.7 Eşleştirme skoru seviyesi birleştirme(olasılıksal sinir ağları için)..... 35
Çizelge 4.8 Öznitelik seviyesi birleştirme(karar ağacı algoritması için)..... 36
Çizelge 4.9 Öznitelik seviyesi birleştirme(destek vektör makineleri için) 36
Çizelge 4.10 Öznitelik seviyesi birleştirme(olasılıksal sinir ağları için)..... 36
Çizelge 4.11 FAR,FRR, eğitim süresi ve test süresi değerleri 37
Çizelge 4.12 ES-SB – kulak biyometrisi elde edilemediğinde(DT için) 39
Çizelge 4.13 ES-SB – yüz biyometrisi elde edilemediğinde(DT için)..... 39
Çizelge 4.14 ES-SB – termal yüz biyometrisi elde edilemediğinde (DT için)..... 40
Çizelge 4.15 ES-SB – kulak biyometrisi elde edilemediğinde (DVM için)..... 40
Çizelge 4.16 ES-SB – yüz biyometrisi elde edilemediğinde (DVM için)..... 41
Çizelge 4.17 ES-SB – termal yüz biyometrisi elde edilemediğinde (DVM için) 41
Çizelge 4.18 ES-SB – kulak biyometrisi elde edilemediğinde (PNN için)..... 42
Çizelge 4.19 ES-SB – yüz biyometrisi elde edilemediğinde (PNN için)..... 42
Çizelge 4.20 ES-SB – termal yüz biyometrisi elde edilemediğinde (PNN için) 43

ÖZET

ÇOKLU-BİYOMETRİK YÖNTEMLERLE KİMLİK DOĞRULAMA

Kadir Sercan BAYRAM

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Doktora Tezi

Tez Danışmanı: Dr.Öğr.Üyesi Bülent BOLAT

Biyometrik özelliklerin kullanıldığı sistemler numara kullanan şifreleme sistemlerine göre daha güvenlidir. Kişilerin kullandıkları şifreler çalınabilirler fakat biyometrik özellikler kullanan kişinin bir parçası oldukları için böyle bir ihtimal bulunmamaktadır. Bunun yanında biyometrik özellikle %100 güvenli değillerdir. Kötü niyetli kişiler biyometrik karakteristiğe sahip kişileri zor kullanarak bu biyometrilerini kullanabilirler.

Günümüzde yapılan tekil biyometrik kimliklendirme çalışmalarında alınan sonuçların; başarı oranı, süre ve hata açısından yeterli performanslara ulaşmamış olmasının nedenleri arasında performansı yüksek olan iris gibi biyometrik parametrelerin elde edilmesinin ve kişilerin bu biyometrik özellikleri vermesinin kabul edilme zorlukları bulunmaktadır. Bunun yanında güvenli tanıma konusunda yapay biyometrilerle kandırma gibi problemler ortaya çıkmaktadır. Tekil-biyometrinin diğer dezavantajı ise kişiden alınan bilgi; şartlardan dolayı okunamadığında tanıma başarısızlıkla sonuçlanmaktadır. Bu çalışma ile birlikte çoklu biyometri kullanarak kişilerin biyometrilerinin herhangi bir tanesi elde edilirken sorunla karşılaşılsa bile diğer biyometrileri sayesinde sistem başarılı olarak çalışmaktadır.

Bu çalışmada ile bu sorunlara çözüm bulunmaya çalışılmış ve daha güvenli bir biyometrik sistem olarak çoklu-biyometri için kulak yüz ve termal yüz, çoklu-algoritma için çok katmanlı algılayıcı, destek vektör makineleri, karar ağacı ve olasılıksal sinir ağları ve çoklu-örnek olarak çoklu bir biyometrik sistem önerilmiştir.

Yüz ve termal yüz görüntüleri “USTC NVIE Spontaneous Database” veritabanından, kulak görüntüleri ise “IIT Delhi Ear Image Database” veritabanından alınmıştır.

Her biyometri için üç farklı öznitelik çıkartma yöntemi ve dört farklı sınıflandırma algoritması (çok katmanlı perceptron, karar ağacı, destek vektör makineleri ve istatistiksel sinir ağları) kullanılarak kimliklendirme çalışması yapılmıştır. Bu yöntemlerle beraber iki farklı birleştirme yöntemi(eşleştirme skoru seviyesi birleştirme ve öznitelik seviyesi birleştirme) kullanılmıştır. Alınan sonuçlara göre kişilerin tekil biyometrilerinden alınan sonuçlara göre çoklu biyometri ve birleştirme işlemi sonucunda alınan sonuçlar (FAR,FRR ve doğruluk oranı) daha başarılı olmuştur.

Anahtar Kelimeler: Çoklu-biyometri, füzyon, eşleştirme skoru seviyesi birleştirme, öznitelik seviyesi birleştirme, kimliklendirme.

ABSTRACT

VERIFICATION BY USING MULTI-BIOMETRIC METHODS

Kadir Sercan BAYRAM

Department of Electronics and Communications Engineering

PhD. Thesis

Adviser: Assist.Prof.Dr. Bülent BOLAT

Systems using biometric features are more secure than encryption systems using numbers. The passwords used by people can be stolen, but there is no such possibility as they are part of the person using the biometric features. However, biometric features are not 100% safe. Malicious people can use these biometrics by forcing people with biometric characteristics. In this study, we tried to find solutions to these problems. A safer biometric system has been proposed.

Today's results in singular identification studies have not achieved enough performance in terms of success rate, error and time. There are difficulties in getting biometric parameters such as iris (which has high performance) because people do not release these biometric characteristics. Besides, problems arise about safe recognition. Another disadvantage is that the in singular-biometri, information can not be read due to the conditions and results in failure. With this study, even if the problem is encountered when any one of the biometrics of the person is being obtained by using multiple biometrics, the system works successfully thanks to other biometrics.

Face and thermal facial images were taken from the "USTC NVIE Spontaneous Database" database and ear images were taken from the "IIT Delhi Ear Image Database" database.

For each biometry, three different feature extracting methods and four different classification algorithms (multi-layered perceptron, decision tree, support vector

machines and statistical neural networks) were used for identification. Two different fusion methods (matching score level fusion and feature level fusion) are used with these methods.

The results (FAR, FRR, and accuracy) resulting from multiple biometry and fusion have been more successful than results from individual biometrics of individuals.

Keywords: Multi-biometri, fusion, matching score level fusion, feature level fusion, identification.

BÖLÜM 1

GİRİŞ

1.1 Literatür Özeti

2002 yılında A.K. Jain ve A. Ross tarafından yapılan "Learning User-Specific Parameters in a Multibiometric System" adlı çalışmada performans arttırmak için iki parametre kullanılmıştır. Karar vermek için kullanılan eşikler sonuçta gerçek bir kullanıcı veya sahte kullanıcı veriyorsa güncellenmekte ve her biyometrik özellik için ağırlıklar sonuçlara göre değiştirilmektedir. Bu çalışmada yüz, parmak izi ve el geometrisi kullanılmıştır. 50 kişi arasından 40 kişi için 5'er örnek (yılda 2), diğer 10 kişi için ise 30'ar örnek (ayda 2 örnek) alınmıştır. Görüntüler 640x480 boyutarındadır. Sonuçlarda eşik seviyesi kullanmanın başarıyı %2, ağırlıkları kullanmanın da %3 oranında arttırdığını belirtmişlerdir [1].

2004 yılında yapılan üç çalışmadan biri, K.I. Chang, K.W. Bowyer ve arkadaşları tarafından yapılan "Multi-biometrics Using Facial Apperance, Shape and Temperature" isimli çalışmadır. Bu çalışmada 3D, 2D ve IR görüntülerin ayrı ayrı ve birleşimleri sonucunda başarı oranları çıkartılmıştır. 297 adet resim üzerinde yapılan çalışmada resimlerin boyutları 640x480 olarak alınmış, IR görüntüler ise 240x320 olarak alınmıştır. Yapılan çalışma sonucunda tekli biyometri yapıldığında 2D için %90,6, 3D için %91,9 ve IR için %71 oranı elde edilmiştir. İkili biyometri yapıldığında bu oranlar 2D+3D için 98,7, 2D+IR için %96,6, 3D+IR için %98 seviyelerine çıkmıştır. Üçlü biyometride ise bu oranın %100 olduğu görülmüştür. Çalışmada temel bileşenler analizi (TBA) kullanılmış ve farklı birleştirme metodlarının sonuçları verilmiştir [2]. Yine aynı şekilde 2004 yılında J.F. Aguilar ve arkadaşları "Discriminative Multimodal Biometric Authentication Based On

Quality Measures" isimli çalışmalarında parmakizi ve imza kullanmışlardır. 75x7 gerçek kullanıcı, 75x10 adet de sahte kullanıcı bulunmaktadır. Destek vektör makinaları (DVM) kullanılarak yapılan çalışmada birleştirme yöntemi olarak da eşleştirme skor seviyesi metodu kullanılmıştır. Çalışma içerisinde tekli biyometri ve çoklu biyometri sonuçları yer almaktadır [3]. Aynı yılda C.W. Lau ve arkadaşları tarafından "Fuzzy Logic Decision Fusion in a Multimodal Biometric System" isimli çalışmalarında konuşma, parmak izi ve yüz biyometrilerini kullanmışlardır. Bulanık mantık yöntemi ile yapılan çalışmada birleştirme yöntemi ise karar seviyesi birleştirmedir. Tekli ve çoklu biyometri sonuçları çalışma içerisinde bulunmaktadır [4].

2005 yılında yapılan iki çalışmadan biri, T. Ko tarafından "Multimodal Biometric Identification For Large User Population Using Fingerprint, Face And Iris Recognition" isimli çalımadır. Çalışmada parmak izi ve yüz görüntüleri için eşleştirme skor seviyesi ile birleştirme kullanılmıştır. Iris görüntülerinden sağ ve sol iris için birleştirme uygulanmış ve sonuçlar verilmiştir [5]. Yine aynı yılda R. Snelick ve arkadaşları tarafından yapılan "Large-Scale Evaluation of Multimodal Biometric Authentication Using State-of-the Art Systems" isimli çalışmada kişilerin 972x2 adet yüz ve yine aynı sayıda parmak izi görüntüleri kullanılmıştır. Farklı normalizasyon metodları ile birleştirme yöntemlerinin sonuçları alınmıştır [6].

2006 yılında yapılan çalışmalardan biri, K. Nandakumar ve arkadaşları tarafından yapılan "Quality-based Score Level Fusion in Multibiometric Systems" isimli çalışmadır. Bu çalışmada iris ve parmak izi görüntüleri kullanılmış ve 320x5 örnek üzerinden sonuçlar alınmıştır. Quality-temelli birleştirme tekniği kullanmışlardır. Tekli ve çoklu biyometri sonuçları çalışmada yer almaktadır [7]. K.W. Bowyer ve arkadaşları tarafından yapılan "Multi-Modal Biometrics: An Overview" isimli çalışmada ise çoklu biyometriye genel bir bakış yapılmıştır. Bununla beraber 2D ve 3D yüz resimleri ve 2D ve 3D kulak resimleri için sonuçlar alınmıştır. Bu sonuçların birbirleriyle karşılaştırılması da çalışmada ayrıntılı olarak yer almaktadır [8]. A. Rattani ve arkadaşları "Robust Feature-Level Multibiometric Classification" isimli çalışmalarını öznitelik seviyesi birleştirme yöntemini kullanarak yüz ve parmak izi üzerine yapmışlardır. 50x5 örnek kullanmışlar ve %97.41'lik başarı oranına ulaşmışlardır [9]. V. Rudolf ve P. Bores "Multi-biometric Techniques, Standard Activities and Experimenting" isimli çalışmalarında

yöntemler hakkında genel bilgi vermişler ve parmak izi, yüz ve iris üzerine beklenen sonuçları vermişlerdir [10]. H.Meng ve arkadaşları "The Multi-Biometric, Multi-Device and Multilingual (M3) Corpus" isimli çalışmalarında yüz, konuşma ve parmak izi üzerine yönelmişlerdir. Verilerin toplanması ile ilgili çoklu araç ve konuşma üzerine de çoklu-dil kullanmışlar ve sonuçlarını bu verilere göre almışlardır [11]. G. Chetty ve arkadaşları yüz ve konuşma üzerine "Multi-Level Liveness Verification for Face-Voice Biometric Authentication" isimli çalışmalarında tek bir birleşim değil birkaç adet birleşme yöntemini kullanarak sonuçlarını almışlardır [12].

2007 yılında yapılan çalışmalardan H. Vajaira ve arkadaşlarının yaptıkları "Evaluation And Analysis Of A Face And Voice Outdoor Multi-Biometric System" isimli çalışmalarında yüz ve konuşma özelliklerini kullanmışlardır. Eşleştirme skoru birleşme özelliğini kullanmışlar ve 116 kişi üzerinden sonuçları almışlardır. Çalışmaya ilişkin ROC eğrileri çıkartmışlardır [13]. S. Dinerstein ve arkadaşlarının yaptıkları "Robust Multi-Modal Biometric Fusion via Multiple SVMs" isimli çalışmalarında yüz, parmak izi ve DNA özellikleri üzerine çalışmışlardır. DVM yöntemini kullanmışlar ve eşleştirme skoru seviyesi birleştirme metodu ile çoklu biyometri kullanmışlardır. Üçlü biyometri kullandıklarında %99.492 gibi bir başarı oranı elde etmişlerdir [14]. A.F. Abate ve arkadaşlarının yaptıkları "Face, Ear and Fingerprint: Designing Multibiometric Architectures" isimli çalışmalarında makalenin başlığında da yer aldığı gibi yüz, kulak ve parmak izi üzerine çalışmışlardır. N-çapraz test protokolü ve hiyerarşi protokolü kullanmışlardır. Yüz ve kulak üzerine yapılan testlerin sonuçlarını almışlardır [15]. H.P. Hui ve arkadaşlarının yaptıkları "Adaptive Weight Estimation in Multi-Biometric Verification Using Fuzzy Logic Decision Fusion" isimli çalışmalarında yüz, parmak izi ve konuşma üzerine çalışmışlardır. Ortalama birleştirme metodu kullanmışlar ve Bulanık mantık ağırlık kestirimi yapmışlar sonuçları bu yöntemlere göre almışlardır [16]. C.Chen ve arkadaşları ise "Multi-Bits Biometric String Generation based on the Likelihood Ratio" isimli çalışmada çoklu parmak izi ve yüz üzerine çalışmalar yapmışlardır. Niceleme ve optimizasyon yapmışlardır. TBA yöntemini kullanarak sonuçları almışlardır [17].

2008 yılında yapılan çalışmalardan C. Wang ve arkadaşlarının yaptıkları "Multi-Modal Biometric Verification Based on FAR-score Normalization" isimli çalışmada yüz ve

parmak izi görüntüleri kullanılmıştır. Her iki özellikten de 100'er resim alınmıştır. Farklı normalizasyon yöntemleri ile Doğrusal diskriminant analizi (DDA) ve Bağımsız bileşenler analizi (BBA) yöntemleri kullanlmış ve sonuçlar bu yöntemlere göre alınmıştır [18]. G. Aggarwal ve arkadaşlarının yaptıkları "Multi-Biometric Cohort Analysis for Biometric Fusion" isimli çalışmalarında yüz ve parmak izi özelliklerini kullanmışlardır. 68x21 adet veri kullanmışlar ve topluluk analizi yapmışlardır. Farklı birleştirme metotlarına göre sonuçları vermişlerdir [19]. J.Cui ve arkadaşlarının yaptıkları "Study on Multi-Biometric Feature Fusion and Recognition Model" isimli çalışmada yüz ve iris görüntüleri baz alınmıştır. 2 boyutlu Fisher doğrusal diskriminant alanizi (FDDA) yöntemini kullanmışlar ve en yakın komşuluk karar kuralını kullanmışlardır. Birleştirme yaptıklarında bazı sonuçlarda %100 başarı oranını elde edebilmişlerdir [20]. K. Nandakumar ve A.K. Jain'in yaptıkları "Multibiometric Template Security Using Fuzzy Vault" isimli çalışmada parmak izi ve iris görüntüleri baz alınmış ve sonuçlar öznitelik seviyesi birleştirme yöntemi kullanarak alınmıştır. Bu çalışmada daha çok kişilerin güvenliklerini nasıl sağlayabiliriz üzerine durmuşlardır. Alınan görüntülerin kodlanması ve tekrar kod çözülmesi işlemlerinin sonuçlarını vermişlerdir [21]. F. Bashir ve arkadaşlarının yaptıkları "Video Surveillance for Biometrics: Long-Range Multi-Biometric System" isimli çalışmada uzun mesafeden kişinin biyometrik özelliklerinin elde edilmesi amaçlanmıştır. Biyometrik özelliklerden yüz ve iris görüntüleri kullanılmıştır. Sistem performans analizleri yapılmış ve sonuçları verilmiştir [22]. R.D. Seely ve arkadaşlarının yaptıkları "The University of Southampton Multi-Biometric Tunnel and Introducing a Novel 3D Gait Dataset" isimli çalışmada çoklu biyometrik özelliklerin elde edilebildiği bir tünel tasarlamışlardır. Yürüyüş, yüz ve kulak özelliklerinin alındığı bu tünelden alınan verilerle yapılan çalışmada sadece yürüyüş analizinin sonuçları verilmiştir [23].

2009 yılında yapılan çalışmalardan N.B. Boodoo ve R.K. Subramanian'ın yaptıkları "Robust Multi-Biometric Recognition Using Face and Ear Images" isimli çalışmada 30 kişiden aldıkları 7'şer yüz ve kulak görüntülerini kullanmışlardır. Karhunen-Loeve ve TBA yöntemini kullanarak karar aşamasında birleştirme yöntemi ile sonuçları elde etmişlerdir [24]. M. Monwar ve M.L. Gavrilova'nın yapmış oldukları "Multimodal Biometric System Using Rank-Level Fusion Approach" isimli çalışmada farklı kişilerden

aldıkları yüz, kulak ve imza görüntülerini kullanmışlardır. Rank seviyesi birleştirme metodunu ve sonuçları alırken TBA ve FDDA yöntemlerini kullanmışlardır [25]. S. Kanade ve arkadaşlarının yaptıkları "Multi-Biometrics Based Cryptographic Key Regeneration Scheme" isimli çalışmada çoklu-biyometrinin şifreleme yöntemi ile çalışmasının sonuçları alınmıştır. İris görüntülerinin hem sağ göz hem de sol göz için örnekleri kullanılmıştır. Öznitelik seviyesinde birleşme metodu kullanılmıştır [26]. J. Wang ve arkadaşlarının yaptıkları "An Effective Multi-Biometrics Solution for Embedded Device" çalışmasında parmak izi ve konuşma kullanılmıştır. DVM metodu ve skor normalizasyonu yapılmıştır. 300x2 örnek veri kullanılmıştır ve sonuçlar bu örneklere göre verilmiştirem [27]. K. Nandakumar ve arkadaşlarının yapmış oldukları "Fusion in Multibiometric Identification Systems: What about the Missing Data?" çalışmasında kaybolan verilere ilişkin çalışma yapılmıştır. Rank seviyesi birleşme ve DVM kullanılmıştır. Çalışmada yüz ve parmak izi görüntüleri baz alınmıştır [28].

2010 yılında yapılan çalışmalardan, D.L. Woodard ve arkadaşları "On the Fusion of Periocular and Iris Biometrics in Non-Ideal Imagery" isimli çalışmada İris ve perioküler doku üzerine çalışmışlardır. Gabor ve Hamming uzaklığı yöntemlerini kullanmışlardır. Birleştirme seviyesinde de eşleştirme seviyesi birleştirme yöntemini kullanmışlardır [29]. L. Allano ve arkadaşları ise "Tuning Cost And Performance İn Multi-Biometric Systems: A Novel And Consistent View Of Fusion Strategies Based On The Sequential Probability Ratio Test (SPRT)" isimli çalışmalarında performans analizi haricinde fiyat analizi de yapmışlardır. Yüz, parmak izi ve iris kullanılan çalışmada SPRT yöntemini kullanmışlar ve sonuçları bu yönteme göre almışlardır [30].

2011 yılında yapılan çalışmalarda, H.A. Aboalsamh "A Multi Biometric System Using Combined Vein and Fingerprint Identification" isimli çalışmasında sensör seçimi, işlemci seçimi gibi birçok konuya değinmiş ve parmak damar izi ile parmak izini kullanmıştır. Kendi kullandığı algoritmayı da çalışmasında vermiştir [31]. M. Belahcene ve arkadaşlarının yaptıkları "Fusion by Combination of Scores Multi-Biometric Systems" isimli çalışmada yüz ve konuşma seslerini kullanmışlardır. Çalışmada Fuzzy integrali kullanılmıştır. Bununla beraber sonuçları alırken 3 adet normalizasyon işlemi yapılmış ve ayrı ayrı sonuçları alınmıştır [32]. K. Popplewell ve arkadaşları "A Comparison of Genetic Feature Selection and Weighting Techniques for Multi-Biometric Recognition"

isimli çalışmada yüz ve perioküler doku kullanmışlardır. Yüz resimlerinde TBA, peroküler dokuda local binary pattern (LBP) kullanmışlardır. Öznitelik seçiminde iki adet yöntem kullanmışlar ve sonuçları yüz ve peroküler için hem ayrı ayrı hem de fusion işlemi sonucunda almışlardır [33]. A. Meraoumia ve arkadaşları "Fusion of Finger-Knuckle-Print and Palmprint for an Efficient Multi-biometric System of Person Recognition" isimli çalışmalarında parmak eklemi izi ve el ayası izini kullanmışlardır. Faz korelasyon fonksiyonu kullanmışlar ve sonuçları buna göre almışlardır [34].

2012 yılında yapılan çalışmalardan, A. Alford ve arkadaşları "Genetic & Evolutionary Biometrics: Hybrid Feature Selection and Weighting for a Multi-Modal Biometric System" isimli çalışmalarında yüz ve perioküler doku üzerine çalışmışlardır. LBP metodu kullanılmış, yüz ve perioküler doku için hem ayrı ayrı hem de birleştirme işlemi sonucunda başarım oranları bulunmuştur [35]. Z. Akhtar ve arkadaşlarının yapmış oldukları "Evaluation Of Serial And Parallel Multibiometric Systems Under Spoofing Attacks" isimli çalışmada yüz ve parmak izi görüntüleri kullanılmıştır. Seri ve paralel birleştirme metodları denenmiş ve sonuçları çalışmada verilmiştir [36].

2013 yılında yapılan çalışmalardan, M. Abdolahi ve arkadaşları tarafından yapılan "Multimodal Biometric system Fusion Using Fingerprint and Iris with Fuzzy Logic" isimli çalışmada parmak izi ve iris görüntüleri kullanılmıştır. Karar seviyesinde birleştirme işlemi yapılan çalışmada Fuzzy logic kullanılmıştır [37]. E. G. Rios ve arkadaşları tarafından "Multi-biometric Face Recognition System using Levels of Fusion" isimli çalışmada öznitelikler çıkartılırken Gabor filtreleri ve TBA kullanılmıştır. Sınıflandırma aşamasında ise geri beslemeli sinir ağları ve DVM kullanılmıştır. Farklı seviyelerde yapılan birleştirme sonuçları ayrı ayrı çalışmada verilmiştir [38].

1.2 Tezin Amacı

Bu tezin amacı kişilerin farklı biyometrik özelliklerini, farklı birleştirme yöntemleri yardımı ile çoklu-biyometrik kimliklendirme yapmaktır. Kişilerin iki boyutlu yüz görüntüleri, termal yüz görüntüleri ve kulak görüntüleri kullanılacaktır. Biyometrik özellikler seçilirken kişileri zorlamadan yani görüntülerin elde edilebilirlik, kabul edilebilirlik parametrelerine dikkat edilmiştir. Aynı zamanda kişilerin biyometrik

karakteristiklerinden herhangi bir tanesinin okunmasında zorluk yaşandığında diğer iki biyometri sayesinde kimliklendirme işleminin başarılı olması hedeflenmiştir.

1.3 Hipotez

Günümüzde bu konuda yapılan çalışmalarda performans ve maliyet kanularına dikkat edilmiş fakat biyometrik özelliklerin elde edilmesi konusundaki zorluklar ihmal edilmiştir. Bu çalışmada örnek olarak yüksek güvenlik gereken bir binaya kişi girmek istediğinde kişi daha kapıya yaklaşırken yüz görüntüsü, yüz termal görüntüsü ve kulak görüntüsü alınacak kişinin bu biyometrik özelliği vermesi zorlanmadan sistem tarafından alınacaktır. Bunu yaparken performans konusu göz ardı edilmeyecektir. Aynı zamanda genetik algoritmalar kullanarak yapılacak optimizasyon çalışaması sonucunda herhangi bir biyometrinin elde edilmesinde zorluk yaşansa dahi diğer iki biyometriden alınan sonuçlar optimize edilip doğru sınıflandırma yapılması beklenmektedir.

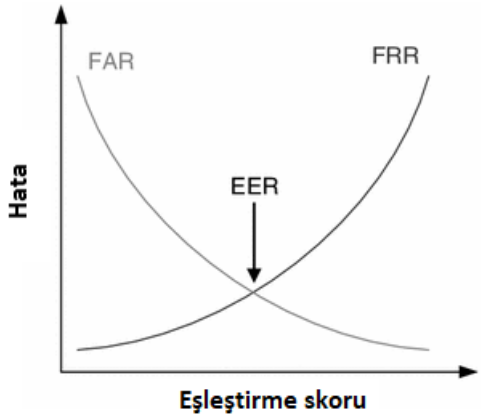
BÖLÜM 2

BİYOMETRİ, ÇOKLU-BİYOMETRİ VE BİRLEŞTİRME İŞLEMİ

Günümüz şartlarında tekli-biyometri kullanarak yapılan kimliklendirme çalışmalarında çok kullanıcı olan sistemlerde başarı oranı, süre, hata oranı parametrelerindeki iyileştirme çalışmaları yeterli seviyede değildir. Bunun yanında tek bir biyometrik karakteristiğe bağlılıktan dolayı güvenli tanıma konusunda problemler ortaya çıkmaktadır [39]. Aynı zamanda tek bir biyometri kullanıldığında bilgi şartlardan dolayı okunamaz ise kimliklendirme işlemi başarıya ulaşamayacaktır. Bu sebeplerden dolayı çoğul-biyometri konusu günümüzde üzerinde çalışılan bir konu haline gelmiştir [40].

Biyometrik özelliklerin kullanıldığı sistemler numara kullanan şifreleme sistemlerine göre daha güvenlidir [41], [42]. Çünkü numara kullanılan sistemlerde kişilerin şifreleri 3. şahıslar tarafından elde edilebilir. Fakat biyometrik karakteristik kullanan sistemlerde; biyometrik karakteristik ilgili kişinin bir parçası olduğu için elde edilme ihtimali yoktur. Bu sistemler de %100 güvenli değildir. Zor kullanarak bu biyometrik karakteristik kötü amaçlar için kullanılabilir. Fiziksel olarak kullanılan biyometrik karakteristiklerden bazıları: parmak izi, iris, yüz (2D ve 3D), el ayası, damar izi, konuşma, imza, kulak, termal yüz, yürüyüş, DNA. Bu biyometrik karakteristiklerin her birinin iyi sonuç verdiği parametre bulunmaktadır.

Biyometrik sistemlerin performanslarına bakıldığında genellikle iki parametre ön plana çıkmaktadır: “Hatalı Kabul Oranı” (False Accept Rate-FAR) ve “Hatalı Red Oranı” (False Reject Rate-FRR)”. Bu parametreler ile beraber farklı parametreler de kullanılabilir. Örnek olarak sistemin eğitim-sınıflandırma hızı, kayıt hatası oranı (Failure to Enroll Rate-FTE-FER) vb.



Şekil 2. 1 FAR, FRR ve EER grafik gösterimi

FAR değeri ne kadar büyük olursa FRR değeri o kadar küçülür. Aynı şekilde bu ifadenin tersi de doğrudur. Bu noktada FAR değeri büyüdükçe hatalı kabul oranı artacaktır. Yani kişi istenilen kişi olmamasına rağmen sistem o kişiyi istenilen kişi olarak tanımlayacaktır. FRR değeri büyürse hatalı red oranı büyüyecektir. Bu da kişi istenilen kişi olmasına rağmen sistem o kişiyi istenilen kişi olarak tanımlamayacaktır. Dolayısıyla eşik seviyesini belirlemek çok önem arz etmektedir. FAR-FRR eğrilerinin kesişme noktasına EER (equal error rate-eşit hata oranı) denmektedir. Dikkat edilirse bu değer FAR ve FRR değerlerinin en düşük olduğu noktadır.

Performans parametrelerinin haricinde biyometrik karakteristikleri seçerken kullanılan bazı parametreler de mevcuttur. Çizelge 2.1'de bu parametreler en yüksek seviye:5 ve en düşük seviye:1 olarak verilmiştir. Bu parametreler;

- *Evrensellik (Universality):* İnsanların çoğunda istenilen biyometrik özelliğin bulunuyor olması.
- *Eşsizlik (Uniqueness):* İnsanların çoğunda istenilen biyometrik karakteristiğin farklı olması.
- *Süreklilik (Stability):* İstenilen biyometrik karakteristiğin zamanla değişme uğramaması.
- *Elde Edilebilirlik (Collectability):* İstenilen biyometrik karakteristiğin cihazlar yardımıyla pratik olarak toplanabilmesi.
- *Performans (Performance):* Başarım oranı.

- *Kabul Edilebilirlik (Acceptability):* İstenilen biyometrik özelliğin toplanmasında insanların itirazlarının olmaması.
- *Maliyet (Cost):* Maliyetin fazla olması.

Bu parametrelere göre bizim problemimize en iyi sonuç vereceğini düşündüğümüz yüz, termal yüz ve kulak biyometrileri seçilmiştir. Çünkü evrensellik, maliyet, performans, elde edilebilirlik ve kabul edilebilirlik parametrelerinin en yüksek olduğu değerler bu üç parametrededir [43]–[45].

Çizelge 2. 1 Biyometrik karakteristikler ve parametreler

Biyometri/Parametre	Evrensellik	Eşsizlik	Süreklilik	Elde Edilebilirlik	Performans	Kabul Edilebilirlik	Maliyet
Yüz	5	3	3	5	4	4	2
Kulak	4	3	4	4	3	4	2
Termal Yüz	5	3	3	5	3	4	3
İris	4	5	4	2	4	2	5
İmza	3	2	2	5	3	5	1
Konuşma	3	3	2	3	3	4	2
El Geometrisi	4	2	3	4	2	3	4
Retina	4	5	5	2	5	2	5
DNA	4	5	5	1	5	1	5
Parmak İzi	4	5	3	3	4	3	4

2.1 Çoklu-Biyometri

Çoklu-biyometrik sistemler tekli-biyometrik sistemlere göre birçok avantaja sahiptirler:

- Sınıf içi benzerliklere karşı iyi sonuç verirler.
- Gürültüye karşı dayanıklıdırlar.
- Sisteme karşı dışarıdan ataklara dayanıklıdırlar [46], [47].

Çoklu-biyometri konusu çok farklı şekillerde yapılabilir. Bu bölüm aşağıda detaylı bir şekilde anlatılmıştır.

2.1.1 Çoklu-Biyometrik Karakteristik

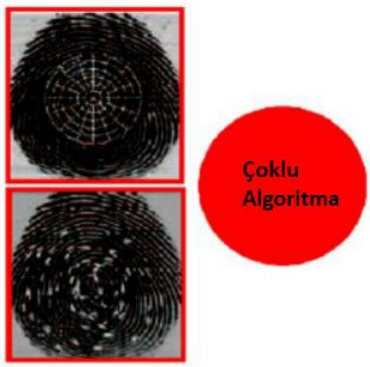
Çoklu-biyometrik karakteristik yönteminde bir veya daha fazla sensör yardımı ile iki veya daha fazla farklı biyometrik karakteristik giriş olarak kullanılır [48]. Kulak, iris, yüz, parmak izi gibi farklı karakteristikler birleştirilerek sınıflandırma işlemi gerçekleştirilir.



Şekil 2. 2 Çoklu-biyometrik sistem [49]

2.1.2 Çoklu-Algoritma

Çoklu-algoritma yönteminde bir adet sensör yardımıyla alınan tek biyometrik karakteristik üzerinde eğitim ve sınıflandırma aşamasında iki veya daha fazla algoritma kullanılır [50]. Bu çoklu-biyometri konusu herhangi bir biyometrik karakteristiğe uygulanabilir olmalıdır.



Şekil 2. 3 Çoklu-algoritma [51]

2.1.3 Çoklu-Örnek

Çoklu-örnek yönteminde tek biyometrik karakteristik için birden fazla örnek alınması sonucunda yapılan eğitim-sınıflandırma işlemi gerçekleştirilir. Örnek olarak parmak izi için 10 farklı parmak için alınan örnekler, iris için sağ ve sol göz irislerinden alınan örnekler, yüz için farklı yönlerden alınmış örnekler vb. Bu kategoriye örnek olarak tek bir biyometrinin farklı çözünürlüklerde alınmış örnekleri de verilebilir. Bu çalışmaya "çoklu-kalite" ismini veren çalışmalar da mevcuttur.



Şekil 2. 4 Çoklu-örnek [51]

2.1.4 Çoklu-Sensör

Çoklu-sensör yöntemi iki veya daha fazla sensör yardımıyla alınan tek bir biyometrik karakteristik için alınan örnekler sonucunda yapılan eğitim-sınıflandırma işlemidir. Örnek olarak infrared ve normal kamera ile alınan yüz görüntüleri, yine aynı şekilde infrared ve optik sensör yardımıyla alınan parmak izi örnekleri verilebilir.



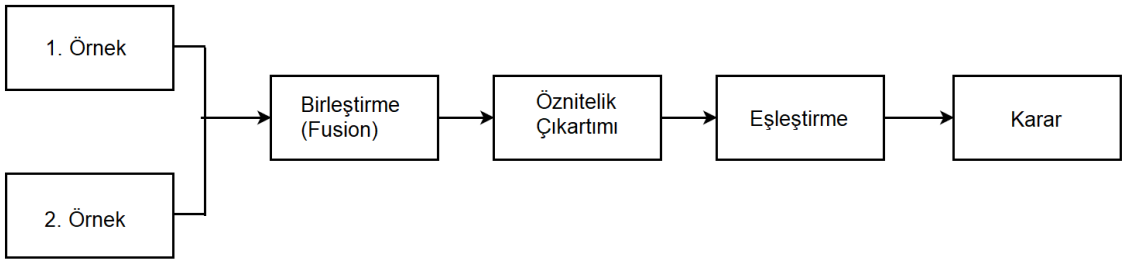
Şekil 2. 5 Çoklu-örnek [51]

2.2 Birleştirme İşlemi

Bölüm 2.1'de verilen çoklu-biyometri konularının gerçekleşebilmesi için birleştirme işlemine ihtiyaç duyulmaktadır. Basit bir biyometrik sistem sensör modülü, öznitelik çıkartımı modülü, eşleştirme modülü ve karar modülünden oluşur. Bu modüllerin çıkışlarındaki bilgiler, diğer modüller için giriş olarak birleştirilebilir ve kullanılabilir.

2.2.1 Sensör-Seviyesi Birleştirme (S-SB)

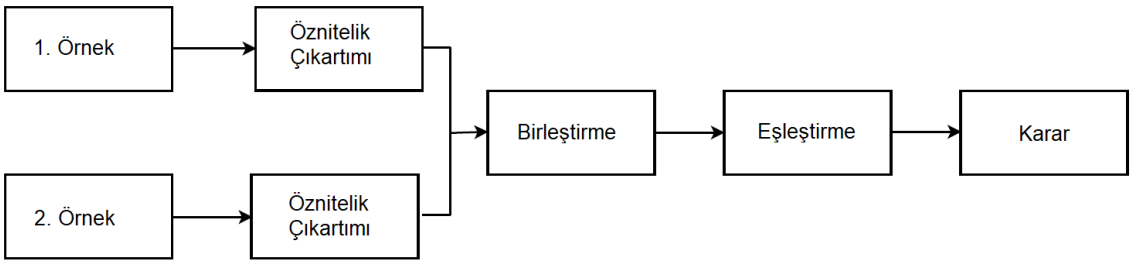
Sensör-seviyesi birleştirme işleminde aynı biyometrik karakteristik için farklı sensörlerden alınan örnekler veya aynı sensörden alınan çoklu örnekler kullanılır. Örnek seviyesi birleştirme şeklinde adlandıran uygulamalarda mevcuttur. Örnek olarak yüz biyometrisi için aynı kamera ile yüzden alınan sol profil fotoğrafı, sağ profil fotoğrafı ve önden alınan profil fotoğrafları örnek verilebilir. Şekil 2. 6'da verilen blok diyagramda sensör seviyesi birleştirme gösterilmektedir.



Şekil 2. 6 Sensör seviyesi birleştirme blok diyagramı

2.2.2 Öznitelik Seviyesi Birleştirme (Ö-SB)

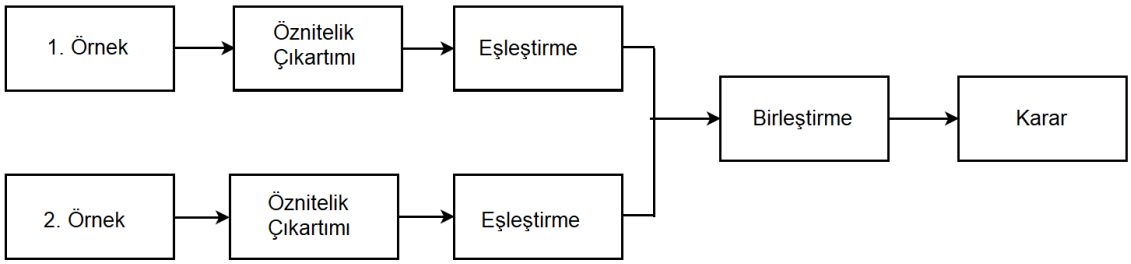
Sensörlerden alınan biyometrik karakteristikler üzerinde farklı öznitelik çıkartımı metotoları uygulanır. Daha sonra ortaya çıkan öznitelik vektörleri birleştirilir. Bu aşamada yapılan birleştirme işlemi öznitelik seviyesi birleştirme olarak adlandırılır. En zengin bilgi öznitelik seviyesinde bulunmaktadır. Kullanılan farklı öznitelik çıkartımı metotları sonucunda ortaya çıkan veri çok büyük olacaktır. Bu sebepten dolayı öznitelik azaltma metodu kullanmak gerekli olabilir. Şekil 2. 7'de verilen blok diyagramda öznitelik seviyesi birleştirme gösterilmektedir.



Şekil 2. 7 Öznitelik seviyesi birleştirme blok diyagramı

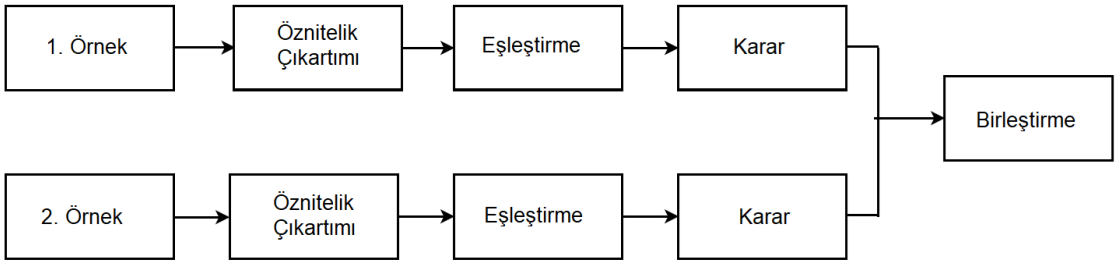
2.2.3 Eşleştirme Skoru-Seviyesi Birleştirme (ES-SB)

Sensörlerden alınan örneklere öznitelik çıkartımı uygulandıktan sonra eğitim işlemi yapılan örneklerle girişteki örneklerin karşılaştırması sonucunda eşleştirme skorları çıkartılır. Çıkartılan bu skorların birleştirilmesi işlemi eşleştirme skoru-seviyesi birleştirme olarak adlandırılır. Çıkartılan skorlar sayısal değerler oldukları için bu eşleştirme skoru-seviyesi birleştirme yöntemi diğer birleştirme yöntemlerine göre daha kolay yapılır. Bu sayısal değerler için normalizasyon yapmak gerekebilir. Şekil **Hata! Başvuru kaynağı bulunamadı.**'de eşleştirme skoru-seviyesi birleştirme blok diyagramı verilmiştir.



2.2.4 Karar-Seviyesi Birleştirme (K-SB)

Sensörlerden alınan örneklere uygulanan öznitelik çıkartımı işleminden sonra elde edilen eşleştirme skorları sonrasında verilen kararlara(sınıflandırma sonucuna) uygulanan birleştirme işlemidir. Bu aşamada ağırlık katsayıları kullanarak bu sınıflandırma sonuçlarının ağırlıkları optimize edilerek belirlenebilir. Şekil 2. 8'da karar seviyesi birleştirme işleminin blok diyagramı görülmektedir.



Şekil 2. 8 Karar seviyesi birleştirme blok diyagramı

BÖLÜM 3

KULLANILAN YÖNTEMLER

Bu bölümde öznitelik çıkartım metotları, öznitelik seçim metotları ve kullanılan sınnıflandırma metotları anlatılmıştır.

3.1 Öznitelik Çıkartımı Metotları

Öznitelik çıkartımı için olarak 3 farklı yöntem kullanılmıştır. Bunlar özyüzler(eigenfaces), yerel ikili örüntü(local binary pattern – LBP) ve gri seviye oluşum matrisidir(gray level co-occurrence matrix – GLCM).

3.1.1 Temel Bileşenler Analizi

Temel bileşenler analizi(TBA) ilk olarak 1901 yılında K.Pearson tarafından ortaya atılmıştır. Bu çalışmayı 1933 yılında Hotellling geliştirmiştir. 1991 yılında Turk ve Pentland "Face Recognition Using Eigenfaces" isimli çalışmalarında TBA'ya iki boyutlu bir yaklaşım getirmişlerdir. Önerilen yönteme öz uzay ismini vermişler ve bu yönteme göre veri seti içerisindeki biyometrilerin özellikle yüz görüntüleri üzerine uygulamışlardır. Bu yöntemle görüntülerin boyutları daha düşük boyutlara gelmekte böylelikle işlem yükü azalmakta ve işlem süresi kısalmaktadır. İstatistiksel bir yöntem olan TBA birbiri ile değişkenleri barındıran veri seti içindeki değişimlerin en optimum seviyede korunarak düşük boyuta indirgeme işlemine TBA denir.

TBA'nın düşük boyutlu uzaylarda verimli çalışması, çevresel etkenlerden kaynaklanan gürültülere karşı performansının yüksek olması ve depolama ihtiyacının az olması avantajlarındandır. Veri setindeki görüntülerin kovaryans matrisinin öznitelik ve özvektörlerinin bulunması, yüksek özniteliklere karşılık gelen özvektörlerin yeni veri

setinde saklanması gerekir. Aynı şekilde düşük özniteliklere karşılık gelen özvektörler ise ihmal edilirler. Böylelikle veri setinin boyutu azaltılmış olur.

Veri setinden elde edilen öz uzaylar, en büyük özniteliğe denk gelen özvektörlere karşılık gelmektedir. Bu işlem de TBA'nın iki boyutta uygulanabildiğini gösterir. Çıkartılan özvektörler görüntü uzayında birbirine ortogonal vektörleri görüntülemektedir. Çünkü kovaryans matrisi simetriktir. Bu sebeple veri setindeki her görüntü, öz uzayların doğrusal bileşiminden oluşabilmektedir. Bu şekilde oluşturulan her özvektörün veri setindeki görüntüler üzerine izdüşümünün alınması ile her görüntüye ait ağırlık vektörleri elde edilir. Bu vektör de görüntülerin tanımlanmasında kullanılmaktadır.

Öz uzay yaklaşımında, her biri NxN boyutunda olan görüntüler $N^{2'}$lik vektörler haline getirilmektedir. Denklem 3.1'de bu işlem görülmektedir.

$$\begin{bmatrix} I1_{11} & \cdots & I1_{1N} \\ \vdots & \vdots & \vdots \\ I1_{N1} & \cdots & I1_{NN} \end{bmatrix}_{NxN} \qquad I1 = \begin{bmatrix} I1_{11} \\ I1_{1N} \\ I1_{21} \\ \vdots \\ \vdots \\ I1_{NN} \end{bmatrix}_{N^2} \tag{3.1}$$

Bu işlemden sonra veri setindeki tüm görüntülerden ortalama görüntü vektörü hesaplanmaktadır. Bu işlem sütun vektörü haline getirilen görüntülere ait pikseller toplanır ve toplam görüntü sayısına bölünerek yapılır. Denklem 3.2'de bu eşitlik verilmiştir. Ortalama görüntü görüntülenmek istendiğinde sütun matrisi tekrar NxN'lik matrise dönüştürülür.

$$\psi = \frac{1}{M}\sum_{n=1}^{M}\Gamma_n = \frac{1}{M}\begin{bmatrix} I1_1 + & \cdots + & IM1_1 \\ \vdots & \vdots & \vdots \\ I_{N^2} + & \cdots + & IM_{N^2} \end{bmatrix} \tag{3.2}$$

Burada Γ görüntü vektörü, ψ ortalama görüntü vektörü, M toplam görüntü sayısı, I veri seti içindeki görüntüler, N piksel sayısını göstermektedir. Her bir görüntü vektöründen ortalama görüntü vektörü çıkartılarak sıfır ortalamaya sahip denklem 3.3'de gösterilen veri seti(A) elde edilir. A matrisinin boyutu N^2xM'dir.

$$A = \begin{bmatrix} \Phi_1 & \Phi_2 & \cdots & \Phi_M \end{bmatrix} \qquad \Phi_1 = \Gamma_1 - \psi \tag{3.3}$$

Elde edilen veri setinden öz uzayların elde edilebilmesi için A matrisi kullanılarak denklem 3.4'de verilen kovaryans matrisi(C) elde edilir. Elde edilen kovaryans matrisinin boyutu görüntü vektörünün uzunluğuna bağlıdır.

$$C = \frac{1}{M}\sum_{n=1}^{M} \Phi_n \Phi_n^T = AA^T \tag{3.4}$$

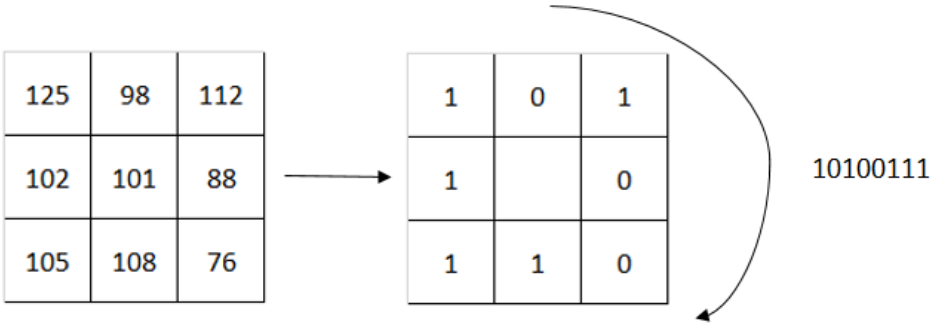
Görüntü vektörü olan sütun vektörünün boyutu N^2'dir. Bu vektörden elde edilen kovaryans matrisi N^2xN^2 boyutundadır. Görüntü vektör boyutunun toplam görüntü sayısından fazla olduğu durumlarda ($N^2>>M$), matrisin elde edilmesi, özdeğer ve özvektörlerin oluşturulması çok zordur. Kovaryans matirisinden elde edilen N^2 adet özvektörden sadece M-1 tanesi anlamlıdır. Anlamlı olan özvektör sayısı öz uzay görüntü sayısına bağlıdır. Bu sebeple N^2xN^2 boyutundaki bir matrisin hesaplanması yerine MxM boyutundaki matrisin hesaplanması daha efektif sonuç verecektir, bu değerleri saklarken de daha az yer kaplayacaktır.

3.1.2 Yerel İkili Örüntü

LBP yöntemi parametrik olmayan bir yöntemdir. Her bir pikseli komşu piksellerle karşılaştırarak görüntülerin yapılarına göre özniteliklerini çıkartır. LBP'de en önemli kazanımlar farklı parlaklıklara olan toleransı, görüntüler için hızlı bir öznitelik çıkartım algoritması olması ve hesaplama işlemlerinin sadeliğidir. Bu yöntem orjinalinde doku analizi için önerilen bir yöntemdir. Komşuluk ilişkilerini tanımlamak için basit ama güçlü bir yaklaşımdır.

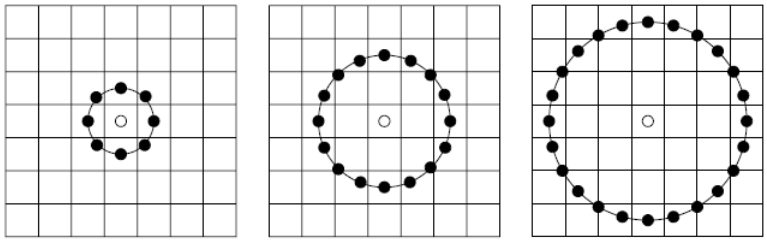
Orjinal LBP operatörü her bir piksel için bir onluk sayılardan oluşan etiket kullanır. Bu çalışmada da kullanılan en basit seviye LBP operatörü 3x3 lük bir piksel matrisinden oluşur. Şekil 3. 1'de görüldüğü gibi her piksel kendisine komşu 8 hücre ile karşılaştırılır. Komşu pikseller merkezde bulunan pikselden çıkartılır. Merkezde bulunan piksel eşik seviyesi olarak adlandırılır. Sonuç negatif ise kendi hücresine 0, pozitif ise 1 yazılır. Daha sonra bu hücrelerde bulunan ikili(binary) sayılar saat yönünde sol en üst hücreden başlayarak yan yana yazılır. Elde edilen bu 8 bitten oluşan sete LBP kodu

denilir ve merkezdeki hücre için kullanılır. Bu kod ikili sistemden onluk sisteme dönüştürülür.



Şekil 3. 1 Basit LBP operatörünün çalışması

Yerel komşuluk etiketlenecek merkez pikselde ortalanmış bir daire üzerinde eşit aralıklarla yerleştirilmiş örnekleme noktalarından oluşur. Örnekleme noktalarına denk gelmeyen pikseller için ekstradan çift yönlü enterpolasyon işlemi uygulanır. Bu işlem örnekleme noktasına çizilen doğruyu kapsayan piksellerin değerlerini de kullanan bir algoritmadır.Böylece herhangi bir yarıçap üzeindeki değerler de dikkate alınmış, veri kaybı olmamış olur. Şekil 3. 2'de örnek LBP operatörleri bulunmaktadır. Bu notasyonda (P,R) kullanılmıştır. P komşu sayısını gösterirken, R değeri ise örnekleme yarıçapını gösterir. Bu çalışmada (8,1) operatörü kullanılmıştır.



Şekil 3. 2 Örnek LBP operatörleri (8,1) – (16,2) – (24,3)

Verilen (x_c, y_c) pikselleri için LBP operatörü sonucu onluk formda denklem 3.5'de verilmiştir.

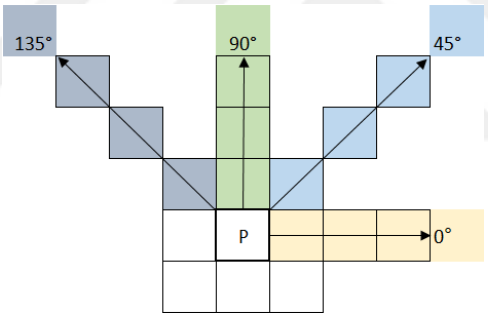
$$LBP_{P,R}(x_c, y_c) = \sum_{P=0}^{P-1} s(i_P - i_c)2^P \qquad (3.5)$$

Burada i_c ve i_P merkez pikselin gri seviye değerleridir. LBP operatörünün ikili çıkışları için $s_{(x)}$ fonksiyonu denklem 3.6'da verilmiştir.

$$s_{(x)} = \begin{Bmatrix} 1 & if & x \geq 0 \\ 0 & if & x < 0 \end{Bmatrix} \quad (3.6)$$

3.1.3 Gri Seviye Eş-Oluşum Matrisi

Gri seviye eş-oluşum matrisi yöntemi istatistik tabanlı öznitelik çıkartım yöntemidir. Bu yöntemde tekrarlanan gri seviye pikselleri bir matris içerisinde sayılır ve saklanır. Örnek olarak sadece bir yön dikkate alındığında sekiz bitlik gri seviye bir görüntü, orijinal verinin büyüklüğü kadar 256x256 GLCM matrisi üretir. Eş-oluşum matrisi açı ve uzaklık değerlerinden oluşur. Bu matris d pikseller arası uzaklık, θ açı olmak üzere $P(i, j \mid d, \theta)$ matrisidir. i ve j değerleri ise piksellerin gri seviye değerleridir. P matrisi bu gri seviyelerin geçiş olasılığıdır. Her bir θ değeri için ayrı ayrı bir NxN kare matris oluşturulur. Açı değerleri 0°, 45°, 90° ve 135° dir. Görüntünün gri ton sayısı düşürülürse hesap sayısı azaltılabilir fakat kabul edilmelidir ki bu işlem sonucunda bilgi kaybı yaşanır. Eş-oluşum matrisi Şekil 3. 3'de $d = 1$, $d = 2$ ve $d = 3$ için gösterilmiştir.



Şekil 3. 3 Eş-oluşum matris örneği

M. Haralick'in yapmış olduğu çalışmada 14 adet özellik tanımlanmıştır. Bu özellikler literatürde görüntü alma ve biyometrik karakteristiklerde kullanılmıştır. Özellikler arasında yer alan kontrast, korelasyon, enerji ve homojenlik bu çalışmada da kullanılmıştır. Bu özellikler hakkında bilgiler şu şekildedir. i ve j değerleri satır-sütun değerlerini gösterirken, σ standart sapmayı, μ ortalamayı göstermektedir.

Kontrast: Merkez piksel ve komşu piksel arasındaki gri seviye veya yoğunluk varyasyonlarının ölçümüdür. Kontrast denklem 3.7'de gösterildiği gibi hesaplanır.

$$\sum_{i,j} |i - j|^2 P(i, j) \quad (3.7)$$

Korelasyon: Eş-oluşum matrisi olan P matrisi içindeki gri seviye değerlerinin lineer bağımlılığını hesaplar. Bu durum merkez pikselin komşu piksellerle olan bağlantısını gösterir. Denklem 3.'de korelasyon özelliğinin formülasyonu verilmiştir.

$$\frac{\sum_{i,j}(ij)P(i,j)-\mu_x\mu_y}{\sigma_x\sigma_y} \tag{3.8}$$

Enerji: Görüntünün ne kadar homojen olduğunu belirtir. Denklem 3.'da enerji özelliğinin formülasyonu verilmiştir.

$$\sum_{i,j}P(i,j)^2 \tag{3.9}$$

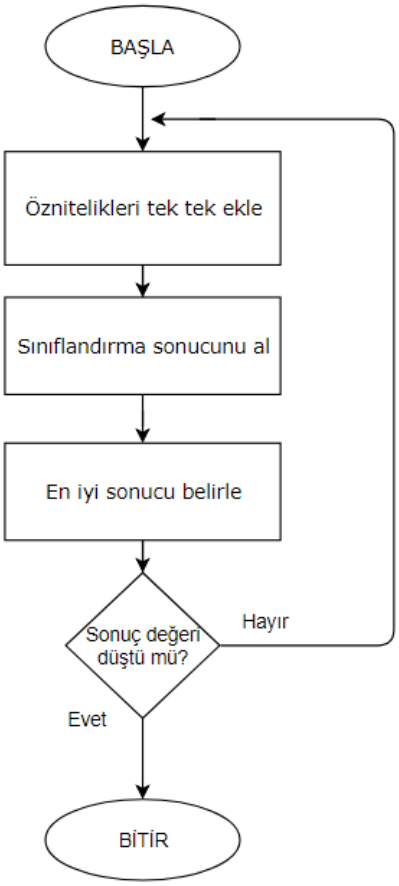
Homojenlik: Görüntüdeki farklı bölgelerin benzerliklerini gösteren bir özelliktir. Bu özelliğin formülasyonu denklem 3.10'da verilmiştir.

$$\sum_{i,j}\frac{P(i,j)}{1+|i-j|} \tag{3.10}$$

3.2 Öznitelik Seçim Metodu

Genel olarak öznitelik seçim algoritmaları veri sayısını ve işlem yükünü azaltmak için kullanılır. Diğer taraftan gereksiz(sonucu etkilemeyen) özniteliklerin çıkartılmasını ve genel doğruluk(accuracy) değerini arttırmaya olanak sağlar. Bu çalışmada ileriye doğru öznitelik seçim algoritması(forward feature selection algorithm) kullanılmıştır.

Bu algoritmada başlangıçta boş bir öznitelik seti vardır. Daha sonra sınıflandırma aşamasına geçebilmek için öznitelik tek tek eklenir. En iyi sonucu veren öznitelik, öznitelik setine eklenir. Bu aşama en yüksek değere ulaşana kadar veya öznitelik sayı sınırlandırması yapılana kadar devam eder. Şekil 3.4'de gösterilen algoritma uygulanır.



Şekil 3. 4 İleriye doğru öznitelik seçim algoritması

3.3 Sınıflandırma Metotları

Bu çalışmada dört farklı sınıflandırıcı kullanılmıştır. Bunlar; çok katmanlı algılayıcı(MLP - multi layer perceptron), karar ağacı(DT - decision tree), destek vektör makineleri(DVM – support vector machines) ve olasılıksal sinir ağları(PNN - probabilistic neural network)dır [52]–[55]. Bu yöntemler farklı füzyon yöntemleri ile beraber kullanılmışlardır.

3.3.1 Çok Katmanlı Algılayıcı

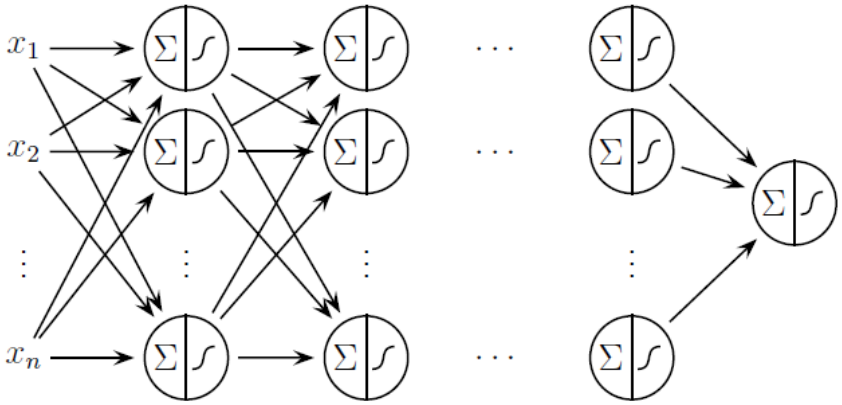
Tek katmanlı algılayıcılar kompleks problemler için uygun değildir. Aynı zamanda el ile ağ yaratmak çok pahalıdır. Bunun için veriden öğrenme algoritması kullanılması gerekmektedir. Bu konuda çok katmanlı algılayıcı fikri ortaya atılmıştır [56], [57]. Tek katmanlı algılayıcı süreksiz fonksiyonların hesaplarında kullanılırken çok katmanlı algılayıcı daha lineer olmayan(yumuşatılmış) fonksiyonlar için kullanılır.

$$\vec{x} \to f_{\log}\left(w_0 + \left\langle \vec{w}, \vec{x} \right\rangle\right) \qquad f_{\log}(z) = \frac{1}{1+e^{-z}} \tag{3.11}$$

Denklem 3.11'de $f_{\log}$ lojistik bir fonksiyondur. w_0 başlangıç ağırlık değeri, $\vec{w}$ güncellenmiş ağırlık değeri, $\vec{x}$ ağırlıklara göre güncellenmiş giriş değerleridir. Bu fonksiyonun özellikleri aşağıdaki gibidir:

- 0-1 arasında tek düze artan bir fonksiyondur,
- sürekli ve türevlenebilir fonksiyondur.

Çok katmanlı algılayıcı sonlu, döngüsel bir grafiğe sahiptir. Bu yapının düğümleri aktivasyon fonskiyonuna sahip nöronlardan oluşur. Şekil 3. 5'de çok katmanlı algılayıcı modeli görülmektedir.



Şekil 3. 5 Çok katmanlı algılayıcı modeli

Çok katmanlı algılayıcı iki veya daha fazla ara katmana sahiptir. Bu katmanlardan $i.$ katmanın çıkışı, $(i+1).$ katmanın giriş değeridir. Çok karmaşık fonksiyonlar çok sayıda nöron yardımıyla hesaplanabilirler. Daha genel olarak çok katmanlı algılayıcılar;

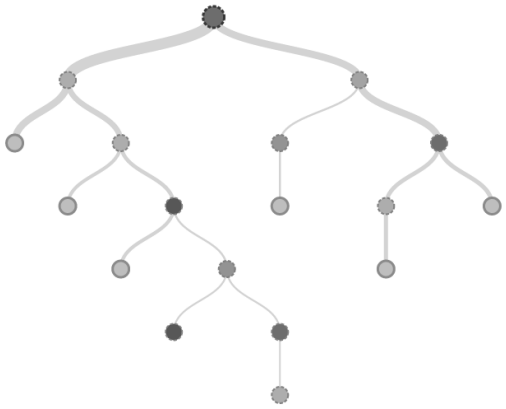
- Herhangi bir bağlantının hedef nöronu olmayan nöronlara giriş nöronları denir. N boyutundaki modellere uygulanacak çok katmanlı algılayıcı n adet giriş nöronuna sahip olmalıdır. Giriş nöronları nöron 1, nöron 2, … şeklinde numaralandırılır,
- Herhangi bir bağlantının kaynağı olmayan nöronlara çıkış nöronları denir. Herhangi bir çok katmanlı algılayıcı yapısı birden fazla çıkış nöronuna sahip

olabilir. Çıkış nöronlarının sayısı eğitim modellerinin hedef(istenen) değerlerinin açıklamasına bağlıdır,

- Çıkış veya giriş olmayan tüm düğümlere gizli nöronlar denir. Grafik periyodik olmayan bir grafik olduğu için tüm nöronlar katmanlar şeklinde giriş değerleri ile düzenlenebilir.
- Çok katmanlı algılayıcı yapısı genellikle bir katmandaki bütün nöronların sıradaki katmandaki tüm nöronlara bağlantılı olarak tasarlanır,
- Bütün bağlantılar reel sayı olan bir ağırlık katsayısına sahiptir,
- Bütün gizli ve çıkış nöronları bias ağırlığına sahiptir.

3.3.2 Karar Ağacı

Gözetimli öğrenme algoritması olan karar ağaçları ağaç tabanlı öğrenme algoritmaları içinde en çok tercih edilenlerden birisidir. Genel olarak çoğu problem için çözüm verebilir. Şekil 3. 6'da örnek karar ağacı modeli görülmektedir.



Şekil 3. 6 Örnek karar ağacı modeli

Karar ağacı algoritmaları bünyesinde önceden tanımlanmış bir hedef değişken barındırırlar. En tepeden aşağı doğru inilen bir stratejileri vardır [58], [59]. Şekil 3. 6'da görüldüğü gibi karar ağaçları çok büyük veri setini her dalda daha küçük parçalara bölmek için kullanılırlar. Her dalda ayrı bir karar uygulayarak küçük yapılara bölerler.

Karar ağaçlarının avantajları şu şekildedir:

- Ağacın karar verme yapıları belirlendikten sonra ağaç görselleştirilebilir.

- Ağacın yorumlanması ve anlaşılması kolaydır.
- Verilerin az da olsa bir ön işlemden geçmesi gerekir.
- Karar ağacını eğitmek için kullanılan verilerin sayısı(karar noktalarının sayısı) maliyeti logaritmik olarak etkilemektedir.
- Verilerin sayısal veya kategorik olarak bulunması karar ağaçları için problem değildir.
- Problem birden çok çıkışlı olsa bile karar ağacı tarafından işlenebilir.
- Karar ağacı modelinin doğrulaması istatistiksel testlerle yapılabilir.
- Parametrik olmayan bir yöntemdir.

Karar ağaçlarının avantajlarının yanında dezavantajları da bulunmaktadır. Bunlar:

- Ağaçları oluştururken dikkat edilmezse çok karmaşık ağaçlar ortaya çıkabilir. Bu durumda da dalların anlaşılması zorlaşabilir.
- Karar ağaçlarında sistem öğrenirken ezberleme yapabilir. Buna "over fitting" denir. Bu problemin çözülebilmesi için parametrelere belli kıstaslar konabilir. Ayrıca dallara budama işlemi yapılabilir. Budama işlemi verinin çok olduğu dallarda yapılamaz fakat daha az verinin bulunduğu dallarda yapılabilir.

Karar ağaçlarında dalların bölünmesi ağacın doğruluğunu belirlemektedir. Bu işlem de bir dalın iki veya daha fazla dala bölünmesi işlemi hedefe göre kullanılacak birden fazla algoritma yardımı ile yapılır. Karar ağaçlarında entropi, gini, sınıflandırma hatası, en küçük kareler gibi algoritmalara kullanılmaktadır.

Verilerin belirsizliği entropi ile ölçülür. Verilerin bölünmesi işlemi yapılırken en optimum yerden bölünmelidir ki entropi en az değeri alsın. Bölünme ne kadar iyi yapılırsa yapılan tahmin de o kadar iyi sonuç verir. Bu işlem içinde denklem 3.12 ve denklem 3.13 kullanılmaktadır.

$$H = -\sum p(x)\log p(x) \tag{3.12}$$

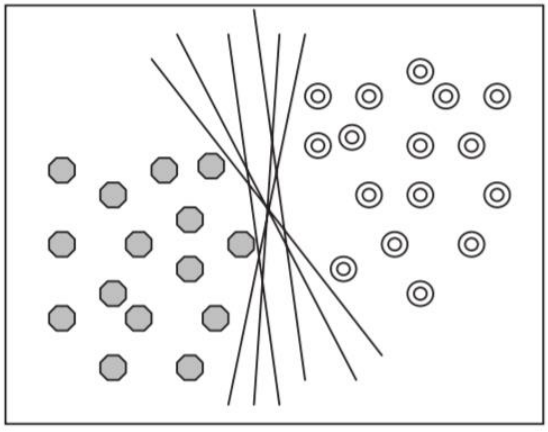
$$Kazanç(S,D) = H(S) - \sum_{V \in D} \frac{|V|}{|S|} H(V) \tag{3.13}$$

Burada p(x) verilerin sınıfına ait yüzdeyi, H ise entropiyi vermektedir. Kazanç denkleminde ise S orijinal veri setini verirken D ise bu veri setinin bölünmüş parçasıdır. Dolayısıyla her V seti orijinal veri setinin alt kümesidir. Kazanç S'nin entropisi ile her bir özniteliğim entropisi arasındaki farkdır.

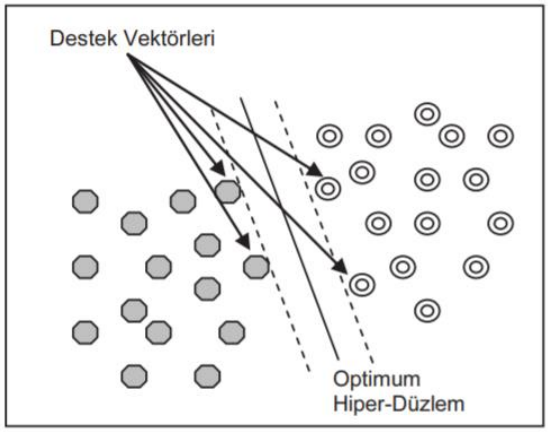
Eğer veri setinde karar ağacı algoritmaları kullanılacaksa eğitim ve test olarak iki parça halinde veri seti bölünmelidir. Algoritma öncelikle eğitim verilerini kullaran ağı eğitir ve bir karar ağacı modeli oluşturur. Daha sonra bu ağaç test seti üzerinde kullanılarak sistemin başarısı ölçülmektedir.

3.3.3 Destek Vektör Makineleri

Destek vektör makineleri istatistiksel öğrenme teorisi tabanlı sınıflandırma yöntemidir. Bu yöntem ortaya çıktığında sadece iki sınıf içeren doğrusal verilerin sınıflandırmasında kullanılıyordu. İleriki zamanlarda çok sınıflı verilerin sınıflandırılmasında en son olarak da doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir. Destek vektör makineleri iki adet sınıfın birbirinden ayrılabilmesini sağlayan n-boyutlu bir hiperdüzlem oluşturmaktadır [60], [61]. Şekil 3. 7'da görüldüğü gibi iki ayrı sınıfı birbirinden ayıran birden çok düzlem belirlenebilir. Fakat destek vektör makinelerinin amacı Şekil 3.8'deki gibi iki sınıfa eşit uzaklıkta bulunan hiper düzlemi bulabilmektir.



Şekil 3. 7 Doğrusal sınıflandırma eğrileri



Şekil 3. 8 Optimum hiper düzlem

Destek vektör ismi ise iki sınıfı birbirinden ayıran en yakın iki doğrusal düzlemden gelmektedir. Bu düzlemlere destek vektörleri denir. Optimum hiper düzlemi

bulabilmek için denklem 3.14 ve denklem 3.15 kullanılır. Burada k örnek sayısını gösterirken x_i i. giriş vektörünü ve y_i sınıfın etiketini(genellikle {-1, 1}) gösterir.

$w.x_i + b \geq +1$ her y=+1 için (3.14)

$w.x_i + b \leq +1$ (3.15)

Optimum hiper düzlemin belirlenebilmesi için öncelikle destek vektörlerinin belirlenmesi gerekir. Bu destek vektörler denklem 3.16'daki gibi ifade edilirler [62], [63]. Bu vektörler kenar vektörleridir.

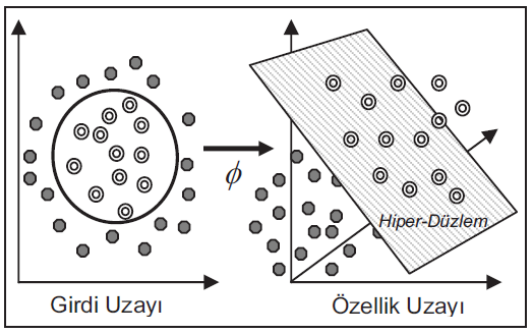
$w.x_i + b = \pm 1$ (3.16)

Eğer kullanılan veri setinin sınıfları doğrusal olarak ayrılamıyorsa giriş vektörlerine çekirdek fonksiyonu uygulanarak doğrusal olarak ayrılabilir duruma getirilir. Bunun için denklem 3.17'de verilen fonksiyon kullanılır. Bu fonksiyon kernel fonksiyonudur.

$K(x_i, x_j) = \varphi(x_i).\varphi(x_j)$ (3.17)

Bu fonksiyon yardımıyla veriler Şekil 3. 9'da görüldüğü gibi yüksek boyutlarda doğrusal olarak ayrılabilir hale gelirler. Bunun için kullanılan kural denklem 3.18'deki gibidir [64].

$$f(x) = sign\left(\sum_i a_i y_i \varphi(x_i).\varphi(x_j) + b\right) \quad (3.18)$$



Şekil 3. 9 Verinin yüksek boyuta dönüştürme işlemi

3.3.4 Olasılıksal Sinir Ağları

Olasılıksal sinir ağları Bayes-Parzen kestiricileri olarak da isimlendirilir. Veri setinin iki sınıfı olduğu kabul edilir ve bunlar A ve B olarak etiketlenirse bu sınıflardan herhangi

birine ait n boyutlu bir k vektörü belirlenir. A ve B sınıflarının olasılık yoğunluk fonksiyonları sırasıyla $F_1(x)$ ve $F_2(x)$ olsun. Bayes teoremine göre k vektörü;

$$\frac{F_1(x)}{F_2(x)} > \frac{L_1 P_2}{L_2 P_1} \tag{3.19}$$

eşitsizliği gerçeklenirse A, tam tersi gerçeklenirse B sınıfına aittir. Burada P_1 ve P_2 sınıflarının görülme olasılıklarıdır. L_1, k vektörünün A sınıfında olmasına rağmen B olarak yanlış sınıflandırılma oranı, L_2 ise k vektörünün B sınıfında olmasına rağmen A olarak yanlış sınıflandırma oranını vermektedir. Bu fonksiyonlara maliyet(cost) fonksiyonu denmektedir. K vektörünün sınıfını doğru tespit edebilmek için olasılık yoğunluk fonksiyonları ve yanlış sınıflandırma oranları(L_1 ve L_2) bilinmelidir. Maliyet fonksiyonları olan L_1 ve L_2 genelde eşit olarak alınıp işleme sokulduklarından sadece $F_1(x)$ ve $F_2(x)$'in bilinmesi yeterlidir. Bu olasılık yoğunluk fonskiyonları Parzen pencereleri[65] ile bulunabilir. Bu işlemin denklemi 3.20'deki gibidir.

$$F(x) = \frac{1}{(2\pi)^{m/2} \sigma^m n} \sum_{i=1}^{n} \exp\left[-\frac{(x - x_i)^T (x - x_i)}{2\sigma^2} \right] \tag{3.20}$$

Bu denklemde m giriş uzayının boyutu, i örüntü numarası, n eğitim verisi sayısı ve σ ayarlanabilir yumuşatma terimidir.

BÖLÜM 4

KULLANILAN VERİ SETİ VE DENEYSEL SONUÇLAR

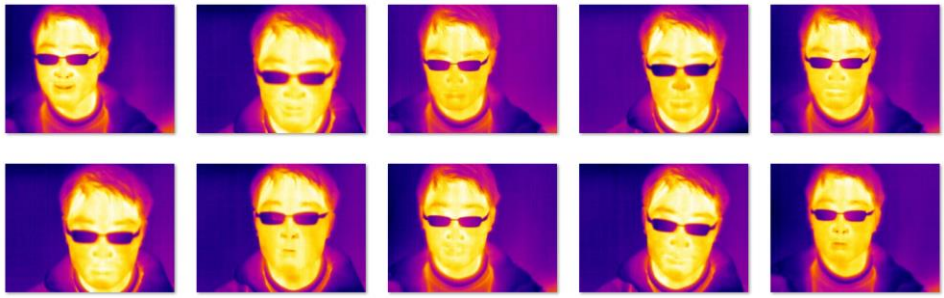
Bu bölümde kullanılan veri seti, deneysel sonuçlar ve bu sonuçların yorumları verilmiştir.

4.1 Kullanılan Veri Seti

Yüz ve termal yüz görüntüleri "USTC NVIE Spontaneous Database'den" alınmıştır [66]–[68]. Kulak görüntüleri ise "IIT Delhi Ear Image Database'den" alınmıştır [69], [70]. Kullandığımız veri seti yapay olarak bu iki veri setinin birleştirilmesinden oluşturulmuştur. Çünkü çalışmamız için kullanabileceğimiz uygun bir veri seti bulunmamaktadır. Verisetinde 120 adet kişi bulunmaktadır. Her kişi için 10 yüz(Şekil 4. 1) ve 10 termal yüz(Şekil 4. 2) görüntüsü bulunmaktadır ve bunların çözünürlükleri sırasıyla 640x480 ve 304x230 dur. Bu veri setine her kişi için 3'er adet kulak(Şekil 4. 3) görüntüsü yapay olarak eklenmiştir. Kulak görüntülerinin çözünürlüğü ise 50x180'dir. Böylelikle veri setinin 120 kişi için 2760 biyometrik örneği bulunmaktadır.



Şekil 4. 1 Yüz görüntü örneği



Şekil 4. 2 Termal yüz görüntü örneği



Şekil 4. 3 Kulak görüntü örneği

4.2 Deneysel Sonuçlar ve Yorumlanması

Bu çalışmada kulak, yüz ve termal yüz görüntülerinden oluşan üç farklı biyometrik ölçüm sisteminin tasarlanması sayesinde güvenli bir sistem oluşturulmuştur. Her biyometrik karakteristik için üç farklı öznitelik kümesi oluşturuldu ve dört farklı sınıflandırıcı kullanıldı. Bunlarla beraber en iyi konfigürasyonu elde edebilmek için literatür taraması da kullanılarak eşleşme skoru seviyesi füzyon ve öznitelik seviyesi füzyon kullanılmasına karar verilmiştir.

İlk aşamada temel bileşenler analizi kullanarak öznitelikler(eigenfeatures) belirlenmektedir. Bu noktada az sayıda özvektör seçilmiştir ve veri büyüklüğü azaltılmıştır. Bu sebeple başka bir öznitelik seçim algoritması kullanılmasına gerek kalmamıştır. Deneyin ilk aşamasında sadece öznitelikler kullanılarak sonuçlar alınmıştır. En iyi doğruluk oranını elde edebilmek için farklı sayıda öznitelikler işleme sokulmuş ve sınıflandırılmıştır. Daha sonra deneysel çalışmalar yerel ikili örüntü ve gri seviye eş-oluşum matrisi kullanarak çıkartılan özniteliklerle tekrarlanmıştır. Bu iki öznitelik çıkartım algoritması için ileriye doğru öznitelik seçim algoritması kullanarak öznitelik sayıları etkisi olmayan özniteliklerin çıkartılmasıyla azaltılmıştır. Bütün deneysel sonuçlar ratgele seçilen eğitim ve test veri setleri ile on defa tekrarlanmış ve sonuçların ortalaması alınmıştır. Deneyler yapılırken kullanılan bilgisayarın işlemcisi Intel Core i5 – 5200U – 2.20GHz, RAM'I 8 GB, ekran kartı AMD Radeon R7 – M260'dır.

Birinci Aşama: Bu aşamada veri seti iki şekilde bölünerek sonuçlar alınmıştır. Birincisinde %70 eğitim seti ve %30 test seti, ikincisinde %60 eğitim seti ve %40 test seti olmak üzere rastgele olarak farklı sayılarda öznitelikler kullanılmıştır. Daha sonra eşleştirme skoru elde edebilmek için her bir biyometri için çok katmanlı algılayıcı kullanılarak eğitim yapılmıştır. Eşleştirme skoru seviyesinde birleştirme işlemi yapılmıştır. Bu işlem yapılırken genetik algoritmalar kullanarak optimizasyon yapılmıştır. Çizelge 4.1, 4.2 ve 4.3 bu aşamanın sonuçlarını(doğruluk oranları) özetlemektedir. Bu adımda çok katmanlı algılayıcının optimum gizli katman sayısı hata oranlarına bakılarak bulunmuştur.

Çizelge 4.1 Eşleştirme skoru seviyesi birleştirme – öznitelikleri(30 adet) kullanarak

Öznitelik sayısı	**30**						
Gizli katman sayısı	**5**	**20**	**40**	**50**	**60**	**70**	**90**
Kulak	6,28	88,99	88,05	88,67	65,09	**89,62**	89,62
Yüz	17,31	62,67	69,88	77,1	87,32	**84,62**	79,92
Termal Yüz	11,06	42,83	50,79	60,87	68,53	**71,03**	76,11
Genetik Algoritmalar ile ES-SB					**83,25**		

Çizelge 4.2 Eşleştirme skoru seviyesi birleştirme – öznitelikleri(40 adet) kullanarak

Öznitelik sayısı	**40**						
Gizli katman sayısı	**5**	**20**	**40**	**50**	**60**	**70**	**90**
Kulak	2,83	86,79	85,22	90,56	89,62	**90,88**	85,84
Yüz	4,01	49,93	74,78	78,41	87,2	**84,5**	91,59
Termal Yüz	11,22	27,89	62,01	58,52	68,53	**73,76**	67,62
Genetik Algoritmalar ile ES-SB					**84,65**		

Çizelge 4.3 Eşleştirme skoru seviyesi birleştirme – öznitelikleri(50 adet) kullanarak

Öznitelik sayısı	**50**						
Gizli katman sayısı	**5**	**20**	**40**	**50**	**60**	**70**	**90**
Kulak	33,96	81,44	89,3	90,25	89,62	**90,56**	88,05
Yüz	19	67,5	80,42	81,55	89,83	**86,63**	90,52
Termal Yüz	9,02	31,76	66,71	71,79	76,57	**72,47**	69,82
Genetik Algoritmalar ile ES-SB					**85,87**		

Bu sonuçlar ayrı ayrı değerlendirildiğinde, 30-40 ve 50 öznitelik için biyometrik karakteristikler için alınan sonuçlara göre en yüksek değerin 70 adet gizli katmanda

alındığı görülebilir. Bu sonuçlara genetik algoritmalar kullanarak eşleştirme skoru seviyesi birleştirme işlemi yapıldığında en yüksek doğruluk değerinin 50 öznitelik ve 70 gizli katman için alındığı görülebilir.

Çizelge 4.4 öznitelikleri ve çok katmanlı algılayıcı kullanarak yapılan öznitelik seviyesi birleştirme sonuçlarını göstermektedir. Bu aşamada her biyometrik karakteristik için eşit sayıda öznitelik hesaplandı ve veri kümesini oluşturabilmek için birleştirildi. Çok katmanlı algılayıcı yardımıyla da bu veriler eğitim ve test işlemine sokuldu.

Çizelge 4.4 Öznitelik seviyesi birleştirme – öznitelikleri kullanarak

Öznitelik sayısı	**Her bir biyometri için 30**						
Gizli katman sayısı	**5**	**20**	**40**	**50**	**60**	**70**	**90**
%	3,78	64,66	83,28	**85,8**	80,44	80,44	85,5
Öznitelik sayısı	**Her bir biyometri için 40**						
Gizli katman sayısı	**5**	**20**	**40**	**50**	**60**	**70**	**90**
%	5,04	81,7	82,64	82,64	82,01	84,22	85,48
Öznitelik sayısı	**Her bir biyometri için 50**						
Gizli katman sayısı	**5**	**20**	**40**	**50**	**60**	**70**	**90**
%	5,04	79,81	82,64	76,34	85,17	83,28	84,43

Alınan sonuçlara göre en yüksek doğruluk oranı her biyometriden 30'ar adet (toplamda 90) öznitelik ve 50 adet gizli katman ile alınmıştır. Öznitelik seviyesi birleştirme işlemi ile eşleştirme skoru seviyesi birleştirme işlemi karşılaştırıldığında her ikisinde de alınan sonuçlar birbirine çok yakındır. Her iki yöntemde de en yüksek doğruluk oranı 85,8 olarak elde edilmiştir.

İkinci Aşama: Bu aşamada yerel ikili örüntü algoritmasından gelen öznitelikler ile gri seviye eş oluşum matrisinden alınan öznitelikler her biyometri için ayrı ayrı birleştirilmiştir. Bu sonuçlara karar ağacı, lineer destek vektör makineleri ve olasılıksal

sinir ağları algoritmaları kullanarak sınıflandırma yapılmıştır. İlk aşamada olduğu gibi bu öznitelikleri kullaranak sınıflandırma algoritmaları yardımıyla doğruluk oranları elde edilmiş ve eşleşme skoru seviyesi birleştirme işlemi veriye uygulanmıştır. Her sınıflandırma işlemi için ileriye doğru öznitelik seçim algoritması kullanılmıştır.

Çizelge 4.5, 4.6 ve 4.7 üç sınıflandırma için eşleştirme skoru seviyesi birleştirme işleminin sonuçlarını vermektedir.

Çizelge 4.5 Eşleştirme skoru seviyesi birleştirme(karar ağacı algoritması için)

	Eşleştirme Skoru-Seviyesi Birleştirme								
Eğitim – Test %	**%60 Eğitim - %40 Test**								
Biyometri	**Kulak**			**Yüz**			**Termal Yüz**		
Öznitelik sayısı	14	**12**	9	14	**12**	10	14	**12**	8
%	76,60	**78,49**	76,60	75,45	**75,14**	74,82	75,15	**78,04**	76,28
Genetik Algoritmalar ile ES-SB				**76,77**					
	Eşleştirme Skoru-Seviyesi Birleştirme								
Eğitim – Test %	**%70 Eğitim - %30 Test**								
Biyometri	**Kulak**			**Yüz**			**Termal Yüz**		
Öznitelik sayısı	14	**10**	8	14	**10**	8	14	**10**	8
%	78,96	**80,37**	78,49	75,18	**77,48**	75,97	76,98	**78,70**	77,31
Genetik Algoritmalar ile ES-SB				**78,25**					

Çizelge 4.5'de verilen karar ağacı sınıflandırma algoritması kullanılarak alınan sonuçlara göre en yüksek doğruluk oranları %70 eğitim – %30 teste ayrılmış veri seti ile 12'şer adet öznitelikde, %60 eğitim – %30 teste ayrılmış veri seti ile 10'ar adet öznitelikte elde edilmiştir. Bu öznitelikler için genetik algoritmalar kullanarak eşleştirme skoru seviyesi birleştirme uygulanmıştır ve en yüksek doğruluk oranı olarak %70 eğitim – %30 test

olarak ayrılan veri setinde %78,25 olarak bulunmuştur. Verisetinin %70'lik kısmının eğitime ayrıldığı durumdaki doğruluk oranı daha yüksek olduğu için karar ağacı kullanarak yapılan öznitelik seviyesi birleştirme işleminde de bu veriseti kullanılmıştır.

Çizelge 4.6 Eşleştirme skoru seviyesi birleştirme(destek vektör makineleri için)

	Eşleştirme Skoru-Seviyesi Birleştirme								
Eğitim – Test %	**%60 Eğitim - %40 Test**								
Biyometri	**Kulak**			**Yüz**			**Termal Yüz**		
Öznitelik sayısı	14	12	**9**	14	**12**	10	14	12	**8**
%	94,89	94,30	**95,28**	90,12	**91,08**	88,05	80,65	79,89	**82,36**
Genetik Algoritmalar ile MS-LF				**91,62**					
	Eşleştirme Skoru-Seviyesi Birleştirme								
Eğitim – Test %	**%70 Eğitim - %30 Test**								
Biyometri	**Kulak**			**Yüz**			**Termal Yüz**		
Öznitelik sayısı	14	**10**	8	14	**10**	8	14	**9**	8
%	96,70	**100**	94,20	93,10	**94,67**	92,39	84,78	**85,48**	83,94
Genetik Algoritmalar ile MS-LF				**98,65**					

Çizelge 4.6'da verilen destek vektör makineleri sınıflandırma algoritması kullanılarak alınan sonuçlara göre en yüksek doğruluk oranına %60 eğitim – %40 test için ayrılan veri setine göre kulak için 9, yüz için 12 ve termal yüz için 8 öznitelik de ulaşılmıştır. %70 eğitim – %30 test için ayrılan veri setinde ise kulak ve yüz için 10'ar öznitelik, termal yüz için 9 öznitelikde ulaşılmıştır. Elde edilen bu skorlar genetik algoritmalar yardımıyla birleştirilmiş ve doğruluk oranları elde edilmiştir. Bu sonuçlara göre en yükek doğruluk oranı %70 eğitim – %30 test olarak ayrılan verisetinde %98,65 olarak bulunmuştur. Verisetinin %70'lik kısmının eğitime ayrıldığı durumdaki doğruluk oranı

daha yüksek olduğu için destek vektör makineleri kullanarak yapılan öznitelik seviyesi birleştirme işleminde de veriseti kullanılmıştır.

Çizelge 4.7 Eşleştirme skoru seviyesi birleştirme(olasılıksal sinir ağları için)

	Eşleştirme Skoru-Seviyesi Birleştirme								
Eğitim – Test %	**%60 Eğitim - %40 Test**								
Biyometri	**Kulak**			**Yüz**			**Termal Yüz**		
Öznitelik sayısı	14	**10**	8	14	**11**	7	14	**11**	8
%	93,36	**97,25**	96,42	94,65	**96,32**	95,47	78,47	**86,42**	83,78
Genetik Algoritmalar ile MS-LF				**93,24**					
	Eşleştirme Skoru-Seviyesi Birleştirme								
Eğitim – Test %	**%70 Eğitim - %30 Test**								
Biyometri	**Kulak**			**Yüz**			**Termal Yüz**		
Öznitelik sayısı	14	**11**	6	14	**10**	8	14	**9**	8
%	96,60	**97,44**	96,46	93,25	**94,88**	91,20	76,12	**79,42**	77,30
Genetik Algoritmalar ile MS-LF				**94,22**					

Çizelge 4.7'de verilen olasılıksal sinir ağları kullanılarak alınan sonuçlara göre en yüksek doğruluk oranına %60 eğitim – %40 test için ayrılan verisetinde kulak için 10, yüz ve termal yüz için 11'er öznitelikte ulaşılmıştır. %70 eğitim – %30 test için ayrılan verisetinde ise kulak için 11, yüz için 10 ve termal yüz için 9 öznitelikte ulaşılmıştır. Elde edilen bu skorlar diğer sınıflandırma algoritmaları için alınan sonuçlarda olduğu gibi genetik algoritmalar yardımıyla birleştirilmiş ve en yüksek doğruluk oranına %70 eğitim için ayrılan verisetinde %94,22 olarak ulaşılmıştır.

Üçüncü Aşama: Bu aşamada her biyometri için elde edilen yerel ikili örüntü algoritmasından gelen öznitelikler ile gri seviye eş oluşum matrisinden alınan

öznitelikler tek bir veri setinde birleştirilmiştir. Bu veri setine karar ağacı, lineer destek vektör makineleri ve olasılıksal sinir ağları algoritmaları kullanarak sınıflandırma yapılmıştır.

Çizelge 4.8 Öznitelik seviyesi birleştirme(karar ağacı algoritması için)

Her biyometri için öznitelik sayısı	**14**	**10**	**8**	**5**
%	79,33	**83,45**	77,40	69,86

Öznitelik seviyesi birleştirme işlemi sonucunda 14x3 adet öznitelik bulunmaktadır. Bu bölümde ileriye doğru öznitelik seçim algoritması kullanarak öznitelik seçimi yapılmış ve Çizelge 4.8'de verilen doğruluk oranları bulunmuştur. Bu sonuçlara göre her biyometri için 10 adet öznitelik de %83,45 doğruluk oranı ile en yüksek doğruluk oranına ulaşılmıştır.

Çizelge 4.9 Öznitelik seviyesi birleştirme(destek vektör makineleri için)

Her biyometri için öznitelik sayısı	**14**	**10**	**8**	**5**
%	96,20	**99,25**	97,32	95,10

Çizelge 4.9'da verilen destek vektör makineleri kullanarak yapılan sınıflandırma sonucunda doğruluk oranlarına bakılırsa en yüksek doğruluk oranına her biyometri için 10 öznitelik de %99,25 ile ulaşılmıştır.

Çizelge 4.10 Öznitelik seviyesi birleştirme(olasılıksal sinir ağları için)

Her biyometri için öznitelik sayısı	**14**	**12**	**10**	**7**
%	94,35	94,46	**96,34**	91,80

Çizelge 4.10'da verilen olasılıksal sinir ağları kullanarak yapılan sınıflandırma sonuçlarına göre en yüksek doğruluk oranına yine her bir biyometri için 10 öznitelik için %96,34 ile ulaşılmıştır.

Çizelge 4.11'de en iyi değerlerin Hatalı Kabul Oranı(False Accept Rate – FAR), Hatalı Red Oranı(False Reject Rate – FRR), eğitim süresi ve test süresi değerleri verilmiştir.

Çizelge 4.11 FAR,FRR, eğitim süresi ve test süresi değerleri

Metot	Tip	FAR (%)	FRR (%)	Eğitim Süresi (sn)	Test Süresi (sn)
Çok Katmanlı Algılayıcı	**Kulak**	0,0018	0,046	4,65	1,70
	Yüz	0,002	0,051	6,42	2,68
	Termal Yüz	0,0024	0,052	5,60	2,75
	GA ile ES-SB	0,00085	0,011	7,40	3,27
	Ö-SB	0,00076	0,011	2,81	1,12
Karar Ağaçları	**Kulak**	0,00022	0,022	4,20	1,82
	Yüz	0,00026	0,028	5,84	2,74
	Termal Yüz	0,00032	0,036	4,78	2,84
	GA ile ES-SB	0,00008	0,01	6,47	3,10
	Ö-SB	0,00007	0,01	2,27	0,83
Destek Vektör Makineleri	**Kulak**	0,00012	0,014	7,48	2,65
	Yüz	0,00018	0,019	7,90	2,96
	Termal Yüz	0,00021	0,016	6,42	2,81
	GA ile ES-SB	0,00004	0,009	8,65	3,47
	Ö-SB	0,00005	0,0096	2,00	0,70
Olasılıksal Sinir Ağları	**Kulak**	0,0002	0,018	4,00	1,20
	Yüz	0,00022	0,021	4,45	2,41
	Termal Yüz	0,00024	0,024	4,21	2,60
	GA ile ES-SB	0,00006	0,0086	4,90	2,85
	Ö-SB	0,00004	0,008	1,86	0,66

Yukarıda verilen sonuçlara göre kulak biyometrisi diğer biyometriler arasında en belirleyici olmuştur. Yerel ikili örüntü ve gri seviye eş-oluşum matrisi kullanarak destek

vektör makineleri ile yapılan sınıflandırma işlemi sonuçlarına göre tüm veriler mükemmel bir şekilde sınıflandırılmıştır.

Çizelge 4.1, 4.2 ve 4.3 ve Çizelge 4.4 karşılaştırılırsa öznitelikler ve çok katmanlı algılayıcı sınıflandırma algoritması kullanılan sonuçlarda öznitelik seviyesi birleştirme işlemi, eşleştirme skoru seviyesi birleştrme işlemine göre daha iyi sonuç verdiği görülmektedir. Yerel ikili örüntü ve gri seviye eş-oluşum matrisi kullanarak elde edilen özniteliklerin karar ağacı ve olasılıksal sinir ağları için yakın değerler verdiği görülmüştür. Bununla birlikte destek vektör makineleri sınıflandırma algoritmasının sonuçlarına bakıldığında eşleştirme skoru seviyesi birleştirme işlemi, öznitelik seviyesi birleştirme işlemine göre daha iyi sonuç vermiştir.

Çizelge 4.11 yorumlandığında her iki birleştirme yöntemi için FAR ve FRR değerleri biyometrilerin tek tek alındığı durumdaki değerinden daha iyidir. Çok katmanlı algılayıcı, karar ağaçları ve olasılıksal sinir ağları algoritmaları öznitelik seviyesi birleştirme yöntemi ile daha iyi FAR/FRR değeri üretirken destek vektör makineleri algoritması eşleştirme skoru seviyesi ile daha iyi sonuç vermiştir. Bununla birlikte birleştirme metotları arasındaki fark çok küçüktür. Dolayısıyla birini diğerine tercih etmek kolay değildir.

Dördüncü Aşama: Bu aşamada tezin amacına uygun olarak; alınan biyometrilerden herhangi birinde sorun(biyometrinin cihaz kaynaklı alınamaması, biyometrinin kişinin giyiminden kaynaklı alınamaması, görüntüde çok fazla gürültü olması, kişinin kendini saklamaya çalışması vb.) olduğunda da kimliklendirme işleminin başarıyla tamamlandığı gösterilmektedir. Bu aşamada en iyi sonuçların alındığı yöntemler kullanılmıştır. Ayrı ayrı her biyometride sorun olduğu düşünülerek sonuçlar alınmıştır.

Çizelge 4.12 ES-SB – kulak biyometrisi elde edilemediğinde(DT için)

	Eşleştirme Skoru-Seviyesi Birleştirme						
Eğitim – Test %	**%70 Eğitim - %30 Test**						
Biyometri	**Kulak biyometrisinin elde edilmesinde sorun olduğunda**	**Yüz**			**Termal Yüz**		
Öznitelik sayısı		14	**10**	8	14	**10**	8
%		75,18	**77,48**	75,97	76,98	**78,70**	77,31
Genetik Algoritmalar ile ES-SB		**76,30**					

Çizelge 4.12'ye göre kulak biyometrisinin elde edilmesinde sorun olduğunda alınan sonuçlara göre kulak biyometrisinin alınabildiği duruma göre başarı oranında düşme olsa bile sınıflandırma işlemi başarılı olmuştur.

Çizelge 4.13 ES-SB – yüz biyometrisi elde edilemediğinde(DT için)

	Eşleştirme Skoru-Seviyesi Birleştirme						
Eğitim – Test %	**%70 Eğitim - %30 Test**						
Biyometri	**Kulak**			**Yüz biyometrisinin elde edilmesinde sorun olduğunda**	**Termal Yüz**		
Öznitelik sayısı	14	**10**	8		14	**10**	8
%	78,96	**80,37**	78,49		76,98	**78,70**	77,31
Genetik Algoritmalar ile ES-SB	**79,46**						

Çizelge 4.13'e göre yüz biyometrisinin elde edilmesinde sorun olduğunda alınan sonuçlara göre yüz biyometrisinin alınabildiği duruma göre sınıflandırma başarısı artmıştır.

Çizelge 4.14 ES-SB – termal yüz biyometrisi elde edilemediğinde (DT için)

	Eşleştirme Skoru-Seviyesi Birleştirme						
Eğitim – Test %	**%70 Eğitim - %30 Test**						
Biyometri	**Kulak**			**Yüz**			**Termal Yüz biyometrisinin elde edilmesinde sorun olduğunda**
Öznitelik sayısı	14	**10**	8	14	**10**	8	
%	78,96	**80,37**	78,49	75,18	**77,48**	75,97	
Genetik Algoritmalar ile ES-SB	**79,10**						

Çizelge 4.14'e göre termal yüz biyometrisinin elde edilmesinde sorun olduğunda alınan sonuçlara göre termal yüz biyometrisinin alınabildiği duruma göre sınıflandırma başarısı artmıştır.

Çizelge 4.12, 4.13 ve 4.14'de verilen sonuçlara göre karar ağacı algoritması kullanılarak alınan sonuçlara göre her bir biyometrinin elde edilmesinde sorun olduğu düşünülerek ilgili biyometri kaldırılmış ve sonuçlar tekrarlanmıştır. Bu durumda yüz ve termal yüz biyometrileri ayrı ayrı kaldırıldığında sınıflandırma başarısı artmıştır. Kulak biyometrisi kaldırıldığında ise sınıflandırma başarılı olmuş fakat doğruluk oranında azalma görülmüştür.

Çizelge 4.15 ES-SB – kulak biyometrisi elde edilemediğinde (DVM için)

	Eşleştirme Skoru-Seviyesi Birleştirme					
Eğitim – Test %	**%70 Eğitim - %30 Test**					
Biyometri	**Kulak biyometrisi elde edilmesinde sorun olduğunda**	**Yüz**			**Termal Yüz**	
Öznitelik sayısı		14	**10**	8	14	**9**	8
%		93,10	**94,67**	92,39	84,78	**85,48**	83,94
Genetik Algoritmalar ile MS-LF	**96,20**					

Çizelge 4.15'de verilen DVM algoritması kullanılarak yapılan sınıflandırma işleminde kulak biyometrisinin elde edilmesinde sorun olduğu varsayılarak sınıflandırma sonucundan çıkartılmıştır. Bu durumda doğruluk oranı düşmüş fakat sınıflandırma başarılı olmuştur.

Çizelge 4.16 ES-SB – yüz biyometrisi elde edilemediğinde (DVM için)

	Eşleştirme Skoru-Seviyesi Birleştirme						
Eğitim – Test %	**%70 Eğitim - %30 Test**						
Biyometri	**Kulak**			**Yüz biyometrisinin elde edilmesinde sorun olduğunda**	**Termal Yüz**		
Öznitelik sayısı	14	**10**	8		14	**9**	8
%	96,70	**100**	94,20		84,78	**85,48**	83,94
Genetik Algoritmalar ile MS-LF				**98,65**			

Çizelge 4.16'da verilen sonuçlara göre yüz biyometrisi elde edilemediğinde DVM algoritması kullanıldığında sınıflandırma oranı sabit kalmış ve sınıflandırma işlemi başarılı olmuştur.

Çizelge 4.17 ES-SB – termal yüz biyometrisi elde edilemediğinde (DVM için)

	Eşleştirme Skoru-Seviyesi Birleştirme						
Eğitim – Test %	**%70 Eğitim - %30 Test**						
Biyometri	**Kulak**			**Yüz**			**Termal Yüz biyometrisinin elde edilmesinde sorun olduğunda**
Öznitelik sayısı	14	**10**	8	14	**10**	8	
%	96,70	**100**	94,20	93,10	**94,67**	92,39	
Genetik Algoritmalar ile MS-LF				**99,70**			

Çizelge 4.17'de verilen sonuçlara göre termal yüz biyometrisinin elde edilmesinde sorun olduğu durumlarda doğruluk oranı artmıştır.

Çizelge 4.15, 4.16 ve 4.17'de alınan sonuçlara göre DVM algotirması kullanılarak alınan sonuçlara göre yüz biyometrisinin elde edilemediği durum için doğruluk oranı sabit kalmış ve termal yüz biyometrisinin elde edilemediği durumlarda doğruluk oranı artmıştır.

Çizelge 4.18 ES-SB – kulak biyometrisi elde edilemediğinde (PNN için)

	Eşleştirme Skoru-Seviyesi Birleştirme						
Eğitim – Test %	**%70 Eğitim - %30 Test**						
Biyometri	**Kulak biyometrisinin elde edilmesinde sorun olduğunda**	**Yüz**			**Termal Yüz**		
Öznitelik sayısı		14	**10**	8	14	**9**	8
%		93,25	**94,88**	91,20	76,12	**79,42**	77,30
Genetik Algoritmalar ile MS-LF		**96,36**					

Çizelge 4.18'de verilen PNN algoritması kullanılarak yapılan sınıflandırma işleminde kulak biyometrisinin elde edilemediği durumda doğruluk oranı artmıştır.

Çizelge 4.19 ES-SB – yüz biyometrisi elde edilemediğinde (PNN için)

	Eşleştirme Skoru-Seviyesi Birleştirme						
Eğitim – Test %	**%70 Eğitim - %30 Test**						
Biyometri	**Kulak**			**Yüz biyometrisinin elde edilmesinde sorun olduğunda**	**Termal Yüz**		
Öznitelik sayısı	14	**11**	6		14	**9**	8
%	96,60	**97,44**	96,46		76,12	**79,42**	77,30
Genetik Algoritmalar ile MS-LF	**91,00**						

Çizelge 4.19'da verilen sonuçlara göre yüz biyometrisi elde edilemediğinde PNN algoritması kullanıldığında sınıflandırma oranı düşmüştür fakat sınıflandırma işlemi başarılı olmuştur.

Çizelge 4.20 ES-SB – termal yüz biyometrisi elde edilemediğinde (PNN için)

	Eşleştirme Skoru-Seviyesi Birleştirme						
Eğitim – Test %	**%70 Eğitim - %30 Test**						
Biyometri	**Kulak**			**Yüz**			**Termal Yüz biyometrisinin elde edilmesinde sorun olduğunda**
Öznitelik sayısı	14	**11**	6	14	**10**	8	
%	96,60	**97,44**	96,46	93,25	**94,88**	91,20	
Genetik Algoritmalar ile MS-LF				**95,00**			

Çizelge 4.20'de verilen sonuçlara göre termal yüz biyometrisinin elde edilmesinde sorun olduğu durumlarda doğruluk oranı artmıştır.

Çizelge 4.18, 4.19 ve 4.20'de alınan sonuçlara göre PNN algotirması kullanılarak alınan sonuçlara göre kulak ve termal yüz biyometrisinin elde edilemediği durum için doğruluk oranı artmıştır.

Herhangi bir biyometrinin elde edilememesinde eşleştirme skoru seviyesi birleştirme işlemi kullanarak yapılan sınıflandırmalarda genelde artış göstermiştir. Bu durumda üç biyometriden bir tanesinin elde edilemediği durumlarda iki biyometri yardımıyla da sınıflandırma işlemi başarıyla tamamlanmıştır.

BÖLÜM 5

SONUÇ VE ÖNERİLER

Bu çalışmada tezin amacı olarak belirlenen kişilerin farklı biyometrilerini kullanarak farklı birleştirme metotları yardımıyla sınıflandırma yapmak ve herhangi bir biyometrinin elde edilememesi durumunda da sistemin başarılı olarak çalıştığını gösterebilmek için çoklu-biyometrik bir sistem önerilmiştir. Üç farklı biyometrik karakteristik kullanılmıştır. Her biyometrik karakteristik için üç farklı öznitelik çıkartım metodu kullanılmıştır ve dört farklı sınıflandırıcı eğitilmiştir. İki adet birleştirme metodu kullanılmıştır.

Sonuçlara göre kimliklendirme aşamasında en iyi sonuçlar; yerel ikili örüntü ve gri seviye eş-oluşum matrisi kullanarak öznitelik çıkartımı yapılan, öznitelikleri ileri yönlü öznitelik seçim algoritması yardımıyla azaltan ve destek vektör makineleri kullanarak sınıflandırma yapılan aşamada eşleştirme skoru-seviyesi birleştirme için %98,65'lik doğruluk oranı, %0,00004 FAR değeri ve öznitelik seviyesi birleştirme için %99,25'lik doğruluk oranı, %0,00005 FAR değeri ile en iyi sonuç elde edilmiştir.

Kimlik doğrulama aşamasındaki en iyi sonuçlar; yerel ikili örüntü ve gri seviye eş-oluşum matrisi kullanarak öznitelik çıkartımı yapılan, öznitelikleri ileri yönlü öznitelik seçim algoritması yardımıyla azaltan ve destek vektör makineleri kullanarak sınıflandırma yapılan aşamada eşleştirme skoru-seviyesi birleştirme için %98,65'lik doğruluk oranı yüz biyometrisi elde edilemediğinde de %98,65'de sabit kalmış, termal yüzün elde edilemediği aşamada ise %99,70'e yükselmiştir.

Elde edilen tüm sonuçlara göre bu problem bir kimliklendirme sorunu olarak görülürse tek başına kulak görüntüsünü kullanmak yeterli olacaktır ve birleştirme işlemleri herhangi bir iyileştirme sağlamamıştır. Fakat problem bir doğrulama sorunu olarak görülürse her iki birleştirme yöntemi de bireysel FAR/FRR sonuçlarına göre daha iyi değerler vermiştir.

Kimliklendirme aşamasında sistemde sadece kulak biyometrisinin yeterli olmasının sebebi kullanılan veri setindeki kulak görüntülerinin gürültüden arındırılmış ve net görüntüler olmasından kaynaklıdır. Fakat buna rağmen birleştirme sonucunda alınan FAR-FRR değerleri daha düşük olduğu için biyometrik sistemlerin güvenliği açısından birleştirme işlemi yapıldıktan sonra sınıflandırma yapılması daha doğrudur.

Bununla beraber herhangi bir biyometrinin elde edilememe durumunda alınan sonuçlara göre karar ağacı algoritması kullanarak sınıflandırma yapılan aşamada yüz veya termal yüz görüntüleri elde edilemediği düşünüldüğünde %78,25 olan doğruluk oranı sırasıyla %79,46 ve %79,10 değerlerine yükselmiştir. Destek vektör makineleri algoritması kullanılarak sınıflandırma yapılan aşamada yüz görüntünün elde edilemediği senaryosu uygulandığında %98,65 olan doğruluk oranı sabit kalmış, termal yüz görüntüsünün elde edilemediği düşünüldüğünde ise %99,70'e yükselmiştir. Olasılıksal sinir ağları algoritması kullanarak sınıflandırma yapılan aşamada kulak görüntülerinin elde edilemediği düşünüldüğünde %94,22 olan doğruluk oranı %96,36'ya, termal yüz görüntülerinin elde edilemediği düşünüldüğünde %95,00'e yükselmiştir. Bu sonuçlara göre tezin amacında sunulan herhangi bir biyometri elde edilemediğinde de başarılı bir şekilde sınıflandırma yapılması öngörüsüne ulaşılmıştır.

Bundan sonraki çalışmalarda büyük veri ile çalışılarak bu sistemin büyük veri seti için de kullanılabilir olduğu gösterilmelidir. Bu aşamada kullanılan sınıflandırma algoritmaları süre açısından verimsiz olabilirler. Bunun için de derin öğrenme ağları kullanılmalıdır.

KAYNAKLAR

[1] Jain, A. K. ve Ross, A.,(2002). "Learning User-Specific Parameters In A Multibiometric System", Int. Conf. Image Process., 1:57-60.

[2] Chang, K. I., Bowyer, K. W., Flynn, P. J., ve Chen, X.,(2004). "Multi-Biometrics Using Facial Appearance, Shape And Temperature", 6. IEEE Int. Conf. Autom. Face Gesture Recognit., Mayıs:43-48.

[3] Fierrez-Aguilar, J., Ortega-Garcia, J., Gonzalez-Rodriguez, J., ve Bigun, J., (2005). "Discriminative Multimodal Biometric Authentication Based On Quality Measures", Pattern Recognit., 38(5):777-779.

[4] Lau, C., Ma, B., Meng, H., Moon, Y. ve Yam, Y., (2004). "Fuzzy Logic Decision Fusion In A Multimodal Biometric System", Interspeech, 1-4.

[5] Ko, T., (2005). "Multimodal Biometric Identification for Large User Population Using Fingerprint, Face and Iris Recognition", Proc. 34th Appl. Imag. Pattern Recognit. Work., 218-223.

[6] Snelick, R., Uludag, U., Mink, A., Indovina, M. ve Jain, A. K., (2005). "Large Scale Evaluation of Multimodal Biometric Authentication Using State-of-the-Art Systems", IEEE Trans. Pattern Anal. Mach. Intell., 27(3):450-455.

[7] Nandakumar, K., Chen, Y., Jain, A. K. ve Dass, S. C., (2006). "Quality-based Score Level Fusion in Multibiometric Systems", 18th Int. Conf. Pattern Recognition(ICPR06), 4:18-21, 2006.

[8] Bowyer, K. W. vd., (2006). "Multi-Modal Biometrics: An Overview", 2nd Work. Multi-Modal User Authentication.

[9] Rattani, A., Kisku, D. R., Bicego, M. ve Tistarelli, M., (2006). "Robust Feature-Level Multibiometric Classification", Proc. Biometric Consort. Conf. – A Spec. issue Biometrics, 1-6.

[10] Volner, R. ve Boreš, P., (2006). "Multi-Biometric Techniques, Standards Activities And Experimenting", BEC 2006 - 2006 Int. Balt. Electron. Conf. Proc. 10th Bienn. Balt. Electron. Conf., 137-140.

[11] Meng, H., vd., (2006). "The Multi-Biometric, Multi-Device and Multilingual (M3) Corpus", Proc. Work. Multimodal User Authentication.

[12] Chetty, G. ve Wagner, M., (2006). "Multi-Level Liveness Verification For Face-

Voice Biometric Authentication", Biometrics Symp. Spec. Sess. Res. Biometric Consort. Conf., 1-6.

[13] Vajaria, H., Islam, T., Mohanty, P., Sarkar, S., Sankar, R. ve Kasturi, R., (2007). "Evaluation and Analysis Of A Face And Voice Outdoor Multi-Biometric System", Pattern Recognit. Lett., 28(12):1572-1580.

[14] Dinerstein, S., Dinerstein, J. ve Ventura, D., (2007). "Robust Multi-Modal Biometric Fusion Via Multiple SVMs", IEEE Int. Conf. Syst. Man Cybern., 1530-1535.

[15] Abate, A. F., Nappi, M., Riccio, D. ve De Marsico, M., (2007). "Face, Ear And Fingerprint: Designing Multibiometric Architectures", Proc. - 14th Int. Conf. Image Anal. Process., 437-442.

[16] Hui, H. P. S., Helen, M. M. ve Mak, M. W., (2007). "Adaptive Weight Estimation in Multi-Biometric Verification Using Fuzzy Logic Decision Fusion", IEEE Int. Conf. Acoust. Speech Signal Process., 4:501-504.

[17] Chen, C., Veldhuis, R. N. J., Kevenaar, T. A. M. ve Akkermans, A. H. M., (2007). "Multi-Bits Biometric String Generation Based On The Likelihood Ratio", IEEE Conf. Biometrics Theory, Appl. Syst. BTAS'07, 1.

[18] Wang, C., Li, Y., Zhang, H. ve Wang, L., (2007). "Multi-Modal Biometric Verification Based On Far-Score Normalization", Int. J. Comput. Sci. Netw. Secur., 8(4):250-254.

[19] Aggarwal, G., Ratha, N. K., Bolle, R. M. ve Chellappa, R., (2008). "Multi-Biometric Cohort Analysis For Biometric Fusion", IEEE Int. Conf. Acoust. Speech Signal Process., 5224-5227.

[20] Cui, J., Li, J. P. ve Lu, X. J., (2008). "Study On Multi-Biometric Feature Fusion And Recognition Model", 2008 Int. Conf. Apperceiving Comput. Intell. Anal., 66-69.

[21] Nandakumar, K. ve Jain, A. K., (2008). "Multibiometric Template Security Using Fuzzy Vault", BTAS 2008 - IEEE 2nd Int. Conf. Biometrics Theory, Appl. Syst., 1-6.

[22] Bashir, F., Usher, D., Casaverde, P. ve Friedman, M., (2008). "Video Surveillance For Biometrics: Long-Range Multi-Biometric System", Proc. - IEEE 5th Int. Conf. Adv. Video Signal Based Surveillance, AVSS 2008, 175-182.

[23] Seely, R. D., Samangooei, S., Middleton, L., Carter, J. N. ve Nixon, M. S., (2008). "The University Of Southampton Multi-Biometric Tunnel And Introducing A Novel 3d Gait Dataset", BTAS 2008 - IEEE 2nd Int. Conf. Biometrics Theory, Appl. Syst.

[24] Boodoo, N. B. ve Subramanian, R. K., (2009). "Robust Multi-Biometric Recognition Using Face And Ear Images", Int. J. Comput. Sci. Inf. Secur., 6(2):164-169.

[25] Monwar, M. M. ve Gavrilova, M. L., (2009). "Multimodal Biometric System Using Rank-Level Fusion Approach", IEEE Trans. Syst. Man, Cybern. Part B Cybern.,39(4):867-878.

[26] Kanade, S., Petrovska-Delacrétaz, D. ve Dorizzi, B., (2009). "Multi-Biometrics

Based Cryptographic Key Regeneration Scheme", IEEE 3rd Int. Conf. Biometrics Theory, Appl. Syst. BTAS 2009.

[27] Wang, J., Li, Y., Liang, P., Zhang, G. ve Ao, X., (2009). "An Effective Multi-Biometrics Solution For Embedded Device," IEEE Int. Conf. Syst. Man Cybern., 917-922.

[28] Nandakumar, K., Jain, A. K. ve Ross, A., (2009). "Fusion In Multibiometric Identification Systems: What About The Missing Data?", Int. Conf. Biometrics, Adv. Biometrics, 5558:743-752.

[29] Woodard, D. L., Pundlik, S., Miller, P., Jillela, R. ve Ross, A., (2010). "On The Fusion Of Periocular And Iris Biometrics In Non-Ideal İmagery", Int. Conf. Pattern Recognit., 201-204.

[30] Allano, L., Dorizzi, B. ve Garcia-Salicetti, S., (2010). "Tuning Cost And Performance In Multi-Biometric Systems: A Novel And Consistent View Of Fusion Strategies Based On The Sequential Probability Ratio Test (SPRT)", Pattern Recognit. Lett., 31(9):884-890.

[31] Aboalsamh, H. A., (2011). "A Multi Biometric System Using Combined Vein and Fingerprint Identification", Int. J. Circuits, Syst. Signal Process., 5(1):29-36.

[32] Belahcène, M., Ouamane, A. ve Ahmed, A. T., (2011). "Fusion By Combination Of Scores Multi-Biometric Systems", 3rd Eur. Work. Vis. Inf. Process., 25:252-257.

[33] Popplewell, K., vd., (2011). "A Comparison Of Genetic Feature Selection And Weighting Techniques For Multi-Biometric Recognition", Proc. 49th Annu. Southeast Reg. Conf. - ACM-SE ’11, 205-208.

[34] Meraoumia, A., Chitroub, S. ve Bouridane, A., (2011). "Fusion Of Finger-Knuckle-Print And Palmprint For An Efficient Multi-Biometric System Of Person Recognition", IEEE Int. Conf. Commun.,1-5.

[35] Alford, A., vd., (2012). "Genetic & Evolutionary Biometrics: Hybrid Feature Selection and Weighting for a Multi-Modal Biometric System", 2012 Proc. IEEE Southeastcon.

[36] Akhtar, Z., Fumera, G., Marcialis, G. L. ve Roli, F., (2012). "Evaluation Of Serial And Parallel Multibiometric Systems Under Spoofing Attacks", 2012 IEEE 5th Int. Conf. Biometrics Theory, Appl. Syst., 283-288.

[37] Abdolahi, M., Mohamadi, M. ve Jafari, M., (2013). "Multimodal Biometric system Fusion Using Fingerprint and Iris with Fuzzy Logic", Int. J. Soft Comput. Eng., 2(6):504-510.

[38] Garcia-Rios, E., Escamilla-Hernandez, E., Aguilar-Torres, G., Jacobo-Sanchez, O. Nakano-Miyatake, M. ve Perez-Meana, H., (2013). "Multi-biometric Face Recognition System using Levels of Fusion", Int. J. Comput., 7(3):99-108.

[39] Çelik, E., (2011). "Recognition Of Palmprint Based On Image Processing With Artificial Neural Network Reliable", Marmara University, Istanbul.

[40] Moutafis, P. ve Kakadiaris, I. A., (2015). "Rank-Based Score Normalization For Multi-Biometric Score Fusion", 2015 IEEE Int. Symp. Technol. Homel. Secur. HST

2015, December.

[41] Filiz, S., (2013). "Biometric Systems in Cyber Security and Face Recognition", Gazi University, Ankara.

[42] Kashyap, B. ve Satao, K. J., (2015). "Implementation of Multi-Biometric Cryptosystem for Information Security Using Elliptic Curve Cryptography", Int. J. Adv. Res. Comput. Commun. Eng., 4(7):376-380.

[43] Vora, A., Paunwala, C. ve Paunwala, M., (2015). "Review on Fusion Algorithms for Multimodal Authentication System", 3(2):911-917.

[44] Delac, K. ve Grgic, M., (2004). "A Survey Of Biometric Recognition Methods", 46th Int. SyrnPoSium Electron. Mar. ELMAR-2004, 46:184-193.

[45] Jain, A. K., Ross, A. ve Prabhakar, S., (2004). "An Introduction to Biometric Recognition", IEEE Trans. Circuits Syst. Video Technol., 14(1):4-20.

[46] Kalra, S. ve Lambda, A., (2014). "A Survey On Multimodal Biometrics", Int. J. Comput. Sci. Inf. Technol., 5(2):2148-2151.

[47] Pathak, M. ve Srinivasu, N., (2015). "Analysis of Multimodal Biometric System Based on Level of Fusion", Int. J. Inven. Eng. Sci., 3(8):8-11.

[48] Gambhir, A., Narke, S., Borhade, S. ve Bokade, G., (2014). "Person Recognition Using Multimodal Biometrics", 4(4):725–728.

[49] https://www.supremainc.com/sites/default/files/upl, 10 Ocak 2018.

[50] Connaughton, R., Sgroi, A., Bowyer, K. ve Flynn, P. J., (2012). "A Multialgorithm Analysis Of Three Iris Biometric Sensors", IEEE Trans. Inf. Forensics Secur., 7(3):919-931.

[51] Mohamed, S., (2012). "Multi-Modal Biometric Authentications: Concept Issues And Applıcations Strategies", 3:23-60.

[52] Turk, M. ve Pentland, A. P., (1991). "Face Recognition Using Eigenfaces", in IEEE Conference on Computer Vision and Pattern Recognition.

[53] Mao, K. Z., Tan, K. C. ve Ser, W., (2000). "Probabilistic Neural-Network Structure Determination For Pattern Classification", IEEE Trans. Neural Networks, 11(4):1009-1016.

[54] Safavian, S. R. ve Landgrebe, D., (1991). "A Survey of Decision Tree Classifier Methodology", IEEE Trans. Syst. Man. Cybern., 21(3):660-674.

[55] Pradhan, A., (2012). "Support Vector Machine - S Survey", Int. J. Emerg. Technol. Adv. Eng., 2(8):82-85.

[56] Werbos, P. J., (1974). "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences", Harvard University.

[57] Rumelhart, D. E., Hinton, G. E. ve Williams, R. J., (1986). "Parallel Distributed Processing: Explorations in the Microstructure of Cognition", Bradford B. Cambridge,MA: MIT Press.

[58] Kantardzic, M., (2011). "Decision Trees and Decision Rules", Data Min., 169-198.

[59] Gök, M., vd., (2017). "Rapidminer ile Veri Madenciliği", Pusula Yayıncılık, Ankara.

[60] Vapnik, V., (1995). "Support Vector Machine", Mach. Learn., 20(3):273-297.

[61] Vapnik, V., (2000). "SVM Method Of Estimating Density, Conditional Probability, And\Nconditional Density", 2000 IEEE Int. Symp. Circuits Syst. Emerg. Technol. 21st Century. Proc., 2.

[62] Bishop, C. M., (2006). "Pattern Recognition and Machine Learning", 4(4).

[63] Kavzoğlu, T. ve Çölkesen, İ., (2010). "Destek Vektör Makineleri İle Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi", Harit. Derg., 144.

[64] Osuna, E., Freund, R. ve Girosi, F., (1997), "An Improved Training Algorithm For Support Vector Machines", Neural Networks Signal Process. VII. Proc. 1997 IEEE Work., 276-285.

[65] Bolat, B. ve Küçük, Ü., (2005). "Olasılıksal Sinir Ağları ile Müzikal Enstrüman Ailelerinin Tanınması", EMO Elektrik-Elektronik-Bilgisayar 11. Ulusal Kongresi, İstanbul.

[66] Wang, S., vd., (2010), "A Natural Visible and Infrared Facial Expression Database For Expression Recognition and Emotion Inference", IEEE Trans. Multimed., 12(7):682-691.

[67] Tong, Y., Wang, Y., Zhu, Z. ve Ji, Q., (2007). "Robust Facial Feature Tracking Under Varying Face Pose And Facial Expression", Pattern Recognit., 40(11):3195-3208.

[68] Lv, Y., Wang, S., ve Shen, P., (2011). "A Real-Time Attitude Recognition By Eye-Tracking", in Proceedings of the Third International Conference on Internet Multimedia Computing and Service - ICIMCS ’11, 170.

[69] IIT Delhi Ear Database, http://www.comp.polyu.edu.hk/~csajaykr/IITD/Database_Ear.htm., 11 Kasım 2017.

[70] Kumar, A. ve Wu, C., (2012). "Automated Human Identification Using Ear Imaging", Pattern Recognit., 41(3):956-968.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı :Kadir Sercan BAYRAM

Doğum Tarihi ve Yeri :09.01.1987, Konya-Ereğli

Yabancı Dili :İngilizce

E-posta :ksercanbayram@gmail.com

ÖĞRENİM DURUMU

Derece	**Alan**	**Okul/Üniversite**	**Mezuniyet Yılı**
Y. Lisans	Elektronik ve Haberleşme Müh.	Haliç Üniversitesi	2011
Lisans	Elektronik ve Haberleşme Müh.	Haliç Üniversitesi	2009
Lise	Fen	Aksaray Fen Lisesi	2004

İŞ TECRÜBESİ

Yıl	**Firma/Kurum**	**Görevi**
2018 - Halen	Hasan Kalyoncu Üniversitesi	Arş. Gör.
2016 - 2018	Hasan Kalyoncu Üniversitesi	Öğr.Gör.
2009 - 2016	Haliç Üniversitesi	Arş.Gör – Öğr.Gör.

YAYINLARI

Makale

1. Bayram, K.S., ve Bolat, B., (2018). "Multibiometric Identification By Using Ear, Face, And Thermal Face", EURASIP Journal on Image and Video Processing, 32.

Bildiri

1. Kizrak, M.A., Bayram, K.S. ve Bolat, B., (2014). “Classification of Classic Turkish Music Makams”, Innovations in Intelligent Systems and Applications (INISTA) Proceedings, 2014 IEEE International Symposium, 23-25 June 2014, Alberobello, Italy, 394-397.

2. Bayram, K.S., Kizrak, M.A. ve Bolat, B., (2013). “Classification Of EEG Signals By Using Support Vector Machines”, Innovations in Intelligent Systems and Applications (INISTA), 2013 IEEE International Symposium, 19-21 June 2013, Albena, Bulgaria, 1-3.

3. Bayram, K.S., Zeytinoglu, A.Z. ve İmeci, Ş.T., (2010). “20 dB Hybrid Stripline Coupler”, The 26th Annual Review of Progress in Applied Computational Electromagnetics, in Conjunction with RFIDay. ACES (Applied Computational Electromagnetic Society) Conference, 25 Nisan 2010, Tampere, Finland, 748-753.

4. Bayram, K.S., Kızrak, M.A., Zeytinoğlu, A.Z. ve İmeci, Ş.T., (2010). “DVB-T’de OFDM Performans Analizi”, V.URSI (International Union of Radio Science), Türkiye-2010 Bilimsel Kongresi, 25-27 Ağustos 2010, ODTÜ, Güzelyurt, Kuzey Kıbrıs Türk Cumhuriyeti, 235-238.

5. Bostancı, Ç., Bayram, K.S. ve İmeci, Ş.T., (2010). “Ek Uzunluklu Mikroşerit Yama Anten Tasarımı”, V.URSI (International Union of Radio Science), Türkiye-2010 Bilimsel Kongresi, 25-27 Ağustos 2010, ODTÜ, Güzelyurt, Kuzey Kıbrıs Türk Cumhuriyeti, 294-297.

6. Bayram, K.S. ve İmeci, Ş.T., (2009). “10 dB Hibrid Şerithattı Kuplör”, III. Haberleşme Teknolojileri ve Uygulamaları Sempozyumu (Habtekus’09), 9-11 Aralık 2009, Yıldız Teknik Üniversitesi, İstanbul.

Proje

1. Gaziantep Kayıtdışı İstihdamla Mücadele Ediyor, Organizasyon Sorumlusu, Hasan Kalyoncu Üniversitesi, 2016-2017.

ÖDÜLLERİ

1. %100 Yüksek Lisans Öğrenim Bursu(Haliç Üniversitesi)

2. %100 YÖK Lisans Öğrenim Bursu (Haliç Üniversitesi)