

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HAVADA İMZA VE YÜZ TANIMAYA DAYALI
ÇOKLU BİYOMETRİK SİSTEM TASARIMI

Serkan SALTÜRK

DOKTORA TEZİ
Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Haberleşme Programı

Danışman
Doç. Dr. Nihan KAHRAMAN

Nisan, 2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HAVADA İMZA VE YÜZ TANIMAYA DAYALI ÇOKLU
BİYOMETRİK SİSTEM TASARIMI

Serkan SALTÜRK tarafından hazırlanan tez çalışması 17.04.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Haberleşme Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Nihan KAHRAMAN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Nihan KAHRAMAN, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Mehmet SAĞBAŞ, Üye
İzmir Bakırçay Üniversitesi

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

Prof. Dr. Zümray DOKUR, Üye
İstanbul Teknik Üniversitesi

Doç. Dr. Bülent BOLAT, Üye
Yıldız Teknik Üniversitesi

Danışmanım Doç. Dr. Nihan KAHRAMAN sorumluluğunda tarafımca hazırlanan Havada İmza ve Yüz Tanımaya Dayalı Çoklu Biyometrik Sistem Tasarımı başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Serkan SALTÜRK

İmza

*Eşime
ve
kuzularıma..*



TEŞEKKÜR

“Aşılmasına imkân olmayan hiçbir duvar yoktur.” (Anton Çehov) sözüyle yola çıkarak insanlığa faydalı olan, iyi niyetle çalışan tüm bilim insanlarına teşekkürlerimi sunarım. Şayet bu insanların çabaları olmasaydı insanlığın tarihi bu kadar uzun olmazdı.

Doktora serüvenimde daima arkamda duran ve bana güvenen değerli hocam Doç. Dr. Nihan Kahraman’a teşekkür etmeyi bir borç bilirim. Bu süreçte hem bilgisi hem güler yüzlülüğü ile zorlukları kolaylaştıran, takıldığımız noktalarda bize yol gösteren hocama “daima mutlu olun, yolunuz açık olsun” diyorum. Tez sürecinde değerli zamanlarını ayıran ve bize maddi manevi katkılarıyla tez çalışmamızın olgunlaşmasına destek olan dünyanın en naif insanlarından hocalarım Doç. Dr. Umut Engin Ayten ve Prof. Dr. Mehmet Sağbaş’a hayat yolculuklarında kendileri gibi karakterli insanlarla karşılaşmalarını dilerim.

Akademik yolculuğumda beni ayağa kaldıran, önderlik ve abilik eden, tecrübeleriyle ve samimiyetiyle bu yolculukta beni cesaretlendiren Doç. Dr. Hüseyin Üvet Hoca’ma, Asil Laboratuvarı’nda yan yana ter döktüğümüz Arş. Gör. İbrahim Cem Balcı, İrem Sayın, Merve Sevgi ve lisans, lisansüstü her seviyeden hayatımızı kolaylaştıran ve güzelleştiren arkadaşlarıma kalpten teşekkürlerimi sunarım. Zira akademik hayatın çileleri ve zorlukları onlarla başarıya dönüştü ve inanıyorum ki daha da güzel çalışmalara birlikte imza atacağız.

Akademik hayatımda olmasalar da her sıkıştığım da sızlanmalarımı dinleyen, bana destek veren ve derdimi paylaşan arkadaşlarım Murat Koç, Mehmet Şeker, Sıla Şeker, İmran Asan ve abilerim Hakan Koç, Ufuk Fidanlı ve Murat Polat’ın asla yalnız yürümelerini temenni ediyorum. Eğitim yolculuğumun başında, sağlam bir bilgi ve insanlık temeli aşılıyarak hayatımın her alanında doğru insan olmayı ve başarmayı öğreten, öğrencisini evladından ayırmayan, değerli öğretmenim Ayten Güraras’ı içtenlikle ve saygıyla selamlıyorum. Bununla beraber, ilgisiyle, bilgisiyle, duasıyla bu noktaya gelmemde emeği olan, sevindiğimde sevinen, üzüldüğümde üzülen tüm gönül dostlarıma da selam gönderiyorum.

Hayatımın her evresinde, hangi koşulda olursa olsun desteğini esirgemeyen çok kıymetli annem, babam, kardeşim ve akademik hayatıma önemli katkıları olan ablam Doç. Dr. Esengül Saltürk'e sonsuz şükranlarımı sunarım. Ayrıca, paylaşımlarıyla hayatıma dokunan amcam Halim Saltürk ve bana hem arkadaş hem sırdaş olan dayım Ahmet Bostancı'ya da içten teşekkürlerimi iletmek isterim. Bununla birlikte, ailelerine katıldığım günden beri maddi, manevi her alanda arkamda duran Sabiha ve Hıdır Soydan'a, bir çalışmanın, doğru bakış açısıyla ne kadar hızlı ve kolay yapılabileceğine dair verdiği ilham için abim Dr. Zafer Soydan'a, dua ve desteğini her zaman hissettiğim ablalarım Zinnur Banu Mayan ve Dr. Dilek Soydan'a ve yıllardır her zorlukta yanımda olan, dostluk ve abilik eden Battal Mayan'a verdikleri destek için çok teşekkür ederim. Zira, güzel dilek ve duaları olmasaydı bu noktaya gelemezdim.

Ve çıktığım tüm kulvarlarda, her tökezlediğimde, bazen önden çeken bazen arkadan iten, her türlü nazıma, zorluğuma incitmeden katlanan değerli eşim Arş. Gör. Tuba Saltürk'e "hayat seninle güzel" diyorum. Son olarak iki kuzum, gözbebeklerim, canımın içi kızlarım Ayşe'me ve Defne'me, tez döneminde aksi bir adama dönüşsem de küçük yaşlarına rağmen bu durumu olgunlukla karşılamaları ve sonsuz sevgileri için müteşekkirim. Hep güzel günlerini görmek dileğiyle.

Serkan SALTÜRK

İÇİNDEKİLER

SİMGE LİSTESİ	viii
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	xi
TABLO LİSTESİ	xiii
ÖZET	xiv
ABSTRACT	xvi
1 GİRİŞ	1
1.1 Biyometri ve Temel Kavramlar	1
1.2 Çoklu Biyometrik Sistemler	3
1.2.1 Çoklu Sensör Sistemleri	3
1.2.2 Çoklu Algoritma Sistemleri	4
1.2.3 Çoklu Birim Sistemleri	4
1.2.4 Çoklu Örnek Sistemleri	5
1.2.5 Çoklu Model Sistemleri	6
1.3 Tezin Amacı	6
1.4 Hipotez	7
2 LİTERATÜR TARAMASI	8
2.1 Biyometrinin Gelişimi, İmza ve Yüz Biyometrisi	8
2.2 Çoklu Biyometri Sistemleri ve İmza Biyometrisi Uygulamaları . . .	12
3 TEORİK TEMELLER	16
3.1 Önerilen Çalışmadaki Biyometrik Özellikler	16
3.1.1 İmza Biyometrisi	16
3.1.2 Havada İmza Biyometrisi	17
3.1.3 Yüz Biyometrisi	18
3.2 Derin Öğrenme Modelleri	19

3.2.1	Evrişimsel Sinir Ağları (Convolutional Neural Networks-CNN)	19
3.2.2	Uzun Kısa-Süreli Bellek (Long Short Term Memory-LSTM)	24
3.2.3	Geçitli Özyinelemeli Birim (Gated Recurrent Unit-GRU)	27
3.2.4	Zamansal Evrişimli Ağlar (Temporal Convolutional Networks-TCN)	28
4	VERİ TOPLAMA VE METODOLOJİ	29
4.1	Verilerin Toplanması ve Ön İşlemler	29
4.1.1	Havada İmza Verilerinin Toplanması	31
4.1.2	Yüz Görüntülerinin Toplanması	33
4.1.3	Veriler Üzerinde Ön İşlemler	34
4.2	Model Oluşturma ve Model Eğitimi	36
4.2.1	CNN, LSTM, GRU ve TCN Modelleri	36
4.2.2	Algoritmaların Karşılaştırılması ve Seçimi	38
4.3	Performans Değerlendirmesi	39
5	UYGULAMA VE TESTLER	41
5.1	Sistem Kurulumu ve Uygulama Ortamı	41
5.2	Model Eğitimi ve Validasyonu	42
5.3	Test Sonuçları ve Analizi	43
6	SONUÇ	45
	KAYNAKÇA	48
	TEZDEN ÜRETİLMİŞ YAYINLAR	58

SİMGE LİSTESİ

s	CNN filtre kaydırma adımı
p	CNN giriş verisine eklenen piksel sayısı
f	CNN girişindeki filtre boyutu
n	CNN girişindeki veri boyutu
h	Lineer interpolasyonda iki nokta arasında seçilen noktanın tahmini mesafesi
$\hat{y}$	Lineer interpolasyonda yeni nokta

KISALTMA LİSTESİ

2GRUNN	Gaussian Gated Recurrent Unit Neural Networks
3B	Üç boyutlu
ANN	Artificial Neural Networks
CNN	Convolutional Neural Networks
DNA	Deoksiriboz Nükleik Asit
DNN	Deep Neural Networks
DTW	Dynamic Time Warping
ECPE	Elliptic Curve Point Embedding
EEG	Elektroensefalografi
EKG	Elektrokardiyografi
FDA	Fisher Discriminant Analysis
FFT	Fast Fourier Transform
GMM	Gaussian Mixture Model
GRU	Gated Recurrent Unit
GSVD	Generalized Singular Value Decomposition
HCC	Haar Cascade Classifier
HMM	Hidden Markov Models
K-PCA	Kernelized Principal Component Analysis
KF	Kalman Filter
LBP	Local Binary Pattern
LDA	Linear Discriminant Analysis
LSTM	Long Short-Term Memory
MHI	Motion History Image

MMS-DNN	Modified Mixed Sequence Deep Neural Network
MP	MediaPipe
MPH	MediaPipe Hands
MPF	MediaPipe Face
OC-SVM	One Class-Support Vector Machine
PCA	Principal Component Analyse
PMT	Pixel Matching Technique
ReLu	Rectifier Linear Unit
RNN	Recurrent Neural Networks
SDA	Subclass Discriminant Analysis
SIFT	Scale Invariant Feature Transform
SVM	Support Vector Machine
TCN	Temporal Convolutional Networks
TDA	Tangential Discrimination Analysis
VGP	Vanishing Gradient Problem
VQ	Vector Quantization

ŞEKİL LİSTESİ

Şekil 1.1	Fiziksel ve davranışsal biyometrik özellik örnekleri (Görüntü oluşturulurken flaticon web sitesindeki ikonlardan yararlanılmıştır [1])	2
Şekil 1.2	Aynı biyometrik görüntünün hem monokrom hem de termal kamera gibi farklı iki sensörle alınması	3
Şekil 1.3	Parmak izi biyometrisinin hem minutiae noktalarının bulunması hem de doku analiziyle modellenmesi	4
Şekil 1.4	Birden çok parmak izi kullanılarak veri alınması	5
Şekil 1.5	Birden çok parmak izi kullanılarak veri alınması	5
Şekil 3.1	Temel bir derin öğrenme ağı	19
Şekil 3.2	Örnek bir verinin 3x3 filtreden geçirilmesi ile oluşan konvolüsyon sonuç matrisi	20
Şekil 3.3	4x4 büyüklükte ve 1 piksel eklenmiş bir verinin, 3x3 bir filtre ile konvolüsyon işlemi sonucunda ortaya çıkan aynı boyuttaki matris	21
Şekil 3.4	Maksimum havuzlama ve ortalama havuzlamanın veriye uygulanması ile ortaya çıkan sonuç matrisi	22
Şekil 3.5	Düzleştirme katmanı ile ortaya çıkan veri	23
Şekil 3.6	RNN Mimarisi [101]	25
Şekil 3.7	LSTM Mimarisi [101]	26
Şekil 3.8	Hücresinin durum geçişleri (a), unutma kapısı (b), giriş kapısı (c), unutma ve giriş kapısı işlemleri (d), çıkış kapısı (e) [101]	26
Şekil 3.9	RNN, LSTM ve GRU yapıları [103]	27
Şekil 3.10	(a) Encoder-Decoder TCN yapısı, (b) Dilated TCN yapısı [104]	28
Şekil 4.1	Katılımcılardan alınan kâğıt üzerinde imza verisi	30
Şekil 4.2	MPH kütüphanesi anahtar noktaları [116]	31
Şekil 4.3	Ekran üzerinde dikdörtgen oluşturulması ve işaret ile orta parmağın yakın olduğu durumda imzanın ekranda çizdirilmemesi	32
Şekil 4.4	Ekran üzerine imzanın çizdirilmesi	33
Şekil 4.5	İmza verisi ve yüz görüntüsünün aynı anda alınması	34
Şekil 4.6	Her bir imza uygulamasında alınan imzanın görsel olarak kaydedilmesi	34

Şekil 4.7	Parçalı olarak atılan bir havada imzanın saklanan sinyalinin bir bölümü. Sinyalin parçalandığı bölge için -1 değerleri yazılmıştır. .	35
Şekil 4.8	52 noktalı bir sinyalin Matlab ortamında 200 noktalı bir sinyale interpolasyonla dönüştürülmesi	36
Şekil 4.9	Görüntüler için oluşturulan CNN modelinin yapısı. Aynı model havada imza sinyal görüntülerine de uygulanmıştır.	37
Şekil 4.10	Dinamik sinyaller için model tasarım örneği	37
Şekil 4.11	Birleşik model mimarisi	38
Şekil 4.12	Veri dağılımlarının bölgelerle görsel temsili	39



TABLO LİSTESİ

Tablo 4.1	Veri Seti Özellikleri	29
Tablo 5.1	Biyometrik özellikler tekil olarak değerlendirildiğinde, tek modelle alınan sonuçlar	43
Tablo 5.2	İmza görüntüsü ve yüz görüntüsü sonuçları	44
Tablo 5.3	İmza görüntüsü ve imza sinyali sonuçları	44
Tablo 5.4	İmza sinyali ve yüz görüntüsü sonuçları	44

Havada İmza ve Yüz Tanımaya Dayalı Çoklu Biyometrik Sistem Tasarımı

Serkan SALTÜRK

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Doktora Tezi

Danışman: Doç. Dr. Nihan KAHRAMAN

Biyometri, bireylerin fiziksel veya davranışsal özelliklerini kullanarak kimlik doğrulama veya tanıma işlemlerini gerçekleştiren bir teknoloji alanıdır. Parmak izi doğrulama, yüz tanıma, retina tarama, imza analizi gibi biyometrik yöntemler, güvenlik sistemlerinde ve kimlik doğrulama uygulamalarında yaygın olarak kullanılmaktadır. Ancak, tek bir biyometrik özellik kullanıldığında, bu sistemlerin karşılaştığı zorluklar ve sınırlamalar bulunmaktadır. Bu noktada, çoklu biyometri kullanımı önem kazanmaktadır. Çoklu biyometri, birden fazla biyometrik özelliğin birleştirilmesiyle tanıma sistemlerinin güvenilirliğini ve doğruluğunu artırmayı amaçlamaktadır. Çoklu biyometrik sistemlerde birleştirilen biyometrik özellikler fiziksel ya da davranışsal biyometri özellikleri olabilmektedir. Bu sistemlerin geliştirilmesi, tek bir biyometrik özelliğin sınırlamalarını aşmayı ve daha kapsamlı bir tanıma süreci sağlamayı amaçlamaktadır. Bu bağlamda sunulan bu tez, çoklu biyometrik modeller üzerinde bir araştırma yapılması ve çoklu biyometrik sistemlerin geliştirilmesini amaçlamaktadır. Çalışma kapsamında gerçekleştirilen uygulama, havada imza ve yüz biyometrilerinin birleştirilmesini hedeflemektedir. Bu çoklu biyometri yaklaşımı, derin öğrenme modelleri arasında yer alan Evrişimsel Sinir Ağları (CNN), Uzun Kısa Süreli Bellek (LSTM), Geçitli Özyinelemeli Birim (GRU) ve Zamansal Evrişimli Ağlar (TCN) algoritmalarının çiftler halinde kullanılmasıyla oluşturulmuştur. Ayrıca, toplanan dinamik ve statik biyometrik verilerin bir arada kullanılmasıyla ortaya çıkarılan mimari güçlendirilmiştir. 25 farklı bireyin 1750 adet yüz, havada imza görüntüsü ve havada imza sinyali verileri üzerinde yapılan bu çalışma, çoklu biyometri sisteminin

potansiyelini ortaya koymaktadır. Oluşturulan derin öğrenme tabanlı modellerle elde edilen %98 'in üzerindeki başarı, çoklu biyometrik sistemlerin güvenilirliği ile gelecek çalışmalardaki potansiyelini göstermektedir.

Anahtar Kelimeler: Çoklu biyometri, havada imza biyometrisi, dinamik biyometrik veri, veri füzyonu.



ABSTRACT

Multi-Biometric System Design Based on In-Air Signature And Face Recognition

Serkan SALTÜRK

Department of Electronics and Communications

Doctor of Philosophy Thesis

Supervisor: Assoc. Prof. Nihan KAHRAMAN

Biometrics is an area of technology concerned with the recognition or authentication of individuals on the basis of their behavioral or physical attributes. In authentication and security applications, biometric techniques such as fingerprint verification, facial recognition, and retina scanning are extensively implemented. Nevertheless, these systems encounter obstacles and constraints when relying on a single biometric characteristic. The implementation of multiple biometrics becomes necessary at this point. In order to enhance the dependability and precision of recognition systems, multi-biometrics endeavors to merge numerous biometric characteristics. When physical or behavioral biometric features are combined in multiple biometric systems, they constitute biometric features. The objective of the development of these systems is to enhance the recognition process by surpassing the constraints imposed by a single biometric characteristic. In this context, this thesis aims to conduct research on multiple biometric models and develop multiple biometric systems. The application implemented within the scope of the study aims to combine in-air signature and facial biometrics. This multiple-biometrics approach was created by utilizing Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM), Gated Recursive Unit (GRU) and Temporal Convolutional Networks (TCN) algorithms, in pairs. Furthermore, the resultant architecture has been fortified through the collection of both dynamic and static biometric data simultaneously. By analyzing 1750 images of faces, in-air signature images, and in-air signature signals data from 25 distinct individuals, this study demonstrates the capabilities of a multi-biometric system. The deep learning-based

model's success rate of more than 98% provides as evidence of the dependability and potential of multiple biometric systems.

Keywords: Multi-biometrics, in-air signature biometrics, dynamic biometric data, data fusion.




1.1 Biyometri ve Temel Kavramlar

Biyometri, bireylerin benzersiz fiziksel veya davranışsal özellikleri üzerinden kimliklerini doğrulama amacıyla kullanılan bir dizi teknolojiyi içeren disiplinler arası bir alanı temsil etmektedir. Parmak izi, yüz tanıma, ses analizi, el geometrisi, retina tarama gibi biyometrik özellikler, günümüzde güvenlik, sağlık, finans gibi alanlarda yaygın olarak kullanılmaktadır. Biyometri, geniş bir kullanım yelpazesine sahip olup birçok sektörde ve alanlarda etkin bir şekilde uygulanmaktadır. Güvenlik ve erişim kontrolünde, parmak izi, yüz tanıma ve retina tarama gibi biyometrik özellikler, hassas bölgelere olan erişimi sınırlamak ve kimlik doğrulama süreçlerini güçlendirmek amacıyla yaygın olarak kullanılmaktadır. Finans sektöründe, bankacılık ve ödeme işlemlerinde müşteri doğrulama süreçlerinde biyometrik teknolojiler, güvenlik standartlarını artırmak ve sahteciliği önlemek için tercih edilmektedir. Sağlık sektöründe, hasta tanımlama ve sağlık kayıtlarının güvenliği için parmak izi veya retina tarama gibi biyometrik yöntemler kullanılmaktadır. Ulaşım sektöründe yolcu tanıma, sınır kontrolü ve havaalanı güvenliği gibi alanlarda da biyometri sistemleri etkin bir rol oynamaktadır.

Bireyin kimliğini belirleme sürecinde kullanılan biyometri, fiziksel ve davranışsal özellikleri kapsar. Fiziksel biyometrik özellikler, parmak izi, retina, yüz, kulak, el ayası, EEG, EKG, DNA gibi vücudun fiziksel yapılarından elde edilen verileri içerirken, davranışsal biyometri özellikleri ses analizi, klavye vuruşları, el yazısı, imza gibi kullanıcının davranışlarına dayanmaktadır (Şekil 1.1).

Bu tez kapsamında ele alınacak biyometrik özellikler fiziksel biyometrik özelliklerden biri olan yüz biyometrisi ve davranışsal biyometrik özelliklerden imza biyometrisidir. Literatürde pek çok çalışmaya konu olan yüz biyometrisi kamera görüntüleri üzerinden elde edilerek çalışılacaktır. İmza biyometrisi için ise literatürde çevrimiçi ve çevrimdışı olmak üzere çeşitli çalışmalar bulunmaktadır. Çalışmada veriler çevrimiçi imza biyometrisiyle havada imza şeklinde kamera yardımıyla alınmış ve değerlendirilmiştir. Biyometrik sistem tasarımında hangi



Şekil 1.1 Fiziksel ve davranışsal biyometrik özellik örnekleri (Görüntü oluşturulurken flaticon web sitesindeki ikonlardan yararlanılmıştır [1])

özelliklerin seçileceği ve hangi biyometrik özelliğin belirli bir uygulama için uygun olup olmadığı, birçok faktöre bağlıdır. Bu faktörlerden evrensellik, biyometrik uygulamaya kaydolmak ya da erişim sağlamak için neredeyse her bireyin ilgili biyometrik özelliğe sahip olması gerekliliğini ifade etmektedir. Tekillik, belirli bir biyometrik özelliğin bireyler arasında yeterince farklı olması gerekliliğini vurgular, aksi takdirde yanlış eşleşme oranı kabul edilemez düzeyde olabilir. Süreklilik ise bireyin biyometrik özelliğinin zaman içinde yeterince sabit olması gerekliliğini ifade eder. Bu faktör için, değişken bir özellik, yüksek yanlış eşleşme oranına neden olacağından, sistem tarafından kullanılan eşleme algoritmasıyla uyumlu olmalıdır. Bu kritik unsurların yanı sıra, biyometrik özelliğin elde edilebilirliğinin ölçüsü olan ölçülebilirlik, özelliği çeşitli algoritmalarla tanımak için gerekli kaynakların performansı, kullanıcıların bu özellikleri verirken ne kadar istekli olabileceğini değerlendiren kabul edilebilirlik ve sahtecilikle kolay ya da zor yanıltılabilme gibi faktörler de bir biyometrik özelliğin seçilip uygulanmasında önemli rol oynar. Bu bağlamda, her bir biyometrik özelliğin kendi avantajları ve sınırlamaları olduğu göz önüne alındığında, hangi biyometrik özelliğin hangi uygulama için uygun olduğunu belirlemek, geniş bir değerlendirme sürecini gerektirir.

1.2 Çoklu Biyometrik Sistemler

Biyometrik özelliklerin bir araya getirilmesi, tek bir biyometrik özelliğin sınırlamalarını aşarak daha güvenilir ve etkili sonuçlar elde etmeyi amaçlamaktadır. Çoklu biyometrik sistemler, birçok farklı biyometrik özelliği birleştirerek kullanmayı hedefler. Bu sistemler, kullanılan farklı biyometrik özelliklerin birbirini tamamlaması ve güvenlik seviyelerini artırmasının yanı sıra, yanlış pozitif ve yanlış negatif sonuçları azaltma potansiyeli taşır. Çoklu biyometri, tek biyometrik özelliğe dayalı sistemlerin karşılaştığı zorlukları aşarak, daha güvenilir ve esnek kimlik doğrulama çözümleri sunmayı amaçlamaktadır. Çoklu biyometri, genel olarak 5 farklı yönden ele alınmaktadır:

1.2.1 Çoklu Sensör Sistemleri

Tek bir biyometrik özelliği görüntülemek veya yakalamak için birden çok sensör kullanılmasıdır. Örnek olarak bir parmak izi tanıma sistemi, bir kişinin parmak izini hem optik bir sensörle görüntüleyerek hem de ultrasonik bir sensörle elde edilen verileri kullanarak değerlendirebilir. Ya da yüz görüntüsünün hem RGB kamerayla hem de kızıl ötesi kamerayla alınması ve farklı sensörlerden gelen verilerin kullanılmasıyla da çoklu sensör sistemleri oluşturulabilir (Şekil 1.2). Birden çok sensör kullanılmasının maliyeti artırması bir dezavantaj olarak görülebilir. Bununla birlikte, belirli bir özellik ile ilişkilendirilmiş çoklu sensör verilerinin dahil edilmesi, genel tanıma sisteminin hassasiyetini artıracaktır.



Şekil 1.2 Aynı biyometrik görüntünün hem monokrom hem de termal kamera gibi farklı iki sensörle alınması

1.2.2 Çoklu Algoritma Sistemleri


Aynı biyometrik verinin farklı algoritmalarla işlendiği ve değerlendirildiği sistemlerdir. Kişiyi ait parmak izi ele alındığında (Şekil 1.3), algoritmaların biri parmak izi minutiae noktalarından, diğeri ise LBP gibi doku tabanlı bir yaklaşımla bazı öznitelikler çıkardığında daha başarılı sonuçlar ortaya çıkabilmektedir. Bu iki algortmadan çıkan sonuçların birleştirilmesi ya da birlikte skorlanması sonucunda daha başarılı sistemler ya da modeller ortaya konulabilmektedir. Tek bir sensörle işlem yapıldığı için maliyeti daha az gibi görünse de bu tip sistemlerin işlem ve zaman maliyeti daha fazla olabilmektedir.



Şekil 1.3 Parmak izi biyometrisinin hem minutiae noktalarının bulunması hem de doku analiziyle modellenmesi

1.2.3 Çoklu Birim Sistemleri


Çoklu birim sistemleri, aynı biyometrik özelliğin aynı kişide farklı konumlarda bulunan bölgelerinden örneklerin alınmasıyla oluşturulur. Bu duruma birden çok parmaktan parmak izi alınması (Şekil 1.4) ya da her iki gözün irisinin görüntüsünün alınması örnek olarak verilebilir. Tek bir sensörden alınan bu tip sistemler farklı koşullardaki değişkenliklere karşı daha dayanıklı bir tanıma sağlamaktadırlar. Toplanan özellikler aynı biyometrik özellik olsa da çok büyük farklılıklar gösterebilmektedir. Bu durum da bir kişiyi tanımak ya da doğrulamak için daha fazla veriyle model oluşturma anlamına geldiği için tekil biyometrilere göre performansı daha yüksek mimariler oluşturulması mümkündür.



Şekil 1.4 Birden çok parmak izi kullanılarak veri alınması

1.2.4 Çoklu Örnek Sistemleri

Bir sensörle aynı biyometrik özelliğin birden fazla örneği alınarak oluşturulan sistemlerdir. Yüz biyometrik verisinin farklı açılardan, farklı aydınlatmalarla alınarak işlenmesi bu sistemlere örnek olarak verilebilir (Şekil 1.5). Bu şekilde daha fazla veri içeren 3B yüz modeli oluşturulabilir. Benzer şekilde aynı kişiden alınan birden çok imza verisi bu çoklu biyometrik model yapısına örnektir. Alınan verilerin işlenmesi özellikle doğrulama sistemlerinde güçlü modeller inşa etmek için kullanılabilir.



Şekil 1.5 Birden çok parmak izi kullanılarak veri alınması

1.2.5 Çoklu Model Sistemleri

Biyometrik kimlik belirlemede birden çok fiziksel ya da davranışsal özelliğin verisini kullanan sistemlerdir. Diğer çoklu biyometrik sistem türleriyle karşılaştırıldığında, bu sistemlerin kullanımı genellikle performansta önemli bir artışa neden olur. Bunun sebebi bir kişinin çeşitli biyometrik özelliklerinin genellikle birbirinden bağımsız kabul edilmesidir. Ancak, belirli biyometrik değişken kombinasyonları önemli bir korelasyon gösterebileceğinden (bu duruma ses ve dudak hareketleri gösterilebilir), böyle kombinasyonlar performansı önemli ölçüde artırmayabilir. Bu sistemler genelde birçok sensöre ve dolayısıyla uygun kullanıcı arayüzlerinin oluşturulmasına ihtiyaç duydukları için uygulama maliyeti daha yüksektir. Daha fazla özellik kullanmak kimlik doğrulama hassasiyetini büyük ölçüde artırırken, uygulama maliyeti, kayıt süresi, veri akışı, öngörülen hata oranı, kullanıcı alışkanlığı gibi pratik faktörler genellikle kullanılabilecek özellik sayısını sınırlar. Bunların yanında zaman zaman güçlü biyometrik özelliklerin çoklu biyometrik sistem kullanıldığında başarımının azaldığı bilinmektedir. Bu tip sistemlerde doğru biyometrik özelliklerden faydalanmak, verileri daha az sensörle ve kolay almak sistemin gerçekleştirilebilirliğini artırmaktadır.

1.3 Tezin Amacı

Günümüzde, kimlik doğrulama ve güvenlik sistemleri bağlamında biyometrik teknolojilerin önemi hızla artmaktadır. Bu bağlamda, özellikle çoklu biyometrik sistemlerin performansını artırmaya yönelik yapılan çalışmalar, biyometri alanında önemli bir araştırma odak noktası haline gelmiştir. **Bu tezin amacı, çoklu biyometrik sistemlerin kullanımıyla biyometrik tanıma ve sınıflandırma başarısını artırmak, özellikle havada imza ve yüz biyometrisinin birleştirilmesi üzerine odaklanarak sadece bir kamera yardımıyla elde edilen bu biyometrik verileri entegre eden modeller ortaya çıkarmak ve başarımını değerlendirmektir.** Bu sistemler, CNN, LSTM, GRU ve TCN gibi derin öğrenme teknikleriyle biyometrik özellikleri birleştirerek çoklu biyometrik model başarımını artırmak üzere geliştirilen yöntemleri değerlendirmeyi amaçlamaktadır. Bu çalışma, söz konusu tekniklerin güvenilirliği ve etkinliği üzerindeki etkilerini ölçerek, çoklu biyometrik sistemlerin performansını artırmaya yönelik önemli bir katkı sunmayı hedeflemektedir.

Biyometrik sistemlerin evrimi, bireylerin kimliklerini doğrulama süreçlerinde önemli bir dönüşüm sağlamıştır. Ancak, tek bir biyometrik özelliğe dayanan sistemlerin sınırlamaları ve güvenlik zorlukları, araştırmacıları çoklu biyometrik sistemlerin potansiyelini keşfetmeye yönlendirmiştir. Bu bağlamda, özellikle havada imza ve yüz biyometrisinin entegrasyonu, bireylerin kimlik doğrulama

süreçlerinde daha güvenilir ve etkili sonuçlar elde etmeyi amaçlamaktadır. Bu tez, çoklu biyometri yaklaşımının iyileştirilmesine yönelik yapılan çalışmaları öne çıkararak, havada imza ve yüz biyometrisinin birleştirilmesinin getirdiği avantajları ve potansiyel zorlukları ele almaktadır. Tezin bu amacı doğrultusunda, sadece bir kamera yardımıyla alınan bu biyometrik verilerin entegrasyonu vurgulanmış, CNN, LSTM, GRU ve TCN gibi derin öğrenme teknikleriyle biyometrik özellikler birleştirilmiştir. Uygulanan yöntemlerin sonuçları çoklu biyometrik sistemlerin performansı açısından değerlendirilmiştir ve çoklu biyometri konusunda gelecekteki çalışmalara ışık tutması hedeflenmektedir.

1.4 Hipotez

Havada imza ve yüz biyometrisinin birleştirilmesi çoklu biyometrik sistemlerin iyileştirilmesine yönelik performansın artırılmasına dönük bir yaklaşımdır. Sadece bir kameradan yararlanılarak el ve yüz anahtar noktalarını çıkaran MPH kütüphanesi yardımıyla bu biyometrik veriler elde edilebilmektedir. Bu tez çalışmasıyla uygulanan mimariyle elde edilen biyometrik özellikler, derin öğrenme teknikleriyle entegre edilerek çoklu biyometrik sistemlerin güvenilirliğini ve etkinliğini artırabilir. Bu araştırmanın hipotezi, CNN, LSTM, GRU ve TCN gibi derin öğrenme teknikleriyle havada imza ve yüz biyometrilerinin hem statik hem dinamik verilere dayalı birleştirilmesinin, çoklu biyometrik sistemlerin performansını iyileştireceğidir.

2 LİTERATÜR TARAMASI

2.1 Biyometrinin Gelişimi, İmza ve Yüz Biyometrisi

Bireyleri, benzersiz bir şekilde tanımlama ve kişisel özellikleri bir bireyle ilişkilendirme yeteneği, insan toplumunun sosyal dokusu açısından çok önemlidir [2]. Kişi tanımlama ya da doğrulama için bireyin fiziksel özelliklerinin kullanılması 19. Yüzyılın ortalarına uzanmakta ve literatürde 1896 yılında karşımıza çıkmaktadır. Her ne kadar otomatize bir sistem olmasa da Bertillon vd. [3], kişinin farklı vücut bölgelerinin ve dövme, yara gibi farklılaşan bölümlerin metrik ölçülerini alarak biyometrik doğrulamanın öncüsü olmuştur. Bu yıllar aynı zamanda parmak izi biyometrisinin ortaya çıktığı zamanlardır [4–6]. Biyometrik sistemlerde otomatize ilk doğrulama sistemi parmak izi biyometrisi ile Trauring tarafından 1963 yılında yapılmıştır [7]. Yüz biyometrisi ise aynı dönemde yüz üzerindeki parçalar arasındaki mesafeler elle hesaplanarak yüz tanıma sisteminde kullanılmıştır. Bu yıllarda iris, yürüyüş yapısı, ses, imza, el geometrisi gibi farklı biyometrik özelliklerin kullanıldığı pek çok çalışma literatürde yerini almıştır [8–14]. Biyometri disiplini kendine yer edinen önemli davranışsal biyometrik özelliklerden biri olan imza biyometrisi, verinin alınış biçimine bağlı olarak çevrimiçi ve çevrimdışı olarak sınıflandırılmaktadır. Çevrimdışı imzalar kâğıt üzerinde el yazısıyla, çevrimiçi imzalar ise çeşitli sensörler, kameralar yardımıyla alınmaktadır. Çevrimdışı imzaların değerlendirmesine giden yolda el ve parmak şekillerinin ve hareketlerinin tanınması da önemli rol oynamıştır. Keskin vd. [15], görüntü tabanlı el pozisyonu tahmini ve el şekli sınıflandırmasını gerçekleştirmek için derinlik sensörleri kullanarak Rasgele Karar Ağaçları (Randomized Decision Forest-RDF) tabanlı sınıflandırıcı tanıtmaktadırlar. Bu sınıflandırıcı, giriş derinlik piksellerini el şekli sınıflarına atamakta ve bunları o el şekli için özel olarak eğitilmiş el pozisyonu tahmincilerine yönlendirmektedir. El eklem noktalarından yararlanarak el hareketlerinin tanınması konusunda çalışan Ma vd. [16] uygulamalarında Kalman Filtresiyle (KF) birlikte LSTM modelinden yararlanmışlardır. Çevrimdışı imza konusunda Arazi [17],

el yazısı örneklerinin harflerin değerlendirmesi, metrik ölçümler gibi dışsal özelliklerini otomatik olarak çıkarmaya odaklanmıştır. Bu çalışma, imzanın belirli bölümlerinden çıkarılan özelliklerin tanıma amaçlı kullanılması üzerine deneysel sonuçlar sunmaktadır. Zimmermann ve Varady [18], imza alınması sırasında ölçülen basınç desenlerinin imza tanıma için kullanılabileceğini ortaya koymaktadır. Spektral analizle imza tanıma üzerine odaklanan Lam ve Kamins [19], imzaların frekans alanına dönüştürülmesini önermekte ve Gauss olasılık modeli kullanarak başarılı bir tanıma yöntemi sunmaktadır. Bunu gerçekleştirirken şekil, hareket, basınç gibi özellikler bu çalışmada incelenmiştir. Burnett ve ekibi [20], hukuki anlaşmazlıklarda, sözleşme imzalayan kişinin biyometrik doğrulamasının kullanıldığı imza tabanlı bir kimlik doğrulama tasarımı üzerinde çalışmışlardır. Fuzzy ve eliptik eğri nokta gömme tekniği (ECPE) kullanılarak imza biyometrik verisinden genel ve özel anahtarlar üretilmektedir. Eşleme tabanlı bir şema, bu anahtarlarla imzalama ve doğrulama işlemlerini gerçekleştirmektedir. Çalışma, ayrıca, olası bir sahteciliği ele alarak biyometrik imza şemasının çalışmada oluşturulan Java kimlik tabanlı şifreleme uygulamasındaki mevcut bileşenlerle nasıl geliştirilebileceğini açıklamaktadır. Hameed vd. [21], çevrimdışı imza doğrulama sistemleriyle ilgili 2021 yılında bir inceleme çalışmasıyla bu sistemler üzerinde uygulanan makine öğrenmesi tekniklerini irdelemişlerdir. Khan vd. 2023 yılında yayınlanan makalelerinde el yazılarının sınıflandırılması Gauss GRU (2GRUNN) adını verdikleri yenilikçi yöntemle yapılmıştır [22]. Farklı bir bakış açısı ile ıslak imzalara yapılacak saldırılar üzerinde çalışan Gonzales-Garcia vd. [23], literatürde önemli yer edinmiş veri setleri üzerinde ataklar gerçekleştirmiş ve bu atakların sonuçlarını değerlendirmiştir. İmza konusunda hem çevrim dışı hem de çevrim içi imza biyometrikleri üzerinde çalışmalar yapan Impedovo ve Pirlo [24–26], imza üzerinde farklı uzaylarda çalışmalarının dışında çeşitli inceleme makaleleri ortaya koymuşlardır. Sharma ve Sundaram [27], Dinamik Zaman Bükme (Dynamic Time Warping-DTW) temelli bir çevrimiçi imza doğrulama sistemini sunmaktadır. Bu çalışmada, Vektör Kuantizasyonu (Vector Quantization-VQ) yönteminin kullanımıyla giriş vektörleri etkili bir şekilde kullanılarak DTW metodunun kullanacağı örneklerin karakteristiklerini daha güçlü ortaya çıkarmaktadır. Aynı araştırmacılar, 2017 tarihli diğer bir çalışmada ise geleneksel DTW eşleştirme şemasını genişleterek yeni bir çevrimiçi imza doğrulama sistemi önermektedirler. Bu sistem, Gauss Karışım Modeli (Gaussian Mixture Model-GMM) özelliklerini kullanarak imza özniteliklerini olasılıksal bir çerçevede hizalamayı öne sürmektedir [28]. Bhattacharya ve diğerleri tarafından sunulan çalışma [29], biyometrik kimlik doğrulama sürecinde imza doğrulamasını ele almaktadır. Piksel Eşleme Tekniği (Pixel Matching Technique-PMT) yöntemi kullanılarak kullanıcının imzası veri

tabanında saklanan örnek imza ile karşılaştırılmaktadır. Önerilen yöntemin performansı, Yapay Sinir Ağları (Artificial Neural Networks-ANN) geri yayılım yöntemi ve SVM tekniği ile karşılaştırılmıştır. Tang, Kang, ve Fang [30], çevrimiçi imza doğrulama sistemlerinde performans düşüşünün önüne geçmek amacıyla bilgi ayrışması kavramını tanıtmaktadır. Bu çalışma, imza verilerindeki karmaşıklığı azaltmak ve performansı artırmak için bilgi ayrışması çerçevesini kullanarak yeni bir DTW algoritması önerir. Sonuçlar, farklı veri setlerine uygulanmış başarılı sonuçlar alınmıştır. Okawa'nın 2020 tarihli çalışması [31], çevrimiçi imza doğrulamada işlev temelli bir yaklaşım için yeni bir strateji önermektedir. Ortalama şablon kümesi ve ağırlıklı çoklu DTW mesafelerini kullanarak, yeni bir yöntem sunmuş ve bu yöntemle çevrimiçi imza doğrulama performansını artırmayı hedeflemiştir. Muramatsu ve Matsumoto, çevrimiçi imza doğrulamada, imza alınması sırasında kalemin yaptığı basınç, tepe yüksekliği ve yüzeyle yaptığı azimut açısı özelliklerini kullanarak skorelama bazlı bir model üretmiştir [32]. İmza alınması sırasında kalemle ilgili özelliklerle ilgilenen bir başka çalışmada Mailah ve Lim [33], ANN kullanarak kalemin basınç, hız ve zaman bilgilerini değerlendirmiştir. Sadak, Kahraman ve Uludağ 2020 yılında yaptıkları araştırmada [34], imza atılması sırasında ortaya çıkan seslerden DTW algoritması kullanarak doğrulama modeli oluşturmuşlardır. Mevcut çalışmada kullanılan biyometrik verilerden biri olan havada imza biyometrisi konusunda, Jeon, Oh ve Toh'un çalışması [35], herhangi bir taşınabilir cihaz olmaksızın el hareketleri tabanlı imza tanıma sistemini önermektedir. Derinlik görüntü sensörü kullanılarak parmak ucu ve avuç içi kütlelerinin belirlenmesi, konum bilgisi yanında hız ve ivme bilgilerinin de kullanıldığı bir sistem ortaya koymaktadır. Takeuchi, Manabe ve Sugawara çalışmalarında [36], havada imzayı yumuşak bir biyometri olarak değerlendirmekte ve yumuşak biyometrik özelliklerin kişi doğrulama görevleri için daha uygun ve rahat alternatifler olarak ortaya çıkmasını ele almaktadır. Bunun yanında, yumuşak biyometrinin kişi doğrulama için ana özellik olamamasından dolayı el şeklini bu özelliklere entegre eden bir kişi doğrulama yöntemi önermektedir. Mobil cihazların ivmeölçerini kullanarak 3D uzayda kullanıcının imzasını çizme işlemi ile ilgili olarak sinyallerin analiz edilmesini içeren bir yöntem sunan Diep, Pham ve Phuong'un [37] çalışması, başarılı girişleri tanımlamak için Destek Vektör Makineleri (Support Vector Machine-SVM) sınıflandırıcılarını eğitmektedir. Sajid ve Cheung [38], giyilebilir kameraların popülerliğini ve bu teknolojinin insan-bilgisayar arayüzü olarak kullanımını ele almaktadır. VSig adlı bir giyilebilir kamera tabanlı sistem, imza tanıma ve doğrulama için önerilmektedir. Fang ve Tang [39], havada imza doğrulaması için benzersiz imza izdüşümleri oluşturmak adına parmak ucu takibini kullanmaktadır. Hızlı Fourier Dönüşümü (Fast Fourier Transform-FFT), DTW ve Gauss dağılımı tabanlı birleştirme algoritmaları ile

temassız ve fiziksel olarak yer deęiřtirmeden doęrulamayı saęlayan bir sistem oluřturmuřlardır. Malik vd. [40], 3B (3boyutlu) derinlik özellięini kullanarak havada imza biyometrisinin potansiyelini daha iyi keřfetmeyi amaçlamaktadır. Tek bir derinlik görüntüsü kullanarak el eklemlerinin 3D konumlarını tahmin eden gerçek zamanlı bir havada imza edinme yöntemi sunmaktadır. 3DAirSig adlı bu yöntem, DTW algoritmasının özelleřmiř bir biçimini kullanarak bařarılı sonuçlar elde etmiřtir. Malik vd. bir dięer çalıřması [41], derin öğrenme tabanlı bir havada imza doęrulama yöntemi önermektedir. Derin öğrenme kullanılarak elde edilen bařarı, geleneksel DTW yöntemini önemli ölçüde ařmaktadır. Khoh, Pang ve Teoh [42], Motion History Image (MHI) yöntemini kullanırken Guerra-Segura, Ortega-Pérez ve Travieso [43], Leap Motion denetleyicisinden yararlanarak havada imza doęrulama sisteminin gücünü donanımla artırmaktadır. Bailador vd. [44], mobil teknolojideki ilerlemelerin bir sonucu olarak ortaya çıkan yeni hizmetlerin tanımlanmasını ele almaktadır. Bu çalıřmada, Gizli Markov Modelleri (Hidden Markov Modelleri-HMM), Bayes sınıflandırıcıları ve DTW gibi farklı desen tanıma tekniklerinin havada imza tanıma sorununu ele almak için performansını analiz etmektedir. Derin evriřimsel sinir aęlarının havada imza tanıma için kullanılabilirlięinin incelendięi çalıřmalarında Behera, Dash ve Dogra [45], yine Leap Motion sensörü kullanarak yakalanan 3B havada imzaları temsil etmek için yeni geometrik özellikler önermektedirler. Bu özellikler, CNN mimarisine uygulanmak üzere düzenlenmiřtir ve çalıřma sonunda ortaya çıkan deneysel sonuçlar, önerilen biyometrik sistemin mevcut geometrik özelliklere kıyasla daha iyi performans gösterdięini kanıtlamaktadır. 3B sensörlerin kullanıldıęı bir dięer çalıřmada Chiu vd. [46], topladıkları havada imza verilerini DTW yöntemiyle karřılařtırmıř ve bu alana katkı saęlayacak, bařarılı sonuçlar elde etmiřlerdir. Tez çalıřmamıza konu olan bir dięer özellik olan yüz biyometrisi, otomatize olarak uygulanan en eski biyometrik özelliklerden biridir. Yüzlerin ayırt edilmesi ya da bulunması konularında Bayes Sınıflandırıcıları, Temel Bileřenler Analizi (Principal Component Analyse-PCA), SVM, HMM, LBP gibi birçok makine öğrenmesi temelli tanıma ve sınıflandırma çalıřmaları yapılmıřtır [47–52]. Doęrulama ve tanıma dıřında yüz ifadeleri, yařlanma gibi farklı özellikleri inceleyen çalıřmalar da bulunmaktadır [53–58]. Son yıllarda geliřen ve popülerleřen derin öğrenme algoritmalarıyla yüz doęrulama ve tanıma konularında da pek çok çalıřma yapılmıřtır. Parkhi, Vedaldi ve Zisserman [59], büyük ölçekli yüz veri setleri ve end-to-end öğrenme kullanarak derin öğrenmeyi yüz tanıma görevinde etkili bir şekilde kullanmıřlardır. Çalıřma, büyük veri seti oluřturmanın karmařıklıklarını ve bu veri setini kullanarak standart yüz benchmarklarında nasıl bařarılı sonuçlar elde edilebileceęini tartıřmaktadır. Wen ve dięerlerinin [60], yüz tanıma görevi için yeni bir denetim sinyali olan "center loss"u önermektedir. Bu sinyalin, her yüz

sınıfı için derin öğrenmeden gelen özelliklerin merkezini öğrenmesi ve bu özellikler ile bunların karşılık gelen sınıf merkezleri arasındaki mesafeyi ölçerek mesafenin artmasını sınıftan uzaklaşma olarak kabul eden bir yaklaşım geliştirmişlerdir. Yüz tanıma için iki farklı mimari içeren "DeepID3" adlı derin sinir ağı modelleri öneren 2015 tarihli çalışmalarında Sun vd. [61], bu mimarileri, VGG net ve GoogLeNet'te önerilen katmanlar üzerinden yeniden oluşturarak yüz tanıma için uyarlamışlardır. Çalışma, bu mimarilerin bir araya getirilmesiyle elde edilen sonuçların farklı veri setlerinde, yüz kimlik doğrulama başarısı üzerindeki etkilerini değerlendirmektedir. Sun ve diğerlerinin diğer bir çalışmasında [62], CNN kullanılarak yüz tanıma ve doğrulama işlemlerini aynı araştırma içinde değerlendirmiş ve yüz tanımada bilinen önemli veri setleri üzerinde yaptıkları testlerde çok başarılı sonuçlar almışlardır. Schroff, Kalenichenko ve Philbin [63], 2015'te yaptıkları çalışmada FaceNet adlı bir sistem sunmaktadır. Bu sistem, yüz görüntülerini kompakt bir Öklid uzaya doğrudan eşleştiren bir haritalama öğrenmektedir. Bu uzay oluşturulduktan sonra, yüz tanıma, doğrulama ve kümeleme gibi görevler, FaceNet vektörlerini, özellik vektörleri olarak kullanarak kolayca uygulanabilir. Çalışma, derin öğrenme yaklaşımının, temsil etme verimliliğini artırdığını göstermektedir ve bu alanda en çok atıf alan yayınlardan biridir. FaceNet benzeri bir yaklaşımı benimseyen Taigman vd. [64], 3D yüz modellemesini ve derin sinir ağı tabanlı yüz temsili kullanmaktadır. Büyük bir yüz veri seti üzerinde eğitilen bu sistem, literatürde bilinen veri setlerine uygulanmış ve yüksek doğruluk oranına ulaşarak mevcut en iyi sonuçları aşmayı başarmıştır. Cao vd. [65], VGGFace2 adlı büyük bir yüz veri setini tanıtmaktadır. Bu veri seti, geniş bir poz, yaşı, aydınlatmayı, etnik grubu ve mesleği kapsayan 9131 katılımcının 3.3 milyon görüntüsünü içermektedir. Çalışma, bu veri setinin yüz tanıma performansını iyileştirdiğini ve IJB-A ve IJB-B gibi alanda sıkça kullanılan yüz tanıma veri setlerinde mevcut en iyi sonuçları aştığını göstermektedir. Yine Sohn'un 2016 yılında gerçekleştirdiği çalışması [66], derin metrik öğrenmenin çeşitli görsel tanıma görevlerinde etkili olduğunu göstermektedir.

2.2 Çoklu Biyometri Sistemleri ve İmza Biyometrisi Uygulamaları

Biyometrik sistemlerin ayrıştırıcı özelliklerine bağlı olarak güvenilirliği yüksek gibi görünse de pek çok problemde daha güvenli sistemler ortaya koymak, tanıma ya da doğrulama başarısını artırmak için birden çok biyometrik özelliğe başvurulmuştur. Literatürde, fiziksel, davranışsal ya da yumuşak biyometrik özelliklerin pek çoğu bir arada kullanılarak farklı disiplinlere yönelik çalışmalar yapılmıştır. Ross ve Govindarajan'ın çalışmaları [67], çoklu biyometrik sistemlerin yüz ve parmak

izi gibi birden çok biyometrik kaynaktan gelen özellikleri kullanarak bireyin kimliğini belirleme veya doğrulama amacıyla kullanıldığını belirtmektedir. Birden çok kaynaktan gelen bilgiler, özellik çıkarma seviyesi, eşleşme skoru seviyesi ve karar seviyesi gibi çeşitli seviyelerde birleştirilebilir. Eşleşme puanı ve karar seviyelerindeki birleşme literatürde yaygın olarak incelenmiş olsa da öznitelik seviyesinde birleşme sorunu literatürde bu dönemde nispeten az çalışılmış bir konudur. Araştırmalarında, öznitelik seviyesinde üç farklı senaryoda birleşme üzerine çalışılmıştır: (i) yüzün PCA ve LDA katsayılarının birleşimi; (ii) bir yüz resminin R, G, B kanallarına karşılık gelen LDA katsayılarının birleşimi; (iii) yüz ve el biyometrik özelliklerinin birleşimi. Çalışmanın sonucunda çoklu biyometri konusunda literatüre katkı adına önemli sonuçlara ulaşılmıştır. 2008 yılında Monwar ve Gavrilova yaptıkları çalışmayla [68], çoklu bir biyometrik sistem tanıtmışlardır. Bu sistem, yüz, kulak ve imza biyometrilerini kullanarak kimlik tespiti için PCA ve FDA (Fisher Discriminant Analyse) yöntemleri üzerine kuruludur. FES diye adlandırdıkları bu model, tek modelli eşleştircilerden elde edilen sonuçları iyileştirmek için lojistik regresyon yöntemi kullanmaktadır. Yine aynı araştırmacılar tarafından 2009 yılında yaptığı çalışma [69], çoklu biyometrik özelliklerden elde edilen bilgilerin birleştirilmesinin daha yüksek tanıma oranlarına yol açabileceğini göstermektedir. Deneysel sonuçlar, çoklu biyometrik özelliklerden elde edilen bilgilerin birleştirilmesinin, özellikle ulusal güvenlik veya diğer istihbarat departmanlarına katkı sağlayabileceğini göstermektedir. Sonuçlar, çoklu biyometrik özelliklerin kullanılmasının, biyometrik sistemin genel performansını artırdığını göstermektedir. Nagar, Nandakumar ve Jain [70], her bir kullanıcının birden çok şablonunu tek bir güvenli eskiz olarak korumak için özellik seviyesinde birleştirme çerçevesi önermektedirler. Çalışma, özellik seviyesinde fuzzy yöntemlerle birleştirme ve bu modeli farklı veri tabanlarına uygulama şeklinde gerçekleştirilmiştir. Jing vd. çalışmalarında [71], kişinin genel biyometrik verisini bir sınıf olarak ele alıp, farklı biyometrik verilerin farklı Gauss dağılımları oluşturabileceği ayrımcı bir perspektifi benimseyerek, Alt Sınıf Ayrım Analizi (Subclass Discriminant Analysis-SDA) temelli yeni bir çoklu model özellik çıkarma ve tanıma yöntemi sunmuştur. Bu yöntemde, bir kişinin farklı biyometrik verileri aynı sınıfa ait farklı alt sınıflar olarak kabul edilir ve alt sınıflar arasındaki farkı maksimize ederek tanıma performansını artırmayı amaçlar. Çalışmada, PCA ile boyut azaltma ve Genelleştirilmiş Tekil Değer Dekompozisyonu (Generalized Singular Value Decomposition-GSVD) tekniği kullanılmıştır. Ayrıca, Çekirdek SDA tabanlı KPCA-SDA ve KSDA-GSVD yöntemleri, lineer olmayan çoklu model özellik çıkarma için sunulmuştur. Çoklu model biyometrik sistemler için sosyal ağ analizi kullanarak karar birleştirme üzerinde yapılan çalışmada, Paul, Gavrilova ve Alhajj yine FDA algoritmasını kullanmıştır [72]. Sosyal ağlar, sınıflar

arasındaki benzerlik ve korelasyona dayalı olarak oluşturulmuş, tekil biyometrikler (yüz, kulak, imza) eşleme puanı metodolojisi kullanılarak birleştirilmiştir. Talreja, Valenti ve Nasrabadi tarafından 2017’de sunulan bir başka çalışmada [73], derin sinir ağları ve hata düzeltme kodlamasını kullanan güvenli bir çoklu biyometrik sistem önerilmiştir. Bu çalışmada, iki füzyon mimarisi, tam bağlantılı mimari ve çapraz mimari, güçlü bir çoklu biyometrik ortak temsil oluşturmak için geliştirilmiştir. Parmak izleri, el sırtı damarı ve el geometrisinin birleştirildiği Gupta ve Gupta’nın 2018 tarihli çalışmasında [74], aynı anda elde edilen parmak izi, el sırtı damarı ve el geometrisini birleştiren çoklu biyometrik bir füzyon temel alınarak çoklu biyometrik bir sistem önerilmiştir. İnceleme çalışması niteliğindeki Bahmed ve Ould Mammar’ın çalışmasında [75], el biyometrik sistemlerinin ve el tabanlı çoklu biyometrik sistemlerin literatürdeki gelişimi incelenmiştir. Bu çalışma, elin sunduğu çeşitli biyometrik belirteçler ve çoklu biyometrik el sistemlerinin tanıma doğruluğunu artırmak için kullanılan kavramlar ve teknikler hakkında bilgi sunmaktadır. Talreja, Valenti ve Nasrabadi bir diğer çalışmalarında [76], yüz ve iris biyometrilerinden güvenli bir çoklu şablon oluşturmak için bir derin öğrenme çerçevesi sunmuşlardır. Bu çerçeve, çoklu biyometrik sistemlerin güvenliğini artırmak ve özel verilerin gizliliğini korumak için tasarlanmıştır. Sabareeswari vd. [77], yüz, kulak ve imza gibi farklı biyometrik özellikler için kimlik doğrulama süreçlerini birleştirerek, biyometrik tanıma performansını artırmayı amaçlamışlardır. Aftab vd. [78], el tabanlı çoklu biyometrik sistemlerin durumu ve gelecekteki zorlukları incelenmişlerdir. Bu çalışmada, bireylerin tanımlanmasında kullanılan el tabanlı çoklu biyometrik sistemlerin mevcut durumu, çeşitli öznitelik çıkarma şemaları ve performans değerlendirmeleri ele alınmıştır. Byahatti vd., 2021 tarihli çalışmalarında [79], derin öğrenme modeli ve transfer öğrenme tekniklerini kullanarak gerçek zamanlı bir çoklu biyometrik sistem önermişlerdir. Bu sistem, kişinin sağ ve sol iris resimlerinden oluşan derin öğrenme modeli temel alınarak geliştirilmiştir ve sistemle iki kamu veri seti üzerinde yüksek doğruluk oranları elde edilmiştir. Parmak izi, parmak damarı ve parmak boğumu baskısının birleştirilmesine dayalı çoklu biyometrik bir sistemin sunulduğu Khodadoust, Medina-Pérez ve arkadaşlarının 2021 tarihli çalışmasında [80], tüketici cihazlarının kilidini açmaktan gözetim ve adli analizlere kadar geniş bir uygulama yelpazesi değerlendirilmektedir. Jay ve Vijayakumar [81], biyometrik kimlik doğrulama teknolojisinin, dünya genelindeki bilgi güvenliği ve güvenlik yasalarındaki artan ihtiyaç nedeniyle günlük yaşamımızda geniş bir şekilde kullanıldığını belirtir. Bu çalışma, çoklu özelliklerin (iris, yüz, parmak damarı ve avuç içi izi) kullanılmasıyla doğru bir şekilde kişiyi tanımlamak için tasarlanmış bir çoklu biyometrik tanıma sistemini ele almaktadır. Birden çok özelliğin kullanılması, biyometrik sistemin doğruluğunu artırır. Birçok ülkede güvenlik ve sağlık sistemlerinde, avuç içi izleri,

kişinin en doğru tanımlamasını hızlı bir şekilde sağlamak için kullanılmaktadır. Cervino [82], yüz videosu ve kalp atış hızı tahmini temel alınarak geliştirilen çoklu biyometrik bir sistem sunmuştur. Bu sistem, yüz tanıma ve kalp atış hızı verilerinin birleştirilmesiyle oluşturulmuş ve böylece doğrulama ve tanıma görevlerinde performans artışı sağlanmıştır. Uzaktan eğitim sürecinde öğrencilerin ses ve görsel biyometrik belirteçleri kullanılarak çoklu biyometrik tanımlama sisteminin önemi vurgulanan çalışmalarında Kovaliuk, Shevchenko ve Kobets [83], ses özelliklerinin analizi ve yüz tanıma yöntemlerini içermektedir. Bu çalışma, eğitim sürecinde katılımın kaydedilmesi ve uzaktan eğitim sınıflarında öğrencilerin tanınması için geliştirilmiştir. Sadak, Kahraman ve Uludağ 2022 yılında yaptıkları çalışmada [84], daha önce imza seslerinin toplandığı çalışmalarına imzanın statik özelliklerini de eklemişlerdir. Öznitelik çıkarma işleminin LBP ve SIFT (Scale Invariant Feature Transform) algoritmalarıyla, sınıflandırmanın ise OC-SVM ile yapıldığı çalışma ile statik ve dinamik verilerin bir arada kullanılmasının performansı artırdığı ortaya çıkarılmıştır. Yine 2022 yılında Wang, Shi ve Zhou ise CNN tabanlı el ayası ve yüz biyometrilerinin füzyon edildiği bir çalışmaya imza atmışlardır [85]. Bu çalışmada farklı CNN mimarileri üzerinde performans değerlendirmeleri yapılmıştır. Bu çalışmaya konu olan çevrimiçi imza ve yüz görüntülerinin birleştirildiği benzer bir çalışmada Singhal ve Shinghal [86], çevrimiçi olarak aldıkları imza sinyali ve yüz görüntüsü üzerinde füzyon safhasında modified context aware ve Tangential discrimination analysis (TDA) algoritmaları kullanılmıştır. Ortaya çıkan özellik vektörleri de modified mixed sequence deep neural network (MMS-DNN) derin öğrenme yöntemiyle eğitilmiştir. Makalede verilen performans verileri bu alanda önemli bir gelişme olarak karşımıza çıkmaktadır.

3

TEORİK TEMELLER

3.1 Önerilen Çalışmadaki Biyometrik Özellikler

Bu tez çalışması kapsamında oluşturulan biyometrik sistemin modellenmesi için havada imza ve yüz biyometrilerinden yararlanılmıştır. Yüz biyometrisi, otomatize olarak kullanılan ilk biyometrik verilerden biridir. Kullanımı oldukça yaygındır ve birçok alandaki biyometrik sistemlerde yüz tanıma ve doğrulamadan yararlanılmaktadır. Havada imza biyometrisi ise davranışsal bir biyometrik özellik olan imza biyometrisini temel alan, özellikle pandemi döneminden sonra kullanımı artan, ekran karşısında çevrimiçi olarak toplanabildiği için uzaktan da kolayca doğrulanabilen bir biyometridir.

3.1.1 İmza Biyometrisi

İmza biyometrisi, bireylerin fiziksel imzalarından tanınmasını sağlayan bir biyometrik kimlik doğrulama yöntemidir. Geleneksel imza, kâğıt ya da ekran üzerine yapılan elle yazılmış işarettir. Bunun yanında, imza biyometrisi, bu fiziksel işareti dijitalleştirerek veri haline getirir. Davranışsal bir biyometrik özellik olan imza biyometrisi, günlük yaşamdaki resmi evrak işlemlerinde önemli bir yer edinmiştir. Kişinin benzersiz imza karakteristiklerini değerlendirerek, imza biyometrisi, belge onay süreçlerinde ve noterlik işlemlerinde güvenli kimlik doğrulama sağlar. Bankacılık sektöründe, özellikle çek işlemlerinde ve sözleşmelerin onaylanmasında, imza biyometrisi kullanılarak güvenliğin ve kimlik doğrulamanın ön planda tutulduğu birçok uygulama mevcuttur. Bu şekilde, imza biyometrisi, resmî belgelerin ve işlemlerin güvenliğini artırarak, kullanıcıların kimliklerini güvenilir bir şekilde doğrulamak ve yetkilendirmek adına etkin bir çözüm sunar. Biyometrinin bu çeşitli uygulama alanları, güvenlik, kullanılabilirlik ve veri güvenliği açısından önemli avantajlar sunarak teknolojinin yaygın kabulünü artırmıştır. İmza biyometrisi genellikle bireyin imza alışkanlıklarını ve özelliklerini analiz ederek çalışır. Bu analiz yapılırken imza biyometrisinin verileri statik ve dinamik olarak değerlendirilir. Statik özellikler

imzanın kâğıt üzerindeki durağan görüntüsünden faydalanarak bulunabilir. Dinamik özellikler arasında imzanın atımı sırasındaki hızı, imza kaleminin basınç noktaları, yine kalemın eğimi, imza atımı sırasında çıkan sesler, imza hareketleri arasındaki zamansal değişimler gibi bulunmaktadır. İmza biyometrisi sistemleri oluşturulurken, bu özellikler öğrenilerek ve kaydedilerek gelecekte gerçekleştirilen imzalar tanınabilmekte ve doğrulama işlemlerinde imza biyometrisi kullanabilmektedir. İmza biyometrik verilerinin analizinde, statik imzaların doğrulaması imzanın belirleyici özniteliklerinin çıkarılması ve görüntü analizi ile yapılabilmektedir. Dinamik imzaların analizinde ise zaman serisi eşleme yöntemleri, basınç verisi analizleri, ses analizleri gibi teknikler uygulanabilmektedir. Fiziksel imza doğrulaması, çevrimiçi ve çevrimdışı ortamlarda farklı şekillerde gerçekleştirilebilir. Çevrimiçi imza biyometrisi, imzanın dijital bir tablet veya başka bir elektronik cihaz üzerinde anlık olarak alınmasıdır. Bu yöntem, imzanın dinamik özelliklerini daha ayrıntılı bir şekilde değerlendirme olanağı sağlar. Çevrimdışı imza biyometrisi ise fiziksel imzanın daha sonradan dijital bir ortamda analiz edilmesidir. Bu durumda, statik özelliklere odaklanma eğilimindedir ve imzanın dijital bir temsili üzerinden yapılan değerlendirmelerle çalışır. İmza biyometrisi, özellikle finansal işlemler, belge onayları ve diğer güvenlik odaklı uygulamalarda günlük hayatın neredeyse her alanında kullanılmaktadır. İmza biyometrisinin kullanıldığı uygulamalar kullanıcıların kimliklerini daha güvenli bir şekilde doğrulamalarına yardımcı olmaktadır.

3.1.2 Havada İmza Biyometrisi

Havada imza biyometrisi, bir kişinin havada belirli bir hareketle yapmış olduğu imza benzeri bir şeklin kullanılmasıyla ortaya çıkan biyometrik özelliktir. Bu biyometrik özelliği kullanan sistemler genellikle özel sensörler ve algoritmalar aracılığıyla kullanıcının el veya parmak hareketlerini izlemektedir. İnsanların imza benzeri bir hareketi gerçekleştirmesi, özgün bir biyometrik özellik oluşturabilmekte ve bu özelliklerden kimlik doğrulama işlemlerinde yararlanılabilmektedir. Havada imza biyometrisi, bir kişinin belirli bir biyometrik şablonu oluşturması için bir dizi ölçümü içermektedir. Bu ölçümler, elin hızı, hareket yolu, basınç noktaları ve parmakların eğimleri gibi faktörleri kapsar. Bu veriler daha sonra bir dizi algoritmalarla işlenebilir ve kişinin benzersiz biyometrik özelliklerini temsil eden bir şablon oluşturulur. Havada imza biyometrisinin avantajları arasında kullanım kolaylığı ve daha az fiziksel temasın gerekliliği gibi biyometrik özelliğin alınmasını kolaylaştırıcı etmenler sayılabilmektedir. Bu tür sistemler genellikle hareketi izlemek ve değerlendirmek için kameraları ya da 3 boyutlu sensörleri kullanır.


Özellikle mobil cihazlarda ve çevrimiçi platformlarda hızlı kimlik doğrulama çözümleri potansiyelleri yüksektir.

3.1.3 Yüz Biyometrisi

Bireylerin yüz özelliklerini kullanarak kimlik doğrulama süreçlerini gerçekleştiren biyometrik verilerdir. Bu biyometrik verilerin kullanıldığı sistemler, bir kişinin yüzünü tanıma, ölçme ve analiz etme yeteneği üzerine odaklanmaktadır. Yüz biyometrisi, biyometrik veriler arasında en eski ve yaygın kullanılan yöntemlerden biridir. Günümüze kadar olan gelişim sürecinde, farklı sensörlerden elde edilen yüz verileri, çeşitli yöntemler ve metotlar kullanılarak yüz biyometrik veri setlerini oluşturmak için kullanılmıştır. Bu algoritmalar arasında Eigenfaces [87], Fisherfaces [88], LBP [89], Haar Cascade Classifiers (HCC) [90], 3B modeller ve CNN gibi derin öğrenme modelleri bulunmaktadır. Eigenfaces ve Fisherfaces, yüzün temel özelliklerini ve yüz yapısını temsil eden özel yüz uzaylarını kullanarak yüz tanıma yapar. LBP, piksellerin lokal yapılarını kullanarak yüz bölgesini ifade eder ve özellik çıkarma süreçlerinde yaygın olarak kullanılır. HCC, öğrenilmiş özelliklere dayalı olarak nesneleri tespit etmek için kullanılır ve yüz tanıma uygulamalarında yüksek performans gösterir. Derin öğrenme modelleri arasında yer alan Derin Sinir Ağları (Deep Neural Networks - DNN) ve bir alt kümesi olarak değerlendirilen CNN, büyük veri setleri üzerinde öğrenme yetenekleri sayesinde karmaşık yüz özelliklerini tanıma ve sınıflandırma konusunda etkili sonuçlar verir. Bu algoritmalar, yüz tanıma teknolojilerinin gelişmiş ve çeşitli uygulama alanlarında başarılı bir şekilde kullanılmasına olanak tanımaktadır. Yüz biyometrisi, genellikle kameralar aracılığıyla elde edilen yüz görüntülerini kullanarak çalışmaktadır. Bu görüntüler, geliştirilen algoritmalarla işlenmekte ve kişinin yüzünde bulunan belirli özelliklerin konumlarına dayalı olarak benzersiz bir tanıma şablonu oluşturulmasına olanak tanımaktadır. Daha sonra, bu şablondan, kimlik doğrulama, tanıma gibi pek çok süreçte yararlanılabilmektedir. Yüz biyometrisi, geniş bir uygulama yelpazesine sahiptir. Güvenlik sistemlerinden kişisel cihazlarda doğrulamaya, havaalanı güvenliğinde bankacılık uygulamalarına kadar pek çok alanda kullanılabilir. Biyometrik verinin kolay ve hızlı şekilde alınabilmesi, veri alınırken fiziksel temas gerekmemesi bu biyometrik özelliği popüler hale getirmiştir. Ancak, bazı güvenlik endişeleri ve gizlilik sorunlarından dolayı yüz biyometrisinin kullanımı genellikle belirli standartlara ve kanuni düzenlemelere tabidir.

3.2 Derin Öğrenme Modelleri

Derin öğrenme, genellikle büyük ve karmaşık veri setlerinden öğrenme yeteneğine sahip DNN kullanılarak gerçekleştirilmektedir. Derin öğrenme, katmanlı bir yapıya sahip olan bu sinir ağlarını kullanarak karmaşık desenleri ve ilişkileri otomatik olarak çıkarmayı amaçlar (Şekil 3.1).




Şekil 3.1 Temel bir derin öğrenme ağı

Derin öğrenme modellerinin oluşturulması için toplanacak veri setinin geniş kapsamlı olması modelin yüksek doğrulukla çalışması için önemlidir. Modellerin başarımlarının artırılmasındaki en önemli adımlardan biri de ön işlem adımlarıdır. Ön işlemlerle veri üzerinde yapılacak düzenlemeler ve bazı verilerin sistemden çıkarılması, sonraki adımlarda modelin genelleştirmesi adına büyük avantaj sağlayabilmektedir. Bunun yanında veri sayısının yeterli olmadığı durumlarda eldeki verilerden yararlanarak yeni örnekler üretilmesiyle veri zenginleştirme işlemleri de başarımları etkileyebilecek önemli adımlardan biridir. Verilerin toplanması işleminden sonra elimizdeki veri setinin analizi yapılarak uygun derin sinir ağı mimarisinin seçimi yapılmıştır. Bu çalışmada farklı tipte veriler için dört farklı derin öğrenme ağı yapısından yararlanılmıştır.

3.2.1 Evrimsel Sinir Ağları (Convolutional Neural Networks-CNN)


Evrimsel Sinir Ağları (CNN), görüntü işleme ve bilgisayarlı görü alanlarında daha önce kullanılan algoritmalarla çok daha gelişmiş bir yaklaşımla alanındaki oyunun kurallarını değiştiren bir modelle ortaya çıkmıştır [91]. İnsanın görsel sistemini simüle etmek ve karmaşık görsel kalıpları çıkarmak için çeşitli katmanlar kullanan CNN, video analizi, nesne tanıma, tıbbi tanı ve teşhis, biyometri gibi alanlarda birçok başarılı çalışmanın temel taşlarından olmuştur. CNN mimarileri,

ele alınan veri setlerinde otomatik özellik çıkarmak ve bu özellikleri kullanarak karmaşık problemleri çözmek adına farklı katman yapılarından oluşmaktadırlar. Öznitelik haritalarının çıkarılması adına mimarinin en temel katmanlarından biri olan evrişim katmanları, girdi olarak alınan görüntünün yerel bölgelerini tarayarak, bu bölgelerdeki desen ve özellikleri (örneğin kenarlar, doku) çıkarır. Her evrişim katmanı, farklı özelliklerin çıkarılmasını sağlayan bir dizi filtre (veya çekirdek) içerir. Bu filtre ya da çekirdek görüntü üstünde kaydırılarak her seferinde bir konvolüsyon işlemine başvurulur. Bu konvolüsyon işlemi uygulanırken filtre sayısı kadar, kullanılan filtreye göre farklı matrisler ortaya çıkar. Yatay ya da dikey ayrıntıların veya köşe desenlerin çıkarılması, resmin keskinleştirilmesi ya da yumuşatılması için farklı konvolüsyon filtreleri uygulanmaktadır. Konvolüsyon işleminde ortaya çıkan ve özellik haritası diye adlandırılan her bir değer de sonrasında bir aktivasyon fonksiyonundan geçirilir. Örneğin, en çok kullanılan aktivasyon fonksiyonlarından biri olan ReLu aktivasyon fonksiyonunda, pozitif değerler aynı şekilde bırakılırken negatif değerler 0 sayısına çekilir. Matematiksel olarak oldukça basitçe uygulanan bu aktivasyon fonksiyonu eğitim modelinin daha basit ve hızlı çalışmasına olanak tanır. ReLu haricinde, konvolüsyondan gelen verinin değerini (0, 1) aralığına çeken sigmoid fonksiyonu, (-1, 1) aralığında çıkış veren tanh fonksiyonu gibi çok çeşitli aktivasyon fonksiyonları da eğitim sırasında kullanılabilir. Konvolüsyon katmanında farklı filtrelerin kullanılmasıyla ortaya çıkan öznitelikler aydınlatma, arka plan karışıklığı, ölçek ya da verinin bir kısmının mevcut olması gibi durumlarda dahi iyi sonuçlar alınabilmektedir. Bu yüzden derin öğrenmede elle çıkartılan öznitelikler yerine bu katmandan çıkan özniteliklerin kullanılır. Konvolüsyon işlemi sırasında giriş verisinin 3x3 boyutlarında bir çekirdek ile filtrelendiği sonucunda oluşan matris (Şekil 3.2)'de gösterilmiştir.



Şekil 3.2 Örnek bir verinin 3x3 filtreden geçirilmesi ile oluşan konvolüsyon sonuç matrisi

Konvolüsyon işleminde görüntü boyutunun her seferinde küçülmemesi adına filtre uygulanmadan önce görsel üzerinde piksel ekleme (padding) işlemi yapılabilir. Böylece her konvolüsyon sonrası görüntü boyutunun azalması engellenirken aynı zamanda kenar ve köşe piksellerin daha doğru değerlendirilmesi sağlanır. Bunun yanında zaman zaman veriye göre piksel ekleme işlemiyle verinin boyutu da artırılabilir. Şekil 3.3’de ele alınan verinin, eklenen piksel ekleme ile boyutunda bir değişiklik olmadan işlenmesi sağlanmıştır.



Şekil 3.3 4x4 büyüklükte ve 1 piksel eklenmiş bir verinin, 3x3 bir filtre ile konvolüsyon işlemi sonucunda ortaya çıkan aynı boyuttaki matris

Veriye filtre uygulanırken dikkat edilmesi gereken özelliklerden biri de s harfiyle temsil edilen kaydırma adımıdır (stride). Kaydırma adımı varsayılan olarak 1 kabul edilse de filtre probleme göre farklı adımlarla da kaydırılabilmektedir. Kaydırma adımı büyüdükçe sonuçta ortaya çıkan veri küçülmektedir. Bu özelliklerden yola çıkarak $n \times n$ boyutlarında bir matrisin p piksel ekleme ve s kaydırma adımı ile $f \times f$ boyutlarında bir filtreden geçirilmesi sonucunda 3.1’de belirtilen boyutlarda bir matris ortaya çıkmaktadır.


$$n \times n \rightarrow ((n + 2p - f)/s + 1) \times ((n + 2p - f)/s + 1) \quad (3.1)$$

Örneğin, Şekil 3.3 örneği ele alındığında başlangıçtaki matris boyutları 4x4 olarak belirlenmiştir. n değeri 4x4 olan matristen 4, p değeri eklenen piksel değeri olan 1, f değeri 3x3 filtreden 3 ve s adımlama değeri örnekteki gibi 1 olarak ele alınırsa ortaya çıkan matris aşağıdaki boyutlarda yani 4x4 olacaktır:

$$4 \times 4 \rightarrow ((4 + 2 * 1 - 3) / 1 + 1) * ((4 + 2 * 1 - 3) / 1 + 1) \quad (3.2)$$


$$4 \times 4 \rightarrow 4 \times 4 \quad (3.3)$$

Evrişim katmanlarında filtrelerin uygulanması ile oluşturulan verinin, havuzlama katmanlarıyla (pooling layers) uzamsal boyutları aşamalı olarak azaltılır. Bu katmanda hem boyut azaltma ile hesaplama maliyetleri düşürülür hem de rotasyon ve konumsal değişikliklere karşı daha güçlü bir eğitim modeli oluşturulmasına yardımcı olunur. Havuzlama katmanları maksimum ve ortalama havuzlama yöntemleriyle uygulanmaktadır. Maksimum havuzlama, havuzlama için belirlenen büyüklükteki her bölgedeki maksimum değer alınarak uygulanırken ortalama havuzlamada bölgedeki verilerin piksel ya da sinyal değerlerinin ortalaması alınır. Şekil 3.4'te konvolüsyon işleminden sonra yapılan maksimum havuzlama örneği bulunmaktadır.



Şekil 3.4 Maksimum havuzlama ve ortalama havuzlamanın veriye uygulanması ile ortaya çıkan sonuç matrisi

Probleme göre bir dizi evrişimsel ve havuzlama katmanlarından sonra verinin tek boyutta sonraki katmanlara aktarılması için bir düzleştirme katmanından (Flatten Layer) yararlanılmaktadır. Düzleştirme katmanı, özellikle CNN mimarilerinin son kısmından önce yaygın olarak kullanılan bir ara katmandır ve ağız mimarisine bağlı olarak farklı boyutlardaki girdileri işlemek için esneklik sağlar. Burada yapılan işlem, ele alınan veriyi, tam bağlantılı katmanların istediği veri şekli olan tek boyutlu bir vektöre çevirmektir (Şekil 3.5).



Şekil 3.5 Düzleştirme katmanı ile ortaya çıkan veri


Mimarinin sonunda da tam bağlantılı katmanlar (Fully Connected Layers) yer almaktadır. Bu katmanlar, öz nitelikleri temsil eden daha yüksek seviyeli özelliklerin kombinasyonunu ve etkileşimini öğrenerek farklı aktivasyon fonksiyonlarıyla, önceki katmanlardan elde edilen öz niteliklerin sınıflandırması ya da regresyon işlemlerinin yapılmasını sağlamaktadır. Bu katmanların dışında ağı daha hızlı ve istikrarlı çalışması için yığın normalizasyonu (Batch Normalization) katmanları ve eğitim sırasında oluşabilecek aşırı öğrenmenin engellenmesi için sönümleme (Drop out) katmanları ağı dahil edilebilmektedir. Yığın normalizasyonu katmanlarında, derin öğrenme ağlarının eğitiminde, geri yayılım (backpropagation) sırasında oluşabilen gradient kaybolma problemi (Vanishing Gradient Problem-VGP) ortadan kaldırılır. VGP, derin öğrenme ağlarında geri yayılım sırasında ağırlıklar ve bias güncellenirken hesaplanan gradientlerin değerlerinin çok küçük hale gelmesi sonucunda ağı eğitiminin başarısız olmasına sebep olur. Bu problemin üstesinden gelmek için yığın normalizasyonu katmanında her bir yığın girdisinin ortalaması ve standart sapması normalize edilerek gradientlerin daha tutarlı olması sağlanır. Özellikle, ReLu fonksiyonunun kullanıldığı ağlarda gradientlerin çok küçük değerlere sahip olması engellenir. Böylece hem ağı eğitim süresinde iyileşme gerçekleşir hem de ağı aşırı öğrenmeye gitmesi engellenir. Sönümleme katmanlarının kullanılması

amaç ise ağı farklı nöronlardan gelen bağlantılarla da eğiterek aşırı öğrenmenin önüne geçmektir. Bunun için rasgele seçilen nöronlar eğitim sırasında devre dışı bırakılır ve model böylece bir önceki katmandan gelen tüm bilgilere bağımlı kalmaz. Böylece daha genelleştirilmiş ve aşırı öğrenmeye dirençli bir model elde edilir. Sönümleme katmanlarının kullanılmasıyla genelde eğitim başarısında bir azalma görülecektir. Ayrıca veri sayısının az olduğu ağlarda kullanımı bir dezavantaj olarak görülmektedir. CNN mimarisi, gelişimi sırasında farklı evrelerden geçmiştir. İlk olarak LeNet [92], evrişim ve havuzlama katmanlarından oluşan en temel mimariyle tanıtılmıştır. Sonrasında ihtiyaca bağlı elementlerin eklenmesi sonucunda AlexNet [93], VGGNet [94], GoogleNet [95], ResNet [96], MobileNets [97], EfficientNet [98] gibi daha gelişmiş mimariler ortaya çıkmış ve birçok uygulamada CNN başarımı artırılmıştır. Bunun yanında hala CNN algoritması üzerinde çalışmalar ve geliştirmeler yapılmaktadır. LeNet: CNN tarihinin ilk dönüm noktalarından biri olan LeNet, basit evrişim ve havuzlama katmanlarına sahip bir mimaridir. El yazısı rakamların tanınması gibi temel görevlerde başarılı olmuştur. AlexNet: 2012 yılında tanıtılan AlexNet, derin öğrenme alanında büyük bir ilgi uyandırmıştır. Bu mimari, çok katmanlı evrişim, ReLU aktivasyonları, dropout ve büyük veri kümeleri üzerinde eğitim gibi yenilikleri içermektedir. VGGNet: Görüntü işleme performansını artıran VGGNet, daha derin yapılar ve küçük boyutlu evrişim filtreleri kullanmaktadır. GoogleNet (Inception): GoogleNet, hesaplama kaynaklarını etkin kullanmak için tasarlanmıştır. İç içe geçmiş modüller sayesinde, daha az parametre ile daha derin ve daha etkili bir ağ yapısı sunmaktadır. ResNet: Derin sinir ağlarının eğitiminde karşılaşılan zorlukları aşmak için geliştirilen ResNet, "kalıntı öğrenme" yaklaşımını kullanır. Bu mimari, hatta yüzlerce katmandan oluşan ağların bile etkili bir şekilde eğitilmesini sağlamaktadır. MobileNets, EfficientNet gibi mimariler: Mobil cihazlar ve sınırlı hesaplama kaynakları için optimize edilmiş olan bu mimariler, hız ve verimlilik açısından önemli iyileştirmeler sunmaktadır. CNN'ler, sürekli gelişen yapay zeka ve makine öğrenimi alanında önemli bir yere sahiptir. Bu mimariler, sağlık, güvenlik, otonom araçlar ve daha pek çok alanda devrim yaratma potansiyeline sahiptir. Görüntü tanıma, video analizi, biyometrik sistemler ve tıbbi görüntüleme gibi uygulamalar, CNN teknolojisinin gücünden faydalanarak daha akıllı ve etkili çözümler sunmaktadır.

3.2.2 Uzun Kısa-Süreli Bellek (Long Short Term Memory-LSTM)

Zaman serisi analizi, konuşma tanıma ve doğal dil işleme gibi sıralı verileri modellemek için başarıyla kullanılan Uzun Kısa-Süreli Bellek (LSTM) mimarisi [99], sinyal işleme problem çözümünün öncülerinden biri olan Yinelemeli Sinir


Ağlarının (Recurrent Neural Networks-RNN) [100] özelleşmiş bir versiyonudur. RNN mimarisindeki hafıza sorunlarına çözüm olarak tasarlanmış ve öğrenme safhasında RNN'den daha etkili bir mimariyle ortaya çıkmıştır. CNN mimarileri, görüntü gibi uzamsal ilişkisi olan verileri işlemek için kullanılmaktadır. RNN'ler de sıra tabanlı verileri modellemek için özelleştirilmiş derin öğrenme modelleridir. Bu modeller uygulanırken parametrelerin modelin farklı bölümleri arasında paylaşılması fikrinden yararlanılmaktadır. Parametrelerin bu şekilde kullanılması, özellikle bazı bilgi parçalarının sinyalde farklı konumlarda olduğu problemlerde model eğitiminde çok önemlidir. Özellikle sinyal içinde tekrarlayan verilerin zaman içindeki ilişkilerinin bulunmasında geleneksel sinir ağı modelleri başarılı sonuçlar vermediği görülmüş ve önceki verilerden yararlanarak tekrarlayan bir ağ yapısı kurulması önerilmiştir. Burada amaç bilginin kalıcı olmasını sağlamak ve için döngülerden yararlanmaktır (Şekil 3.6).



Şekil 3.6 RNN Mimarisi [101]


Sinyallerin değerlendirmesi sırasında üzerinde çalışılan veri parçaları tahmini kolay sonuçlar veriyorsa RNN'ler çok başarılı şekilde çalışmaktadır. Ancak bazı durumlarda geçmiş sinyallere bağımlılık türü daha farklı ve fazladır. Bu durumlarda mimarinin doğru şekilde kurgulanması için kullanılan geri yayılım algoritmasında güncellemeler yapılırken ağ gittikçe kararsızlaşır ve doğru şekilde eğitilemez. Bu problemin çözümü adına RNN mimarileri güncellenerek daha başarılı algoritmalar oluşturulmuştur. RNN türevi LSTM algoritması, önceki adımlardan gelen bilgileri etkili bir biçimde hatırlama ve uzun vadeli bağımlılıkları öğrenme konularında başarılı sonuçlar vermektedir. LSTM mimarilerinin temelinde bir hücre durumu bulunmaktadır ve bilginin saklanması ve taşınması bu hücrenin görevidir. Hücreye yeni bir bilgi ekleme, hücreden bilgi çıkarma ve gereksiz bilginin atılması için mimaride kapılar bulunmaktadır. Hücrenin diğer hücrelerle bağlantıları RNN'den farklı olarak döngüsel ve uzun süreli bağımlılıkları da modelleyebilirler. LSTM mimarileri yapılarında bulunan gizli durumlarda yaptığı işlemlerle önceki durumları

hatırlar ve bağlantı kurar (Şekil 3.7).



Şekil 3.7 LSTM Mimarisi [101]

LSTM'lerde hücre durumu bir önceki durumdan bir sonraki duruma geçerken ağı en verimli şekilde oluşturulması adına bazı kapılar kullanılır. Hücre durumları C harfi ile ifade edilmiştir (Şekil 3.8 a).




Şekil 3.8 Hücrenin durum geçişleri (a), unutma kapısı (b), giriş kapısı (c), unutma ve giriş kapısı işlemleri (d), çıkış kapısı (e) [101]

LSTM'de başlangıç adımı, hücre durumunda saklanacak veya atılacak bilgiyi belirlemektir. Bu seçim, "unutma kapısı" adı verilen bir sigmoid katmanı tarafından yapılır. Bu katman, önceki katmandan gelen bilgi $h(t-1)$ ve mevcut girdi olan $x(t)$ girdilerine göz atar ve bir önceki hücre durumu olan $C(t-1)$ hücre durumundaki her değer için 0 ile 1 arasında bir değer üretir. 1, bilginin tamamen korunmasını, 0 ise tamamen atılmasını temsil eder (Şekil 3.8 b). Unutma kapısı ile bir önceki bilgi durumundan gelen bilgi çarpılarak unutulacak ve tutulacak bilgiler ilk sonuç olarak hesaplanır (Şekil 3.8 d). Bir sonraki aşamada, hücre durumuna eklenecek yeni bilgilerin belirlenmesi gerçekleştirilir. Bu süreç iki bölümden

oluşmaktadır. İlk bölümde, "giriş kapısı" adı verilen bir sigmoid katman aracılığıyla hangi değerlerin güncelleneceği tespit edilir. İkinci bölümde ise, tanh katmanı, duruma eklenebilecek yeni aday değerlerin bir vektörünü, yani bir sonraki katmana verilecek hatırlatma bilgisini üretir (Şekil 3.8 c). Buradan çıkan sonuç ile ilk sonuç bilgisi toplanır ve bu sonuç da ikinci sonuç olarak tutulur. Son kapı olan çıkış kapısında ise hücre durumunun çıktısına karar verilir (Şekil 3.8 e). Burada bir tanh fonksiyonu kullanılır ve hücrenin hangi bilgilerinin bir sonraki katmana aktarılacağı seçilir. LSTM mimarisinin farklı versiyonları da mevcuttur. RNN mimarisindeki geri yayılım sırasında gradyanların kaybolması problemine çözüm olarak geliştirilen algoritma özellikle dil işlemede çok başarılı performans göstermektedir.

3.2.3 Geçitli Özyinelemeli Birim (Gated Recurrent Unit-GRU)

LSTM yapıları gibi RNN mimarisinin özelleşmiş şekillerinden biridir. Yapısı LSTM mimarisine göre daha basit olmasına rağmen bazı veriler üzerinde LSTM algoritmasından daha başarılı sonuçlar vermektedir. GRU, giriş, çıkış ve güncelleme kapılarından oluşan yapısı ile LSTM benzeri bir model ortaya çıkarsa da daha basit verilerin işlendiği, hızlı modeller gerektiren durumlarda daha az parametre ve hesaplama maliyetine sahip olmasından dolayı tercih edilmektedir [102]. Bu algoritmaların yapısal olarak genel şekilleri aşağıda verilmiştir (Şekil 3.9).




Şekil 3.9 RNN, LSTM ve GRU yapıları [103]

GRU algoritmasında LSTM algoritmasındaki unutmaya kapısına benzer sıfırlama kapısı mevcuttur ve unutmaya kapısı ile benzer bir işlem görür. Benzer şekilde giriş ve çıkış kapıları yerine daha basit bir güncelleme kapısı mevcuttur. LSTM mimarisine göre parametre sayısı daha az olduğu için hız olarak daha başarılıdır. Performans olarak zaman zaman LSTM'den daha başarılı sonuçlar ortaya çıkarmaktadır. Dil modelleme ve çeviri alanlarında kullanılan önemli algoritmalarından biridir.

3.2.4 Zamansal Evrişimli Ağlar (Temporal Convolutional Networks-TCN)

Zaman serileri üzerinde etkili çalışan derin öğrenme ağlarından biri olan Zamansal Evrişimli Ağlar (TCN), sıralı veri analizi, doğal dil işleme, video analizi ve zaman serisi tahmini problemlerinde önemli bir alternatif olarak tasarlanmıştır [104]. Yöntem tanıtılırken oluşturulan "Encoder-Decoder TCN" yapısı, uzun menzilli zamansal desenleri verimli bir şekilde yakalayabilmek için havuzlama ve örnek artırma yöntemlerini kullanırken, "Dilated TCN" yapısı, genişletilmiş konvolüsyonları (dilated convolutions) kullanmaktadır (Şekil 3.10). Bu yapılar, verinin bileşenlerini, segment sürelerini ve uzun menzilli bağımlılıklarını yakalamak için tasarlanmıştır. Burada, farklı büyüklükteki adımlarla uygulanan zamansal konvolüsyon işlemiyle model, hem geçmiş bilgilerin hem de anlık verilerin dikkate alınmasını sağlayarak daha geniş bir bağlamda öğrenme becerisine sahip olmaktadır. TCN modellerinin en önemli avantajlarından biri de daha az parametre ile çalışmalarına rağmen RNN türevi uygulamalarla kıyaslandığında başarılı sonuçlar ortaya çıkarmalarıdır. Az parametreyle çalışmaları da ağı hafifletmekte ve buna bağlı olarak hızlandırmaktadır.

Evrişim katmanlarını kullanarak paralel işleme yeteneği, uzun vadeli bağımlılıkları modelleme yeteneği, modelin öğrenme kapasitesini artıran ve işlem süresini kısaltan havuzlama katmanları ve zaman serileri problemlerine uygun mimarisiyle TCN ağlarının pek çok sinyal işleme probleminde kullanımına başvurulmuştur.



Şekil 3.10 (a) Encoder-Decoder TCN yapısı, (b) Dilated TCN yapısı [104]

4

VERİ TOPLAMA VE METODOLOJİ

4.1 Verilerin Toplanması ve Ön İşlemler

Verilerin toplanması safhası bir yapay zekâ probleminin çözümünde en önemli noktalardan biridir. Verilerin güvenilir şekilde toplanması daha sonraki safhalarda hızlı ilerlenmesi, sonuç doğruluğunun güvenilirliğinin garantilenmesi ve performansın artırılması için kritik önem arz etmektedir. Bu çalışmada, çoklu biyometrik bir model geliştirmek için katılımcılardan yüz görüntüleri ile ekran önünde havada attıkları havada imza görüntüleri toplanmıştır. Veriler toplanmadan önce Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü'nden etik kurulu izni alınarak verilerin sadece akademik çalışmalarda kullanılacağına dair güvenliği garanti edilmiştir. Bu çalışmada 11 erkek, 14 kadın toplam 25 katılımcıdan 70'ten fazla havada imza sinyali, havada imza görüntüsü ve yüz görüntüsü toplanmış bunların 70'er tanesi veri setini oluşturmak için uygulamaya dahil edilmiştir. Her biyometrik veri türünden 1750 adet veri toplanan çalışmada katılımcıların büyük kısmı 18-30 yaş aralığındadır (4.1). Bu verilerin dışında farklı çalışmalarda kullanılmak üzere katılımcıların havada imzasının yanında fiziksel imzası da tekrarlı sayıda kâğıt üzerinde toplanmıştır (Şekil 4.1) Alınan veriler kaydedilirken anonimleştirilmiş ve her katılımcı bir id ile ilişkilendirilerek saklanmıştır.

Tablo 4.1 Veri Seti Özellikleri

Özellik	Örnek Sayısı (Toplam = 25)
Erkek / Kadın	11 / 14 (%44 / %56)
Yaş Grupları	
>40	2 (%8)
30-40	4 (%16)
20-30	11 (%44)
10-20	8 (%32)



Ek-6. Gönüllü Veri Formu

Aşağıda alınan ad, soyad, imza ve kişisel bilgileriniz akademik bir çalışma için kullanılacak ve farklı hiçbir mecrada paylaşılmayacaktır.

Cinsiyet: ☒ Kadın ☐ Erkek
Yaş: 36

AD SOYAD

Yasemin

İMZA

Yasemin

AD SOYAD

Yasemin

İMZA

Yasemin

AD SOYAD

Yasemin

İMZA

Yasemin

AD SOYAD

Yasemin

İMZA

Yasemin

AD SOYAD

Yasemin


İMZA

Yasemin

Şekil 4.1 Katılımcılardan alınan kâğıt üzerinde imza verisi

4.1.1 Havada İmza Verilerinin Toplanması


Son yıllarda, pek çok platformda kullanıcı deneyimlerinin ve hareketlerinin algılanması için el şekli, el hareketleri ya da el eklem noktalarının alınması konularında çeşitli çalışmalar yapılmış ve uygulamalar ortaya çıkarılmıştır [12, 35, 36, 38, 42, 75, 78]. Bu uygulamalara sanal ve artırılmış gerçeklik, işaret dili algılama, dijital içerik sunma gibi pek çok örnek verilebilir [105–109]. Çalışmada alınacak biyometrik verilerden biri olan havada imzanın alınması için daha önceki çalışmalarda OpenPose [110], HandPose, MediaPipe [111–113] gibi kütüphanelerin yanı sıra, LeapMotion [114, 115] gibi hem donanım hem de yazılım entegrasyonu olan başarılı sistemler bulunmaktadır. Bunlardan MediaPipe kütüphanesinin kullanılması, farklı biyometrik verilerin alınması için özelleşmiş alt kütüphaneleriyle çalışmamızda kullanmamıza en uygun yöntem olarak ele alınmıştır. MediaPipe kütüphanesinin alt kütüphanelerinden biri olan MediaPipe Hands (MPH) el ve el üzerindeki eklem noktalarının koordinatlarının elde edilmesi için tasarlanmış makine öğrenmesi temelli bir uygulamadır. MPH, el üzerindeki 21 noktanın koordinatlarını çok başarılı ve yeterince hızlı bir şekilde takip eden, Python ortamında başarıyla çalışan yüksek performanslı bir araçtır (Noktalar kütüphanede sırasıyla şöyle isimlendirilmiştir; wrist, thumb_cmc, thumb_mcp, thumb_ip, thumb_tip, index_finger_mcp, index_finger_pip, index_finger_dip, index_finger_tip, middle_finger_mcp, middle_finger_pip, middle_finger_dip, middle_finger_tip, ring_finger_mcp, ring_finger_pip, ring_finger_dip, ring_finger_tip, pinky_mcp, pinky_pip, pinky_dip, pinky_tip) (Şekil 4.2). Yüksek doğrulukla el eklem koordinatlarını bulabilen MPH mevcut çalışmada kullanılmak için kendini kanıtlamış ve yeterli bir uygulama olarak değerlendirilmiştir.



Şekil 4.2 MPH kütüphanesi anahtar noktaları [116]

Havada imza biyometrik verilerinin eğitim için toplanması kâğıt üzerinde atılan


fiziksel imzanın alınmasına göre daha fazla titizlikle yapılması gereken bir uygulamadır. Bu yüzden işlemlere başlanmadan önce imzanın en doğru şekilde alınabilmesi adına MPH kütüphanesi kullanılarak ekran üzerinde farklı katılımcılardan örnekler alınmıştır. Bu örneklerde kullanıcıların yaşadığı zorluklara bağlı olarak veri alımının son şekli verilmiştir. Çalıştırılan Python temelli uygulama başladığında katılımcının ad ve soyadı bilgisi program tarafından alınıp bu bilgilerle katılımcıya ait bir klasör oluşturulmuştur. Veriler katılımcılardan bir operatör yardımıyla alınırken öncelikle havada imzanın kameraya uzaklık olarak hangi bölgede uygulanacağı tespit edilmiştir. Bunun için ilgili katılımcı havada imzayı atabileceği en rahat noktayı seçtikten sonra bu bölgede elini tam açarak kameraya göstermiştir. Bu bölgede elin büyüklük ve derinlik değerleri alınmış ve bir klavye komutu ile çalışmanın sonraki bölümlerinde kullanılmak üzere bu değer saklanmıştır. El derinlik ve büyüklük verilerinin saklanmasıyla ekranda dikdörtgen şeklinde bir alan gösterilmiş ve katılımcıdan bu kutunun içine imza atması beklenmiştir. Bu dikdörtgen ekranın sağ üst bölgesine sabitlenmiş ve boyutları 800x250 ölçülerindedir. Bu boyutlara uzun testler sonucunda karar verilmiştir. Uygulama sadece dikdörtgen içinde işaret parmağının ucunun koordinatlarını alacak şekilde tasarlanmıştır. Bunun yanında fiziksel imza atarken bazen kalem kaldırılarak oluşturulan birbirinden ayrı parçalar için bir kural tanımlanmıştır. Bu kurala göre kullanıcının işaret ve orta parmakları arasındaki mesafe, işaret parmak ucunun (index_finger_tip) kendinden önceki MPH noktasına (index_finger_dip) uzaklığından daha küçük olduğunda yazma işlemi durdurulacaktır. Yani imza atılırken işaret ve orta parmaklar bir araya getirildiğinde imza işlemine ara verilecektir (Şekil 4.3).



Şekil 4.3 Ekran üzerinde dikdörtgen oluşturulması ve işaret ile orta parmağın yakın olduğu durumda imzanın ekranda çizdirilmemesi

Bu kurallar anlatıldıktan sonra katılımcılara denemeler yapması ve uygulamayı

tanınması için süre verilmiş sonrasında veri kayıt işlemine geçilmiştir. Havada imzanın uygulanması sırasında ekran üzerindeki dikdörtgen şeklinin içinde uygulayıcının göreceği şekilde imzanın şekli çizdirilmiştir Şekil 4.4. Katılımcının her imzası sonrası klavyeden verilen komutla imzalar kaydedilmiş ve ekran üzerindeki imza temizlenmiştir. Burada havada imzanın ekran üzerindeki görselinin yanında imzanın zamana bağlı koordinatları da bir metin dosyasında saklanmıştır.

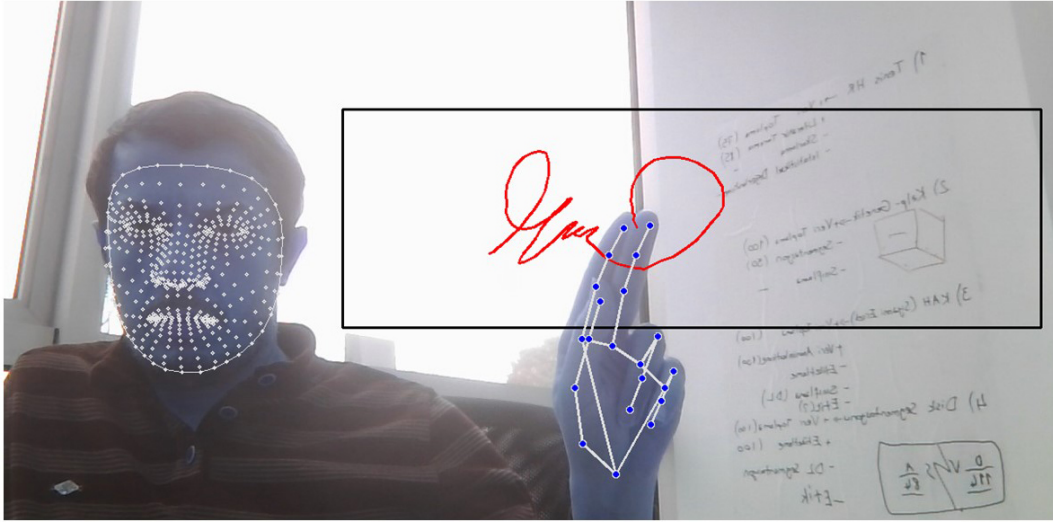


Şekil 4.4 Ekran üzerine imzanın çizdirilmesi

4.1.2 Yüz Görüntülerinin Toplanması

Yüz görüntülerinin imza görüntüleri ile birlikte toplanabilmesi için farklı bir kütüphane kullanmak yerine MediaPipe'in başka bir alt kütüphanesi olan MediaPipe Face (MPF) kütüphanesine başvurulmuştur. Fotoğraf, video ya da canlı gerçek zamanlı streamlerde bulunan yüz görüntülerinde anahtar noktalar oluşturarak yüz sınırlarının koordinatlarının tespit edilmesini mümkün kılan MPF, pek çok çalışmada kullanılmıştır. Algoritma, yüz üzerinde 468 anahtar noktaya kadar bulunmasıyla 3 boyutlu uzayda yüzün sınırlarını tahminlemektedir.


Çalışmada imzaların toplanması sırasında imza atımı bittiğinde bir klavye tuşuyla imzanın görüntü ve zaman-koordinat sinyali kaydedilirken aynı anda yüz görüntüsü de kaydedilmektedir (Şekil 4.5). Böylece her imza için birer yüz görüntüsü de elde edilmiştir. Bu işlem, eksik ya da hatalı veri olabilmesi ihtimaline karşı, her katılımcı için 75 ± 2 kez tekrar edilmiştir.



Şekil 4.5 İmza verisi ve yüz görüntüsünün aynı anda alınması

4.1.3 Veriler Üzerinde Ön İşlemler

Python uygulaması üzerinde kullandığımız MPH ve MPF kütüphaneleri ile elde edilen havada imza sinyali, imza görüntüsü ve yüz görüntüsü biyometrik verilerinin derin öğrenme modellerinde kullanılabilmesi için çeşitli ön işlemlerden geçirilmesi gerekmektedir. Bu ön işlemlerle, hem verilerde modeli bozabilecek uç örnekler çıkarılmış hem de veriler boyut düzenlemesiyle modellere uygun hale getirilmiştir. Toplanan biyometrik verilerden statik havada imza görüntüsü ele alındığında ekran üzerindeki dikdörtgenin tamamı kaydedilmektedir. Bu yüzden öncelikle imza dışında kalan boş alan temizlenmiştir. Bu işlemden sonra imza görseli modelleme işleminde kullanacağımız 256x256 boyutlarına getirilmiş ve bu şekilde ayrı bir klasörde saklanmıştır (Şekil 4.6).



Şekil 4.6 Her bir imza uygulamasında alınan imzanın görsel olarak kaydedilmesi

Aynı biyometrik verinin dinamik kısmı olan koordinat-zaman bilgilerinin tutulduğu havada imza sinyalleri kayıt sırasında diğer biyometrik verilerle birlikte alınmıştır. Ancak bu biyometrik verinin saklanması için gerekli bilgiler bir metin belgesinde saklanmıştır. Alınan veriler havada imza atılırken işaret parmağının takip ettiği noktaların x ve y koordinatları ile zaman bilgileridir. İmzanın atılması sırasında oluşacak boşluklar için metin dosyasına x, y koordinatları ve zaman bilgisi yerine “-1” değerleri eklenerek birden fazla parçalı imza kaydedilmiştir (Şekil 4.7).



```

361, 163, 13.434991199999999
363, 162, 13.468422499999999
366, 161, 13.501719900000001
370, 158, 13.5355423
374, 157, 13.568538700000001
379, 154, 13.6018738
386, 149, 13.637944999999998
392, 144, 13.671762600000001
402, 146, 13.708127600000001
414, 149, 13.742149399999999
-1, -1, -1
504, 137, 27.8022115
510, 135, 27.8367254
511, 135, 27.871876800000003
515, 134, 27.904798
519, 133, 27.939616100000002
530, 116, 27.9842243
534, 110, 28.0238511
533, 103, 28.0591655
533, 93, 28.092375099999998
534, 87, 28.126416300000002
536, 82, 28.1601978
536, 76, 28.194109599999997
535, 71, 28.228782000000002
536, 67, 28.261666499999997
534, 63, 28.295414200000003

```


Şekil 4.7 Parçalı olarak atılan bir havada imzanın saklanan sinyalinin bir bölümü. Sinyalin parçalandığı bölge için -1 değerleri yazılmıştır.

Bu dinamik veride koordinatların orijinden başlaması için x ve y değerlerinden en küçük olanları xmin ve ymin olarak seçilmiş ve x değerlerinden xmin, y değerlerinden ymin değerleri çıkarılmıştır. Benzer şekilde, t0, ilk zaman değeri alınarak tüm zaman değerlerinden bu değer çıkarılmıştır. Böylece hem koordinatlarda orijinden hem de zaman verisinde de standart olarak aynı noktadan başlayan dinamik veriler oluşturulmuştur. Derin öğrenme modeli için tüm verilerin boyutu aynı olmalıdır; bu nedenle, verilere lineer interpolasyon uygulanmıştır (Denklem 4.1). Bu işlem sırasında sinyallerdeki nokta sayısı değerlendirilmiş ve interpolasyonun, maksimum uzunluktaki sinyalin iki katı olan 200 değerinde uygulanmasına karar verilmiştir. İnterpolasyon işlemi Python yazılımındaki interp1d fonksiyonu ile uygulamaya dahil edilmiştir. Denklem 1'deki matematiksel işlemle y(n) ve y(n+1) başlangıç ve bitiş noktası olarak kabul edildiğinde $\hat{y}(n+h)$, y(n) noktasından h uzaklıktaki tahmin edilen yeni noktayı ifade etmektedir.

$$\hat{y}(n+h) = (1-h)y(n) + hy(n+1) \quad (4.1)$$

İnterpolasyon işleminden sonra tüm dinamik sinyaller aynı boyutta ve derin öğrenme modeline uygun hale gelmiştir. Aşağıdaki şekilde interpolasyon uygulanan bir sinyal örneği bulunmaktadır (Şekil 4.8).

Yüz biyometrik verisi için MPF kütüphanesi yüzün sınırlarını belirlemektedir. Bu yüzden yüz verileri üzerinde sadece bu kütüphanenin FACE_OVAL parametresi kullanılarak yüzler kaydedilmiştir. Burada çıkan tek problem katılımcıların zaman zaman yüzlerini ekrandan çıkarmaları ya da yüz bölgeleri görünemeyecek şekilde kapatmalarındır. Böyle durumlar için normalde almamız gereken veriden daha fazla veri alınmış ve yüz verilerinin toplanamadığı örneklerin yerine yedek veriler



Şekil 4.8 52 noktalı bir sinyalin Matlab ortamında 200 noktalı bir sinyale interpolasyonla dönüştürülmesi


eklenmiştir.

4.2 Model Oluşturma ve Model Eğitimi

4.2.1 CNN, LSTM, GRU ve TCN Modelleri


Bu çalışmada veri toplama safhasında alınan görüntü verileri (yüz ve imza görselleri) 256x256x3 ebatlarına getirilmiş ve %80 eğitim, %20 test verisi olacak şekilde ayrılmıştır. Biyometrik veriler birbirinden bağımsız olarak analiz edildiğinde, görüntülerin eğitimi için kullanılan CNN derin öğrenme mimarisinin ana yapısı, 32, 64, 128 filtreli 3 farklı konvolüsyon katmanını takip eden 2x2 maksimum havuzlama katmanlarıyla oluşturulmuştur. Bu katmanlardan sonra ortaya çıkan özellikleri temsil eden özellik haritası, bir düzleştirme katmanı ile tek boyutlu bir vektöre dönüştürülmüştür. Bu vektör de tam bağlantılı katmanlara giriş değeri olarak model tarafından sunulmuştur. CNN modelinde, tam bağlantılı katmanlardan ilki 512 nörona sahiptir ve ReLu (Rectifier Linear Unit) aktivasyon fonksiyonunu kullanmaktadır. İkinci tam bağlantılı katman ise veri setindeki katılımcıların, dolayısıyla sınıfların sayısını belirten 25 nörondan oluşmaktadır ve burada SoftMax aktivasyon fonksiyonundan yararlanılmıştır. CNN mimarisi hem imza görüntüsü hem de yüz görüntüsü için aynı model parametreleri ile uygulanmıştır (Şekil 4.9).

Dinamik biyometrik havada imza sinyallerinin modellenmesi için RNN mimarisinin özelleşmiş şekilleri olan LSTM, GRU mimarileriyle TCN mimarisi üzerinde çalışmalar yapılmıştır. Giriş verisi olarak alınan 1750 adet 200x3 boyutlarındaki



Şekil 4.9 Görüntüler için oluşturulan CNN modelinin yapısı. Aynı model havada imza sinyal görüntülerine de uygulanmıştır.


sinyaller öncelikle %80 eğitim, %20 test verisi olacak şekilde ayrılmıştır. Model eğitimi sırasında LSTM modeli, 128 ve 32 nöron içeren iki katmanla bu katmanları takip eden 512 nöronlu ve 25 nöronlu iki tam bağlantılı katmanla oluşturulmuştur (Şekil 4.10). Tam bağlantılı katmanlarda CNN mimarisine benzer şekilde sırasıyla ReLu ve SoftMax aktivasyon fonksiyonları kullanılmıştır. GRU modelinin oluşumu LSTM mimarisine çok benzemekle birlikte LSTM katmanları yerine GRU katmanlarından yararlanılmıştır. TCN mimarisinde ise 256 ve 64 filtrelili iki ayrı tek boyutlu (1B) konvolüsyon katmanını izleyen 1B maksimum havuzlama katmanı, 512 ve 25 nöronlu tam bağlantılı katmanlarla takip edilerek model ortaya çıkarılmıştır. TCN’de adım sayıları 1, 2, 4, 8, 16, 32 olarak ele alınmıştır.



Şekil 4.10 Dinamik sinyaller için model tasarım örneği

Tek bir biyometrik verinin kullanıldığı modellerden sonra çoklu biyometrik

modeller oluşturulmuştur. Bu modellerde havada imza görüntüsü-havada imza sinyali, havada imza görüntüsü-yüz görüntüsü ve havada imza sinyali-yüz görüntüsü ikilileri ele alınarak çoklu biyometrik modeller oluşturulmuştur. Bu modellerde, biyometrik özelliğin yalnız değerlendirildiği modellerdeki katman sayıları ve mimariler bire bir kullanılmıştır. Birleştirme işlemi yapılırken önce farklı modellerden elde edilen özellik haritalarından çıkan düzleştirilmiş katmanlar bir araya getirilmiştir. Birleşik model olarak adlandırılan bu veriyle tam bağlantılı katmanda sınıflandırma işlemi uygulanmıştır (Şekil 4.11).




Şekil 4.11 Birleşik model mimarisi

4.2.2 Algoritmaların Karşılaştırılması ve Seçimi

Bu çalışmada, görsel veriler için CNN, sinyal verileri için LSTM, GRU ve TCN algoritmalarından yararlanılmıştır. CNN, çok boyutlu verilerde en sık kullanılan yöntemlerin başında gelmektedir ve yüksek başarımıyla kendini kanıtlamış bir algoritmadır. CNN modelinin tasarımı sürecinde filtre sayısı, öğrenme adımı gibi parametreler değerlendirilerek optimal sonuca ulaşmak için farklı mimariler üzerinde durulmuştur. Sinyal verileri için ise LSTM, GRU ve TCN modelleri kullanılmıştır. Bu modellere karar verilirken, eğitim süresi, bellek kullanımı, sinyal özelliklerini ne kadar iyi yakaladıkları gibi faktörler üzerinde durulmuştur. LSTM ve GRU'nun daha karmaşık ilişkileri öğrenme kabiliyeti, TCN'nin paralel işleme yeteneği ve dilate edilmiş konvolüsyonlar kullanarak geniş bir bağlamı daha etkili bir şekilde yakalama yeteneği değerlendirmiş ve uygulamada kullanılmaları uygun bulunmuştur.

4.3 Performans Değerlendirmesi

Yapay zeka çalışmalarında oluşturulan makine öğrenmesi ya da derin öğrenme modellerinin başarısının değerlendirilebilmesi için sistem performansını doğru ölçüp analiz etmek kritik öneme sahiptir. Yapılan çalışmada oluşturulan modellerin başarısını değerlendirmek için literatürdeki çalışmalarda sıklıkla kullanılan doğruluk (accuracy) (Denklem 4.2), duyarlılık (sensitivity) (Denklem 4.3), kesinlik (precision) (Denklem 4.4), F1 Score (Denklem 4.5), AUC (Area Under Curve) metrikleri kullanılmıştır. Bu metriklerin hesaplanabilmesi için dört temel değer kullanılmaktadır. Doğru pozitif (true positive-TP) modelin pozitif olarak tanımladığı durumların gerçekten pozitif olması, doğru negatif (true negative-TN) modelin negatif olarak tanımladığı durumların gerçekten negatif olması, yanlış pozitif (false positive-FP) modelin pozitif olarak tanımladığı durumların gerçekte negatif olması, yanlış negatif (false negative-FN) modelin negatif olarak tanımladığı durumların gerçekte pozitif olması durumlarını ifade ederler Şekil 4.12. Doğruluk, doğru olarak bulunan örneklerin, tüm örneklerle oranıdır. Duyarlılık ise pozitif olup doğru bulunanların, tüm pozitif bulunanlara oranıdır. Kesinlik değeri, pozitif olup doğru bulunan örneklerin, pozitif olarak değerlendiren tüm örneklerle oranıdır. F1 skor değeri, kesinlik ve duyarlılık değerlerinin çarpımlarının toplamına bölümünün 2 katını ifade eder. Bu değerlere göre metrikler Denklem 4.2-4.3-4.4-4.5'te hesaplanmıştır.



Şekil 4.12 Veri dağılımlarının bölgelerle görsel temsili

Uygulamanın performansının değerlendirilmesi sırasında, sklearn.metrics

kütüphanesinin sunduğu metrikler kullanılarak sonuçlar elde edilmiştir. Bu kütüphane, regresyon analizi, sınıflandırma, boyut azaltma, kümeleme, model seçimi, veri ön işleme gibi geniş bir yelpazedeki makine öğrenimi algoritmalarını içermektedir. Bu çeşitlilik, uygulamanın farklı veri türleri ve problem alanlarına uygun şekilde değerlendirilmesine imkan tanımaktadır. Bu metriklerin kullanımı, algoritmaların performansını değerlendirmeye ve uygun model seçimine destek olmaktadır.

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (4.2)$$

$$Sensitivity = TP / (TP + FN) \quad (4.3)$$

$$Precision = TP / (TP + FP) \quad (4.4)$$

$$F1Score = 2 * (Sensitivity * Precision) / (Sensitivity + Precision) \quad (4.5)$$

5

UYGULAMA VE TESTLER

5.1 Sistem Kurulumu ve Uygulama Ortamı

Derin öğrenme uygulamalarının etkin ve başarılı bir şekilde yürütülmesi, özellikle veri miktarının büyüklüğü, yüksek işlem gücü gereksinimi ve çok katmanlı mimarilere olan ihtiyaç göz önünde bulundurulduğunda, güçlü ve uygun bir sistem altyapısının varlığına ihtiyaç duyulmaktadır. Derin öğrenme modellerinin eğitimi ve test edilmesi sırasında kullanılan büyük veri setleri, bu modellerin doğru ve etkili bir şekilde eğitilmesi için yüksek hafıza kapasitesi ve hızlı işlem yetenekleri gerektirmektedir. Ayrıca, derin öğrenme algoritmalarının karmaşık yapısı ve çok katmanlı mimarilerini uygulamak için ileri düzey hesaplama kapasiteli ve güçlü donanım çözümlerine ihtiyaç vardır. Bu gereklilikler, araştırmanın başarısını doğrudan etkileyen faktörlerdir ve bu yüzden, bu çalışma için kullanılan sistem kurulumu ve uygulama ortamının, bu zorunlulukları karşılayacak şekilde tasarlanmış olması kritik bir öneme sahiptir. Mevcut çalışmada kullanılan donanım Intel Core i7-11800H, 2.3GHz işlemci, 16GB RAM ve 64 bit Microsoft Windows işletim sistemine sahiptir. Sistem üzerinde biri harici olmak üzere 2 kamera mevcuttur. Bu kameralardan dahili olan cihaz 1280x720 çözünürlükte 0.92 MP, 30 fps (frame per second) özelliklerine sahiptir. Harici kamera ise 1920x1080, 2 MP, 30 fps özelliklerindedir. Uygulamaya öncelikle dahili kamerayla başlanmış, sonrasında daha yüksek performans gösteren harici kamera ile verilerin alınmasına karar verilmiştir. Uygulama oluşturulurken yapay zeka konusunda sayısız kütüphanesi ve birçok alanda yazılan açık kaynaklı yazılımları barındıran Python dili ve PyCharm ortamı kullanılmıştır. PyCharm, Python dilindeki geliştirmeleri destekleyen kapsamlı bir entegre geliştirme ortamıdır. Kod tamamlama, hata denetimi ve güçlü entegrasyon özellikleri sayesinde geliştiricilere verimli bir çalışma deneyimi sunmaktadır. Ayrıca, sürekli güncellemeler ve geniş topluluk desteğiyle kullanıcıların ihtiyaçlarına hızlı ve etkili çözümler sağlamaktadır. Bunun yanında, derin öğrenme modellerini geliştirmek için Tensorflow kullanılmıştır. TensorFlow, derin öğrenme alanında çok güçlü bir açık kaynak kodlu kütüphanedir

ve karmaşık sinir ağı modellerinin oluşturulması, eğitilmesi ve dağıtılmasını sağlar. İnce detaylarla uğraşma zorunluluğunu ortadan kaldıran, modüler yapısı, geliştiricilere farklı uygulama alanlarına yönelik özelleştirilebilir çözümler geliştirmelerine olanak tanımaktadır. GPU ve TPU gibi yüksek performanslı donanımlarla uyumlu olması, büyük veri setlerinde ve karmaşık görevlerde etkili bir şekilde kullanılabilmesini sağlamaktadır. Bu çalışmada, veriler dizüstü bilgisayara entegre kameralarla toplandığı için verinin alınması için sabit bir ortama ihtiyaç yoktur. Buna rağmen verilerin büyük bir kısmı Yıldız Teknik Üniversitesi laboratuvarlarında alınmış ve lokal olarak depolanmıştır.

5.2 Model Eğitimi ve Validasyonu

Derin öğrenme modellerinin farklı veri setleri üzerinde yüksek performans sergileyebilmesi için, modelin çeşitli hiperparametrelerinin dikkatlice ayarlanması gerekmektedir. Bu çalışmada, çeşitli biyometrik verilerin eğitiminde kullanılan CNN, LSTM, GRU ve TCN algoritmalarının en iyi sonuçları verebilmesi için bir dizi hiperparametre ayarlaması ve testi gerçekleştirilmiştir. Bu hiperparametrelerden yığın boyutu (batch-size), modelin her adımda değerlendirdiği veri örnek sayısını belirtmektedir. Elektronik sistemlerin ikili sayı sisteminde çalışmasından dolayı yığın boyutları genelde ikinin katları şeklinde belirlenir. Çalışmada yığın boyutları seçilirken daha öncesinde bu konuda yapılan çalışmalar ve elimizdeki donanımın temel özellikleri değerlendirilmiştir. Bunun sonucunda 16, 32 ve 64 yığın boyutunda testler yapılmıştır. Yığın boyutunun 64 örnek olduğu süreçte eğitim donanım tarafından bitirilememiş, 16 olduğu boyutta ise zaman maliyeti yüksek, performansı geliştirmeyen bir durum ortaya çıkmıştır. Yapılan testler sonucunda yığın boyutuna 32 örnek olarak karar verilmiştir. Hiperparametrelerden epoch sayısı, eğitim veri setinin tamamının bir kere işleme sürecini ifade eder. Herhangi bir erken durdurma kriteri (early stopping criteria) eklenmez ve epoch sayısı veri setinin büyüklüğüne göre çok büyük seçilirse model veri setini ezberler ve eğitim başarısı çok yüksek olsa da test başarısı düşer. Epoch sayısının az olduğu uygulamalarda ise model potansiyel başarıya ulaşamaz. Erken durdurma kriteri bu noktada modelin belirli sayıda başarısının yükselmemesi durumunda eğitimi sonlandırır. Böylece aşırı öğrenmenin önüne geçilebilmektedir. Bu çalışmada oluşturulan modellerde epoch sayısı 50, durdurma kriteri 5 olarak seçilmiştir. Bu değerler, yapılan testler sonucunda ortaya çıkmıştır. Erken durdurma kriterinin artırılması durumunda modelde büyük değişiklikler olmamıştır. Eğitim, farklı modellerde, epoch sayısı erken durdurma kriterine göre 34 ile 48 değerleri arasındayken sonlanmıştır. Bir diğer hiperparametre olan öğrenme oranı için 0.0001 ile 0.1 arasında değerler ve Adam optimize edici

ile testler yapılmıştır. Öğrenme oranının çok küçük olduğu durumlarda zaman maliyeti fazla olmuş ve bazı lokal maksimum bölgelerde eğitim durmuştur. Bu oran daha büyük değerlere ayarlandığında ise modelin performansı istenen düzeyde olmamaktadır. Ardı ardına yapılan testler sonucunda tüm modellerde öğrenme oranının 0.01 olmasına karar verilmiş ve bu öğrenme oranında model en başarılı sonuçları vermiştir. Modelin giriş verilerinden elde ettiği özellik haritalarının değerlendirildiği tam bağlantılı katmanlarda kullanılan fonksiyonlar da önemli hiperparametrelerdendir. Bu çalışmada tekil ya da bileşik modellerin sonunda 2 adet tam bağlantılı katman kullanılmıştır ve bu katmanlardan ilkinde ReLu, ikinci katmanda ise SoftMax aktivasyon fonksiyonundan yararlanılmıştır. Biyometrik doğrulama ya da tanıma modellerinin uygulama aşamasındaki güvenilirliğini test etmek, genelleştirme yeteneğini artırmak ve aşırı öğrenmenin önüne geçmek için validasyon testleri uygulanmıştır. Modele başvurulması sırasında eğitim verisi rasgele 10 eşit parçaya bölünmüş 10 katlamalı çapraz doğrulama yöntemiyle ortaya çıkan sonuçların ortalaması alınmıştır.

5.3 Test Sonuçları ve Analizi

Bu tez çalışması kapsamında toplanan biyometrik yüz, havada imza görüntüsü ve havada imza sinyali verileri üzerinde farklı derin öğrenme teknikleri uygulanmıştır. Bu teknikler uygulanırken öncelikle biyometrik özellikler tekil olarak değerlendirilmiştir. Yapılan testler sonucunda CNN derin öğrenme algoritması kullanılarak oluşturulan modelde imza görüntüleri üzerinde, 10 katlamalı çapraz doğrulukla ortalama %90.39 doğruluk ve %89.88 F1 skor değerlerine ulaşılmıştır. Aynı algoritmanın yüz resimlerine uygulanması sonucunda ise %92.28 doğruluk, %91.33 F1 skor değerleri ortaya çıkmıştır. Dinamik havada imza sinyallerinde ise LSTM algoritması ile %91.84 doğruluk, %91.96 F1 skor model başarısı elde edilmiştir. Aynı veri üzerine uygulanan GRU %91.22 doğruluk, %91.12 F1 skor üretirken TCN algoritması ise %91.81 doğruluk ve %90.33 F1 skor değerleriyle sonuçlanmıştır. Bu sonuçlar ve diğer metrikler aşağıdaki tabloda ayrıntılı olarak sunulmuştur (Tablo 5.1).

Tablo 5.1 Biyometrik özellikler tekil olarak değerlendirildiğinde, tek modelle alınan sonuçlar

(%)	Yöntem	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	AUC
Yüz görüntüsü	CNN	92.28	91.90	92.15	91.33	97.65
İmza görüntüsü	CNN	90.39	90.21	90.28	89.88	97.80
İmza sinyali	LSTM	91.84	91.37	91.63	91.96	98.65
	GRU	91.22	91.01	92.62	91.12	97.66
	TCN	91.81	91.68	93.29	90.33	97.73

Çalışmaya konu olan biyometrik özelliklerin birlikte kullanılmasıyla çoklu biyometrik modeller ortaya çıkarılmıştır. Bu durumun gerçekleştirilmesi için biyometrik özellikler çiftler halinde farklı derin öğrenme teknikleriyle test edilmiştir. Yüz görüntüsü ve havada imza görüntüsü giriş değerleri olarak imlemente edildiğinde CNN+CNN mimarisi kullanılmış ve %92.48 doğruluk ile %91.47 F1 skor değerlerine ulaşılmıştır (Tablo 5.2).

Tablo 5.2 İmza görüntüsü ve yüz görüntüsü sonuçları

(%)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	AUC
CNN + CNN	92.48	91.91	91.99	91.47	97.56

Havada imza sinyali ve havada imza görüntüsünün bir arada kullanılması sonucunda CNN+LSTM mimarisiyle %81.49 doğruluk, %81.64 F1 skor, CNN+GRU mimarisiyle %80.45 doğruluk, %80.59 F1 skor, CNN+TCN mimarisinin kullanılmasıyla ise %86.90 doğruluk, %87.22 F1 skor sonuçları ortaya çıkmıştır. Tüm metriklerin sonuç değerlerinden anlaşılacağı üzere çoklu biyometrik veri kullanmak her zaman başarıyı artırmamaktadır (Tablo 5.3).

Tablo 5.3 İmza görüntüsü ve imza sinyali sonuçları

(%)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	AUC
CNN + LSTM	81.49	82.01	83.23	81.64	91.09
CNN + GRU	80.45	81.04	82.06	80.59	91.14
CNN + TCN	86.90	87.18	88.48	87.22	93.17

Bu akademik çalışmada değerlendirilen en son ve en başarılı model, yüz görüntüsü ve imza sinyali biyometrik verilerinin giriş verileri olarak değerlendirmesiyle oluşturulmuştur. CNN+LSTM mimarisiyle doğruluk ve F1 skorları sırasıyla %96.22, %96.02 değerleri, CNN+GRU modeliyle %95.14 doğruluk, %94.83 F1 skor değerleri, CNN+TCN algoritmasıyla ise %98.01 doğruluk ve %97.89 F1 skor değerlerine ulaşılmıştır. Bu değerlere göre imza sinyali ve yüz görüntüsü üzerinde kullanılan algoritma ikililerinden CNN+TCN mimarisi bu çalışmadaki en başarılı sonuçları vermiştir (Tablo 5.4).

Tablo 5.4 İmza sinyali ve yüz görüntüsü sonuçları

(%)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	AUC
CNN + LSTM	96.22	96.07	96.48	96.02	98.75
CNN + GRU	95.14	94.97	95.27	94.83	98.71
CNN + TCN	98.01	97.89	98.11	97.89	98.98

6 SONUÇ

Günümüz dünyasındaki teknolojik ilerlemeler ve dijitalleşme, güvenlik ve kimlik doğrulama ihtiyaçlarını ön plana çıkarmıştır. Kişisel verilerin ve varlıkların korunması, dijital kimliklerin yönetilmesi ve güvenli erişimin sağlanması, biyometrik teknolojilerin etkin kullanımını zorunlu kılmaktadır. Pek çok biyometrik tanımlama yöntemi, benzersiz ve taklit edilmesi zor özellikler sunduğu için güvenlik sistemlerinde giderek daha fazla tercih edilmektedir. Biyometrik özelliklerin kolay alınabilir olması da verinin değerlendirilmesini kolaylaştırdığı için tercih edilebilecek özelliklerdendir. Bu bağlamda, bu tez çalışmasında geliştirilen modeller ve yapılan analizler, biyometrik doğrulama sistemlerinin daha güvenilir, etkili ve erişilebilir hale getirilmesine yönelik önemli katkılar sağlamayı hedeflemektedir. Çalışmanın en önemli motivasyonu, biyometrik verilerin basit bir sensör yardımıyla alınabilmesi, kişinin fiziksel olarak yer değiştirmesine gerek olmadan imza biyometrik verisinin doğrulanabilmesi ve birden çok biyometrik özelliğin derin öğrenme metotlarıyla birleştirilerek performansı yüksek bir biyometrik doğrulama mimarisinin geliştirilmesidir.

Araştırma dahilinde sadece basit bir kamera kullanılarak toplanan havada imza ve yüz biyometrik verileri üzerinde çoklu biyometrik derin öğrenme modelleri tekil ve çiftler halinde uygulanmıştır. Tekil biyometrik veriler giriş verisi olarak verildiğinde başarılı sayılabilecek değerler alınabilmesine rağmen birden çok biyometrik veriden yararlanıldığında performans değerlerinin çok daha tatmin edici sonuçlara ulaştığı kanıtlanmıştır. Zamana bağlı koordinat değerleri alınan dinamik havada imza verisi ile yüz görüntülerinin toplanması, CNN ve TCN derin öğrenme modellerinin uygulanması ile oluşturulan mimaride doğruluk değeri %98.01 olarak bulunmuştur. Araştırmada çıkan bulgular, çevrimiçi olarak da alınabilen havada imza biyometrisinin önümüzdeki yıllarda biyometrik bir veri olarak kullanılabileceği yönündedir. Bunun yanında biyometrik özelliklerin farklı mimarilerle birleştirilmesi sonucu çok daha yüksek performanslı mimariler ortaya çıkabilmektedir.

Araştırma sürecinde alınan imza verisi, günlük yaşamda neredeyse tüm resmi işlemlerde doğrulama aracı olarak kullanılan bir biyometrik veridir. Havada imza biyometrik verisi literatürde henüz istenen seviyeye ulaşmadığı için gönüllü bulma konusunda zaman zaman zorluklar yaşanmıştır. Bununla birlikte çalışmaya destek olan katılımcılardan bazıları gerçek imzaları yerine belirledikleri paraf imzalarını atmışlardır. Bu durum, veri güvenliğinin etik izinlerle garanti altına alınmış olmasına rağmen havada imza biyometrisi çok karşılaşılan bir veri olmadığı için karşılaşılmıştır. Havada imza alınmasıyla ilgili Python programlama dili, MP kütüphanesiyle oluşturduğumuz uygulama el üzerindeki anahtar noktaları üç boyutlu uzayda tahminlemektedir. Bu yüzden, nadir de olsa tahmin sonuçlarında küçük hatalar yaşanabilmektedir. Bu durum bazen ekranda farklı bir el belirmesi ya da bir nesnenin elin şekline benzemesinden kaynaklanmıştır. Katılımcıların yüz verileri kolayca alınabilmesine rağmen havada imza verileri konusunda kullanıcı davranışlarının analiz edilmesi için uzun bir süre testler gerçekleştirilmiştir. Bunun sonucunda, katılımcılara verilen direktiflerle kısa sürede havada imza verisi oluşturulabilmiştir. Sadece birkaç dakika alıştırma ile katılımcılardan kolayca veri alınması sağlanmıştır.

Çoklu biyometrik doğrulama, son yıllarda önemli bir yol kateden çevrimiçi platformlarda kullanıcı kimliklerinin doğrulanması için tekil biyometrik sistemlere göre daha başarılı yöntemler sunmaktadır. Birden çok biyometrik özelliğin kullanılması güvenlik seviyesini artırarak yetkisiz erişimleri kısıtlar. E-ticaret, finansal işlemler, eğitim gibi alanlarda ihtiyaç duyulan kimlik doğrulama işlemleri için alınacak biyometrik özelliklerin güvenilirliği dışında kolay alınabilmesi de önemli ve değerlidir. Çoklu biyometrik modeller, günümüzde yapılan çevrimiçi toplantılar, eğitimdeki ders ve sınavlar, bankacılık işlemleri gibi faaliyetlerin doğrulama problemlerini çözülebilecek potansiyeli barındırmaktadır.

Bu çalışma kapsamında, katılımcılardan ekran önünde veri almadan önce kağıt üzerinde, her katılımcı için beşer adet fiziksel imza toplanmıştır. Öncelikli amaç bu verinin geniş kapsamlı olarak kullanıma hazır hale getirilmesidir. Ayrıca, önümüzdeki dönemde, havada imzalarla fiziksel imzaların birleştirilmesi ve havada imzanın geçerliliğinin ölçülmesi adına yeni bir akademik çalışma için gerekli veriler toplanmıştır. Bu çalışmayla, fiziksel imzanın yerini havada imzaya bırakma potansiyelinin değerlendirilmesi hedeflenmektedir.

Havada imza ve yüz verilerinin çevrimiçi olarak toplanmasıyla yapılan doğrulama işlemi bu verilerin bir qr koda çevrilmesi ile değerlendirilebilecektir. Uygulanabilecek bir diğer çalışma da toplanan verilerin qr kod şeklinde bir dokümana aktarılmasıdır. Böylece imza yerine bir kamerayla alınan verilerin belge

üzerinde doğrulamasının yapılması hedeflenmektedir.

Yine üzerinde durulabilecek bir başka uygulama da son zamanlarda birçok akademik çalışmada kullanılan sanal gerçeklik ve artırılmış gerçeklik cihazlarıyla uzaktan havada imza atılması üzerine çalışmalardır. Bu uygulamalar için tasarlanmış cihazlardaki birden çok kamera ile havada imzanın 3B olarak alınması daha yüksek performansla gerçekleştirilebilir.



- [1] Flaticon, *Flaticon*, <https://www.flaticon.com/>.
- [2] A. Jain, R. Bolle, S. Pankanti, "Introduction to biometrics," *Biometrics*, pp. 1–41, 1996. doi: 10.1007/0-306-47044-6_1.
- [3] A. Bertillon, R. W. McClaughry, *Signaletic instructions including the theory and practice of anthropometrical identification*. Werner Company, 1896.
- [4] W. J. Herschel, "Skin furrows of the hand," *Nature*, vol. 23, no. 578, pp. 76–76, 1880. doi: 10.1038/023076b0.
- [5] F. Galton, "Personal identification and description," *The Journal of the Anthropological Institute of Great Britain and Ireland*, vol. 18, p. 177, 1889. doi: 10.2307/2842415.
- [6] H. Faulds, "On the skin-furrows of the hand," *Nature*, vol. 22, no. 574, pp. 605–605, 1880. doi: 10.1038/022605a0.
- [7] M. Trauring, "Automatic comparison of finger-ridge patterns," *Nature*, vol. 197, no. 4871, pp. 938–940, 1963. doi: 10.1038/197938a0.
- [8] R. P. Wildes *et al.*, "A machine-vision system for iris recognition," *Mach Vis Appl*, vol. 9, no. 1, pp. 1–8, 1996. doi: 10.1007/BF01246633/METRICS.
- [9] R. P. Wildes, "Iris recognition: An emerging biometric technology," *Proceedings of the IEEE*, vol. 85, no. 9, pp. 1348–1363, 1997. doi: 10.1109/5.628669.
- [10] L. G. Kersta, "Voiceprint identification," *J Acoust Soc Am*, vol. 34, no. 5_Supplement, pp. 725–725, May 1962. doi: 10.1121/1.1937211.
- [11] G. R. Doddington, "Speaker recognition—identifying people by their voices," *Proceedings of the IEEE*, vol. 73, no. 11, pp. 1651–1664, 1985. doi: 10.1109/PROC.1985.13345.
- [12] R. Sanchez-Reillo, C. Sanchez-Avila, A. Gonzalez-Marcos, "Biometric identification through hand geometry measurements," *IEEE Trans Pattern Anal Mach Intell*, vol. 22, no. 10, pp. 1168–1178, Jan. 2000. doi: 10.1109/34.879796.
- [13] A. Mauceri, *Feasibility study of personnel identification by signature verification*. Display Techniques Branch, Rome Air Development Center, Research and ..., 1965.
- [14] D. D. Zhang, "Other behavioral biometrics," pp. 227–241, 2000. doi: 10.1007/978-1-4615-4519-4_11.

- [15] C. Keskin, F. Kirac, Y. E. Kara, L. Akarun, "Hand pose estimation and hand shape classification using multi-layered randomized decision forests," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 7577 LNCS, no. PART 6, pp. 852–863, 2012. doi: 10.1007/978-3-642-33783-3_61/COVER.
- [16] C. Ma, A. Wang, G. Chen, C. Xu, "Hand joints-based gesture recognition for noisy dataset using nested interval unscented kalman filter with lstm network," *Visual Computer*, vol. 34, no. 6–8, pp. 1053–1063, Jan. 2018. doi: 10.1007/S00371-018-1556-0/FIGURES/4.
- [17] B. Arazi, "Automatic handwriting identification based on the external properties of the samples," *IEEE Trans Syst Man Cybern*, vol. SMC-13, no. 4, pp. 635–642, 1983. doi: 10.1109/TSMC.1983.6313153.
- [18] K. P. Zimmermann, M. J. Varady, "Handwriter identification from one-bit quantized pressure patterns," *Pattern Recognit*, vol. 18, no. 1, pp. 63–72, Jan. 1985. doi: 10.1016/0031-3203(85)90007-X.
- [19] C. F. Lam, D. Kamins, "Signature recognition through spectral analysis," *Pattern Recognit*, vol. 22, no. 1, pp. 39–44, Jan. 1989. doi: 10.1016/0031-3203(89)90036-8.
- [20] A. Burnett, A. Duffy, T. Dowling, "A biometric identity based signature scheme," *Cryptology ePrint Archive*, 2004.
- [21] M. M. Hameed, R. Ahmad, M. L. M. Kiah, G. Murtaza, "Machine learning-based offline signature verification systems: A systematic review," *Signal Process Image Commun*, vol. 93, p. 116 139, Apr. 2021. doi: 10.1016/J.IMAGE.2021.116139.
- [22] S. Khan, D. K. Singh, M. Singh, D. F. Mena, "Automatic signature verifier using gaussian gated recurrent unit neural network," *IET Biom*, vol. 2023, pp. 1–12, Nov. 2023. doi: 10.1049/2023/5087083.
- [23] C. Gonzalez-Garcia, R. Tolosana, R. Vera-Rodriguez, J. Fierrez, J. Ortega-Garcia, "Introduction to presentation attacks in signature biometrics and recent advances," in *Advances in Computer Vision and Pattern Recognition*, 2023, pp. 447–466. doi: 10.1007/978-981-19-5288-3_16/COVER.
- [24] S. Impedovo, G. Pirlo, "Verification of handwritten signatures: An overview," 2007.
- [25] D. Impedovo, G. Pirlo, "Automatic signature verification: The state of the art," *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, vol. 38, no. 5, pp. 609–635, 2008. doi: 10.1109/TSMCC.2008.923866.
- [26] D. Impedovo, G. Pirlo, "On-line signature verification by stroke-dependent representation domains," in *Proceedings - 12th International Conference on Frontiers in Handwriting Recognition, ICFHR 2010*, 2010, pp. 623–627. doi: 10.1109/ICFHR.2010.102.

- [27] A. Sharma, S. Sundaram, "An enhanced contextual dtw based system for online signature verification using vector quantization," *Pattern Recognit Lett*, vol. 84, pp. 22–28, Dec. 2016. doi: 10.1016/J.PATREC.2016.07.015.
- [28] A. Sharma, S. Sundaram, "A novel online signature verification system based on gmm features in a dtw framework," *IEEE Transactions on Information Forensics and Security*, vol. 12, no. 3, pp. 705–718, Mar. 2017. doi: 10.1109/TIFS.2016.2632063.
- [29] I. Bhattacharya, P. Ghosh, S. Biswas, "Offline signature verification using pixel matching technique," *Procedia Technology*, vol. 10, pp. 970–977, Jan. 2013. doi: 10.1016/J.PROTCY.2013.12.445.
- [30] L. Tang, W. Kang, Y. Fang, "Information divergence-based matching strategy for online signature verification," *IEEE Transactions on Information Forensics and Security*, vol. 13, no. 4, pp. 861–873, Apr. 2018. doi: 10.1109/TIFS.2017.2769023.
- [31] M. Okawa, "Online signature verification using single-template matching with time-series averaging and gradient boosting," *Pattern Recognit*, vol. 102, p. 107227, Jun. 2020. doi: 10.1016/J.PATCOG.2020.107227.
- [32] D. Muramatsu, T. Matsumoto, "Effectiveness of pen pressure, azimuth, and altitude features for online signature verification," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 4642 LNCS, 2007, pp. 503–512. doi: 10.1007/978-3-540-74549-5_53/COVER.
- [33] M. Mailah, B. H. Lim, "Biometric signature verification using pen position, time, velocity and pressure parameters," 2008.
- [34] M. S. Sadak, N. Kahraman, U. Uludag, "Handwritten signature verification system using sound as a feature," in *2020 43rd International Conference on Telecommunications and Signal Processing, TSP 2020*, Jul. 2020, pp. 365–368. doi: 10.1109/TSP49548.2020.9163442.
- [35] J. H. Jeon, B. S. Oh, K. A. Toh, "A system for hand gesture based signature recognition," in *2012 12th International Conference on Control, Automation, Robotics and Vision, ICARCV 2012*, 2012, pp. 171–175. doi: 10.1109/ICARCV.2012.6485153.
- [36] A. Takeuchi, Y. Manabe, K. Sugawara, "Multimodal soft biometric verification by hand shape and handwriting motion in the air," in *2013 International Joint Conference on Awareness Science and Technology & Ubi-Media Computing (iCAST 2013 & UMEDIA 2013)*, IEEE, 2013, pp. 103–109.
- [37] N. N. Diep, C. Pham, T. M. Phuong, "Sigver3d: Accelerometer based verification of 3-d signatures on mobile devices," *Advances in Intelligent Systems and Computing*, vol. 326, pp. 353–365, 2015. doi: 10.1007/978-3-319-11680-8_28/COVER.

- [38] H. Sajid, S. C. S. Cheung, "Vsig: Hand-gestured signature recognition and authentication with wearable camera," in *2015 IEEE International Workshop on Information Forensics and Security, WIFS 2015 - Proceedings*, Dec. 2015. doi: 10.1109/WIFS.2015.7368566.
- [39] Y. Fang, W. Kang, Q. Wu, L. Tang, "A novel video-based system for in-air signature verification," *Computers and Electrical Engineering*, vol. 57, pp. 1–14, Jan. 2017. doi: 10.1016/J.COMPELECENG.2016.11.010.
- [40] J. Malik, A. Elhayek, S. Ahmed, F. Shafait, M. I. Malik, D. Stricker, "3dairsig: A framework for enabling in-air signatures using a multi-modal depth sensor," *Sensors 2018*, vol. 18, no. 11, p. 3872, Nov. 2018. doi: 10.3390/S18113872.
- [41] J. Malik, A. Elhayek, S. Guha, S. Ahmed, A. Gillani, D. Stricker, "Deepairsig: End-to-end deep learning based in-air signature verification," *IEEE Access*, vol. 8, pp. 195 832–195 843, 2020. doi: 10.1109/ACCESS.2020.3033848.
- [42] W. H. Khoh, Y. H. Pang, A. B. J. Teoh, "In-air hand gesture signature recognition system based on 3-dimensional imagery," *Multimed Tools Appl*, vol. 78, no. 6, pp. 6913–6937, Mar. 2019. doi: 10.1007/S11042-018-6458-7/TABLES/7.
- [43] E. Guerra-Segura, A. Ortega-Pérez, C. M. Travieso, "In-air signature verification system using leap motion," *Expert Syst Appl*, vol. 165, p. 113 797, Mar. 2021. doi: 10.1016/J.ESWA.2020.113797.
- [44] G. Bailador, C. Sanchez-Avila, J. Guerra-Casanova, A. De Santos Sierra, "Analysis of pattern recognition techniques for in-air signature biometrics," *Pattern Recognit*, vol. 44, no. 10–11, pp. 2468–2478, Oct. 2011. doi: 10.1016/J.PATCOG.2011.04.010.
- [45] S. K. Behera, A. K. Dash, D. P. Dogra, P. P. Roy, "Air signature recognition using deep convolutional neural network-based sequential model," in *Proceedings - International Conference on Pattern Recognition*, vol. 2018-August, Nov. 2018, pp. 3525–3530. doi: 10.1109/ICPR.2018.8546265.
- [46] L. W. Chiu, J. W. Hsieh, C. R. Lai, H. F. Chiang, S. C. Cheng, K. C. Fan, "Person authentication by air-writing using 3d sensor and time order stroke context," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11010 LNCS, 2018, pp. 260–273. doi: 10.1007/978-3-030-04375-9_22/TABLES/7.
- [47] B. Moghaddam, T. Jebara, A. Pentland, "Bayesian face recognition," *Pattern Recognit*, vol. 33, no. 11, pp. 1771–1782, Nov. 2000. doi: 10.1016/S0031-3203(99)00179-X.
- [48] G. Guo, S. Z. Li, K. Chan, "Face recognition by support vector machines," in *Proceedings - 4th IEEE International Conference on Automatic Face and Gesture Recognition, FG 2000*, 2000, pp. 196–201. doi: 10.1109/AFGR.2000.840634.

- [49] A. V. Nefian, M. H. Hayes, “Hidden markov models for face recognition,” in *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, vol. 5, 1998, pp. 2721–2724. doi: 10.1109/ICASSP.1998.678085.
- [50] J. W. Tanaka, J. A. Sengco, “Features and their configuration in face recognition,” *Mem Cognit*, vol. 25, no. 5, pp. 583–592, 1997. doi: 10.3758/BF03211301/METRICS.
- [51] W. Zhao, A. Krishnaswamy, R. Chellappa, D. L. Swets, J. Weng, “Discriminant analysis of principal components for face recognition,” in *Face Recognition*, 1998, pp. 73–85. doi: 10.1007/978-3-642-72201-1_4.
- [52] T. Ahonen, A. Hadid, M. Pietikäinen, “Face description with local binary patterns: Application to face recognition,” *IEEE Trans Pattern Anal Mach Intell*, vol. 28, no. 12, pp. 2037–2041, 2006. doi: 10.1109/TPAMI.2006.244.
- [53] M. T. Posamentier, H. Abdi, “Processing faces and facial expressions,” *Neuropsychol Rev*, vol. 13, no. 3, pp. 113–143, Sep. 2003. doi: 10.1023/A:1025519712569/METRICS.
- [54] A. J. Calder, A. M. Burton, P. Miller, A. W. Young, S. Akamatsu, “A principal component analysis of facial expressions,” *Vision Res*, vol. 41, no. 9, pp. 1179–1208, Apr. 2001. doi: 10.1016/S0042-6989(01)00002-5.
- [55] G. Tonguç, B. Ozaydın Ozkara, “Automatic recognition of student emotions from facial expressions during a lecture,” *Comput Educ*, vol. 148, p. 103797, Apr. 2020. doi: 10.1016/J.COMPEDU.2019.103797.
- [56] D. O. Melinte, L. Vladareanu, “Facial expressions recognition for human–robot interaction using deep convolutional neural networks with rectified adam optimizer,” *Sensors 2020, Vol. 20, Page 2393*, vol. 20, no. 8, p. 2393, Apr. 2020. doi: 10.3390/S20082393.
- [57] J. Zhao, S. Yan, J. Feng, “Towards age-invariant face recognition,” *IEEE Trans Pattern Anal Mach Intell*, vol. 44, no. 1, pp. 474–487, Jan. 2022. doi: 10.1109/TPAMI.2020.3011426.
- [58] A. A. Moustafa, A. Elnakib, N. F. F. Areed, “Age-invariant face recognition based on deep features analysis,” *Signal Image Video Process*, vol. 14, no. 5, pp. 1027–1034, Jul. 2020. doi: 10.1007/S11760-020-01635-1/FIGURES/6.
- [59] O. M. Parkhi, A. Vedaldi, A. Zisserman, “Deep face recognition,” *BMVC 2015 - Proceedings of the British Machine Vision Conference 2015*, 2015.
- [60] Y. Wen, K. Zhang, Z. Li, Y. Qiao, “A discriminative feature learning approach for deep face recognition,” *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9911 LNCS, pp. 499–515, 2016. doi: 10.1007/978-3-319-46478-7_31/TABLES/4.

- [61] Y. Sun, D. Liang, X. Wang, X. Tang, "Deepid3: Face recognition with very deep neural networks," *Feb. 2015*, Accessed: 1 22, 2024. [Online]. Available: <https://arxiv.org/abs/1502.00873v1>,
- [62] Y. Sun, Y. Chen, X. Wang, X. Tang, "Deep learning face representation by joint identification-verification," *Adv Neural Inf Process Syst*, vol. 27, 2014.
- [63] F. Schroff, D. Kalenichenko, J. Philbin, "Facenet: A unified embedding for face recognition and clustering," pp. 815–823, 2015.
- [64] Y. Taigman, M. Y. Marc', A. Ranzato, L. Wolf, "Deepface: Closing the gap to human-level performance in face verification," pp. 1701–1708, 2014.
- [65] Q. Cao, L. Shen, W. Xie, O. M. Parkhi, A. Zisserman, "Vggface2: A dataset for recognising faces across pose and age," *Proceedings - 13th IEEE International Conference on Automatic Face and Gesture Recognition, FG 2018*, pp. 67–74, Jun. 2018. doi: 10.1109/FG.2018.00020.
- [66] K. Sohn, "Improved deep metric learning with multi-class n-pair loss objective," *Adv Neural Inf Process Syst*, vol. 29, 2016.
- [67] A. A. Ross, R. Govindarajan, "Feature level fusion of hand and face biometrics," in <https://doi.org/10.1117/12.606093>, vol. 5779, Mar. 2005, pp. 196–204. doi: 10.1117/12.606093.
- [68] M. M. Monwar, M. Gavrilova, "Fes: A system for combining face, ear and signature biometrics using rank level fusion," in *Proceedings - International Conference on Information Technology: New Generations, ITNG 2008*, 2008, pp. 922–927. doi: 10.1109/ITNG.2008.254.
- [69] M. M. Monwar, M. L. Gavrilova, "Multimodal biometric system using rank-level fusion approach," *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 39, no. 4, pp. 867–878, 2009. doi: 10.1109/TSMCB.2008.2009071.
- [70] A. Nagar, K. Nandakumar, A. K. Jain, "Multibiometric cryptosystems based on feature-level fusion," *IEEE transactions on information forensics and security*, vol. 7, no. 1, pp. 255–268, 2011.
- [71] X. Y. Jing *et al.*, "Palmprint and face multi-modal biometric recognition based on sda-gsvd and its kernelization," *Sensors 2012, Vol. 12, Pages 5551-5571*, vol. 12, no. 5, pp. 5551–5571, Apr. 2012. doi: 10.3390/S120505551.
- [72] P. P. Paul, M. L. Gavrilova, R. Alhajj, "Decision fusion for multimodal biometrics using social network analysis," *IEEE Trans Syst Man Cybern Syst*, vol. 44, no. 11, pp. 1522–1533, Nov. 2014. doi: 10.1109/TSMC.2014.2331920.
- [73] V. Talreja, M. C. Valenti, N. M. Nasrabadi, "Multibiometric secure system based on deep learning," *2017 IEEE Global Conference on Signal and Information Processing, GlobalSIP 2017 - Proceedings*, vol. 2018-January, pp. 298–302, Mar. 2018. doi: 10.1109/GLOBALSIP.2017.8308652.
- [74] P. Gupta, P. Gupta, "Multibiometric authentication system using slap fingerprints, palm dorsal vein, and hand geometry," *IEEE Transactions on Industrial Electronics*, vol. 65, no. 12, pp. 9777–9784, Dec. 2018. doi: 10.1109/TIE.2018.2823686.

- [75] F. Bahmed, M. O. Mammar, "A survey on hand modalities and hand multibiometric systems," *Lecture Notes in Intelligent Transportation and Infrastructure*, vol. Part F1409, pp. 73–88, 2020. doi: 10.1007/978-3-030-37629-1_7/COVER.
- [76] V. Talreja, M. C. Valenti, N. M. Nasrabadi, "Deep hashing for secure multimodal biometrics," *IEEE Transactions on Information Forensics and Security*, vol. 16, pp. 1306–1321, 2021. doi: 10.1109/TIFS.2020.3033189.
- [77] T. C. Sabareeswari, M. S. L. Stuart, "Identification of a person using multimodal biometric system," *International Journal of Computer Applications IJCA*, vol. 3, no. 9, pp. 12–16, Jul. 2010. doi: 10.5120/769-1077.
- [78] A. Aftab, F. A. Khan, M. K. Khan, H. Abbas, W. Iqbal, F. Riaz, "Hand-based multibiometric systems: State-of-the-art and future challenges," *PeerJ Comput Sci*, vol. 7, e707, Oct. 2021. doi: 10.7717/PEERJ-CS.707/TABLE-9.
- [79] P. Byahatti, M. S. Shettar, H. M. Therar, L. E. A. Mohammed, A. A. J. Ali, "Multibiometric system for iris recognition based convolutional neural network and transfer learning," *IOP Conf Ser Mater Sci Eng*, vol. 1105, no. 1, p. 012032, Jun. 2021. doi: 10.1088/1757-899X/1105/1/012032.
- [80] J. Khodadoust, M. A. Medina-Pérez, R. Monroy, A. M. Khodadoust, S. S. Mirkamali, "A multibiometric system based on the fusion of fingerprint, finger-vein, and finger-knuckle-print," *Expert Syst Appl*, vol. 176, p. 114687, Aug. 2021. doi: 10.1016/J.ESWA.2021.114687.
- [81] V. T. Jay, T. Vijayakumar, "Synthesis of palm print in feature fusion techniques for multimodal biometric recognition system online signature," *Article in Journal of Innovative Image Processing*, 2021. doi: 10.36548/jiip.2021.2.005.
- [82] G. Cervino, "Multibiometric system based on face video and heart rate estimation," in *Proceedings - 9th International Workshop on Biometrics and Forensics, IWBIF 2021*, May 2021. doi: 10.1109/IWBIF50991.2021.9465081.
- [83] T. Kovaliuk, A. Shevchenko, N. Kobets, "Multibiometric identification of the student by his voice and visual biometric indicators in the process of distance education," *Digital Platform Information Technologies in Socio-cultural Sphere*, vol. 5, no. 1, pp. 90–102, Jun. 2022. doi: 10.31866/2617-796X.5.1.2022.261293.
- [84] M. S. Sadak, N. Kahraman, U. Uludağ, "Dynamic and static feature fusion for increased accuracy in signature verification," *Signal Process Image Commun*, vol. 108, p. 116823, Oct. 2022. doi: 10.1016/J.IMAGE.2022.116823.

- [85] Y. Wang, D. Shi, W. Zhou, "Convolutional neural network approach based on multimodal biometric system with fusion of face and finger vein features," *Sensors* 2022, Vol. 22, Page 6039, vol. 22, no. 16, p. 6039, Aug. 2022. doi: 10.3390/S22166039.
- [86] M. Singhal, K. Shinghal, "Secure deep multimodal biometric authentication using online signature and face features fusion," *Multimed Tools Appl*, pp. 1–20, Sep. 2023. doi: 10.1007/S11042-023-16683-1/FIGURES/10.
- [87] M. Turk, A. Pentland, "Eigenfaces for recognition," *J Cogn Neurosci*, vol. 3, no. 1, pp. 71–86, Jan. 1991. doi: 10.1162/JOCN.1991.3.1.71.
- [88] A. Martinez, "Fisherfaces," *Scholarpedia*, vol. 6, no. 2, p. 4282, 2011. doi: 10.4249/SCHOLARPEDIA.4282.
- [89] M. Pietikäinen, "Local binary patterns," *Scholarpedia*, vol. 5, no. 3, p. 9775, 2010. doi: 10.4249/SCHOLARPEDIA.9775.
- [90] P. Viola, M. Jones, "Rapid object detection using a boosted cascade of simple features," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 1, 2001. doi: 10.1109/CVPR.2001.990517.
- [91] K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biol Cybern*, vol. 36, no. 4, pp. 193–202, Apr. 1980. doi: 10.1007/BF00344251/METRICS.
- [92] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2323, 1998. doi: 10.1109/5.726791.
- [93] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in Neural Information Processing Systems*, vol. 25, 2012. doi: 10.1145/3065386.
- [94] K. Simonyan, A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, Sep. 2014. doi: 10.1109/ICCV.2015.123.
- [95] C. Szegedy *et al.*, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1–9.
- [96] K. He, X. Zhang, S. Ren, J. Sun, "Deep residual learning for image recognition," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2016, pp. 770–778, Dec. 2015. doi: 10.1109/CVPR.2016.90.
- [97] A. G. Howard *et al.*, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," Apr. 2017. doi: 10.1109/CVPR.2017.182.

- [98] M. Tan, Q. V. Le, “Efficientnet: Rethinking model scaling for convolutional neural networks,” *36th International Conference on Machine Learning, ICML 2019*, vol. 2019, pp. 10 691–10 700, May 2019. doi: 10 . 1109 / ICML . 2019 . 118.
- [99] S. Hochreiter, J. Schmidhuber, “Long short-term memory,” *Neural Comput*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997. doi: 10 . 1162 / NECO . 1997 . 9 . 8 . 1735.
- [100] D. E. Rumelhart, G. E. Hinton, R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, 1986. doi: 10 . 1038 / 323533a0.
- [101] C. Olah, *Understanding lstm networks – colah’s blog*, Accessed: 4 24, 2024, 2015. [Online]. Available: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [102] K. Cho, B. van Merriënboer, D. Bahdanau, Y. Bengio, “On the properties of neural machine translation: Encoder-decoder approaches,” in *Proceedings of SSST 2014 - 8th Workshop on Syntax, Semantics and Structure in Statistical Translation*, Sep. 2014, pp. 103–111. doi: 10 . 3115 / v1 / w14 - 4012.
- [103] T. Toharudin, R. S. Pontoh, R. E. Caraka, S. Zahroh, Y. Lee, R. C. Chen, “Employing long short-term memory and facebook prophet model in air temperature forecasting,” *Commun Stat Simul Comput*, vol. 52, no. 2, pp. 279–290, 2023. doi: 10 . 1080 / 03610918 . 2020 . 1854302.
- [104] C. Lea, R. Vidal, A. Reiter, G. D. Hager, “Temporal convolutional networks: A unified approach to action segmentation,” in *Lecture Notes in Computer Science*, vol. 9915, 2016, pp. 47–54. doi: 10 . 1007 / 978 - 3 - 319 - 49409 - 8_7.
- [105] K. M. Sagayam, D. J. Hemanth, “Hand posture and gesture recognition techniques for virtual reality applications: A survey,” *Virtual Real*, vol. 21, no. 2, pp. 91–107, Jun. 2017. doi: 10 . 1007 / S10055 - 016 - 0301 - 0 / TABLES / 8.
- [106] J. N. Voigt-Antons, T. Kojic, D. Ali, S. Moller, “Influence of hand tracking as a way of interaction in virtual reality on user experience,” in *2020 12th International Conference on Quality of Multimedia Experience, QoMEX 2020*, May 2020. doi: 10 . 1109 / QOMEX48832 . 2020 . 9123085.
- [107] D. Xu, “A neural network approach for hand gesture recognition in virtual reality driving training system of spg,” in *18th International Conference on Pattern Recognition (ICPR’06)*, IEEE, vol. 3, 2006, pp. 519–522.
- [108] S. Reifinger, F. Wallhoff, M. Ablasmeier, T. Poitschke, G. Rigoll, “Static and dynamic hand-gesture recognition for augmented reality applications,” *Lecture Notes in Computer Science*, vol. 4552, no. PART 3, pp. 728–737, 2007. doi: 10 . 1007 / 978 - 3 - 540 - 73110 - 8_79 / COVER.
- [109] M. M. Damaneh, F. Mohanna, P. Jafari, “Static hand gesture recognition in sign language based on convolutional neural network with feature extraction method using orb descriptor and gabor filter,” *Expert Syst Appl*, vol. 211, p. 118 559, Jan. 2023. doi: 10 . 1016 / J . ESWA . 2022 . 118559.

- [110] Z. Cao, T. Simon, S.-E. Wei, Y. Sheikh, “Realtime multi-person 2d pose estimation using part affinity fields,” 2017. doi: 10.1109/CVPR.2017.882.
- [111] C. Lugaresi *et al.*, “Mediapipe: A framework for building perception pipelines,” Jun. 2019. [Online]. Available: <https://arxiv.org/abs/1906.08172v1>.
- [112] C. Lugaresi *et al.*, *Mediapipe: A framework for perceiving and processing reality*, 2024. [Online]. Available: <https://github.com/google/mediapipe>.
- [113] F. Zhang *et al.*, “Mediapipe hands: On-device real-time hand tracking,” Jun. 2020. [Online]. Available: <https://arxiv.org/abs/2006.10214v1>.
- [114] F. Weichert, D. Bachmann, B. Rudak, D. Fisseler, “Analysis of the accuracy and robustness of the leap motion controller,” *Sensors 2013, Vol. 13, Pages 6380-6393*, vol. 13, no. 5, pp. 6380–6393, May 2013. doi: 10.3390/S130506380.
- [115] L. E. Potter, J. Araullo, L. Carter, “The leap motion controller: A view on sign language,” in *Proceedings of the 25th Australian Computer-Human Interaction Conference: Augmentation, Application, Innovation, Collaboration, OzCHI 2013*, 2013, pp. 175–178. doi: 10.1145/2541016.2541072.
- [116] Google, *Hand landmarker - mediapipe solutions*, Google Developers, Accessed: 01.02.2024. [Online]. Available: https://developers.google.com/mediapipe/solutions/vision/hand_landmarker.

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. Salturk, S., Kahraman N. "Deep learning-powered multimodal biometric authentication: integrating dynamic signatures and facial data for enhanced online security" Neural Computing & Applications (2024). <https://link.springer.com/article/10.1007/s00521-024-09690-2>

Konferans Bildirisi

1. Salturk, S., Kahraman, N. "A Paradigm Shift in Signature Processes: In-Air Digital Signatures" 9th International European Conference On Interdisciplinary Scientific Research, held on January 19-21, 2024 / Valencia, Spain organised by Universitat de València & IKSAD Institute.