



**T.C.
HALIÇ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

El Damar İzi Kullanarak Kimlik Tespiti

YÜKSEK LİSANS TEZİ

**Hazırlayan
Masoumeh ZEHTAB NAYEBİ**

**Danışman
Dr.Öğr. Üyesi Zeynep TURGUT**

İstanbul - 2020

**T.C.
HALIÇ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

El Damar İzi Kullanarak Kimlik Tespiti

YÜKSEK LİSANS TEZİ

**Hazırlayan
Masoumeh ZEHTAB NAYEBİ**

**Danışman
Dr.Öğr. Üyesi Zeynep TURGUT**

İstanbul 2020

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Bilgisayar Mühendisliği Anabilim Dalı Dalı Tezli Yüksek Lisans Programı Öğrencisi Masoumeh ZEHTAB NAYEBİ tarafından hazırlanan “*El Damar İzi Kullanarak Kimlik Tespiti*” konulu çalışması jürimizce Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 07.02.2020

(Jüri Üyesinin Ünvanı, Adı, Soyadı ve Kurumu):

İmzası

Jüri Üyesi : Dr. Öğr. Üyesi Zeynep TURGUT
: Haliç Üniversitesi (Danışman)

Jüri Üyesi : Prof. Dr. Mübariz EMİNLİ
: Haliç Üniversitesi

Jüri Üyesi : Doç. Dr. Muhammed Ali AYDIN
: İstanbul Üniversitesi - Cerrahpaşa

Bu tez Enstitü Yönetim Kurulunca belirlenen yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulunun kararıyla kabul edilmiştir.

Prof. Dr. M.Burcu IRMAK YAZICIOĞLU
Vekil Müdür

El Damar İzi Kullanarak Kimlik Tespiti

ORIJINALLIK RAPORU

% **14**

BENZERLİK ENDEKSİ

% **8**

İNTERNET
KAYNAKLARI

% **6**

YAYINLAR

% **13**

ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

- 1** Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) % **1**
Öğrenci Ödevi
- 2** www.ibrahimcayiroglu.com % **1**
İnternet Kaynağı
- 3** Mehmet Kara, Kamil Dimililer. "Bleeding Detection in Retinal Images Using Image Processing", 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), 2018 % **1**
Yayın
- 4** Submitted to Eskisehir Osmangazi University % **1**
Öğrenci Ödevi
- 5** iaesjournal.com % **1**
İnternet Kaynağı
- 6** Submitted to Düzce Üniversitesi % **1**
Öğrenci Ödevi
- 7** Submitted to Istanbul Aydın University % **1**
Öğrenci Ödevi

Dr. Öğretim Üyesi
Zeynep TURGUT
Görzelli

10/01/2020

TEZ ETİK BEYANI

Yüksek Lisans Tezi olarak sunduğum “El Damar İzi Kullanarak Kimlik Tespiti” başlıklı bu çalışmayı baştan sona kadar danışmanım Dr. Öğr. Üyesi Zeynep TURGUT 'un sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Masoumeh ZEHTAB NAYEBİ



ÖNSÖZ

Bu çalışma 2019 – 2020 yılları arasında T.C. Haliç Üniversitesi Bilgisayar Mühendisliği Bölümü'nün bilimsel araştırma ve uygulama çalışmalarına verdiği destek ile hazırlanmıştır.

Tez çalışmamda konunun belirlenmesi ve tamamlanması süresince büyük bir gayret ve özveriyle çalışmamı takip eden, gösterdiği sabır ve hoşgörüsü bana destek olan tez danışmanım Sayın Dr. Öğr. Üyesi Zeynep TURGUT'a çok teşekkür ederim. Yüksek lisans eğitimim süresince yardımlarını benden esirgemeyen Prof. Dr. Mübariz EMİNLİ'ye ayrıca teşekkürlerimi sunarım.

Ayrıca ailem ve arkadaşlarım özellikle sevgili babam Alireza ZEHTAB NAYEBİ ve sevgili annem Maryam ZEHTAB NEYABİ'ye sonsuz teşekkür ederim.

İstanbul 2020

Masoume ZEHTAB NAYEBİ

İÇİNDEKİLER

Sayfa No.

TEZ ETİK BEYANI	iii
ÖNSÖZ	iv
İÇİNDEKİLER	I
KISALTAMALAR	III
ŞEKİLLER	IV
ÇİZELGELER	VI
ÖZET	VII
ABSTRACT	VIII
1. GİRİŞ	1
2. BİYOMETRİK SİSTEMLER	2
2.1. Biyometrik Sistem Türleri.....	3
2.2. El Sırtı Damar İzi Tanımlamaya Dayalı Biyometrik Sistem Tasarım Çalışmaları	8
3. GEREÇ VE YÖNTEM	9
3.1. Görüntüleme Aşaması.....	9
3.1.1. Veri Kümesi	10
3.1.2. Veri Sayısının Arttırılması	10
3.2. Ön İşlem Aşaması	11
3.2.1. İstenilen Alanın Çıkarılması ve Arka Plan Kaldırma	12
3.2.2. Görüntü Netliğinin Arttırılması.....	12
3.2.2.1. Ortanca Filtresi.....	12
3.2.3. Görüntünün Bölümlenmesi	13
3.2.3.1. Matematiksel Morfoloji	13
3.2.4. Kenar Algoritmaları	16

	Sayfa No.
3.2.5. İskelet Çıkarımı.....	17
3.3. Özellik Çıkarma	17
3.3.1. Dalgacık Dönüşümü.....	18
3.4. Entropi.....	18
3.5. Varyans	19
4. MAKİNE ÖĞRENMESİ TEKNİKLERİ	20
4. 1. Karar Destek Makineleri (Support Vector Machine – SVM).....	21
4. 2. Doğrusal Ayraç Analizi (Linear Discriminant Analysis – LDA)	22
4.2.1. K En Yakın Komşu (K Nearest Neighbors - KNN).....	24
4. 3. Yapay Sinir Ağları (Artificial Neural Network – ANN)	24
4. 4. Evrişimsel Sinir Ağları (Convolutional Neural Network – CNN).....	26
4.5. Performans Değerlendirme Metrikleri	27
5. BULGULAR VE TARTIŞMA	30
6. SONUÇLAR	37
7. KAYNAKLAR	38
8. ÖZGEÇMİŞ.....	40

KISALTMALAR

ANN : Artificial Neural Networks (Yapay Sinir Ağları)

CNN : Convolutional Neural Network (Evrşimsel Sinir Ađı)

FN : False Negative (Yanlıř Negatif)

FP : False Positive (Yanlıř Pozitif)

KNN : K Nearest Neighbors (K En Yakın Komřu)

LDA : Linear Discriminant Analysis (Dođrusal Ayraç Analizi)

SVM : Support Vector Machine (Karar Destek Makineleri)

TN : True Negative (Dođru Negatif)

TP : True Positive (Dođru Pozitif)

ŞEKİLLER

Sayfa No.

Şekil 2.1. Parmak izi çıkıntısı	3
Şekil 2.2. Göz iris tanımlamaya ait temsili görüntü.....	4
Şekil 2.3. Retina görünüşüne ait temsili görüntü.....	4
Şekil 2.4. El ve parmak geometrisine dayalı nitelik çıkarma aşaması.....	5
Şekil 3.1. İlgili görüntüleme modülü ve elde edilmiş el sırtı fotoğrafı.....	10
Şekil 3.2. Birkaç pikselde Ortanca Filtre çalışması	13
Şekil 3.3. Genleşme işlemi	14
Şekil 3.4. Piksellerde genleşme işlemi.....	14
Şekil 3.5. Erozyon işlemi.....	15
Şekil 3.6. Piksellerde genleşme işlemi.....	15
Şekil 3.7. Açma işlemi	16
Şekil 3.8. Kapatma işlemi	16
Şekil 3.9. İskelet görüntüdür.....	17
Şekil 4.1. SVM performansı	21
Şekil 4.2. Düz bir çizgide iki değişken arasındaki ilişki.....	22
Şekil 4.3. LDA'nin sınıflamasına göre düz çizgide iki değişken arasındaki ilişki.....	23
Şekil 4.4. Yapay sinir ağının.....	25
Şekil 4.5. Evrişimsel sinir ağı	27
Şekil 4.6. Karışıklık matrisi	28
Şekil 5.1. Normal ve farklı oranlarda gürültü eklenmiş görüntüler.....	30
Şekil 5.2. Ortanca filtresi kullanıldıktan sonra elde edilen görüntü	31
Şekil 5.3. Kapatma algoritması uygulandıktan sonra elde edilen sonuçlar	32
Şekil 5.4. Canny algoritması kullandıktan sonra elde edilen görüntüler	33
Şekil 5.5. Arka plan kaldırıldıktan sonra elde edilen görüntüler	33

Sayfa No.

Şekil 5.6. İskelet çıkarıldıktan sonra elde edilen görüntü.....	33
Şekil 5.7. İskelet birleştirme	34
Şekil 5.8. Dalgacık dönüşümü sonrası görüntü	35



ÇİZELGELER

Sayfa No.

Çizelge 2.1. Biyometrik tanımlama sistemlerinin özellikleri	6
Çizelge 2.2. Biyometrik tanımlama sistemlerinin avantajlar	7
Çizelge 5.1. SVM sınıflandırıcısı kullanılarak elde edilen performans metrikleri ...	35
Çizelge 5.2. LDA sınıflandırıcısı kullanılarak elde edilen performans metrikleri ...	35
Çizelge 5.3. ANN sınıflandırıcısı kullanılarak elde edilen performans metrikleri ...	36
Çizelge 5.4. CNN sınıflandırıcısı kullanılarak elde edilen performans metrikleri ...	36

ÖZET

EL DAMAR İZİ KULLANARAK KİMLİK TESPİTİ

Kimlik tanımlama sistemleri özellikle makine öğrenme yöntemlerinin başarıml oranlarının artması ile biyometrik tabanlı hale gelmiştir. Biyometrik kimlik tanımlama sistemleri güvenilir, değiştirilmesi güç parametrelerin kullanılması ile yüksek bir güvenlik seviyesi sunarlar. Bu tez çalışmasında el sırtı damar izi kullanılarak bir biyometrik kimlik tespit sistemi önerilmiştir. Literatürde yer alan örnek veri kümesi üzerinde ilgili sistem test edilmiştir. Kullanılan veri kümesi içerisine gürültülü veriler eklenerek veri sayısı arttırılmıştır. Ön işleme tabi tutulan görüntüler üzerinde SVM, ANN, LDA+KNN, ve CNN yöntemleri kullanılarak sınıflandırma işlemi yapılmıştır. En yüksek kimlik tespit doğruluğuna CNN kullanıldığında erişildiği, CNN yönteminin diğer yöntemlere kıyasla daha yüksek performans sağladığı tespit edilmiştir.

Anahtar Kelimeler : Biyometrik kimlik tanımlama, makine öğrenmesi ,el damar izi tanıma, SVM, LDA, KNN, ANN, CNN.

ABSTRACT

IDENTIFICATION THROUGH HAND VEIN PATTERNS

Identification systems have become biometric based, especially with the increase in the performance rates of machine learning methods. Biometric identification systems offer a high level of security by using reliable, difficult-to-change parameters. In this thesis, a biometric identification system is proposed using dorsal hand vein patterns. The relevant system has been tested on the sample dataset in the literature. The number of data were increased by adding noisy data to the data set used. Classification was made on the preprocessed images using SVM, ANN, LDA + KNN, and CNN methods. It has been determined that the highest identification accuracy is achieved when CNN is used, and CNN method provides higher performance compared to other methods.

Keywords: Biometric identification, machine learning, hand vessel trace recognition, SVM, LDA, KNN, ANN, CNN.

1. GİRİŞ

Bu tez çalışmasında el sırt damar izi kullanılarak bir biyometrik kimlik tanımlama sistemi önerilmiştir. Bu sistem daha önceden kaydedilmiş olan el sırtı damar izlerinin kullanılarak onay ve doğrulama işleminden oluşmaktadır.

El sırtı damar izi verilerinin oluşturulması aşamasında (Enrollment), farklı kişiler için ana örnek olarak Badawi (2006) tarafından oluşturulan veri kümesi kullanılmıştır. Bu veri kümesi içerisinde 100 el (50 sağ ve 50 sol olmak üzere) görüntüsü yer almaktadır. Önerilen yöntemin doğruluğunun sınanabilmesi adına veri kümesi içerisinde yer alan görüntülere gürültü eklenerek görüntü sayısı arttırılmış toplam 4000 görüntü verisi oluşturulmuştur. Bu görüntüler, özelleştirilebilir örnekler oluşturmak için ön işleme (Pre_Processing), özellik çıkarma (Feature_Extraction) ve modelleme – sınıflandırma (Modelling - Classification) aşamaları sırasında işlenir. Ön işleme aşamasında ikilik değerlere sahip görüntüler üzerinde görüntü kalitesinin arttırılması ve el damar izi kısmının çıkarılması amaçlanmıştır. Elde edilen damar izi iskelet görüntüleri üzerinde makine öğrenmesi yöntemleri kullanılarak sınıflandırma işlemi yapılmıştır.

Bu tez çalışması içerisinde veri kümesi içerisinde yer alan görüntülerin sınıflandırılması amacıyla SVM, ANN, LDA + KNN ve CNN teknikleri kullanılmıştır. Kullanılan yöntemlerin performansları analiz edilmiş, en yüksek performansı sunan CNN yöntemi ile el sırtı damar izi kullanılarak kimlik tanımlama sistemi önerilmiştir.

Önerilen kimlik tespit sistemi ile çoklu çalıştırma sonrası CNN makine öğrenmesi yöntemi ile ortalama olarak %99.64 doğruluğa ulaşılmıştır.

2. BİYOMETRİK SİSTEMLER

Günümüz dünyasında kimlik tanımlamasının yapılması pek çok alanda hayati önem taşımaktadır. Bugün dijitalleşen dünya ile kimlik belirleme sistemleri bütünüyle mekanik bir hale getirilmeye çalışılmaktadır. Geçmişte bir suçlunun tanımlanması için sıklıkla parmak izi ve yüz tanıma uygulamaları kullanılmıştır. Ancak bugün daha kapsamlı yapılar tasarlanmakta ve farklı biyolojik teknikler kimlik tanımlama amacıyla kullanılmaktadır (<https://en.wikipedia.org/wiki/Biometrics>.,Erişim tarihi: 21 Mart 2019).

Biyometrik sistemler kişilere ait verilerin ölçülmesini ve istatistiksel analizini içerirler. Bireysel tanımlama için vücut özelliklerini ölçen ve analiz eden bir teknoloji aracılığı ile kişiye ait özel nitelikleri (fizyolojik veya davranışsal nitelikler) kullanılarak bir kişinin otomatik olarak tespit edilebilmesini sağlarlar. Bu amaçla daha önce kişilere ait saklanan veriler ile birebir eşleştirme yapılarak (1:1) veya kişiye ait daha önce saklanan verilerden bir şema edinilmesi yolu ile bire-çok eşleştirme (1:N) yapılarak hareket edilir. Genel olarak biyometrik sistemler iki farklı özellik türünü tanımlamak için kullanılan: davranış parametreleri ve fizyolojik parametreler. Davranış parametreleri, kişiye özel davranış modellerinin tanımlanmasını içerir. Fizyolojik parametreler ise bir sınıftaki tanımlama işleminin temelini bir kişinin statik özelliklerinin ölçümü ve analizi olarak kabul eder. Örneğin, el geometrisi, el damarları, iris, parmak izleri vb. İyi bir biyometrik sistem:

- Benzersiz,
- Herkes tarafından kolayca ve hızlıca erişilebilir,
- Kolayca ayırım yapmaya imkan verebilir,
- Kullandığı ayırıcı nitelik bir insanın hayatı boyunca değişmeyecek biçimde, seçilmiş temele dayanır olmalıdır.

Kullanılabilecek biyometrik sistemler arasında parmak izi, retina, iris, el yapısı, göz imza, ses, damar izi ve DNA tanımlama dayalı yöntemler bulunmaktadır. Bu sistemlerin her birinin kendine has birçok kullanım avantaj ve dezavantajları vardır. Genel olarak, biyometrik sistemin türü kullanılacağı alana göre seçilmektedir.

2.1. Biyometrik Sistem Türleri

Bu bölümde bazı biyometrik sistemlerin performans incelemesi yer almaktadır.

- Parmak izi ile tanımlama: Parmak izleri, cildin ucundaki çıkıntı ve protezlere dayalı olarak kimlik tanımlama amacıyla kullanılır. Parmak izi tanıma teknikleri, en sık kullanılan biyometrik tanımlama yöntemlerinden biridir ve aynı zamanda kimliği tanımlamak için en güvenilir yöntemlerden biridir. Parmak izi tanıma teknikleri, tanımlamada güvence ile kararlılığı garanti eder ve bu nedenle çeşitli uygulamalarda kullanılır. Bununla birlikte, parmak izi tanıma sistemleriyle ilgili birçok pratik sorun vardır: örneğin, bir parmak izi elde edildiğinde, cildin esnekliği bireyin parmak izlerinde değişiklik yapabilir. Şekil 2.1’de parmak izi çıkıntısına ait örnek görüntü yer almaktadır. Parmak izi üzerinde yer alan şekiller sonlanma (termination), çatallanma (bifurcation), göl (lake), bağımsız çıkıntı (independent ridge), nokta veya ada (poin tor island), dağ kolu (spur), çapraz (crossover) şekillerinde olabilir.

sonlanma
çatallanma
göl
bağımsız çıkıntı
nokta veya ada
dağ kolu
çapraz




Şekil 2.1. Parmak izi çıkıntısı (Josef Ström Bartunek,2004)

Parmak izi üzerinde yer alan çıkıntıların ayırıcı nitelik olarak kullanılarak sınıflandırma işleminin yapılması biyometrik tanımlama sistemlerinde sıklıkla rastlanmaktadır.

- İris ile tanımlama:1936'da Frank Burch adlı bir göz doktoru, kornea deseni ile bireylerin teşhis edilebileceğini ortaya koymuştur. Ancak 1985 yılında Leonard Flom ve Aran Safir adlı iki göz doktoru tarafından farklı insanların kornealarının tamamen farklı olduğu tespit edilmiştir. Adı geçen araştırmacılar


kornea kimliğini ilk olarak 1987'de kaydetmeyi başarmışlardır. Nükleer Savunma Teşkilatı, 1995 yılında korneaya dayalı kimlik tanımlama için ilk çalışmaları başlatmıştır. İrisin yapısı embriyonun üçüncü ayından itibaren oluşmaya başlar ve sekizinci aya kadar tamamen stabilize hale gelir. İrisin görünümü ve karmaşık yapısı, ondan çok sayıda karşılaştırılabilir özellik elde etmemizi sağlar. Şekil 2.2 içerisinde göz iris tanımlamaya ait temsili fotoğraf yer almaktadır. İris yüzeyinin görüntülenmesi zorlu bir işlem değildir ancak zorlukları bulunmaktadır. Örneğin, ortam ışığı değişirse veya gözün dönüş açısı uygun değilse, görüntünün kontrastı, çözünürlüğü ve odağı değişirse, hata oranı elde etme olasılığı yükselir.



Şekil 2.2. Göz iris tanımlamaya ait temsili


görüntü(<http://www.advancedsourcecode.com/dctiris.asp> ,Erişim tarihi: 21 Mart 2019).

- **Retina ile tanımlama:** Bu yöntemde, retina görüntülenir ve retina yapısı işlenir. Bu damarların yapısı tek yumurta ikizlerinde dahi değişiklik göstermektedir. Retinaya dışarıdan erişim olmadığından, bu yöntem parmak izleri, iris vb. diğer biyometrik tanımlama yöntemlerine göre daha yüksek bir güvenlik seviyesine sahiptir. Şekil 2.3 içerisinde retinanın görünüşüne ait temsili resim yer almaktadır. Örneğin, parmak izleri yapay deri tabakaları, iris ise kimlik tanımlama sistemlerini kandırabilmek için özel lensler içerebilir. Ancak benzer aldatmaya dayalı yaklaşımlar retina tabanlı sistemlerde işe yaramamaktadır. Görüntüleme kısıtlamaları iris ile aynıdır, ancak daha az hassasiyete sahiptir. Öte yandan, görüntüleme esnasında retinaya gelen ışık miktarı bu tür kimlik tanımlama sistemlerinin genel olarak kullanabilmesi önündeki en büyük kısıttır.



Şekil 2.3. Retina görünüşüne ait temsili görüntü (<https://tr.depositphotos.com/vector-images/retina.html> ,Erişim tarihi: 21 Mart 2019)

- El ve parmak geometrisi ile tanımlama: Bu yöntemde analiz edilen ve karşılaştırılan, parmağın uzunluğu ve çapı, eklemlerin yeri, avuç içi şekli ve büyüklüğüdür. Bu teknik çok basit olmasına karşın düşük maliyetlidir. Parmağın kuruluşu gibi cildin görünümündeki değişiklikler karşılaştırmanın sonucunu etkilemez. Parmak izine dayalı yöntemde ise kuru ve normal bir cilde sahip olmak gerekir. Bununla birlikte, farklı insanlarda ifade edilen geometrik yapı gerçekten keskin bir farklılık değildir ve aynı özelliklere sahip birkaç kişi bulunabilir. Öte yandan, bahsi geçen geometrik yapı büyüme sırasında ve çeşitli faktörlere bağlı olarak değişebilir. Bu sorunlar bu yöntemin etkinliğini büyük ölçüde azaltır. Şekil 2.4 içerisinde el ve parmak geometrisine dayalı nitelik çıkarma aşaması görünmektedir.



Şekil 2.4. El ve parmak geometrisine dayalı nitelik çıkarma aşaması
https://www.researchgate.net/figure/Hand-geometry-features-according-to-7_fig2_235950674, Erişim tarihi: 21 Mart 2019)

- DNA testi ile tanımlama: Kuşkusuz, DNA testi, kimliği doğrulamanın en önemli yollarından biridir. DNA tek boyutlu ve benzersiz bir koddur. Bu yöntem en doğru biyometrik form olsa da, konumları güvence altına almak için kullanılmaz. DNA örneği alma işlemi özel araçlar ve kimyasalların kullanımını gerektirir. Tek yumurta ikizlerinin DNA yapısı büyük ölçüde birbirlerine benzer ve bu yöntem için bir dezavantaj ortaya koyar. Ancak yine de ilgili yöntemin tanımlama doğruluğunu düşürmez.
- El sırtı damar izine dayalı tanımlama: Parmak izleri gibi her bireyin damarlarının şekli benzersiz bir özelliktir. El sırtı damar izleri tek yumurta ikizlerinde dahi farklılık gösterir. Zamanla damarların yalnızca boyutları değişir. Damar izine dayalı tespit yönteminde, avuç içine veya el sırtına

kızılötesi ışık uygulanır. Bu, cildin altındaki damarların durumunu daha belirgin bir biçimde görmeye yardımcı olmaktadır. Kandaki hemoglobinin, ışık spektrumunun yaklaşık $6/7 \times 10$ dalga boyuna sahip kısımlarını emer. Bu, damarların kararmasına izin verir ve sensör görüntü bilgilerini alarak saklarlar. Damar izine dayalı tespit tekniğinin avantajlarından biri, fiziksel temas gerektirmemesi ve doğruluğunun makul derecede yüksek olmasıdır. Bu yöntem özellikle iş yerleri, konumsal kimlik tespitleri için kullanışlıdır. Parmak izine doğrudan ve hızlı bir alternatif olan bu yöntemin, maliyet etkindir, doğruluk oranı yüksektir ve çeşitli alanlarda kimlik tanımlama için kullanılmaktadır (https://article.tebyan.net/111497/-/تشخیص-هویت-با-کف-دست-و-رنگ-ها, Erişim tarihi: 23 Mart 2019).

Çizelge 2.1’de biyometrik tanımlama sistemlerinin özellikleri görülmektedir (Sabhanayagam ve ark.(2018)).

Çizelge 2.1. Biyometrik tanımlama sistemlerinin özellikleri

Tanımlayıcı / Kriter	Evrensellik	Eşsizlik	Toplanabilirlik	Performans	Kabul Edilebilirlik	Tuzağa Düşürme
Parmak İzi	Orta	Yüksek	Orta	Yüksek	Orta	Orta
İris	Yüksek	Yüksek	Yüksek	Yüksek	Orta	Alçak
Retina	Yüksek	Yüksek	Orta	Yüksek	Alçak	Alçak
El ve Parmak Geometrisi	Yüksek	Orta	Yüksek	Orta	Orta	Alçak
El Damar İzi	Orta	Yüksek	Orta	Yüksek	Orta	Alçak

Çizelge 2.2’de biyometrik tanımlama sistemlerinin avantajları görülmektedir (Sabhanayagam ve ark.(2018)).

Çizelge 2.2. Biyometrik tanımlama sistemlerinin avantajlar

Yöntem	Avantajları
Parmak İzi	<ul style="list-style-type: none">• En sık kullanılan teknolojidir.• Diğer biyometrik sistemlere kıyasla ucuzdur.• Birden fazla parmak tanımlanması kolaydır, kullanımı kolaydır.• Veri tabanları üzerinde yüksek bellek kullanımı gerektirmez.
İris	<ul style="list-style-type: none">• Sistemle fiziksel temasta bulunmasını gerektirmez.• Küçük şablon boyutuna sahiptir, işleme hızı 2 ila 5 saniye aralığındadır.• Yaşam boyunca sabit kalan özelliklere dayalıdır.
Retina	<ul style="list-style-type: none">• Taklit edilmesi güçtür, kişiye özgü olduğundan güvenilirdir.• Hata oranı 10.000.000'dan 1'dir (neredeyse % 0).• Kimlik doğrulanmasında yüksek güvenlik sağlar.• Çok hızlı doğrulama gerçekleştirir.
DNA	<ul style="list-style-type: none">• En yüksek doğruluğu sağlar.• Aynı DNA profilini paylaşan 2 kişinin yüz milyarda birinden az olma olasılığı vardır.
El ve Parmak Geometrisi	<ul style="list-style-type: none">• Sonuç cilt neminden veya doku değişikliklerinden etkilenmez.• Kullanımı kolaydır ve küçük şablon boyutuna sahiptir.
El Damar İzi	<ul style="list-style-type: none">• Temassız ve hijyenik tanımlama sağlar.• Büyük oranda kesindir• Farklı ve benzersizdir.

2.2. El Sırtı Damar İzi Tanımlamaya Dayalı Biyometrik Sistem Tasarım Çalışmaları

Literatürde el sırtı damar izi kullanılarak gerçekleştirilen kimlik tanımlama sistemlerine ait çeşitli örnekler bulunmaktadır.

1. Farklı Cihazlarda El Sırtı Damar İzine Dayalı Tanımlama (Dorsal Hand Vein Recognition Across Different Devices (2016)), Bu Norah A. Al-johaniaand Lamiaa A. Elrefaei tarafından yazılan bu çalışmada en önemli nitelikler analiz edilmektedir. Gri tonlamalı görüntüler normalize edildikten sonra, gradyan farkına dayalı bir segmentasyon yöntemi kullanılır ve özellikleri çıkararak eşleştirmek için SIFT kullanılır. Bu makaledeki ayırım doğruluğu % 90,17'ye kadar çıkmaktadır. Bu yöntem, el sırtı damar izine dayalı tanımlama ile ilgili sorunu farklı cihazlarda etkili bir şekilde çözebilir (Wang ve ark.(2016)).

2. Yiding Wang and Zhanyong Zhao tarafından 2013 yılında Fourier Spektral Analizi ile El Sırtı Damar İzine Dayalı Canlılık Tespiti (Liveness Detection of Dorsal Hand Vein Based on the Analysis of Fourier Spectral) adlı çalışma gerçekleştirilmiştir. İlk olarak, Fourier Dönüşümü uygulanarak, bir özellik, tek dalga boylu kızılötesi görüntülerin engellenen her spektrumundan türetilen spektral enerjinin istatistiksel bir değeri olarak çıkarılmıştır. Kümeleme aşamasında sınıflandırıcı olarak makine öğrenmesi yöntemlerinden karar destek makineleri kullanılmıştır (Wang ve Zhao(2013)).

3. Dorsal Hand-vein Images Recognition System based on Grey Level Co-occurrence Matrix and Tamura Features adlı çalışma 2017 yılında Abbas H. Hassin Alasadi ve Muqdad Hanoon Dawood tarafından gerçekleştirilmiştir. Bu çalışmanın amacı, damar görüntülerini analiz etmek ve damarları segmentlere ayırarak damarına göre her bir kişiyi tanıma kabiliyetine sahip olan bir sistem tasarlamaktır. Deneysel sonuçlar MDC sınıflandırıcısının dalgacık dönüşümü ve GLCM ve Tamura özellikleri kullanımı durumunda %92 doğruluk elde ettiğini göstermiştir (Alasadi ve Dawood(2017)).

3. GEREÇ VE YÖNTEM

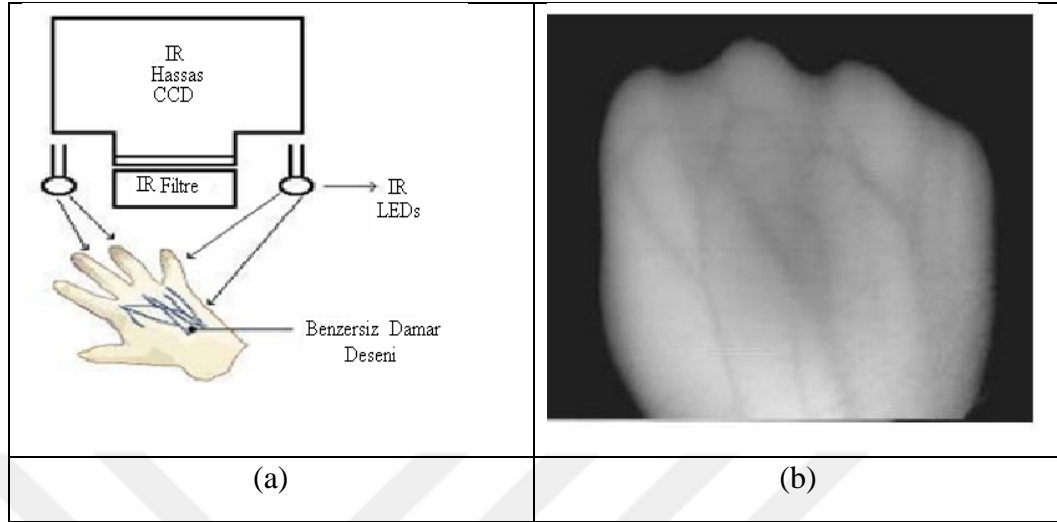
Bu çalışma içerisinde el sırtı damar izi görüntülerine dayanarak bir kimlik tanımlama sistemi önerilmiştir.

3.1. Görüntüleme Aşaması

El sırtı damar izi görüntülerinin elde edilmesi amacıyla kullanılan iki temel yöntem vardır. Bu yöntemlerden birisi uzak kızılötesi dalga boylarının kullanılmasını içeren FIR (Far Infrared Radiation) yöntemi iken diğeri yakın kızılötesi dalga boylarının kullanılmasına dayanan NIR (Near Infrared Radiation) yöntemidir. FIR yöntemi ile kullanılan uzak kızılötesi dalga boyları insan sağlığına zararlı olmasa da direkt olarak temas ettikleri nesnelere ısınmasına sebep olurlar. NIR yönteminde yakın kızılötesi dalga boylarını içeren LED'ler kullanılır. İnsan kanında yer alan hemoglobinin yakın kızılötesi dalga boyuna karşı çok hassas olduğundan kendisini çevreleyen ortamdaki daha yoğun bir biçimde dalgaların emilmesini sağlar. Böylelikle el iskelet ve damar izi yapısına ait daha koyu bir görüntü elde edilir. Bu yöntemde, damarların görüntülerini kaydetmek için LED ampullerle donatılmış bir monokrom(Charge Coupled Device - CCD) kamera kullanılır (Cross ve Smith(1995), Lin ve Fan(2004), Badawi (2006), Shahin ve ark. (2007), Shahin ve ark.(2010),). Her ne kadar ilk olarak görünür ışıkta kullanılmak üzere tasarlanmış olsa da, CCD kameralar elektromanyetik spektrumun IR dalga boylarına yaklaşık 1100 nm'ye kadar duyarlıdır. Bu, 700-1400 nm'de yakın kızılötesi tayfı kapsayan bir aralıktır (Kano ve ark.(2002)).

Şekil 3.1a'de Badawi el damar veri kümesinin oluşturulmasında aygıt yer almaktadır. İlgili aygıt elin arkasını aydınlatmak amacıyla bir yakın kızılötesi soğuk aydınlatma kaynağı (IR LED) içermektedir. Düşük maliyetli, tek renkli bir CCD kamera IR filtre ile donatılmış bir biçimde elin arkasını görüntülemek için kullanılır. Şekil 3.1.a'de ilgili görüntüleme modülü Şekil 3.1.b'de ise bu yöntemle

elde edilmiş Dr. Badawi el veri kümesi içerisinde bulunan el sırtı fotoğrafına ait fotoğraf yer almaktadır.



Şekil 3.1. İlgili görüntüleme modülü ve elde edilmiş el sırtı fotoğrafı (Shahin ve ark.(2007))

3.1.1. Veri Kümesi

Bu çalışma içerisinde “Dr. Badawi el damar veri kümesi (Dr. Badawi hand vein dataset)” olarak bilinen veri kümesi kullanılmıştır. İlgili veri kümesi içerisinde 100 ele ait 500 fotoğraf bulunmaktadır. Her bir kişiye ait el örneği için 5 örnek alınmıştır. Veri kümesinde yer alan kişilerin yaşı 16-65 arasında değişmektedir, farklı meslek gruplarına sahiptirler ve herhangi bir sağlık sorunları bulunmamaktadır. Veri kümesi içerisinde sağ ve sol ellere ait farklı fotoğraflar yer almaktadır. Dr. Badawi el damar veri kümesi damar izleri aracılığı ile kimlik tanımlanması yapılabilmesi için kullanılabilmesi gibi sağ ve sol eller arasındaki farklılıkların analiz edilebilmesine olanak tanınacak biçimde organize edilmiştir. 1-50 arasındaki veriler kişilere ait sol el görüntülerini içerirken 51-100 arası veriler kişilere ait sağ el görüntülerini içermektedir. Bu tez çalışması içerisinde sağ ve sol el ayrımı yapılmamış, sol ve sağ ellerin farklı kişileri yansıttığı kabul edilerek 100 farklı sınıflandırma kümesi oluşturulmuştur.

3.1.2 Veri Sayısının Arttırılması

Görüntü işleme yaklaşımlarının etkinliğinin sınanması amacıyla veri kümeleri içerisinde yer alan görüntülerin arttırılması amacıyla kullanılan çeşitli teknikler mevcuttur. Bu teknikler arasında temel olarak geometrik dönüşümler, kaydırma,

renk uzayı dönüşümleri, kırpma, rotasyon, çevirme, gürültü eklenmesi vb. yöntemler yer almaktadır.

Bu çalışma içerisinde kullanılan “Dr. Badawi el damar veri kümesi” içerisinde yer alan verilere çeşitli oranlarda gürültü eklenerek toplam 500 adet olan fotoğraf sayısı 4000 olacak şekilde arttırılmıştır.

3.2. Ön İşlem Aşaması

Görüntü işleme, çeşitli uygulamalarda ve alanlardaki görüntüden alakasız gürültü verilerini çıkardıktan sonra görüntünün kalitesini artırma tekniğidir. Bir görüntüdeki gerekli parçaları çıkarmak için, kimlik tanımlama gerçekleştirilmeden önce görüntülerin daha iyi görselleştirilmesi için görüntü ön işleme tekniklerinden bazılarına ihtiyaç duyulur. Görüntü kalitesinin arttırılması, filtreleme teknikleri, gürültünün giderilmesi ve kontrast arttırma vb. yöntemler kullanılarak elde edilir. Piksel yoğunluğunu ve görüntü kalitesini arttırma işlemi de ön işleme tabi tutularak gerçekleştirilir. Ön işleme gerçekleştirildikten sonra görüntü kalitesi artar (Saniei ve ark.(2009) , <http://www.mathworks.com/>.,Erişim tarihi: 05 Mart 2019).

Görüntü ön işleme genellikle kimlik doğrulamanın ilk ve en pratik kısmıdır. Adım adım görüntü ön işleme süreci şu adımları içerir:

- İstenilen alanı çıkarma ve arka planı kaldırma (Regionof Interest - ROI)
- Görüntü netliğini arttırma
- Resmi bölümlere ayırma
- İskelet çıkarımı ve işleme operasyonları

3.2.1. İstenilen Alanın Çıkarılması ve Arka Plan Kaldırma

Elde edilen el görüntüsünde yer alan damar bölgesinin çıkarılması için fotoğrafın işlenmesi gerekmektedir ([http://www.mathworks.com.](http://www.mathworks.com/).,Erişim tarihi: 05 Mart 2019). Eşit yoğunlukta veya birbirine yakın olan bitişik pikseller, belirli bir sınırın altında olduklarında sıfır olarak değerlendirilir. Bu, hedefin arka plandan çıkarılmasını sağlar.

3.2.2. Görüntü Netliğinin Arttırılması

Görüntüler üzerinde herhangi bir işlem yapmadan önce, görüntü kalitesini artırmak önemlidir. Bu sebeple, bir ortanca filtresi (medianfilter) kullanılmıştır. Bu filtrenin diğer filtrelerle göre avantajı, bozulmayı azaltmanın yanı sıra, görüntünün kenarlarını başarıyla tespit edebilmesidir (<http://www.mathworks.com>.,Erişim tarihi: 05 Mart 2019).

3.2.2.1. Ortanca Filtresi

Ortanca filtresi komşu pikselleri sıralayıp sıranın ortasındaki değerin alınması prensibine dayanır. Eğer incelenen bölgede (şablonun içerisi) çift sayıda piksel varsa, orta değer olarak, ortada bulunan iki pikselin ortalaması kullanılır (Cross ve Smith(1995)).

Ortanca filtresi resim üzerindeki detayların kaybolmaması noktasında ortalama filtresinden çok daha iyi sonuç verir. Ortanca filtre her pikselin değerini hesaplamak için yakınındaki komşularına bakar. Ortanca filtresinde piksel değeri komşu piksel değerlerinin ortalaması ile değiştirmek yerine (ortalama filtresi), komşu pikselleri sıralayıp sıranın ortasındaki değeri alır. Eğer incelenen bölge (şablonun içerisi) çift sayıda piksel varsa, orta değer olarak, ortada bulunan iki pikselin ortalaması kullanılır).

Şekil 3.2’de ortadaki piksele göre işlem yapılırsa bu pikselin değeri olan 150 sayısının çevresindeki pikselleri iyi bir şekilde temsil etmediği görülebilir. Bu pikselin değerini değiştirirken öncelikle çevresindeki piksellerin değerinin bir sıraya göre dizilmesi gerekmektedir. Bunlar 109, 110, 121, 122, 131, 135, 140, 141, 145 değerlerinden oluşur. Bu değerlerin en ortasında ise 131 sayısı vardır. Buna göre 150 sayısı 131 sayısı ile değiştirilir. Burada 131 sayısı ortanca (median) değeridir.

Burada kullanılan örnek şablon 3×3 piksel boyutlarındadır. Daha büyük şablonların kullanılması daha fazla pürüzsüzleştirme (yumuşatma) etkisi üretir.

Bu filtrenin avantajları aşağıdakileri içerir:

- Bir pikselin değerinin değiştirilmesi gerekiyorsa, yeni değer bitişik piksellerden alınır. Bu şekilde, fotoğrafın pikselleri dışında hiçbir veri yeni veri olarak kaydedilmez. Bu, gerçekçi olmayan veri girişini önler.
- Gerçekleştirilen testlerde ortanca filtresi, damarların kenar görüntülerinin korunmasında ortalama ve Gauss filtrelerinden daha iyi sonuç vermiştir.

110	140	131	131	154	150	110	140	131	131	154	150	
135	113	1	2	110	109	120	135	113	142	110	109	120
123	135	13	131	122	112	123	135	135	141	122	112	
126	116	121	140	131	102	126	116	121	140	131	102	
133	135	160	142	110	123	133	135	160	142	110	123	

Şekil 3.2. Birkaç pikselde Ortanca Filtre çalışması

3.2.3. Görüntünün Bölümlenmesi

Bu aşamada, damar düzenini çıkarmak için uyarlanabilir eşikler yöntemi kullanılmıştır. Bu eşik türünde, görüntü boyunca eşik değerleri görüntünün yerel görüntüsünün bir işlevi olarak değişir. Yönteme ait denklem 3.1’de görülmektedir.

$$I(i,j)=\begin{cases} 1 & I(i,j) \geq T_{ij} \\ 0 & \end{cases} \quad (3.1)$$

Aksi halde, Denklem 3.3’deki gibi, T sabit değildir ve dinamik bir miktar, bitişik piksel değerlerine (j , i) bağlıdır (<http://aicode.ir/learning/learning-articles/61-thresholding.html>., Erişim tarihi: 01 Nisan 2019).

3.2.3.1. Matematiksel Morfoloji

Matematiksel morfoloji içerisinde iki temel işlem yer almaktadır. (<http://blog.class.vision/1396/12//morphology-opening-closing/>.,Erişim tarihi: 05 Nisan 2019):

- Genleşme (Dilation)
- Erozyon (Erosion)


Ayrıca bir dizi kombine işlem de mevcuttur:

- Açılış ve Kapanış (Opening and Closing)
- İnceltme ve Kalınlaşma (Thinning and Thickening)

Genleşme işlemi, ikili görüntüyü genişletir ve görüntüdeki boşlukları kaldırır.

Görüntüyü genişletmenin yanı sıra aynı zamanda kırık kenarları da kaldırır.

Şekil 3.3’de Genleşme işleminin çalışma biçimi görülmektedir.



Şekil 3.3. Genleşme işlemi (<http://blog.class.vision/1396/12/morphology-opening-closing/>, Erişim tarihi: 05 Nisan 2019).

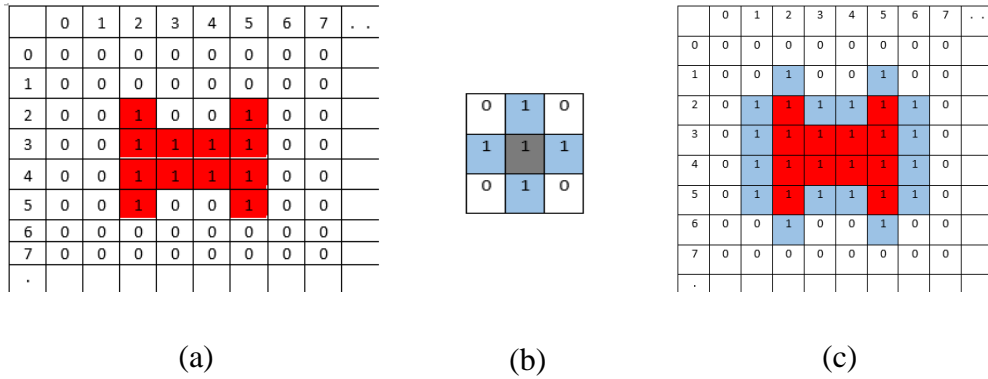
A ve B kümeleri Z^2 'nin bir alt kümesiye, A kümesinin B tarafından ikili tanımlaması $A \oplus_b B$ (b ikili anlamına gelir) sembolü ile temsil edilir ve Denklem 3.2'deki gibi tanımlanır:

$$A \oplus_b B = \{c \in Z^2 \mid c = a + b \text{ for some } a \in A, b \in B\} \quad (3.2)$$

$A \oplus_b B$ işleminin sonucu Denklem 3.3'de görülmektedir.


$$A \oplus_b B = \bigcup_{b \in B} (A)_b = \bigcup_{a \in A} (B)_a \quad (3.3)$$

Dilatasyon işleminde girişler ikilik düzeydedir. Şekil 3.4.a içerisinde yapılan dilatasyon işlemine giren görüntü örneği yer almaktadır. Görüntü üzerinde çalışan filtre ise Şekil 3.4.b içerisinde gösterilmiştir. İlgili şekil içerisinde yer alan gri alan başlangıç noktasını yansıtmaktadır. B filtresini ikilik görüntü üzerinde hareket ettirerek ve başlangıç noktasını her piksele yerleştirerek yapılır. İkili görüntü üzerinde filtre gezdirilir. Filtre üzerinde yer aldığı pikseller ile çarpıldıktan sonra OR işlemi uygulanarak orjine karşılık gelen piksel değeri elde edilir. Filtrenin gezdirilmesi sonucu elde edilen değerler Şekil 3.4.c üzerinde sunulmuştur. Böylece Şekil 3.4.c $A \oplus_b B$ işleminin sonucunu içerir.



Şekil 3.4. Piksellerde genleşme işlemi

Erozyon işlemi ise görüntüyü analiz eder, aslında görüntüyü daraltır ve fazladan parçaları siler. Şekil 3.5 içerisinde erozyon işleminin çalışması sonucu başlangıçta yer alan resimlerin değişimleri yansıtılmaktadır.




Şekil 3.5. Erozyon işlemi (<http://blog.class.vision/1396/12//morphology-opening-closing/>, Erişim tarihi: 05 Nisan 2019).

Şekil 3.6.a içerisinde yer alan görüntünün Şekil 3.6.b içerisinde yer alan filtre tarafından erozyon işlemine tabi tutulması, Denklem 3.4’de yer alan biçimde tanımlanır.


$$A \ominus B = \{ x: B_x \subseteq A \} \quad (3.4)$$

Erozyon işleminde girişler ikilik düzeydedir. Şekil 3.6.a içerisinde yapılan erozyon işlemine giren görüntü örneği yer almaktadır. Görüntü üzerinde çalışan filtre ise Şekil 3.6.b içerisinde gösterilmiştir. İlgili şekil içerisinde yer alan yeşil alan başlangıç noktasını yansıtmaktadır. B filtresini ikilik görüntü üzerinde hareket ettirerek ve başlangıç noktasını her piksele yerleştirerek yapılır. İkili görüntü üzerinde filtre gezdirilir. Filtre üzerinde yer aldığı pikseller ile çarpıldıktan sonra AND işlemi uygulanarak orjine karşılık gelen piksel değeri elde edilir. Filtrenin gezdirilmesi sonucu elde edilen değerler Şekil 3.6.c üzerinde sunulmuştur. Böylece Şekil 3.6. $A \ominus B$ işleminin sonucunu içerir.




Şekil 3.6. Piksellerde genişleme işlemi

Açma ve Kapama İşlemleri: Bu iki işlem ikili görüntülerdeki en önemli süreçlerdir. Açma işleminde ilk olarak dilatasyon ardından erozyon işlemi yapılır. Açma işleminin örnek üzerinde gerçekleştirilmiş hali Şekil 3.7’de yer almaktadır. Buna göre şekilde var olan resim üzerinde açma işlemi yapılarak, ilk olarak dilatasyon ardından erozyon işlemi uygulanmıştır. Açma işlemi, görüntüyü daraltmadan gürültüyü ortadan kaldırmakta, görüntüyü büyütmeden boşlukları doldurmaktadır.



Şekil 3.7. Açma işlemi (<http://blog.class.vision/1396/12//morphology-opening-closing/>.,Erişim tarihi: 05 Nisan 2019)

Kapatma işlemi Açma işleminin tersine bir sıralamayla hareket eder. Buna göre gerçekleştirilen bir kapatma işleminde ilk olarak erozyon ardından dilatasyon işlemi yapılır. Kapatma işleminin örnek üzerinde gerçekleştirilmiş hali Şekil 3.8’de yer almaktadır. Buna göre şekilde var olan resim üzerinde kapatma işlemi yapılarak, ilk olarak erozyon ardından dilatasyon işlemi uygulanmıştır.



Şekil 3.8. Kapatma işlemi (<http://blog.class.vision/1396/12//morphology-opening-closing/>.,Erişim tarihi: 05 Nisan 2019)

3.2.4. Kenar Algoritmaları

Görüntünün kenarı, görüntüdeki parlaklığın aniden değiştiği noktadır. Düzenleme, görüntü işlemedeki en önemli temel işlemlerden biridir, bu nedenle nesne tanıma ve görüntü segmentasyonu gibi üst düzey işlemlerin verimliliği doğrudan bu düşük seviyeli işlemin verimliliğine bağlıdır. (<https://www.mathworks.com/help/images/edge-detection.html>., Erişim tarihi: 06 Nisan 2019).

Bu alanda kullanılabilecek birçok algoritma yer almaktadır (görüntünün türüne ve ilgili işleme bağlı olarak, her bir algoritmanın kendi avantajları ve dezavantajları bulunmaktadır): Sobel kenar algoritması, Canny Edge algoritması,

Zero Cross kenar algoritması, ,Log kenar algoritması, Prewitt kenar algoritması, Roberts kenar algoritması bunlardan bazılarıdır.


3.2.5. İskelet Çıkarımı

Bir desenin iskeletini çıkarmak, desenin genel şeklinin yok edilmemesi için deseni daraltmak anlamına gelir. Bu nedenle, bir desenin iskeleti desenin kendisi olarak tanınabilmeli ve böylece desenin genel şeklini tahmin edebilmelidir (<http://aicode.ir/learning/learning-articles/111-object-detection-matlab>.,Erişim tarihi: 15 Mayıs 2019).

Bir desen için elde edilen iskelet aşağıdaki özellikleri içermelidir:

- Yeterince ince olmalıdır.
- Bağlantılı olmalıdır (yani iskeletleme işlemi iskeletin parçalanmasına neden olmamalıdır).

Bu iki koşul karşılandığında iskeletleştirme algoritması durur. Şekil 3.9.a içerisinde yer alan görüntü üzerinde isketleştirme algoritması çalıştırıldığında Şekil 3.9.b elde edilmekte iskelet çıkarılmaktadır.



Şekil 3.9. iskelet görüntüdür (<http://aicode.ir/learning/learning-articles/111-object-detection-matlab.html>.,Erişim tarihi: 15 Mayıs 2019)

3.3. Özellik Çıkarma

Özellik (feature) görüntüyü oluşturan alt bileşenlerin bütünüdür. Kimlik tespitinin yapılmasında bu bileşenlerin çıkarılması, yüksek öneme sahip olanların ayırt edilmesi yüksek başarılı bir biyometrik tanımlama sistemi oluşturabilmek adına büyük önem taşımaktadır. Bu çalışmada özellik çıkarmak amacıyla dalgacık dönüşümü kullanılmıştır (Saniei ve ark.(2009)).

3.3.1. Dalgacık Dönüşümü

Dalgacık dönüşümü, görüntüyü farklı konumlara ve ölçeklere sahip bir dizi dalgacık işlevi biçiminde görüntüler. Her görüntü ayrıştırma, biri görüntü ayrıntılarıyla ilişkili yüksek frekansları, diğeri görüntünün düşük frekanslarını veya düzgün kısımlarını temsil eden bir çift dalga formundan oluşur. Dalgacık dönüşümünün sonucu, dalgacığın bu konumlara ve ölçeklere katkısını ölçen bir dalgacık ifadesidir. Basitçe söylemek gerekirse, dalgacık dönüşümü görüntüyü farklı çözünürlükteki görüntülere böler (Misiti ve ark.(2013) , Saniei ve ark.(2009)).

Bu çalışmada, dalgacık dönüşümü, her görüntünün iki boyutlu bir dalgacık dönüşümünden türetileceği şekilde, yatay, dikey ve dikey doğrultulardaki katsayıların dört katsayısına ve bu katsayıların çarpımını elde edecek şekilde türetmek için kullanılmıştır. Görüntü bu yönlerde yeniden oluşturulmuştur.

Dalgacık dönüşümü, tamamen farklı bir değer fonksiyonu ile Fourier dönüşümüne benzer. Aralarındaki temel fark Fourier dönüşümünün sinyali sinüslere ve kosinüslere ayrıştırmasıdır. Yani Fourier uzayında lokalize olan fonksiyonların aksine dalgacık dönüşümü hem gerçek hem de Fourier uzayında lokalize olan fonksiyonları kullanır (<http://gwyddion.net/documentation/user-guide-en/wavelet-transform.html>.,Erişim tarihi: 04 Mayıs 2019). Genel olarak, dalgacık dönüşümü Denklem 3.5 ile ifade edilir.

$$F(a, b) = \int_{-\infty}^{\infty} f(x)\psi_{(a,b)}^*(x)dx \quad (3.5)$$

3.4. Entropi

Bilgi teorisinde entropi (veya daha doğrusu Shannon entropisi) her mesaj - veride yer alan bilginin matematiksel ortalamasıdır. Burada, veri mutlaka bir metinden oluşmak zorunda değildir ve herhangi bir bilgi akışına sahip olabilir. Her mesajın entropisi belirsizlik miktarıdır; mesaj ne kadar rastgele olursa, değer o kadar büyük olur ve değer o kadar az rastgeledir (<https://blog.faradars.org/information-entropy/>.,Erişim tarihi: 04 Mayıs 2019).

Entropi, giriş görüntüsünün dokusunu karakterize etmek için kullanılacak istatistiksel bir rastgelelik ölçümüdür (<https://www.mathworks.com/help/images/ref/entropy.html>., Erişim tarihi: 4 Mayıs 2019).

Denklem 3.6'daki eşitliği kullanarak $H(x)$ entropisini hesaplamak mümkündür:

$$H(x) = -\sum_{i=1}^n P_i \log_2 P_i \quad (3.6)$$

P_i değeri, verilen bir sembolün gerçekleşme olasılığıdır. Burada semboller pikseldir. Basitleştirmek için, tek kanallı 8 bitlik bir görüntüyü (256 yoğunluk seviyesi) ele alındığında p_i değeri Denklem 3.7'deki gibi hesaplanabilir.

$$P_i = \frac{\text{Yoğunluk seviyesi } i \text{ tekrar sayısı}}{\text{Yoğunluk seviyesi sayısı}} \quad (3.7)$$

3.5. Varyans

Varyans bir dağılım ölçüsüdür. Varyans değeri, beklenen veya gözlemlenen değerlerin karesinin beklenen değerle ortalaması alınarak hesaplanır. Ortalamaya kıyasla, ortalamanın dağıtım yerini temsil ettiği söylenirken, varyans verilerin ortalamaya nasıl dağıldığını gösteren ölçüdür. Daha az varyans, dağılımın bir örneği seçilirse, ortalamanın yakınında olması beklendiği anlamına gelir. Bir karenin varyansı, başlangıç miktarından biridir. Varyans bir veri serisinin ortalama değer etrafında nasıl dağıldığını gösterir (<https://fa.wikipedia.org/wiki/وارِيانس>, Erişim tarihi: 04 Mayıs 2019). Denklem 3.8'deki varyansın nasıl hesaplandığını gösterir (burada \bar{x} , x_i verilerinin aritmetik ortalamasıdır).

$$\frac{1}{n} (\sum_{i=1}^n (x_i - \bar{x})^2) \quad (3.8)$$

4. MAKİNE ÖĞRENMESİ TEKNİKLERİ

Makine öğrenmesi teknikleri temel olarak eğitici ve eğitici olmayan yaklaşımlar olarak ikiye ayrılır. Eğitici olmayan yaklaşımlar içinde yer alan kümeleme, numuneyi ve yeni verileri aynı kategorilerde gruplamak anlamına gelir. Bir küme birbirine benzeyen verileri içerir. Küme kayıtları birbirine en çok benzeyen ve en azından diğer kümelere benzemeyen veri kayıtlarıdır. Sınıflandırmadan farklı olarak, kümelemede gözlemci yoktur ve algoritma içerisinde hiçbir etiket verisi yer almaz (eğitim verisi yoktur). Veri kümeleme, çok boyutlu verinin, mesafe ölçümüne dayanmaktadır. Çok boyutlu çok sayıda veri kümesinde, veri alanı genellikle tek biçimli noktalarla doldurulmaz. Veri kümeleme, yoğun ve yoğun nüfuslu yerleri algılar, böylece genel bilgi dağılımı biçimini tanımlar. Kümeleme, veri örneklerinin yanı sıra hacim azaltma uygulamalarındaki benzerlik ve farklılıkları analiz etmek için kullanılabilir.

Bu tür bir algoritmada tahmin, veri kümesindeki diğer özellikler üzerindeki bir veya daha fazla ayrık değişkene dayanır. Sınıflandırmanın amacı, önce küçük bir veri seti kullanarak uygun bir model oluşturmak ve daha sonra üretilen modele dayanarak gelecekte gözlenen verileri uygun şekilde sınıflandırmaktır. Dokümantasyon kategorizasyonu, bir dokümanı önceden tanımlanmış bir sınıfa bağlamak anlamına gelir. Başka bir deyişle, belgelerin sınıflandırılmasının amacı, konuyu en az hatayı içeren belgeyi gösteren uygun konu kategorisini bulmaktır. Bu, bir belgeyi önceden tanımlanmış sınıflardan birine veya dinamik sınıflandırmaya bağlayarak, incelenecek belgenin yeni bir konu kategorisinin tanımlanmasına yol açarak yapılabilir.

Bu çalışma içerisinde sınıflandırma yöntemlerinden ve nitelik azaltım tekniklerinden Karar Destek Makineleri (Support Vector Machine – SVM), Doğrusal Ayraç Analizi (Linear Discriminant Analysis – LDA) + K En Yakın Komşuluk (K Nearest Neighbor – KNN), Yapay Sinir Ağları (Artificial Neural Network - ANN) ve derin öğrenme yaklaşımı Evrişimli Sinir Ağları (Convolutional Neural Network – CNN) kullanılmıştır.

4. 1. Karar Destek Makineleri (Support Vector Machine – SVM)

Karar destek makinesi, veri sınıflandırmasında en yaygın algoritma ve yöntemlerden biridir.


Basitçe ifade etmek gerekirse, destek vektörleri, verilerin n-boyutlu uzayda, kümelerin sınırlarını işaretleyen, verileri sınırlayan ve sınıflandıran, bunlardan birini hareket ettiren sınıflandırma çıktısı ile sonuçlanabilen bir dizi noktadır. Aslında, bir karar destek makinesi, vektörleri karşılaştırarak verilerin en iyi sınıflandırılmasını ve ayrılmasını tanımlayan bir küme veya sınırdır (<https://matlabkar.com/support-vector-machine-svm/>, Erişim tarihi: 15 Haziran 2019).

Bu algoritma diğer veri noktalarına duyarlı değildir ve tüm kümelere (destek vektörleri) olabildiğince yakın veriler arasında en iyi sınırı bulmayı amaçlar.

- Bu algoritmalar, bir eşleme işlevi için parametrelerin nasıl belirlenebileceği gibi doğal sınırlamalara sahiptir.
- Karar destek makineleri karmaşık ve zaman alıcı hesaplamalar gerektirir ve karmaşıklıkları nedeniyle çok fazla bellek tüketir.
- Ayrık ve sayısal olmayan veriler de bu yöntemle uyumlu değildir ve dönüştürülmesi gerekir.

Bununla birlikte, SVM'ler tutarlı bir teorik temele sahiptir ve ürettikleri çözümler küresel ve benzersizdir. Karar destek makineleri günümüzde veri madenciliğinde en yaygın tahmin teknikleridir.

Şekil 4.1'de iki verinin ayrılması için karar destek makinesinin (SVM) performansını göstermektedir (A Tutorial for Support Vector Machine).




Şekil 4.1. SVM performansı (Wei-Lun Chao(2011)).

4. 2. Doğrusal Ayraç Analizi (Linear Discriminant Analysis – LDA)

Doğrusal Ayraç Analizi (Linear Discriminant Analysis – LDA) boyut azaltımına dayalı bir tekniktir. Makine Öğrenimi ve örüntü sınıflandırma uygulamaları için ön işleme adımı olarak kullanılır. LDA'nın amacı, boyut probleminin oluşturduğu sorunlardan kaçınmak ve kaynakları ve boyutsal maliyetleri azaltmak için daha yüksek boyutlu alandaki özellikleri daha düşük boyutlu bir alana yansıtmaktır.

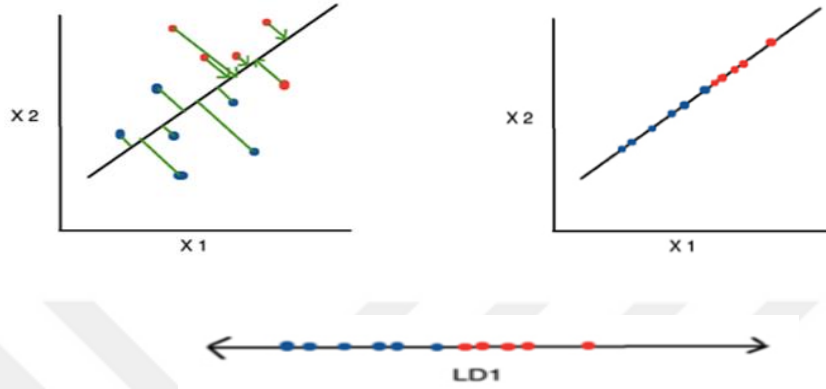
LDA, rekabetçi makine öğrenimi modellerinin hazırlanmasının bir parçası olarak kabul edilen denetimli bir sınıflandırma tekniğidir. Bu boyut azaltma kategorisi, görüntü tanıma ve tahmine dayalı analiz gibi alanlarda kullanılır. Boyut azaltım teknikleri Makine Öğrenmesi, Veri Madenciliği, Biyoinformatik ve Bilgi Alma uygulamalarında önemlidir. Temel amaç veri kümesini daha düşük boyutlu bir alana yansıtarak gereksiz ve bağımlı özellikleri kaldırmaktır. Basit bir ifadeyle, verilerin çoğunu korurken belirli bir veri kümesindeki boyutları (yani değişkenler) azaltırlar. Çok boyutlu veriler, birbirleriyle korelasyonu olan birden fazla özellik içerir. Boyutsal küçültmeyle çok boyutlu veriler yalnızca 2 veya 3 boyutta çizilebilir. Doğrusal ayraç analizi verilerin, kolayca anlaşılabilir açık bir şekilde sunulmasına izin verir (<https://www.knowledgehut.com/blog/data-science/linear-discriminant-analysis-formachine-learning>., Erişim tarihi: 25 Haziran 2019).

Her rengin farklı bir sınıfı temsil ettiği iki değişken arasındaki ilişkiyi biri kırmızı diğeri mavi ile gösterilen örnek üzerinde, boyut sayısı 1'e düşürülmek istendiğinde x ekseninde oluşan sonuç Şekil 4.2'de yer almaktadır.



Şekil 4.2. Düz bir çizgide iki değişken arasındaki ilişki (<https://www.knowledgehut.com/blog/data-science/linear-discriminant-analysis-for-machine-learning>.,Erişim tarihi: 25 Haziran 2019)

Bu yaklaşım, ikinci özellik tarafından sağlanan yararlı bilgileri ihmal eder. Ancak, bunu yansıtmak amacıyla LDA kullanılabilir. LDA iki özellikten gelen bilgileri kullanarak varyansı en aza indirir ve iki değişkenin sınıf mesafesini en üst düzeye çıkarır. Şekil 4.3, LDA'nın nasıl çalıştığını göstermektedir.



Şekil 4.3. LDA'nın sınıflamasına göre düz çizgide iki değişken arasındaki ilişki
(<https://www.knowledgehut.com/blog/data-science/linear-discriminant-analysis-for-machine-learning>.,Erişim tarihi: 25 Haziran 2019)

LDA öncelikle daha yüksek boyut uzayındaki özellikleri daha düşük boyutlara yansıtmaya odaklanır. Bunu işlem üç adımda özetlenebilir:

- İlk olarak, farklı sınıfların ortalaması arasındaki mesafe olan sınıflar arasındaki ayrılabilirliğin hesaplanması gerekir. Buna sınıflar arası varyans denir. Bu denklem 4.1'de görülmektedir.

$$S_b = \sum_{i=1}^g N_i (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T \quad (4.1)$$

- İkinci olarak, her bir sınıfın ortalaması ve örneği arasındaki mesafe hesaplanmalıdır. Buna sınıf içi varyans denir. Bu denklem 4.2'de görülmektedir.

$$S_w = \sum_{i=1}^g (N_i - 1) S_i = \sum_{i=1}^g \sum_{j=1}^{N_i} (x_{i,j} - \bar{x}_i)(x_{i,j} - \bar{x}_i)^T \quad (4.2)$$

- Son olarak, sınıflar arası varyansı en üst düzeye çıkararak ve sınıf içi varyansı en aza indiren alt boyutlu alanı oluşturulmalıdır. P, Fisher ölçütü olarak da adlandırılan düşük boyutlu uzay projeksiyonu olarak kabul edilir. Bu Denklem 4.3'de görülmektedir.

$$P_{lda} = arg \max_p \frac{|P^T S_b P|}{|P^T S_w P|} \quad (4.3)$$

LDA'nın temsili oldukça basittir. Model, verilerin her sınıf için hesaplanan istatistiksel özelliklerinden oluşur. Birden fazla değişken olması durumunda aynı özellikler çok değişkenli Gaussian üzerinden hesaplanır.

Tahminler, LDA denkleminde istatistiksel özellikler sağlanarak yapılır. Özellikler verilerden tahmin edilir. Son olarak, model değerleri LDA modelini oluşturmak için saklanır.

4.2.1. K En Yakın Komşu K Nearest Neighbors _KNN)

K-en yakın komşuları (KNN) algoritması, hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılabilen, basit, uygulaması kolay denetimli bir makine öğrenme algoritmasıdır. KNN algoritması benzer verilerin yakınlarda olduğunu varsayar. Başka bir deyişle, benzer veriler birbirine yakındır. KNN algoritmasının başarımı, bu varsayımın, doğru olmasına bağlıdır. KNN, bir grafikteki noktalar arasındaki mesafeyi hesaplayarak benzerlik fikrini yakalar. (<https://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761>.,Erişim tarihi: 11 Mayıs 2019).

KNN mesafe fonksiyonları :

- Euclidean :

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (4.4)$$

- Manhattan :

$$\sum_{i=1}^k |x_i - y_i| \quad (4.5)$$

- Minkowski:

$$(\sum_{i=1}^k (|x_i - y_i|^q))^{1/q} \quad (4.6)$$

4. 3. Yapay Sinir Ağları (Artificial Neural Network – ANN)

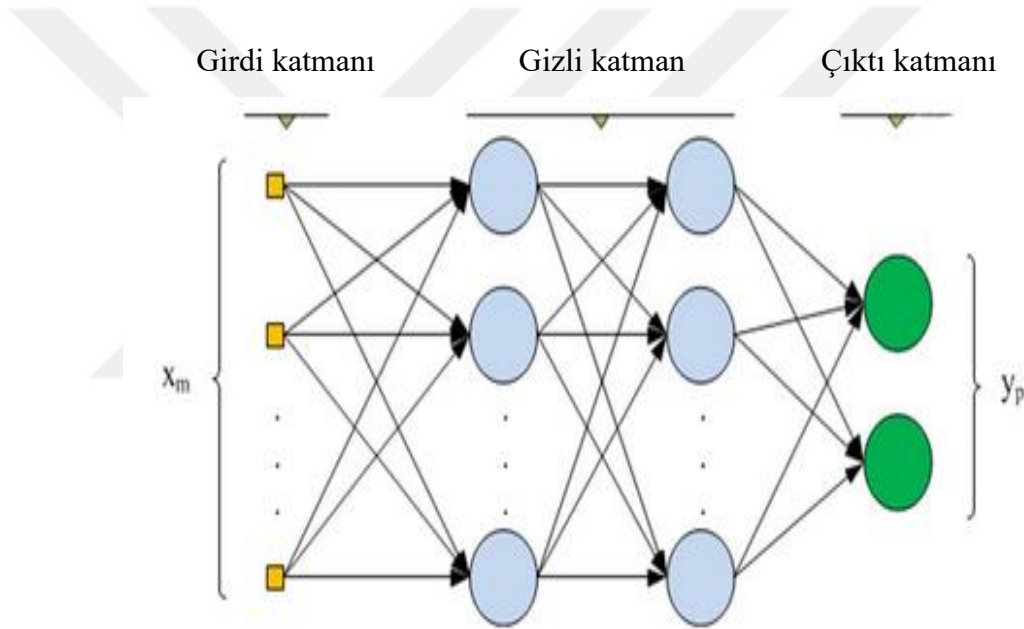
Yapay sinir ağının temel felsefesi, insan beyninin işlem özelliklerini biyolojik işlem yöntemiyle olağan hesaplama yöntemlerine yaklaşmak üzere modellemektir. Başka bir deyişle, yapay sinir ağı, eğitim yoluyla çoklu veri kümeleri arasındaki ilişki hakkındaki bilgileri yakalayan ve benzer durumlarda kullanmak üzere saklayan

bir yöntemdir (https://fa.wikipedia.org/wiki/شبکه_عصبی_مصنوعی.,Erişim tarihi: 11 Mayıs 2019).

İnsan beynine benzer şekilde çalışmaktadır:

- Sinir ağı öğrenimi eğitim yoluyla yapılır.
- Bilgi depolama sistemine benzer bir ağırlıklandırma, insan beyninin sinir ağında gerçekleşir.

Yapay sinir ağı üç katmandan: girdi, çıktı ve işleme (gizli) katmanından oluşur. Her katman, kullanıcı nöronlar arasındaki iletişimi kısıtlamadığı sürece, genel olarak diğer tüm tabaka nöronları ile ilişkili olan bir grup nöron içerir, ancak her tabakanın nöronları aynı tabakanın diğer nöronları ile etkileşime girmez. Şekil 4.4’de ise bir yapay sinir ağının göstermektedir.



Şekil 4.4. Yapay sinir ağının (<https://blog.faradays.org/neural-networks-0-to-100/>.,Erişim tarihi: 11 Mayıs 2019)

Matematiksel olarak giriş denklemi Denklem 4.7’deki gibi gösterilebilir:

$$X_i^T = [x_{i1} \dots \dots x_{ip} \quad 1] \quad (4.7)$$

X, giriş vektörü ve x, ağ giriş değişkenidir. Denklem 4.7 içerisinde yer alan ilişkide 1 numaraya değerine yanlılık (bias) değeri denir. Yanlılığın birincil rolü, her nöron için sabit bir eğitim değeri sağlamaktır. Aslında, sapma değeri aktivasyon fonksiyonunu veya transfer fonksiyonunu değiştirmeye izin verir. Bu denklem 4.8’de görülmektedir.

$$W_{ij}^T = [w_{j1} \dots \dots w_{jp} \quad - \theta] \quad (4.8)$$

W , ağırlık vektörü ve w , giriş vektörünün her değişkeninin ağırlığıdır. Aktivasyon, giriş ağırlıklarının toplamı ve her bir nöronun eşik değeri nedeniyle gerçekleşir. Aktive edilmiş sinyal, bir transfer fonksiyonuna bağlı olarak nörondan çıkarılır. Bu denklem 4.9'de görülmektedir.

$$NET_i(x_i) = X_i^T W_i \quad \rightarrow \quad output_j = O_j = sf(NE T_j) = \frac{1}{1+e^{-\beta(NE T_j)}} \quad (4.9)$$

Gizli katman, tek katmanlı veya çok katmanlı olabilir ve bu nedenle, tek katmanlı veya çok katmanlı sinir ağı olarak adlandırılır.


4. 4. Evrişimsel Sinir Ağları (Convolutional Neural Network – CNN)

Derin öğrenme algoritmaları, girdi verilerinin çok sayıda dağıtılmış temsilini keşfetmeyi amaçlayan makine öğrenme algoritmalarının bir alt kümesidir.

Evrişimsel sinir ağları (CNN), çoklu katmanların güçlü bir şekilde eğitildiği en önemli derin öğrenme yöntemlerinden biridir. Bu yöntem çok etkilidir ve özellikle görüntü üzerinde kullanılan en yaygın yöntemlerden biridir. Genel olarak, bir CNN ağı üç ana katmandan oluşur: konvolüsyon katmanı, ortaklama katmanı ve tam bağlı katman. Farklı katmanlar farklı görevler yerine getirir. Her bir sinir ağında eğitimin iki aşaması vardır: ileri ve geri yayılım. Yayılım sonrası ilk adımda, giriş görüntüsü ağa beslenerek, hesaplamalar yapılır. Ardından ağ çıkışı hesaplanır. Burada, ağ parametrelerini veya başka bir deyişle ağ eğitimini ayarlamak için, çıktı sonucu ağ hata oranını hesaplamak için kullanılır (<http://www.radoo.ir/P/Convolution-neural-network>.,Erişim tarihi: 21 Mayıs 2019). Bunu yapmak için, ağ çıkışını doğru cevabı veren bir kayıp fonksiyonu ile karşılaştırır ve hata oranı hesaplanır. Bir sonraki adım, hesaplanan hata oranına dayalı olarak geri yayılım aşaması ile başlar. Bu noktada her parametrenin gradyanı zincir kuralına göre hesaplanır ve tüm parametreler ağıdaki hata üzerindeki etkilerine göre değiştirilir. Parametreler güncellendikten sonra, bir sonraki ileri besleme aşaması başlar. Bu adımların tekrarladıktan sonra ağ eğitimi sona erecektir (<http://www.radoo.ir/P/SimpleintroCNN>.,Erişim tarihi: 21 Mayıs 2019).

Konvolüsyon katmanları, yerel olarak kısıtlandıkları için yerel özellikleri ayıklayabilir. Evrişimsel sinir ağları, örüntü tanıma, konuşma tanıma, doğal dil

işleme ve video analizi gibi geniş bir alan yelpazesini kullanan derin öğrenmenin çekirdeğidir. Şekil 4.5’de ise bir evrişimsel sinir ağı (CNN) göstermektedir.



Şekil 4.5. Evrişimsel sinir ağı (Johania ve Elrefaei (2019))

4.5. Performans Değerlendirme Metrikleri

Bir sınıflandırıcının performans analizinin gerçekleştirilmesinde karışıklık matrisi’nden (confusionmatrix) yola çıkılır.

- Doğru Pozitif (True Positive - TP): El sırtı damar izinden yola çıkılarak aranılan kişinin isabetli olarak bulunduğu durum.
- Doğru Negatif (True Negative - TN) : El sırtı damar izinden yola çıkılarak aranılan kişinin isabetli olarak bulunamadığının belirtildiği durum.
- Yanlış Pozitif (False Positive - FP): El sırtı damar izinden yola çıkılarak aranılan kişinin isabetsiz olarak bulunduğunun belirtildiği durum.
- Yanlış Negatif (False Negative - FN) : El sırtı damar izinden yola çıkılarak aranılan kişinin isabetsiz olarak bulunamadığının belirtildiği durum.

Şekil 4.6’de doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerlerinden oluşan karışıklık matris (confusion matris) görülmektedir.

Tahmin Edilen Değerler	Negatif(0) Pozitif(1)	Gerçek Değerler	
		Pozitif(1)	Negatif(0)
		TP	FN
		FP	TN

Şekil 4.6. Karışıklık matrisi

Karışıklık matrisinden yola çıkılarak doğruluk, hata, özgüllük, duyarlılık, F1-skoru, Matthews korelasyon katsayısı, kappa performans metrikleri hesaplanabilmektedir. İlgili performans metrikleri Doğruluk hesaplaması denklem 4.10 içerisinde, Hata denklem 4.11 içerisinde, Özgüllük denklem 4.12 içerisinde, Duyarlılık denklem 4.13 içerisinde, Hassasiyet denklem 4.14 içerisinde, F1-Skoru denklem 4.15 içerisinde, Matthews Korelasyon Katsayısı denklem 4.16 içerisinde, Kappa denklem 4.17 içerisinde yer almaktadır.

- Doğruluk (Accuracy):

$$\frac{TP+TN}{TP+TN+FP+FN} \quad (4.10)$$

- Hata (Error):

$$1 - \frac{TP+TN}{TP+TN+FP+FN} \quad (4.11)$$

- Özgüllük (Specificity):

$$\frac{TN}{TN+FP} \quad (4.12)$$

- Duyarlılık (Sensitivity - Recall):

$$\frac{TP}{TP+FN} \quad (4.13)$$

- Hassasiyet (Precision):

$$\frac{TP}{TP+FP} \quad (4.14)$$

- F1-Skoru (F1-Score):

$$\frac{2(Precision*Sensitivity)}{(Precision+Sensitivity)} \quad (4.15)$$

- Matthews Korelasyon Katsayısı (Matthews Correlation Coefficient):

$$\frac{TP*TN-FP*FN}{\sqrt{(TP+FP)(TN+FN)(TP+FN)(TN+FP)}} \quad (4.16)$$

- Kappa:

$$\frac{\frac{(TP+TN)}{(TP+TN+FP+FN)} - \left[\frac{(TN+FP)(TN+FN) + (FN+TP)(FP+TP)}{(TP+TN+FP+FN)^2} \right]}{1 - \left[\frac{(TN+FP)(TN+FN) + (FN+TP)(FP+TP)}{(TP+TN+FP+FN)^2} \right]} \quad (4.17)$$




5. BULGULAR VE TARTIŞMA

Bu çalışma içerisinde kullanılan Dr. Badawi el damar veri kümesi, önerilen yöntemin doğruluğunu sınavabilmek adına veri arttırma işlemine tabi tutulmuştur. Bu amaçla veri kümesi içerisinde yer alan 100 veriye farklı oranlarda gürültü eklenerek toplam 4000 veri elde edilmiştir. Verilere 0.01 – 0.07 aralığında değişen tuz biber gürültüsü eklenmiştir. Her bir gürültü oranından veriye eşit sayıda ekleme yapılmıştır. Şekil 5.1.a’de veri setinde yer alan örnek el sırtı damar izi görüntüsü yer almaktadır. Şekil 5.1.b.’da siyah beyaz el sırtı damar izi örneğine 0.01(gürültü yoğunluğu) gürültü eklenmiş hal, Şekil 5.1.c’de siyah beyaz el sırtı damar izi görüntüsüne 0.02(gürültü yoğunluğu) gürültü eklenmiş hal, Şekil 5.1.d’de siyah beyaz el sırtı damar izi görüntüsüne 0.05(gürültü yoğunluğu) gürültü eklenmiş hal görünmektedir.



(a)



(b)


(c)

(d)

Şekil 5.1. Normal ve farklı oranlarda gürültü eklenmiş görüntüler (shahin ve ark.(2007))

İkinci adımda istenilen alanı çıkarma ve arka planı kaldırma işlemi gerçekleştirilmiştir. Bu amaçla, görüntü alanını bulmak için, aynı yoğunluğa sahip olan veya birbirine yakın; alt sınırdan daha düşük olan piksel değerlerine sıfır değeri atanmıştır. İlgili işlemler için Genişletilmiş Maxima Dönüşümü kullanılmıştır. Bu aşamadan sonra, ellerin aralığı arka plandan tamamen ayrı olacaktır. Bu adımın sonucu, Şekil 5.2.a'da gösterilmiştir.

İstenilen arka planın kaldırılmasından sonra görüntüyü yüksek başarımla elde ederek işleyebilmek adına önce görüntü netliğini arttırmak gerekmektedir. Bu sebeple, 3×3 büyüklüğünde bir ortanca filtre, görüntüdeki bozulmaları gidermek için kullanılmıştır. Ortanca filtresinin kullanılmasının ardından elde edilen görüntü Şekil 5.2.b'de yer almaktadır.



Şekil 5.2. Ortanca filtresi kullanıldıktan sonra elde edilen görüntü

Netliği arttırılmış görüntü üzerinde el damar düzeni çıkarılmıştır. Bu adımda damar düzenini çıkarmak için uyarlanabilir eşikler (adaptive thresholding) işlemi gerçekleştirilmiştir. Bu eşikleme türünde, görüntü boyunca eşik değerleri görüntünün yerel görüntüsünün bir türevi olarak değişmektedir. Gri görüntünün yoğunluğu, genel küçük resim ve yerleşime göre görüntü boyunca tamamen değişir. Damar deseni ile tüm görüntü için eşik değeri tatmin edici bir şekilde elde edilemez.

Bu nedenle, yerleşik algılama algoritması takip edilir. Daha önce açıklandığı gibi, bu algoritma, merkez piksele bitişik piksellerin analizine dayanarak her piksel için eşik değerlerini hesaplar. Şekil 5.3.a'da gösterilen ikili görüntüde, damar deseninin tamamen çıkarılması gösterilmiştir.

Uyarlanabilir eşik işlemleri gerçekleştirildikten ve damarların düzeni çıkarıldıktan sonra görüntü arterler içerisinde kırılmış ve ayrılabilir noktalara sahip olduğundan, kapatma algoritması (closing algorithm), diskin yapı elemanı ile birlikte, görüntünün bütünlüğü için 3 yarıçapında kullanılmıştır. Kapatma algoritması uygulandıktan sonra elde edilen sonuç Şekil 5.3.b’de yer almaktadır.



Şekil 5.3. Kapatma algoritması uygulandıktan sonra elde edilen sonuçlar

İlerleyen aşamalarda el çevresinin yer aldığı bölgenin ve damar izinin tamamen çıkarılması işlemi gerçekleştirilmiştir. Damar deseninin azami görüntüsünü korumak amacıyla işlenmiş alanın kareler veya dikdörtgenler gibi geometrik şekillerde elde edilmesinden kaçınılmaktadır. Tüm damarların görüntüsünün, ayırt edici özelliklerin işlenmesi ve maksimize edilmesi için tamamen geliştirilmesi tercih edilmektedir. Daha sonra görüntüyü işleyebilmek amacıyla, el kadranını çıkarmak için, bir kenar bulma algoritması kullanılmıştır.


Bu çalışmada, Canny kenar bulma algoritması kullanılmıştır. Diğer kenar bulma algoritmalarıyla kıyaslandığında, örneğin Sobel algoritmasından farklı olarak elde edilen damar izi görüntüsünde süreklilik sağlamakta, görüntüde kırılım noktaları oluşturmaktan kaçınılmaktadır. Şekil 5.4.a’da Canny kenar bulma algoritması kullanıldıktan sonra elde edilen görüntü yer almaktadır.

Kenarları bulunan görüntü üzerinde her damar için iki kenar arasındaki değere bir değer atanmalıdır. Böylece bu alanlar sınıflandırma aşamasında anlamlı bir biçimde kullanılabilir. Bu amaçla, filtreleme adımında elde edilen görüntüde (Şekil 5.4.b’de) yer alan pikseller ve kenar bulma adımında elde edilen görüntüde (Şekil 5.4.a’da) yer alan pikseller kullanılır. Eğer Şekil 5.4.b içerisinde yer alan piksel değerleri 1 ise ve eğer Şekil 5.4.a değerinde yer alan pikseller 0 ise yeni oluşturulacak görüntü üzerinde piksel değerleri 1 olarak atanır. Böylelikle arka planın ve yalnızca damar bölgelerine ait alanın beyaz renge sahip olması sağlanır.



Şekil 5.4. Canny algoritması kullandıktan sonra elde edilen görüntüler

İskeleti tam olarak çıkarmak için el iskeleti ve arka plan renklerini farklılaştırmak gerekmektedir. Bu amaçla beyaz arka planı oluşturan değerler görüntüden temizlenmiştir. Şekil 5.5.a'da yer alan şekil üzerinde arka plan değerlerinin siyaha çevrilmesi ilk adım Şekil 5.5.b'de ikinci adım tamamlanmış hali ile Şekil 5.5.c'de görülmektedir.



Şekil 5.5. Arka plan kaldırıldıktan sonra elde edilen görüntüler

Şekil 5.5.c içerisinde son olarak elde edilen görüntüde yer alan damarlar oldukça kalındır. Damarların desenini çıkarmak için ilk olarak damarların kalın olması gereklidir. Şekil 5.5.c üzerinde iskelet çıkarma algoritması uygulanmıştır. Şekil 5.6'da, iskelet çıkarma algoritmasının kullanılması sonucunda elde edilen sonuç görülmektedir.



Şekil 5.6. İskelet çıkarıldıktan sonra elde edilen görüntü

Şekli 5.6 içerisinde yer alan çıkarılmış iskelet görüntüsü üzerinde istenmeyen bir dizi yatay çizgi yer almaktadır. Bu nedenle tekrar erozyon işlemi kullanılarak görüntü istenmeyen yatay çizgilerden temizlenmiştir. Erozyon işlemi esnasında 1×3 boyutunda bir filtre kullanılmıştır.

Bu aşamadan sonra, genişleme algoritması, kırılma noktalarını bağlamak ve kırılma noktalarını çıkarmak için 5×1 boyutunda dikdörtgen filtre ile gerçekleştirilmiştir. Son aşamada ise 1×5 boyutunda bir filtre ile açma işlemi gerçekleştirilmiştir. Böylelikle 5 pikselden küçük olan görüntü değerlerinin damar deseni oluşturmadığı kabul edilmiş ve görüntüden temizlenmiştir. Arka arkaya gerçekleştirilen bu işlemler sonucunda iskelet bir bütün olarak birleştirilmiştir. İskelet birleştirme işlemi öncesinde ve sonrasında elde edilen görüntüler sırasıyla Şekil 5.7.a ve Şekil 5.7.b içerisinde yer almaktadır.

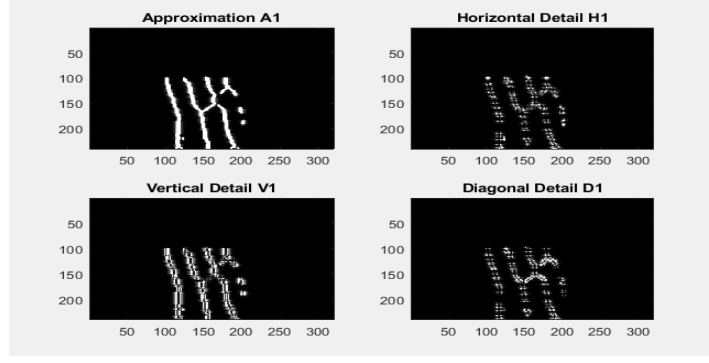


Şekil 5.7. İskelet birleştirme

Bu aşamada her görüntü için sadece iki özellik (entropi ve varyans) elde edilmiştir. Ancak başarımlarını arttırmak adına özelliklerin artırılması gerekmektedir. Özellikleri artırmak için önce dalgacık dönüşümünü kullanılmıştır.

Dalgacık dönüşümünü kullanarak görüntü dört farklı yönde yeniden oluşturulur. Şekil 5.8'de, bu görüntünün ayrışabilir dört alt resminin bir dalgacık dönüşümü ile temsil edilen hali yer almaktadır.

Böylece, dalgacık dönüşümü kullanılarak, her görüntünün özellik sayısı sekiz özelliğe çıkarılır.



Şekil 5.8. Dalgacık dönüşümü sonrası görüntü

Her el için dalgacık dönüşümü uygulamasına göre, dördü entropi ve dördü görüntülerin varyansı ile ilişkili toplam sekiz özellik belirlenmiştir.

Elde edilen nitelikler ikili SVM sınıflandırıcısı ile sınıflandırılmış ve performans ölçümü gerçekleştirilmiştir. İlgili sınıflandırıcısının sınanması adına oluşturulan veri kümesinin %80'i eğitim %20'si test amacıyla bölümlenmiştir. Çoklu çalışma deneylerinin sonucuna göre doğruluk oranı %81,61 olarak elde edilmiştir. Çizelge 5.1'de diğer niteliklerin ortalamasını göstermektedir.

Çizelge 5.1. SVM sınıflandırıcısı kullanılarak elde edilen performans metrikleri

SVM Iterasyon	Doğruluk (Accuracy) (%)	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)	Özgüllük Specificity (%)	F1 Score (%)	Matthews Korelasyon Katsayısı (%)	Kappa (%)
Ortalaması	0.8161	0.8404	0.8161	0.9981	0.8145	0.8196	0.8923

Elde edilen nitelikler ikili LDA+KNN sınıflandırıcısı ile sınıflandırılmış ve performans ölçümü gerçekleştirilmiştir. İlgili sınıflandırıcısının sınanması adına oluşturulan veri kümesinin %80'i eğitim %20'si test amacıyla bölümlenmiştir. Çoklu çalışma deneylerinin sonucuna göre doğruluk oranı 76,41 elde edilmiştir. Çizelge 5.2'de diğer niteliklerin ortalamasını göstermektedir.

Çizelge 5.2. LDA sınıflandırıcısı kullanılarak elde edilen performans metrikleri

LDA+KNN Iterasyon	Doğruluk (Accuracy) (%)	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)	Özgüllük Specificity (%)	F1 Score (%)	Matthews Korelasyon Katsayısı (%)	Kappa (%)
Ortalaması	0.7641	0.7844	0.7641	0.9976	0.7604	0.7649	0.9161

ANN ve CNN yöntemlerinin kullanımında görüntülere ait nitelik çıkarımı ilgili yöntemler tarafından hesaplandığı için entropi ve varyans değerleri kullanılmamıştır.

Elde edilen nitelikler ikili ANN sınıflandırıcısı ile sınıflandırılmış ve performans ölçümü gerçekleştirilmiştir. İlgili sınıflandırıcısının sınanması adına oluşturulan veri kümesinin %80'i eğitim %20'si test amacıyla bölümlenmiştir. Çoklu çalışma deneylerinin sonucuna göre doğruluk oranı 98.45 elde edilmiştir. Çizelge 5.3'de diğer niteliklerin ortalamasını göstermektedir.

Çizelge 5.3. ANN sınıflandırıcısı kullanılarak elde edilen performans metrikleri

ANN Iterasyon	Doğruluk (Accuracy) (%)	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)	Özgüllük Specificity (%)	F1 Score (%)	Matthews Korelasyon Katsayısı (%)	Kappa (%)
Ortalaması	0.9845	0.9872	0.9845	0.9998	0.9844	0.9850	0.2172

Elde edilen nitelikler ikili CNN sınıflandırıcısı ile sınıflandırılmış ve performans ölçümü gerçekleştirilmiştir. İlgili sınıflandırıcısının sınanması adına oluşturulan veri kümesinin %80'i eğitim %20'si test amacıyla bölümlenmiştir. Çoklu çalışma deneylerinin sonucuna göre doğruluk oranı 99.64 elde edilmiştir. Çizelge 5.4'de diğer niteliklerin ortalamasını göstermektedir.

Çizelge 5.4. CNN sınıflandırıcısı kullanılarak elde edilen performans metrikleri

CNN Iterasyon	Doğruluk (Accuracy) (%)	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)	Özgüllük Specificity (%)	F1 Score (%)	Matthews Korelasyon Katsayısı (%)	Kappa (%)
Ortalaması	0.9964	0.9964	0.9964	1.000	0.9963	0.9965	0.8196

6. SONUÇLAR

Bu çalışma içerisinde örnek bir veri kümesi kullanarak el sırtı damar izi görüntülerine dayalı biyometrik kimlik tanımlama sistemi geliştirilmiştir. Örnek veri kümesi olarak Badawi el damar veri kümesi olarak kullanılmıştır. Veri kümesi içerisinde yer alan toplam 100 farklı görüntü üzerine gürültü eklenerek 4000 farklı görüntü elde edilmiştir. Görüntüler ön işleme aşamasında morfolojik operatörler, kenar çıkarma algoritmaları vb. işlemler uygulanmıştır. Netliği artırılmış, damar izi çıkartılmış görüntüler üzerinde kimlik tespiti yapabilmek için çeşitli makine öğrenmesi yöntemleri kullanılmıştır.

Makine öğrenmesi yöntemleri olarak yapay sinir ağları, k en yakın komşuluk, karar destek makineleri ve evrimsel sinir ağları tercih edilmiştir. En yakın komşuluk yönteminin başarımını arttırabilmek adına doğrusal ayraç analizi kullanılarak nitelik azaltılmış, daha sonra sınıflandırma işlemi gerçekleştirilmiştir. Gerçekleştirilen çoklu çalıştırmalar ve sınamalar sonrasında en yüksek doğruluğa CNN yöntemi ile %99.64 olarak erişilmiştir. CNN sahip olduğu çok katmanlı yapısı ve görüntüler üzerinde niteliklerin güçlü temsili ile diğer makine öğrenmesi yöntemlerine kıyasla daha yüksek doğruluğa erişmektedir.

7. KAYNAKLAR

Alasadi, A. H. H., Dawood, M. H. (2017) Dorsal Hand-vein Images Recognition System based on Grey Level Co-occurrence Matrix and Tamura. *International Journal Applied Pattern Recognition*, 4(3):207.

Al-johania, N. A., & Elrefaei, L. A.(2019). Dorsal Hand Vein Recognition by Convolutional Neural Networks: Feature Learning and Transfer Learning Approaches.

Badawi, A. M. (2006) Hand Vein Biometric Verification Prototype: A Testing Performance and Patterns Similarity. In *Proceedings of The 2006 International Conference on Image Processing, Computer Vision, and Pattern Recognition (IPCV'06: June 26-29, Las Vegas, USA)*.

Bartunek, J. S. (2004). Minutiae extraction from fingerprint with neural network and minutiae based fingerprint verification.

Chao, W. L. A.(2011). tutorial for support vector machine.

Cross, J. M., Smith, C. L. (1995) Thermographic imaging of the subcutaneous vascular network of the back of the hand for biometric identification. In *Proceedings The Institute of Electrical and Electronics Engineers. 29th Annual 1995 International Carnahan Conference on Security Technology, IEEE*, s:20-35.

Kono, M., Ueki, H., Umemura, S. I. (2002) Near-infrared finger vein patterns for personal identification. *Applied Optics*, 41(35):7429-7436.

Lin, C. L., Fan, K. C. (2004) Biometric verification using thermal images of palm-dorsa vein patterns. *IEEE Transactions on Circuits and systems for Video Technology*, 14(2):199-213.

Misiti, M., Misiti, Y., Oppenheim, G., & Poggi, J. M. (Eds.). (2013). *Wavelets and their Applications*. John Wiley & Sons.

Sabhanayagam, T., Venkatesan, V. P., SenthamaraiKannan, K. (2018) A comprehensive survey on various biometric systems. *International Journal of Applied Engineering Research*, 13(5):2276-2297.

Saniei, E. , Setayeşi, S. , Şirmardi, P. , (2009)Identify Identity Through The Pattern Of The Arteries Behind The Hand. Iran's first national software engineering conference, s:166-176

Shahin, M., Badawi, A., Kamel, M. (2007) Biometric authentication using fast correlation of near infrared hand vein patterns. *International Journal of Biological and Medical Sciences*, 2(3): 141-148.

Shahin, M. K., Badawi, A. M., Rasmy, M. E. (2010) Multimodal biometric system based on near-infra-red dorsal hand geometry and fingerprints for single and whole hands. *International Journal of computer and Information Engineering*, 4(4): 268-283.

Wang, Y., Zhao, Z. (2013) Liveness detection of dorsal hand vein based on the analysis of Fourier spectral. In *Chinese Conference on Biometric Recognition*. Springer, Cham. s:322-329.

Wang, Y., Zheng, X., Wang, C. (2016) Dorsal Hand Vein Recognition Across Different Devices. In *Chinese Conference on Biometric Recognition*. Springer, Cham. s.307-316.

<http://aicode.ir/learning/learning-articles/111-object-detection-matlab/>(15.5.2019)

<http://aicode.ir/learning/learning-articles/61-thresholding.html/>(1.4.2019)

<http://blog.class.vision/1396/12//morphology-opening-closing/>(5.4.2019)

<http://gwyddion.net/documentation/user-guide-en/wavelet-transform.html/>(6.5.2019)

<http://www.advancedsourcecode.com/dctiris.asp/>(21.3.2019).

<http://www.mathworks.com/>(5.3.2019)

<http://www.radoo.ir/P/Convolution-neural-network/>(21.5.2019)

<http://www.radoo.ir/P/SimpleintroCNN/>(21.5.2019)

<https://article.tebyan.net/111497/تشخيص-هویت-با-کف-دست-و-رگ-ها/>(23.3.2019)

<https://blog.faradars.org/information-entropy/>(4.5.2019)

<https://blog.faradars.org/neural-networks-0-to-100/>(11.5.2019)

https://fa.wikipedia.org/wiki/مصنوعی_عصبی_شبکه(11.5.2019)

<https://fa.wikipedia.org/wiki/وارיאانس>(4.5.2019)

<https://en.wikipedia.org/wiki/Biometrics/>(21.3.2019)

<https://matlabkar.com/support-vector-machine-svm/>(15.6.2019)

<https://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761/>(11.5.2019)

<https://tr.depositphotos.com/vector-images/retina.html/>(21.3.2019)

<https://www.knowledgehut.com/blog/data-science/linear-discriminant-analysis-for-machine-learning/>(25.6.2019)

<https://www.mathworks.com/help/images/edge-detection.html/>(6.4.2019)

<https://www.mathworks.com/help/images/ref/entropy.html/>(4.5.2019)

https://www.researchgate.net/figure/Hand-geometry-features-according-to-7_fig2_235950674/(21.3.2019)

8. ÖZGEÇMİŞ

Masoumeh ZEHTAB NAYEBİ, 1981 yılında doğdu. İlk ve Orta öğrenimini Rasht'de tamamlamıştır. 2006 yılında Azad Eslami Lahican Üniversitesi Bilgisayar Mühendisliği Bölümünden mezun olmuştur. 2007 – 2017 yılları arasında GİL (GOLSAR) hastanesinde çalışmıştır. 2016 yılında Azad Eslami Lahican Üniversitesi Muhasebe Bölümünden mezun olmuştur. Haliç Üniversitesi Bilgisayar Mühendisliği programında tezli yüksek lisans öğrenimine 2018 yılında başlamıştır.

