



**T.C.  
SELÇUK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKA YÖNTEMLERİ İLE EL  
DAMAR DESENİ TANIMA**

**Hasan TUTUMLU**

**YÜKSEK LİSANS TEZİ**

**Elektrik-Elektronik Mühendisliği**

**Ağustos-2011  
KONYA  
Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Hasan TUTUMLU tarafından hazırlanan “Yapay Zeka Yöntemleri İle El Damar Deseni Tanıma” adlı tez çalışması **23/01/2021** tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Prof.Dr.Novruz ALLAHVERDİ

#### Danışman

Prof.Dr. Novruz ALLAHVERDİ

#### Üye

Yrd. Doç. Dr. Nihat YILMAZ

#### Üye

Öğr. Gör. Dr. Yalçın EZGİNCİ

### İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Bayram SADE  
FBE Müdürü

Bu tez çalışması BAP Koordinatörlüğü tarafından **101001015** nolu proje ile desteklenmiştir.

## **TEZ BİLDİRİMİ**

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## **DECLARATION PAGE**

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Hasan TUTUMLU

Tarih: 27/01/2011

## ÖZET

### YÜKSEK LİSANS

#### YAPAY ZEKA YÖNTEMLERİ İLE EL DAMAR DESENİ TANIMA

**Hasan TUTUMLU**

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Danışman: Prof.Dr. Novruz ALLAHVERDİ**

**2011, 70 Sayfa**

**Jüri**

**Prof.Dr. Novruz ALLAHVERDİ  
Yrd.Doç.Dr.Nihat YILMAZ  
Öğr.Gör.Dr.Yalçın EZGİNCİ**

Günümüzde güvenliğin her geçen gün daha fazla ön plana çıkması, kişinin çok daha fazla şifreyi aklında tutmak zorunda kalması ve daha fazla kartın yanında bulundurulması gerekliliğini ortaya çıkarmıştır. Bu yaklaşımların giderek pratiklikten ve güvenilirlikten uzaklaşması, biyometrik tekniklere olan ilgiyi artırmıştır. Biyometrik insan tanımlamadır. Kişinin sadece kendisinin sahip olduğu, kendisi olduğunu kanıtlamaya yarayan, değiştiremediği ve diğerlerinden ayırt edici olan fizyolojik özelliklerin tanınması prensipleri ile çalışır. Şirketlerin kaynaklarını ve değerli bilgilerini tehdit eden güvenlik açıkları, ulusal güvenliği tehdit eden terörist saldırıları, giriş için kullanılan şifre ve kart gibi tanıtıcıların unutulması, kaybolması ve çalınması risklerinin olması, özellikle havaalanı ve şirket binalarının girişlerinde biyometrik sistemlerin kullanımına olan talebi artırmıştır. Bu tez çalışmasında kullanılan el damar yapısı özellikle taklit edilmesi ve kopyalanması mümkün olmayan bir yapıya sahiptir ki bu sistemi daha güvenilir bir hale getirmesi açısından önemlidir.

Bu tez çalışmasında, insan el damarları kullanılarak bir biyometrik tanıma gerçekleştirilmiştir. Tanıma sistemi 4 aşamadan oluşmaktadır. Öncelikle, yumruk şeklinde tutulan insan el görüntüleri, üst taraftan yakın kızılötesi kamera vasıtasıyla

alınmıştır. Alınan el görüntülerinden damar bölgesi ayrıştırılmış ve ayrıştırılan bu damar görüntüsü ön işlem aşamasından geçirilerek damar desenleri belirgin hale getirilmiştir. Ardından gri seviyeli damar deseni siyah-beyaz görüntüye dönüştürülerek sayısallaştırılmıştır. Sayısal damar veri setleri yapay sinir ağları (YSA) ile sınıflandırılarak tanıma gerçekleştirilmiştir.

Bu çalışmada el damar görüntüsünü almak için yakın kızılötesi monokrom kamera kullanılmıştır. Elin üst bölgesinde deri altında bulunan damarlar yaklaşık 650-900 nm aralığında dalga boyuna sahip kızılötesi ışık altında belirgin halde görünmektedir. Bunun sebebi damarlarda dolaşan kanda bulunan Hemoglobinin kızılötesi ışığı belli oranda absorbe ediyor olmasından kaynaklanmaktadır. Bu çalışmada kullanılan kızılötesi ışık kaynağının dalga boyu 880 nm dir.

Deneysel çalışma amacıyla 103 kişiden, her bir kişiden 9 el görüntüsü olmak üzere, toplam 927 adet resim alınmıştır. Alınan görüntüler 752x480 boyutlarında gri seviyeli resimdir. Alınan bu el görüntülerinde yer alan damar bölgesi, 240x180 boyutunda dikdörtgensel kesit olarak resimden kesilerek alınmıştır. Alınan bu kesit görüntüde yer alan kırışık deri yapısı ve kıllar gibi gürültülerin damar deseninde yer almaması için görüntüde ortalama filtre ve histogram eşitleme işlemleri kullanılmıştır. Ardından otsu algoritması kullanılarak gri seviyeli damar deseni görüntüsü, siyah-beyaz görüntüye dönüştürülmüştür.

Damar deseninin öznitelik vektörünün çıkarılması amacıyla damar deseni resimleri 20x20 pixel boyutlarında küçük parçalara bölünmüştür. Elde edilen her kare, ortalama mutlak sapma yöntemi kullanılarak 0-1 aralığında sayısal verilere çevrilmiştir. Dolayısıyla, 240x180 boyutundaki el damar görüntüsü, 20x20 boyutlarında alt görüntülere bölünerek 108 adet veri içeren öznitelik vektörü elde edilmiştir. Elde edilen bu veriler sınıflandırma amacıyla kullanılan yapay sinir ağına giriş olarak verilmiştir.

Sınıflandırma aşamasında, 103 kişiden alınan tüm damar verilerinin %70'i eğitim (TRN), %20'si doğrulama (VLD) ve geri kalan %10 ise test (TST) veri kümesi olarak belirlenmiştir. Damar görüntülerinin tanınması amacıyla çok katmanlı perseptron YSA mimarisi kullanılmıştır. Öğrenme algoritması olarak hızlı yayılım (Quick Propagation), online geriyayılım (Online Back Propagation) ve yığın geriyayılım (Batch Back Propagation) kullanılmıştır. Gizli katman nöron sayısı, deneme-yanılma metodu

kullanılarak 101 olarak belirlenmiştir. Aktivasyon fonksiyonu olarak tanjant hiperbolik ve lojistik fonksiyonları kullanılmıştır.

Yapılan deneysel çalışmalar sonucunda, yığın geriyayılım öğrenme algoritması ile tanjant hiperbolik aktivasyon fonksiyonunun %100 test doğrulama oranı ile en iyi doğru sınıflandırma oranına sahip olduğu görülmüştür. Ancak, yığın geriyayılım algoritmasının eğitim iterasyon sayısı ve süresinin diğer öğrenme algoritmalarına göre çok daha uzun olduğu görülmüştür. Bununla birlikte genel test sonuçlarına bakıldığında, lojistik aktivasyon fonksiyonunun hızlı ve online geriyayılım algoritmasında daha iyi sonuçlar verdiği görülmüştür.

**Anahtar Kelimeler:** biyometri, biyometrik tanıma, el damar deseni tanıma, yapay sinir ağları,

## **ABSTRACT**

### **MS THESIS**

#### **HAND VEIN PATTERN RECOGNITION WITH ARTIFICIAL INTELLIGENCE METHODS**

**Hasan TUTUMLU**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
SELÇUK UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE  
IN ELECTRICAL-ELECTRONICS ENGINEERING**

**Advisor: Prof.Dr.Novruz ALLAHVERDI**

**2011, 70 Pages**

**Jury**

**Advisor: Prof.Dr.Novruz ALLAHVERDI**

**Yrd.Doc.Dr.Nihat YILMAZ**

**Öğr.Gör.Dr.Yalçın EZGİNCİ**

The fact that security is becoming more and more important today forces individuals to keep many more numbers in mind and carry more cards with them. Lack of practicality and security in this regard has increased interest in biometrical techniques. Biometrics means identification of humans. It works on principles of physiological features that only one person possesses, that help to prove his/her identity, that he or she can not alter and that distinguish him or her from others. Existence of risks such as security gaps that threaten companies' resources and valuable information, terrorist attacks that pose a threat to national security, forgetting, or losing of passwords or cards that are used to enter or having them stolen have increased the demand for the use of biometric systems especially at airport and company building entrances.

The present thesis study involves taking images of veins in human hands via infrared cameras, digitalising the images that were taken through image processing algorithms and classifying them using especially artificial neural networks. Vascular structure of human is impossible to imitate or copy, which is important in that it makes the system more reliable. Moreover, the use of such an identification system is

important in terms of supervision of personnel employed in government institutions, banks, private businesses, intelligence and military organisations and factories, and removing security gaps of electronic devices such as notebooks and mobile phones and automobile and similar vehicles.

Firstly, a close-range monochrome infrared camera was used to obtain an image of hand veins in this study. Subcutaneous veins in the upper section of the hand appear distinctively under infrared rays between 650-900 nm wavelength. This is because the hemoglobin within the blood that runs through veins absorb infrared rays to a certain extent. The wavelength of the infrared light source used in this study was 880 nm.

103 people to an experimental study, each image of a people who used to be 9 in total, each image was 927. Illustrated the size of 752x480 gray level images taken. Images taken in the hand vascular region, the size of 240x180 with a rectangular cross-section was cut from the picture. This cross-sectional structure of the received image of the wrinkled skin, hair and nails, such as noise in the image to the absence of vascular pattern was used an average filter and histogram equalization process. Then the algorithm otsu vascular pattern of gray-level image, converted into black-and-white image.

Vascular pattern, vascular pattern feature vector for the purpose of pictures is divided into small pieces the size of 20x20 pixels. Obtained from each frame, the average absolute deviation method in the range of 0-1 has been translated into numerical data. Therefore, hand-vessel view 240x180 size, the size of 20x20 sub-images containing the feature vector is obtained by dividing 108 pieces of data. The obtained data are used for classification is given as input to artificial neural network.

The classification stage, 103 people received training, 70% of all vessel data (TRN), 20% validation (VLD) and the remaining 10% of the test (TST) was determined as a set of data. ANN architecture used for multi-layer perceptron for the recognition of vascular images. Propagation learning algorithm quick propagation, Online Back Propagation and Batch Back Propagation is used. The number of hidden layer neurons, determined as 101 using the method of trial and error. Hyperbolic tangent and logistic functions were used as activation function.

After experimental studies, batch back propagation learning algorithm hyperbolic tangent activation function, with a 100% verification rate test was found to have the best correct classification rate. However, batch propagation algorithm iteration number and duration of training was longer than the other learning algorithms. However, considering the overall test results, logistic activation function was the better results fast and online propagation algorithm.

**Keywords:** Biometric, biometric recognition, hand vein pattern recognition, artificial neural network

## ÖNSÖZ

Bu çalışmayı gerçekleştirmemizde desteğini esirgemeyen danışmanım Prof.Dr.Novruz ALLAHVERDİ hocama, gece gündüz her an desteğini almış olduğum Yrd.Doç.Dr.H.Erdinç KOÇER hocama sonsuz teşekkürlerimi sunarım.

Ayrıca çalışmamı teşvik eden ve destek veren Yrd.Doç.Dr.Mustafa YILMAZ hocama, maddi manevi destek olan eşime ve aileme teşekkür ederim.

Hasan TUTUMLU  
KONYA-2011

## İÇİNDEKİLER

<b>ÖZET .....</b>	<b>iv</b>
<b>ABSTRACT.....</b>	<b>vii</b>
<b>ÖNSÖZ .....</b>	<b>x</b>
<b>İÇİNDEKİLER .....</b>	<b>xi</b>
<b>ŞEKİLLER LİSTESİ .....</b>	<b>xiii</b>
<b>TABLOLAR.....</b>	<b>xiv</b>
<b>SİMGELER VE KISALTMALAR .....</b>	<b>xv</b>
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1 Tezin Organizasyonu .....	2
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>4</b>
<b>3. MATERYAL VE METOT.....</b>	<b>8</b>
<b>4. BİYOMETRİK SİSTEMLER .....</b>	<b>9</b>
4.1 Biyometrik Teknikler.....	9
4.2. Biyometrik Sistemin Seçimi .....	12
4.3.Biyometrik Çeşitleri.....	13
4.3.1. Yüz tanıma.....	14
4.3.2. Parmakizi tanıma .....	15
4.3.3. El geometrisi .....	16
4.3.4. Ses tanıma .....	16
4.3.5. El yazısı ve imza tanıma .....	18
4.3.6. Retina tanıma .....	18
4.3.7. Kulak şekli tanıma .....	18
4.3.8. DNA tanıma.....	19

4.3.9. Vücut ısısı (termogram) tanıma .....	19
4.3.10. Yürüyüş tanıma .....	19
4.3.11. Dudak hareketi tanıma .....	19
4.3.12. İris tanıma .....	20
4.3.13. Damar Tanıma .....	21
5.1. El görüntüsünün alınması .....	22
5.2. Referans Noktasının Tespiti.....	24
5.3. Resimden Kesitin Alınması .....	25
6.1. Görüntüye Filtre Uygulanması .....	27
6.2. Histogram Eşitlemesi .....	28
6.3. Otsu Eşik Belirleme Yöntemi .....	29
6.4. Sayısallaştırma .....	32
<b>7. YAPAY SİNİR AĞLARI İLE DAMAR TANIMA .....</b>	<b>34</b>
7.1. Yapay Zeka (YZ) ve Yapay Sinir Ağları (YSA) .....	34
7.1.1. YSA'nın genel özellikleri.....	35
7.1.2. YSA'nın dezavantajları .....	36
7.1.3. YSA'nın temel yapısı .....	37
7.1.4. Yapay sinir ağı hücresi .....	38
7.1.5. Performans fonksiyonunun seçimi.....	41
7.1.6. Çok Katmanlı Perseptron Modeli .....	42
7.1.7. Öğrenme Algoritmaları.....	48
7.2. Deneysel Sonuçlar .....	54
<b>KAYNAKLAR .....</b>	<b>62</b>
<b>ÖZGEÇMİŞ .....</b>	<b>70</b>

## ŞEKİLLER LİSTESİ

Şekil 3.1. El-damar deseni tanıma sistemi blok şeması.....	8
Şekil 4.2. Yüz tanıma .....	14
Şekil 4.3. Parmak izi.....	15
Şekil 4.4. El geometrisini belirleyen noktaların belirlenmesi .....	16
Şekil 4.5. Ses Frekansı.....	17
Şekil 4.6. İris görüntüsünün alınması .....	20
Şekil 5.1. El damar deseni görüntüsünün alınması.....	22
Şekil 5.2. El-damar görüntüsünün alındığı düzenek.....	23
Şekil 5.3 Örnek el görüntüsü .....	23
Şekil 5.4 Resimlerin isimlendirilip kaydedilmesi.....	24
Şekil 5.5. Referans bölgelerinin tespit edilmesi .....	24
Şekil 5.6. Dairesel bölgeleri tespit eden 7x7 boyutlu maske.....	25
Şekil 5.7. Merkez referans noktasının bulunması.....	25
Şekil 5.8. Kesitin alınması .....	26
Şekil 5.9. 240x180 piksel boyutunda elde edilmiş kesit.....	26
Şekil 6.1 a) Orijinal görüntü, b) Filtre uygulanmış görüntü.....	28
Şekil 6.2 Histogram eşitlenmiş görüntü .....	29
Şekil 6.3 6 seviye gri tonlama içeren resim ve histogram .....	29
Şekil 6.4 (a) Arka plan seviyeleri, (b) Ön plan seviyeleri .....	30
Şekil 6.5 Otsu Yöntemi sonucu .....	31
Şekil 6.6 (a) Otsu uygulanmadan önce, (b) Otsu uygulandıktan sonra.....	32
Şekil 6.7 (a) Orijinal ikili kodlu görüntü, (b) Alt görüntülere bölme işlemi .....	33
Şekil 7.1 Temel yapay sinir ağı hücresi.....	39
Şekil 7.2. Çok katmanlı perseptron ağ yapısı .....	43
Şekil 7.3. Eğitim işlemi.....	47
Şekil 7.4 Geri yayılım algoritmasının akış şeması .....	49
Şekil 7.5 Yığın geriyayılım öğrenme algoritması MSE-iterasyon grafiği.....	57
Şekil 7.6 Hızlı yayılım öğrenme algoritması MSE-iterasyon grafiği.....	57
Şekil 7.7 Online geriyayılım öğrenme algoritması MSE-iterasyon grafiği.....	57

## TABLÖLAR

<b>Tablo 4.1</b> Biyometrik tanımada kullanılan özellikler .....	10
<b>Tablo 6.1.</b> Farklı eşik değerlerinde ağırlık, ortalama ve varyans sonuçları tablosu.....	31
<b>Tablo 7.2</b> YSA eğitim sonuç karşılaştırma tablosu.....	56

## SİMGELER VE KISALTMALAR

### Simgeler

**b:** bias eşik değeri

**x:** giriş matrisi

**y:** çıkış matrisi

**w:** ağırlık

**n:** giriş sayısı

**f:** aktivasyon fonksiyonu

**$\beta$ :** eğim sabiti

**e:** euler sabiti

**N:** çıkış sayısı

**E:** toplam hatası

**$\epsilon$ :** kazanç

**$\alpha$ :** değişim katsayısı

**$\Sigma$ :** Toplam

**F:** Mutlak sapma

**m:** piksel değerlerinin ortalaması

### Kısaltmalar

**YSA:** Yapay Sinir Ağı

**MSE:** Ortalama Karesel Hata

**SSE:** Toplam Karesel Hata

**RMS:** Ortalama Karesel Hatanın Karekökü

**MLP:** Multi Layer Perseptron (Çok Katmanlı Algılayıcı)

**MNN:** Modular Neural Networks (Modüler Sinir Ağları)

**LVQ:** Learning Vector Quantization (Vektör Kuantalamalı Öğrenme)

**RBF:** Radial Basis Function (Radyal Tabanlı Fonksiyon)

**PNN:** Probabilistic Neural Network (Olasılık Tabanlı Ağ)

**ART:** Adaptif Rezonans Teori

**SOM:** Self Organizing Map (Kendi kendine Organize olabilen Ağ)

**CMOS:** Complementary Metal Oxide Semiconductor (Bütünleyici Metal oksit yarıiletken)

**IR:** Infrared (Kızılötesi)

**LED:** Light Emitting Diode (Işık yayan diyot)

**TRN:** Training(Eđitim)

**VLD:** Validation(Dođruluk)

**TST:** Test

**CCR:** Dođru Sınıflandırma Oranı

## 1. GİRİŞ

Günümüzde insanoğlunun ihtiyaç duyduğu en önemli konulardan birisi de güvenlidir. Bu konuda yıllardan beri teknolojiye paralel olarak bir gelişim süreci söz konusudur. Fakat geçmişten bu yana geliştirilmiş teknolojiler bu konuda yetersiz kalmaktadır. Bu sebeple son yıllarda ortaya çıkan kavramlardan biriside biyometridir.

Biyometri bireyleri birbirinden ayıran ölçeklenebilir psikolojik veya davranışsal karakteristiklerin kimlik tespitinde kullanılan bilgisayar kontrollü sistemler olarak tanımlanabilir. Biyometrik sistemler kişinin sadece kendisinin sahip olduğu ve diğerlerinden ayırt eden fiziksel veya davranışsal özelliklerinin tanınması prensibi ile çalışmaktadır. Bu teknolojide parmak izi, el geometrisinin incelenmesi, el damar deseni, yüz özelliklerinin karşılaştırılması, ses ve konuşma analizi, iris ve retina tanımlanması gibi süreçler yer almaktadır. Biyometrik teknolojilerin çalışma prensibi birbirine benzer. Öncelikle kayıtlar toplanır ve bu kayıtlar bir kod olarak ilgili sistemde saklanır. Talep edildiği vakit toplanmış olan bu kayıtlar ile ilgili kişi anında karşılaştırılır ve sonuca varılır. Biyometrik sistemler hızlı çalıştıkları için kısa sürede birçok karşılaştırma yapabilme özelliğine sahiptir.

Yanılma olasılığını en aza indirme prensibi ile çalışan bu sistemlerin kart, şifre ya da pin numarası kullanan diğer tanıma metotlarına oranla daha çok tercih edilmesindeki en büyük faktörler, kullanıcının kendini tanıtmak için nüfus kağıdı gibi tanıtıcıları taşımak mecburiyetinde olmaması ve şifre gibi bilgileri ezberlemek zorunda olmaması olarak sıralanabilir. Kişilerin kendilerine has fizyolojik özelliklerinden faydalanarak otomatik kimliklendirme yapan bu teknoloji, güvenliğin öneminin hızla arttığı günümüzde geniş kullanım alanı bulacak teknolojilerden biri olacaktır.

Bu tez çalışmasında, kişi tanıma ve takibinin yapılabilmesi için insan el damar deseni biyometrisini kullanan bir düzenek tasarlanmıştır. İnsanın uzuvlardan biri olan el yapısında, deri altında yer alan, hücreleri besleyen damarlar yer almaktadır. Bu damar yapısı her insanda, hatta bir insanın sağ ve sol elinde bile farklı yapılarda gelişmektedir. Bu insanoğlunun yaradılışından gelen bir yapıdır. Bununla birlikte damar yapısı taklit edilemez ve değiştirilemez bir özelliktir.

Bu çalışmada, ilk olarak el görüntüsünü almak üzere kızılötesi ışık kaynağı ve kameranın sabitlenmesi için bir düzenek tertip edilmiştir. Her seferinde aynı görüntünün alınabilmesi ve görüntüden kesit alınabilmesi amacı ile iki adet referans noktası belirlenmiştir. Bu referans noktalarına elin yerleşimi sağlandıktan sonra 103 kişiden, her kişiye ait 9 adet görüntü olmak üzere, toplam 927 görüntü oda sıcaklığında (~23 °C) belli süre aralıklarıyla alınmıştır. Alınan görüntüler belirli bir sırada kaydedilmiştir. Bu görüntülerde yer alan referans noktalarından başparmağa yakın olanının merkez koordinatları görüntü işleme algoritmaları ile tespit edilmiştir. Bu referans noktası kullanılarak damar desenini içeren 240x180 pixel boyutunda kesitin alınması işlemi gerçekleştirilmiştir. Resimden alınan kesit damar görüntüsü farklı bir klasörün içine kaydedilmiştir. Alınan bu kesit resimde elimizin üst tarafında yer alan damar yapıları görülebilmektedir. Fakat damarın yanı sıra derinin üstünde bulunan kıllar ve kırışıklıklar da resimde yer almaktadır. Bu görüntülerin damar desenini etkilememesi için filtreleme işlemi uygulanmıştır. Ardından damar çizgilerinin belirginleştirilmesi amacıyla görüntüye histogram eşitleme uygulanmıştır. Otsu algoritması kullanılarak siyah beyaz görüntüye dönüştürülen damar desen görüntüsü öznelik çıkarımı amacıyla 20x20 boyutlarında karelere bölünmüştür. Her kare ortalama mutlak sapma yöntemi kullanılarak 0-1 aralığında sayısal verilere dönüştürülmüştür. Bu damar veri kümeleri Yapay Sinir Ağında eğitilerek tanıma işlemi gerçekleştirilmiştir.

### **1.1 Tezin Organizasyonu**

Bu tez çalışması giriş, kaynak araştırması, materyal ve metot, biyometrik sistemler, el damar bölgesinin tespiti, görüntünün iyileştirilmesi ve sayısallaştırma, yapay sinir ağları ile damar tanıma ve sonuçlar ve tartışma olmak üzere sekiz bölüm ve kaynaklardan oluşmaktadır.

Birinci bölüm, giriş bölümü olup konunun genel tanımı yapılmış, çalışmanın amacı ve önemi üzerinde durulmuştur.

İkinci bölümde bu alanda yapılmış önceki çalışmalar hakkında literatür bilgisi verilmiş, bu çalışmaların özellikleri belirtilmiştir.

Üçüncü bölümde tez çalışmasında kullanılan materyal ve metotlar verilmiştir.

Dördüncü bölümde biyometrik sistemler hakkında bilgi verilmiş ve çeşitlerinden bahsedilmiştir.

Beşinci bölümde, el damar bölgesinin tespiti için kullanılan yöntemler ve sonuçları verilmiştir.

Altıncı bölümde, el damar bölgesi görüntüsünün iyileştirilmesi ve sayısallaştırılması işlemleri aşama aşama anlatılmıştır. Uygulama ile ilgili resimler, şekiller ve tablolar sunulmuştur.

Yedinci bölümde, öncelikle yapay sinir ağları hakkında bilgi verilmiş, el damar verilerinin sınıflandırılması ile ilgili uygulama sonuçları tablolar haline sunulmuştur.

Sekizinci bölümde ise sonuçlar ve tartışma yer almaktadır.

Tez çalışmasının sonunda yararlanılan kaynaklar verilmiştir.

## 2. KAYNAK ARAŞTIRMASI

Dünyada birçok şirket ve kurum güvenliklerini koruma ve süreçlerini daha efektif kılma amacıyla biyometrik tanıma sistemlerini tanımakta ve kullanmaktadır. Biyometrik tanıma sistemleri güvenliğin öneminin hızla arttığı günümüzde geniş kullanım alanı bulacak teknolojilerden biri olacaktır. Damar tanıma sistemleri de gün geçtikçe çok daha fazla noktada tercih edilmeye başlanmıştır.

Örneğin, Japonya da birçok banka Temmuz 2004 yılından bu yana müşterilerinin kimlik tespiti için bu yöntemi kullanmaktadır. Fujitsu bu teknolojiyi elektronik kontrollü kapı kitleme sistemleriyle bağdaştırmıştır. Fujitsu bu uygulamaları sensör boyutlarını küçülterek ve doğrulama hızını arttırarak farklı alanlarda kullanımını arttırmayı planlamaktadır.

Ülkemizde, Yüksek Öğretim Kurumu kütüphanesinde yapılan taramada, el-damar deseni tanıma ile ilgili yapılmış tez çalışmasına rastlanılmamıştır. Ancak konu ile ilgili son yıllarda bazı akademik araştırmalar yapılmıştır ve yapılmaktadır. Örneğin Boğaziçi Üniversitesi Bilgisayar Mühendisliği'nde 2010 yılında yapılan "el damar görüntüleriyle biyometrik tanıma" konulu araştırmada 4 farklı koşulda (ağır yük taşıma sonrası, elin buzun içinde bırakılması vb) 100 kişiden alınan 3'er resim üzerinde bağımsız bileşen analizi yöntemi uygulanmış ve %97,7 başarı oranı elde edilmiştir (A. Yüksel, 2010)

(Cross,J.M. ve ark., 1995) Giriş kontrol sistemleri, giriş için yetkili kişilerin olumlu kimlik bilgilerini gerektirir. Yetkili bir kişi tarafından yüksek güvenlik erişimi kontrol etmek için bir kart bulundurma zorunluluğu geleneksel yaklaşım olmuştur. Son zamanlarda ciddi çabalar olumlu kimlik sağlamak için bireylerin uygun biyometrik özelliklerini belirlemek için yapılmıştır. . Daha popüler biyometrik giriş kontrol teknikleri için yüz görüntüleri, el geometrisi, parmak izi ve retina desenleri dahil ettik. Ayrıca klavye girişi, elle atılan imza ve ses desen dinamikleri makul yetkili kişileri belirlemede başarılı olmuştur. Bu çalışmada elin arkasında bulunan damar deseni kullanarak benzersiz bir kimlik için kişisel biyometrik yazarlar tarafından üstlenilmiştir. Kabaca pozitif tanımlamada damar desenler elde etmek için , düşük maliyetli otomatik termografik görüntüleme sistemi prototipi geliştirilmiştir. Damar deseni elde etmek için

görüntü işleme ve damar kalıbı eşleştirme stratejileri dikkat çekmektedir. Sistem için kabul ve red oranları ile ilgili sonuçlar elde edilmiştir.

(Chung ve arkadaşları-2000) “El damar deseni ayıklaması kullanılarak biyometrik tanımlama sistemi” gerçekleştirmişlerdir. Çalışmada 160x120 pixel,5000 siyah beyaz el damar görüntüsü üzerinde alçak geçirgen gaussian filtre kullanarak kişi başı 150 ms hızda tanıma gerçekleştirmiş ve %99,45 güvenilirlik elde etmişlerdir.

(Sebastian,L. and G. Albano, 2003) “Olumsuz koşullar altında El damarları segmentasyonu ve eşleşme” adlı çalışmalarında, görüntü elde etme işleminde çok basit bir CDD kamera ve LED diyotlar kullanarak 60 kişiden kızılötesi görüntü almışlardır. kötü aydınlatma koşullarında görüntü elde etme sürecini ve düşük piksel çözünürlüğünü ele almışlar, segmentasyon ve eşleme sırasında bu problemleri ortalama ve medyan filtreleme, iskeletleştirme ve budama gibi bazı tipik görüntü işleme teknikleri kullanarak, kötü görüntü elde etme koşullarında bile, güvenilir bir damar tabanlı tanıma sistemi gerçekleştiklerini bildirmişlerdir.

Watanabe ve ark., (2004) yaptığı çalışmada, insanın kan damarlarını kişisel tanımlama faktörü olarak kullanan, temassız avuç içi damar tanımlama cihazı tartışılmıştır. Damar bilgisinin damarların insan vücudunun içinde yer almasından dolayı tanımlaması oldukça güçtür. Avuç damar tanımlaması teknolojisi yüksek oranda doğruluk imkanı sağlar ve şu sonuçları ortaya koyar: Yanlış red oranı(FRR) %0,01,yanlış kabul oranı (FAR) %0,00008 veya daha azdır. Bu çalışma 140000 avuç inceleyen Fujitsu araştırmasına dayanmaktadır.

(Lin ve Fan 2004) “Avuç içi el damar deseni termal görüntüsü kullanarak biyometrik doğrulama” çalışmalarında Avuç içi damar kalıplarının termal görüntüleri kullanarak kişisel doğrulama için yeni bir yaklaşım sunmuşlardır. Kızılötesi kamera ile avuç içi damar deseni görüntülerini termal(ısı) olarak yakalamışlardır. Deneyleri avuç içi termal görüntüleri kullanılarak yapmışlar ve sonuçları kabul edilebilir bir doğruluk oranı ile tatmin edici bulmuşlardır.(FRR:% 2.3 ve FAR:% 2.3)

(Miura, N., A. Nagasaka ve T. Miyatake, 2004) “Tekrarlanan çizgi izleme ile parmak damar deseni çıkarımına dayalı kişisel kimlik doğrulama uygulaması”

çalışmalarında; Parmak damar deseni çıkarımında kızılötesi ışık altında çekilen bir parmak görüntüsünde sadece damar deseni değil, aynı zamanda parmak kemiklerinin ve kaslarının çeşitli kalınlıklarda düzensiz bir yapı içerdiğini belirtmişlerdir. Önerilen yöntemde parmak damar deseni görüntüsünü net elde etmek için çeşitli kademelerde başlayan çizgi izleme yöntemi kullanarak ayıklama işlemi gerçekleştirmişlerdir. Deneysel sonuçlarda, bu yöntemin doğru desen çıkarma sağladığını, kişisel kimlik doğrulamada eşit hata oranının 0.145% olduğunu göstermişlerdir.

(Badawi ve ark.-2007) El damar desenlerini kullanarak hızlı bir kimlik doğrulama sistemi sunmuşlardır. Sistem performansını değerlendirmek için, bir prototip tasarlamış, 16 yaş ve üstünde, farklı cinsiyette, farklı yaşlardaki 50 kişiden alınan bir veri kümesi oluşturmuşlardır. Her bir kişiden 10 resmi farklı zamanlarda almışlardır. Bunlardan 5'i sol ve 5'i sağ el görüntüsüdür. Doğrulama testi analizinde, test için 2 fotoğraf ve desenleri temsil etmek için 3 görüntü kullanmışlardır. FAR 0.02 ve% 3.00% ile FRR eşiği 80 bildirilmişlerdir. Sistem verimi% 99,95 olarak bulmuşlardır. EER eşik 77 'de % 0.25 olarak bildirmişlerdir. Aynı kişiden alınan sağ ve sol damar desenleri arasında hiçbir benzerlik bulmadıklarını bildirmişlerdir.

(Wang, Y., T. Liu and J. Jiang, 2008.) “el damar deseni tanıma için çok çözünürlüklü dalgacık algoritması” çalışmalarında, Yaşları 18-60 arasında olan bireylerden yakın kızılötesi kamera kullanarak,640x480 pixel boyutta, 820 el damar görüntüsü almışlardır. “çok çözünürlüklü dalgacık analizi” temelinde bir el damar tanıma algoritması geliştirmişlerdir. el damar doku özelliğinin üç seviyeli dalgacık ayrıştırma ile elde edilebildiğini bildirmişlerdir. Destek vektör makineleri(DVM), minimum mesafe sınıflandırıcı(MDC), K- en yakın komşu(KNN) özelliğini doğrulama için kullandıklarını bildirmişlerdir. Sınıflandırmada Doğru Tanıma Oranı (CCR-correct recognition rate) MDC=%94,31, KNN(K=5)=%96.14, KNN-SVM=%99.59 olduğunu ve önerdikleri yöntemin etkin olduğunu bildirmişlerdir.

(Kumar ve Prathyusha-2009) “El damar Nirengi ve düğüm(eklem) şekli kullanarak Kişisel Kimliklendirme” çalışmasında 100 bireyin el damar görüntülerinde nirengi ve düğüm biçim bilgilerine göre desen çıkarımı ve eşzamanlı kimlik doğrulamasında yeni bir yaklaşım sunmuşlardır. Önerdikleri yöntemde, düşük maliyetli, tam otomatik ve yakın kızılötesi kamera kullanarak, temassız görüntüleme

gerçekleştirdiklerini bildirmişlerdir. Temassız el damar görüntüleri kullanarak önerdikleri sistemden elde edilen deney sonuçlarının % 1.14 (FAR,FRR eşit hata oranı) umut verici olduğunu ve kullanıcı tanımlama için daha kullanıcı dostu bir alternatif önerdiklerini bildirmişlerdir.

(Wu, J.D. ve S.H. Ye, 2009) “Radon Transformu ve Yapay Sinir Ağı kullanarak, parmak damar desenlerinde sürücü tanımlama” çalışmalarında, parmak damar teknolojisi ve yapay sinir ağı kullanan bir sürücü tanımlama sistemi sunmuşlardır. Önerdikleri sistemde yakın kızıl ötesi CCD kamera ve kızılötesi ışık kaynağı yer almaktadır. Biyometrik kimlik doğrulama için yakın kızılötesi parmak damar desenleri kullanılmıştır. Bu sistemde özellik çıkarımı için Radon dönüşümü, sınıflandırma için sinir ağını birlikte kullanmışlardır. Yapay sinir ağı tekniklerinden Radyal tabanlı fonksiyon ağı ve olasılıksal sinir ağı kullanılarak bir sürücü tanımlama sistemi geliştirmeyi önermişlerdir. Deneysel sonuçlar önerilen sistemin kişisel kimlik için iyi bir performans göstermiştir. PNN ağının ortalama tanımlama oranı % 99,2 üzerinde olduğunu belirtmişlerdir.


(Soni M., ve ark., 2010) “Yeni bir damar deseni tabanlı doğrulama sistemi” isimli çalışmalarında, düşük maliyetli kamera ve ışık kaynağı yardımıyla kaliteli görüntü toplamak için yeni bir emme bazlı teknik geliştirdiklerini ileri sürmüşlerdir. Sistem otomatik olarak ilgili bölgeyi algılar ve özellikleri ayıklamak için ön işleme gerek olmadığını bildirmişlerdir. Karar alma işlemi için Öklid Mesafe temelli eşleme tekniği kullandıklarını, 341 kişiden toplanan 1750 el damar görüntü örneklerinden bir veri seti üzerinde test edildiğini belirtmişlerdir. Tanıma sisteminin doğruluğunu, %0.03 yanlış ret oranı (FRR) ve T=25 eşik değerinde %99,26 olarak bulmuşlardır.

### 3. MATERYAL VE METOT

Bu tez çalışmasında kişilerin biyometrik kimliğini belirleyebilen, el-damar deseni tanıma sistemi gerçekleştirilmiştir. Sistemde, yakın çekim özellikli, 752x480 pixel çözünürlüğe sahip, monokrom (gri seviye) usb kamera, 880nm dalga boyunda çalışan kızılötesi ışık kaynağı ve bilgisayardan oluşmaktadır. Kullanılan bilgisayarın özellikleri ise, Intel i7 core işlemci, 4 GB RAM, Windows 7 işletim sistemine sahiptir.

Gerçekleştirilen el-damar deseni tanıma sistemi, yedi aşamadan oluşmaktadır.

- Birinci aşamada kişinin el üstü görüntüsü kamera vasıtası ile bilgisayara aktarılmaktadır.
- İkinci aşamada elde edilen resimde görülen referans noktalarının görüntü işleme algoritmaları ile belirlenmesi işlemi gerçekleştirilir.
- Üçüncü aşamada belirlenen referans noktalarına göre 240x180 pixel boyutunda kesit alma işlemi gerçekleştirilir.
- Dördüncü aşamada, elde edilen resimde görüntü işleme algoritmaları veya filtreleri kullanılarak, damar yapısı dışında, istenmeyen yapılar (kıl, kırışıklıklar vs.) resimden arındırılır.
- Beşinci aşamada, elde edilen resimde, histogram eşitlemesi işlemi gerçekleştirilir. Bu aşamada gri seviyedeki resim ‘‘Otsu Algoritması’’ kullanılarak siyah-beyaz görüntüye dönüştürülmüştür.
- Altıncı aşamada, resim 20x20 piksel boyutlarında bölünerek her bir alt görüntü ortalama mutlak sapma yöntemi ile sayısallaştırılır. Elde edilen veriler dosyaya yazılır ve kaydedilir.
- Yedinci aşamada, elde edilmiş olan bu sayısal veriler Yapay Sinir Ağları ile sınıflandırılır. Bu şekilde tanıma işlemi gerçekleşmiş olur (Şekil 3.1).



Şekil 3.1. El-damar deseni tanıma sistemi blok şeması

## 4. BİYOMETRİK SİSTEMLER

Biyometrik kelimesi ilk anda insana “yeni bir ileri teknoloji” hissi uyandırır da aslında uzun süredir kullanılan oldukça basit bir tekniktir. Biyometrik insan tanımlamadır. Daha teknik bir ifadeyle, biyometrik kişilerin kendilerine has fizyolojik özelliklerini ölçen ve bu özellikleri kullanarak teşhis ve doğrulama uygulamalarında kullanılan genel bir tekniktir (Wildes 1997).

Biyometrik sistemler kişinin sadece kendisinin sahip olduğu ve diğerlerinden ayırt eden fiziksel veya davranışsal özelliklerinin tanınması prensibi ile çalışmaktadır. Bu teknolojide parmak izi ve el geometrisinin incelenmesi, yüz özelliklerinin karşılaştırılması, ses ve konuşma analizi, iris ve retina tanımlanması gibi süreçler yer almaktadır. Biyometrik teknolojilerin çalışma prensibi birbirine benzerdir. Öncelikle kayıtlar toplanır ve bu kayıtlar bir kod olarak ilgili sistemde saklanır. Talep edildiği vakit toplanmış olan bu kayıtlar ile ilgili kişi anında karşılaştırılır ve sonuca varılır. Biyometrik sistemler hızlı çalıştıkları için kısa sürede birçok karşılaştırma yapabilme özelliğine sahiptir. Yanılma olasılığını en aza indirme prensibi ile çalışan bu sistemlerin kart, şifre ya da pin numarası kullanan diğer tanıma metotlarına oranla daha çok tercih edilmesindeki en büyük faktörler, kullanıcının kendini tanıtmak için nüfus kağıdı gibi tanıtıcıları taşımak mecburiyetinde olmaması ve şifre gibi bilgileri ezberlemek zorunda olmaması olarak sıralanabilir.

Bu bölümde literatürde yer alan ve insan tanıma amacıyla Biyometrik kimliklendirme sistemlerinde kullanılan bazı teknolojiler, biyometrik çeşitleri, biyometrik sistemlerin seçiminde kullanılan faktörler, çoklu-biyometrikler ve biyometrik sistemlerin karşılaştırılmalı performans değerlendirmeleri verilmiştir.

### 4.1 Biyometrik Teknikler

Günümüzde çok çeşitli biyometrik tanıma teknikler kullanılmaktadır. Bunlar içerisinde en sık uygulananlar yüz tanıma, parmak izi tanıma, iris tanıma, el geometrisi tanıma, el damarı tanıma, ses tanıma, el yazısı ve imza tanıma olarak sıralanabilir. Ayrıca retina tanıma, kulak şekli tanıma, DNA tanıma, koku tanıma, vücut ısısı

(termogram) tanıma, yürüyüş tanıma ve dudak hareketi tanıma teknikleri de biyometrik tanıma uygulamalarında kullanılmıştır.

Biyometrik alanında kullanılan genel fizyolojik ve davranışsal özellikler aşağıdaki tabloda gösterilmiştir (Bolle ve ark. 2004).

**Tablo 4.1** Biyometrik tanımda kullanılan özellikler

<b>Sık Kullanılan Biyometrikler</b>		<b>Az Sıklıkta Kullanılan Biyometrikler</b>	
<i>Fizyolojik</i>	<i>Davranışsal</i>	<i>Fizyolojik</i>	<i>Davranışsal</i>
El Geometrisi	Ses	Retina	Yürüyüş
Yüz	El Yazısı ve İmza	Kulak Şekli	Dudak Hareketi
Parmak izi		DNA	
İris		Termogram (Isı)	
Parmak damarı			
El damarı			

Biyometrik teknikler içerisinde en popüler olanı parmak izi (fingerprint) tanımadır (Bolle ve ark. 2004). Bu teknikte parmak ucunda bulunan parmak izi, bir tarayıcı yardımıyla taranarak analiz edilmektedir. İlk geliştirildiğinde çok uzun zaman alan bu iş, bugünkü ileri teknolojik cihazlarla çok kısa sürelerde tamamlanmaktadır (Jain ve ark. 1999a).

Bununla birlikte yüz ve iris tanıma da son yıllarda üzerinde çok çalışılan biyometrik çeşidi durumuna gelmiştir. Biyometrik sistemlerin çalışma prensipleri hepsinde aynıdır.

Biometrik sistemlerin güvenilir olmalarının yanı sıra pratik olmaları da gerekir ve bu yüzden kişileri hangi yöntemlerle tanındıkları da önemli bir etkidir. Biyometrik tanıma sistemlerinde karşılaştırma işlemi iki temel amaç için yapılır. Teşhis veya tanıma (identification) ve doğrulama (authentication or verification) (Bolle ve ark. 2004).

**Teşhis (Identification) prensibi:** Bu prensibe göre sisteme bilginiz sunulur ve sistem bu bilgiye göre kişiye ait olan tüm diğer bilgileri veritabanından bulup çıkarır.

**Doğrulama (Verification) prensibi:** Bu prensibe göre bir kimse sisteme kimliğini girer. Sistem bu kimsenin gerçekten girilen kimliğin sahibi olup olmadığını, o kimliğe ait olan kayıtları inceleyerek karar vermeye çalışır.

Söz konusu sistemler oldukça güvenli sonuçlar vermektedirler. Fakat ikinci prensibe göre kişilerin bir şifre veya kullanıcı kodunu ezberlemeleri gerekir. Kullanıcıların ezberleme problemi ortaya çıktığı durumlarda ise kişiye kaybetmemesi gereken bir kart verilmesi düşünülür. Fakat tüm bunlar risk faktörünü artırdığı için, genelde doğrulama prensibi yoğun olarak tercih edilmez.

Biometrik tanıma sistemlerinin çalışma prensibi şu şekildedir. Önce kayıtlı bir imge alınır. Bu imaj dijital koda çevrilir. Bu kod gerekirse yapılan işleme göre şifrelenir ve kaydedilir. Daha sonra kullanıcı herhangi bir cihaz aracı ile kendini sisteme tanıtır. Genellikle aynı kişiye ait olsa bile, girilen kod ile kayıtlı olan kodun birebir tutma olasılığı yoktur. Bunda birçok faktör etkili olabilir. Bu faktörlerden en yoğun olarak rastlananları aşağıda sıralanmıştır:

1. Ortamın ışıklandırması
2. Kişinin bakış açısı
3. Teşhisi yapılacak uzvun cihaza göre durma açısı
4. Cihazın ve kontrol edilen uzvun temizlik derecesi ve nemi

Bu olumsuz etkilerden dolayı, girilen kod, belirlenen bir standart sapma aralığında, sistemde kayıtlı bulunan kodlarla karşılaştırılır. Tanınma aralığında olan kod kabul edilir ve sisteme giriş onaylanır. Genel anlamda bir biyometrik sistemin aşamaları Şekil 4.1 de gösterilmiştir (Bolle ve ark. 2004).

Havaalanı, askeri bölgeler, hastaneler, şirket binaları v.b. yerlerin girişinde gerekli olan güvenlik sistemi, biyometrik sistemler kullanılarak en üst seviyede sağlanmış olur. Çoğu binanın girişinde veya bir internet sitesinde anahtar, pin numarası veya şifre gibi çalınması, kaybolması, unutulması veya taklit edilmesi kolay yöntemler

kullanılmaktadır. Ancak bu tür sistemlerin güvenlik seviyesi asla bir biyometrik sisteminki kadar olmamaktadır.

Biyometrik sistemler kullanılan metoda göre belirli bazı parametreleri analiz ederler. Bu parametrelerin sayısı taranacak fiziksel özelliğe göre değişir. Örneğin bir parmak izi için dikkat edilecek parametre sayısı 100 kadardır. İris için bu sayı çok daha fazla (250 ve üzeri) olmaktadır (Wildes 1997). Ayrıca sistemde kullanılacak yonteme ve oluşturulan algoritmaya göre de bu sayı değişir. Çok fazla parametre olan sistemler çok daha fazla güvenli olmaktadır. Ancak parametre sayısı arttıkça işlem süresi uzayacaktır. İşlem süresi ne kadar kısalsa güvenirlilik o kadar azalacaktır.

#### **4.2. Biyometrik Sistemin Seçimi**

Bir biyometrik sistem seçilmeden önce sistemin gereksinimleri dikkatli bir şekilde değerlendirilmelidir. Bu gereksinimler önem sırasına göre aşağıda listelenmiştir (Bolle ve ark. 2004):

- Gerekli güvenlik seviyesi
- Doğruluk
- Maliyet ve işlem zamanı
- Kullanıcıya uygunluk

Kişisel bilgisayar kullanılmayan sistemlerde genellikle ses ve imza tanıma teknikleri tercih edilmektedir. Ancak ses ve imza tanıma teknikleri, birçok kişisel bilgisayar ve ağ kullanıcı doğrulaması için iyi bir teknik olarak görülmemektedir. Fiziksel özelliklere göre çözümler sunan biyometrik teknikler daha kesin sonuç verir, bundan dolayı daha yüksek bir güvenlik seviyesine sahiptir.

Retinal tarama ve iris tanıma sistemleri, kişisel tanımlamanın en yüksek doğrulukta yapıldığı yollardan ikisidir. Ancak, bunların her ikisi de uygulama aşamasında çok fazla maliyetlidir ve çok fazla güvenlik gerektirmeyen sistemlerde bu sistemlerin kullanılması düşünülmemelidir. El, yüz ve parmak izi doğrulama teknikleri, daha az maliyetli donanımlara sahip tekniklerdir ve bir çok uygulamada yeterli

doğrulama sunar. Kaza sonucu meydana gelen kesikler, çizikler, kirlenme, yara izleri ve yaşlanma gibi fiziksel değişiklikler biyometrik doğrulama tekniklerinden bazıları için sonucu etkileyebilmektedir. Bu yüzden, biyometrik sistemde kullanılan veritabanları, bu tür problemleri yok etmek için güncellenmelidir.

Bir biyometrik sistem tasarlanırken, sistemin maliyetini ve işlem zamanını belirli kriterlere uygun olarak değerlendiren bir uzmanla çalışılması, en uygun sistemi belirlemek ve gerçekleştirmek için gereklidir. Bu kriterler:

Kişisel bilgisayar uyumlu donanım ve yazılımın araştırılması, satın alınması ve kurulması.

Biyometrik görüntü yakalama donanımının belirlenmesi (okuyucular, kameralar, tarayıcılar v.b.) ve bu donanıma uygun yazılımın seçilmesi.

Sistem için gerekli donanım ve yazılımı var olan ortamla bütünleştirmek için gerekli zamanın belirlenmesi.

Kullanıcılara ait tanıma verilerinin bir veritabanında biriktirilmesi ve korunması.  
Gerektiğinde veritabanı'nın güncellenmesi.


Kullanıcılar, parmakizi, yüz veya el tanınması gibi biyometrik teknikleri genellikle daha az zorlayıcı bulmaktadırlar. Ancak bazı kullanıcılar kendi parmak izlerinin bir veritabanında kayıtlı olmasından dolayı rahatsızlık duyabilirler. Sistem tasarlanırken, sistem çalışanlarına, seçilen biyometrik teknikle ilgili bilgi ve eğitim verilmelidir. Böylece sistem uygulanmadan önce sistem hakkında gerekli bilgileri önceden bilme şansına sahip olacaklardır.

### **4.3.Biyometrik Çeşitleri**

Biyometrik sistemler kullanılan biyometrik özelliğe göre değişiklik arz etmektedir. Biyometrik özellikler iris, yüz, parmak izi, el geometrisi, el damar deseni, ses, el yazısı ve imza, retina, kulak şekli, DNA, vücut ısısı, yürüyüş, dudak hareketi şeklinde sıralanabilir.

### 4.3.1. Yüz tanıma

Yüz tanıma sistemleri bir vesikalık fotoğraf incelemek yerine, yüzde bulunan yaklaşık 50 kadar noktayı analiz eder (Şekil 4.2). Yüz karakteristiği tanımlanırken göz çukurlarının saptanması, elmacık kemiğini çevreleyen bölgelerin taranması, ağız kenarlarının belirlenmesi, kulak memesinin analizi gibi çeşitli metotlar kullanılır (Hong ve Jain 1998).



Şekil 4.2. Yüz tanıma

Birçok yüz tanıma sisteminde saç stili, saçın uzunluğu veya kısalığı gibi belirleyicilere dikkat edilmez. Örnek imaj oluşturulurken en genel yöntem, kişinin kamera karşısında sabit dururken çeşitli açılardan yüzün görüntülerinin alınmasıdır. Bunun yanı sıra, kızılötesi algılayıcılarla da yüzün farklı açılardan görüntüleri alınabilir. Alınan görüntü işlenerek daha önce alınmış olan görüntü bilgisiyle karşılaştırılır. Görüntünün öznelikleri çıkarılırken göz çukuru, burun, kulak gibi organların konumuna, bunlar arasındaki çapraz ilişkilere ve yüzün genel durumuna dikkat edilir. Yüz tanıma sistemleri fiziksel bir temas gerektirmediğinden daha çok tercih edilirler. Ancak yüz tanımlama sistemleri uygulamalarda sınırlı başarı sağlamışlardır. Çünkü bıyık gelişimi, kilo alma-verme, ikizinin olması gibi bazı tanıma problemleri yüz tanıma sistemlerinde çok sık karşılaşılan durumlardır (Jain ve ark. 1999).

### 4.3.2. Parmakizi tanıma

Parmakizi (Şekil 4.3) tanıma sistemleri günümüzde en yaygın kullanılan biyometrik tanıma sistemidir. Oldukça uzun bir geçmişe sahip olan bu biyometrik çeşidi 20. yüzyılın başlarında özellikle kriminal uygulamalarda tercih edilmiştir. Parmak izi taranırken çoğunlukla optik algılayıcılar kullanılmaktadır. Ancak son yıllarda teknolojiye gelişmelerle birlikte termal ve kapasitif ölçüm yapan tarayıcı cihazlar kullanılmaya başlanmıştır. Optik tarayıcılar bir ışık kaynağından gönderilen ışınların tarayıcı yüzey üzerine yerleştirilmiş parmakta bulunan çukurlar ve çıkıntılara göre yansıtılarak, CCD algılayıcılara gönderilmesi prensibine göre çalışır. Diğer tip tarayıcılar ise yalnızca parmaktaki izleri taramakla kalmaz aynı zamanda parmaktaki statik etkileri ölçerek taranan parmağın canlı bir parmak olup olmadığını tarar (Inglis ve ark. 1998, Lee ve ark. 1999, Dickinson ve ark. 2000). Termal tarayıcılar ise parmakta bulunan girinti ve çıkıntıların arasındaki ısı farklılıklarını tespit ederek parmak izini oluşturur. Bir parmak izindeki tüm izler dikkate alınmaz. Bunun yerine izdeki bazı özel noktalar; bunlar, girinti ve çıkıntı arası uzaklıklar, hat sonları, çatallaşmalar, bazı kesişim bölgeleri v.b. işlenir ve daha sonra çeşitli görüntü işleme yöntemleriyle sayısal hale getirilir ve veritabanına kaydedilir.




Şekil 4.3. Parmak izi

Parmak izi tanıma sistemleri kullanım kolaylığı, düşük fiyatı ve küçük ebatları nedeniyle ev, ofis gibi yerlerde daha çok tercih edilirler. Ancak tarama sırasında optik tarayıcıyla fiziksel temasın olması, parmağın kirli, yağlı veya ıslak olması gibi görüntü kalitesini düşürebilecek etkenlerin bulunması, çabuk kopyalanabilir olması ve aşırı sürtünmeden izlerin bozulması gibi faktörler parmak izi tanıma sistemlerini diğerlerinden daha az güvenli yapmaktadır (Uludağ ve ark. 2001).

### 4.3.3. El geometrisi

El geometrisi aynı zamanda el taraması olarak da adlandırılır. Bu sistemde el üç boyutlu olarak taranır, elin ve parmakların fiziksel karakteristikleri analiz edilir (Şekil 4.4). Tarama sırasında parmakların uzunluğu ve genişliği, birleşme noktaları arasındaki uzaklıklar, parmaklardaki oynak yerlerinin geometrisi gibi noktalara dikkat edilir (Jain ve ark. 1999b). Bazı sistemlerde yalnızca üç parmak (baş, orta ve işaret parmağı) taranır. Bazılarında ise doksandan fazla ölçüm yapılır. El geometrisi ile çalışan biyometrik sistemler uygulaması oldukça kolay sistemlerdir. Tarayıcı cihaz olarak normal bir optik algılayıcı kamera kullanılabilir. El geometrisi biyometrik sistemleri parmak izi, yüz ve iris tanıma sistemleri kadar hassas ve güvenilir değildir. Veritabanında tutulan bilgiler, diğer biyometrik sistemlere oranla daha az yer kapladığından kullanıcı sayısının fazla olduğu sistemlerde daha çok tercih edilmektedir.




Şekil 4.4. El geometrisini belirleyen noktaların belirlenmesi

### 4.3.4. Ses tanıma

Ses tanıma, bazı kaynaklarda konuşma tanıma olarak da bilinir (Campbell 1999). Biyometrik sistemler içerisinde oldukça sık kullanılan bir davranışsal tanıma şeklidir. Diğer biyometrik sistemlere göre çok daha kolay uygulanır. Günlük yaşamımızda sesin ne kadar çok kullanıldığı düşünüldüğünde, ilginç bir biyometrik yöntem olarak

karşımıza çıkan ses tanıma teknolojisi, güvenilirlik açısından çok tercih edilen bir teknoloji değildir. Buna rağmen insan sesi davranışsaldır ve bu bile tek başına belirleyici bir unsur olmaktadır. Sistem kişilerin seslerine ait akustik seslerin kaydedilip dijital ortama dönüştürür (Şekil 4.5).



Şekil 4.5. Ses Frekansı

Kullanıcı önce sistemin önceden belirlediği birkaç sözcükten oluşan metni okuyarak sesini sisteme tanıtır. Kaydedilen ses spektral analizler kullanılarak dijitalleştirilir. Kullanıcı daha sonra aynı metni kullanarak sisteme giriş yapar. Bazı ses tanıma sistemlerinde ise önceden belirlenmiş bir metin kullanılmaz. Bu tür sistemlerde kişinin ses görüntüsüne dikkat edilir. Diğer bir deyişle o kişiye ait ses frekans bilgileri kullanılır. Bu teknikte ses frekansları üç boyutlu görüntüleri oluşturmakta ve sesin en küçük birimleri, özel bir takım biçimlerde karakterize edilmektedir (Furui 1997). Ses tanıma sistemleri telefon üzerinden bir sisteme ulaşım için daha uygun bir yapıdadır. Ancak bu tür bir sistemde kişinin ses dalgaları telefonda iletilirken bozulmalara uğrayabilir. Bu da o sistemi daha az güvenilir kılacaktır. Ayrıca kaydedilen ses bilgisinin çok fazla yer kaplaması, sesin yaşlılık, hastalık veya psikolojik durumlardan dolayı değişmesi, kayıt sırasında arka plandaki gürültüler ve hem kayıt sırasında hem de sisteme giriş sırasında okunan metinde yanlış sözcük kullanılması gibi dezavantajlar ses tanıma sistemlerini daha kullanışsız ve güvensiz hale getirir.

#### 4.3.5. El yazısı ve imza tanıma

El yazısı ve imza tanıma sistemleri diğerleri kadar geniş kullanım alanı olmayan bir biyometrik teknolojidir (Nalwa 1997). Genellikle belge kullanılan güvenlik sistemlerinde tercih edilir. Kullanıcının el yazısı veya imzası taranarak yazının veya imzanın karakteristik özellikleri çıkarılır. Bu karakteristik özellikler kalem hızı ve basıncı, imzadaki bazı çizgilerin durumu, yazı karakterlerinin şekilleri gibi özelliklerdir (Srihari ve ark. 2002). Diğer biyometrik sistemlere göre çok daha az güvenlidir.

#### 4.3.6. Retina tanıma

Retina göz yuvarlağının iç kısmında arka tarafta yer alan ince sinirlerin ve damarların bulunduğu ağ tabakadır (Şekil 4.6). Bu tabakada yer alan ışığa duyarlı sinirler ışığı optik sinirler vasıtasıyla beyne iletir. Retina tarayıcı cihazlar gözbebeği içerisinden tarama yaparlar. Bir optik algılayıcı retinanın yapısını düşük yoğunluklu ışınlar kullanarak tarar. Bu işlem sırasında kullanıcı yaklaşık 1cm'lik bir delikten kımlıdamadan bakar. Tarayıcı cihaz tarama sırasında yaklaşık altı tur döner ve her turda belirlenen noktaları kaydeder. Daha sonra bu bilgiler dijitalleştirilerek kaydedilir (Hill 1999). Ancak tarama sırasında gözün tarayıcıya fiziksel teması, gözde oluşabilecek ve retina yapısına zarar verebilecek travmaların olması, tarama işleminin oldukça zahmetli olması ve uzun sürmesi gibi faktörler retina tanıma sistemlerini daha az tercih edilir hale getirmiştir.

#### 4.3.7. Kulak şekli tanıma

Kulak şeklinin biyometrik olarak kullanılması düşüncesi diğer biyometriklere göre çok daha yakın zamanda ortaya atılmıştır. Bir grup araştırmacı, kenar bulma teknikleri kullanarak, kulağın temel yapısını elde etmiş ve bu görüntünün özneliklerini kullanarak tanıma işleminde kullanmıştır (Burge ve Burger 2000). Kulak şeklinin her insanda farklı olma olasılığı diğer biyometriklere oranla daha düşüktür. Bu yüzden bu tür bir tanıma şekli güvenilir olmayacaktır. Zaten uygulamada kulak şeklinin kullanımı oldukça düşüktür.

#### **4.3.8. DNA tanıma**

DNA tanıma biyometrik tanıma çeşitleri içerisinde en mükemmelidir. Her insanın farklı DNA yapısı olduğu düşünüldüğünde bu tür bir biyometrik sistemin güvenilirliği tartışılmaz. Ancak tek yumurta ikizlerinin DNA yapıları aynı olduğu da bir gerçektir. Bu da bu tarz bir sistemin eksik yönüdür (NRC 1996). DNA yapısının elde edilmesi oldukça güç ve günler, hatta haftalar alan uzun süren bir süreçtir. Bununla birlikte oldukça maliyetli ve karmaşık bir uygulamadır. Ayrıca hiç kimse biyometrik bir sisteme giriş için kendi DNA yapısını kolay kolay vermek istemez. Bütün bunlar, DNA yapısının biyometrik tanıma amacıyla kullanılmasının önünde önemli engellerdir.

#### **4.3.9. Vücut ısı (termogram) tanıma**

Vücut ısı (termogram) ölçüm görüntüleri kızılötesi spektrumun değişik bandında yer almaktadır. Bu alanda yapılan ilk çalışmalar el veya yüzün termal görüntülerini kullanmıştır (Prokoski ve Riedel 1999). Aslında termal görüntülerin yüz tanıma için kullanılması avantajlı bir durumdur. Yüzde bulunan oyukların ve çıkıntıların termal olarak daha belirgin alınacağı açıktır. Bununla birlikte vücut ısısının değişken olması bu tür bir tanıma sistemi için negatif bir durumdur.

#### **4.3.10. Yürüyüş tanıma**

Yürüyüş tanıma davranışsal bir biyometrik şeklidir. Genellikle video görüntüleri kullanılarak elde edilen yürüyüş şekli kişilerin tanınmasında kullanılabileceği düşüncesi yirminci yüzyılın sonlarında ortaya atılmıştır (Nixon ve ark. 1999). Yürüyüş şeklinin zamanla değişken olması bu tür bir tanıma sistemini oldukça güvensiz hale getirmektedir.

#### **4.3.11. Dudak hareketi tanıma**

Dudak hareketi davranışsal bir biyometrik şeklidir. Kişilerin konuşma sırasında yaptıkları dudak hareketlerinin video görüntüsü içerisinde alınarak tanıma amacıyla

kullanılması prensibine göre çalışır (Nabiyev ve Yavuz 2005). Dudak hareketleri genellikle sabit bir metin okutulur. Bu tarz bir tanıma sisteminde hem yüz şekli hem de dudak hareketleri birlikte kullanılarak sistemin güvenilirliği artırılabilir.

#### 4.3.12. İris tanıma

İris, gözün ön kısmında bulunan ve fibroz (lifli) dokudan oluşan renkli tabakadır. İriste yaklaşık 250 den fazla görsel karakteristik bulunmaktadır. Bunlar daireler, benekler, çizgiler gibi belirleyici şekillerdir (Wildes 1997). İrisin, bebek embriyo olarak anne karnındayken oluşması ve insanın ölümüne kadar değişmemesi iris tanıma sistemlerinin güvenilirliğini oldukça yükseltir. İris görüntüsünün alınması işlemi biyometrik taramalar içerisinde en basit olanlarından biridir. Sıradan CCD kamera kullanılarak yaklaşık 15-20 cm uzaklıktan tarama yapılır (Şekil 4.6).



Şekil 4.6. İris görüntüsünün alınması

Bununla birlikte iris üzerinde ışık yansımalarının önüne geçmek amacıyla kızılötesi aydınlatmalı kameralar da kullanılmaktadır. Kullanıcı ile tarayıcı arasında fiziksel temas olmasına gerek yoktur. Bu da sistemin kullanıcı dostu olmasını sağlamaktadır. İris görüntüsü alınırken kişilerin gözlüklerini çıkarmasına bile gerek yoktur. İris deseninin zamanla değişmemesi, ayırt edici özelliklerinin çok olması ve iris

görüntüsünün çok kolay elde edilmesi iris tarama sistemlerini daha çok tercih edilir hale getirmiştir (Wildes 1997).

#### **4.3.13. Damar Tanıma**

İnsan vücudunda bulunan damarlar, yapı itibariyle deri altında yer almaktadır. Damar tanıma sistemlerinde çoğunlukla el ve parmaklarda yer alan damarlar kullanılmaktadır.


Yapılan damar tanıma çalışmalarının bir kısmı işaret parmağında yer alan damar desenini kullanmaktadır. İşaret parmağında yer alan damarlar birbirine çok yakın yapıda kılcal damarlar içermektedir. Dolayısıyla damar deseninin elde edilmesi zordur ve birbirine benzeme oranı yüksektir. Bu da sistemin güvenilirliğini azaltmaktadır. Bir diğer damar tanıma çeşidi olan avuç içi damarlarının kullanılması üzerine de bir çok çalışma yapılmıştır. Ellerin üstünde yer alan ağaç şekilli bu damarlar bir bireyin kimliğini tespit edebilecek bilgiler içermektedir. Biyometrik tanıma sistemlerinin birçoğunda insan vücudunun dış görünümü ile çalışılmaktadır. Dolayısıyla dışarıdan gelebilecek fiziksel etkiler ve kazalar sonucu bu biyometrik özellikler değişebilmektedir. Ayrıca parmak izi gibi özellikler kopyalanabilir durumdadır. Bu istenmeyen bir durumdur ve sistemin güvenilirliğini oldukça düşürmektedir. El damarları ise deri altında yer aldığından, dış etkilerden etkilenmez bir özelliktir. Ayrıca damarın kopyalanması gibi bir durumdan söz edilemez.

## 5. EL DAMAR BÖLGESİNİN TESPİTİ

Damar tanıma sisteminin ilk aşaması olan görüntünün alınması ve damar bölgesinin tespit edilmesi işlemleri bu bölümde anlatılacaktır. İlk olarak görüntünün alınması için kullanılan donanım ve düzeneden bahsedilecektir. Ardından el damar bölgesinin tespiti ve resimden ayrıştırılması işlemleri ayrıntılı olarak sunulacaktır.


### 5.1. El görüntüsünün alınması

El damar görüntüsünün alınması işlemi diğer biyometrik sistemlerdeki görüntü alınması işlemlerinden daha basittir. Yakın kızılötesi aydınlatmalı bir kamera ile yaklaşık 5 ile 15 cm arasında belli bir mesafeden görüntü alınır (Şekil 5.1).



Şekil 5.1. El damar deseni görüntüsünün alınması

Bu çalışmada görüntülerin alınabilmesi için, yakın CMOS (Complementary Metal Oxide Semiconductor) monokrom kamera kullanılmıştır. Işıklandırma amaçlı 880nm dalga boyunda çalışan IR (infrared – kızılötesi) LED aydınlatmalı ışık kaynağı kullanılmıştır. Işık kaynağı, kameranın objektifine yerleşebilecek nitelikte dairesel şekillidir. Görüntülerin düzgün bir şekilde alınabilmesi için hazırlanan düzenek, kamera, ışık kaynağı, aşağı-yukarı ayarlanabilen kasa ve elin yerleşeceği tabladan oluşmaktadır. Tabla üstüne, elin yerleştirileceği iki adet çivi çubuk monte edilmiştir. Bu çubukların üst kısmı beyaz renge boyanarak referans noktasının daha kolay belirlenmesi sağlanmıştır (Şekil 5.2).




Şekil 5.2. El-damar görüntüsünün alındığı düzenek

DeneySEL çalışma için kullanılmak üzere 103 kişiden (erkek ve bayan) 752x480 boyutlarında el görüntüsü alınmıştır. Bu görüntüler oda sıcaklığında (yaklaşık 23 C) ve değişik zaman aralıklarında elde edilmiştir. Her denekten 9 adet görüntü olmak üzere toplam 927 adet el görüntüsü bilgisayara kaydedilmiştir. Aşağıdaki şekilde (Şekil 5.3) örnek bir el görüntüsü verilmiştir. Alınan 927 adet el görüntüsü, belirli bir isimlendirme ile bilgisayarda farklı bir klasör içerisine kaydedilmiştir (Şekil 5.4)




Şekil 5.3 Örnek el görüntüsü



Şekil 5.4 Resimlerin isimlendirilip kaydedilmesi

## 5.2. Referans Noktasının Tespiti


Bilgisayara kaydedilmiş el görüntülerinde referans noktasını bulmak için önce resimde yer alan tüm gri seviye piksel değerleri (0-255 arasında), iki boyutlu bir diziyeye aktarılmıştır. Bu dizide yer alan tüm piksel değerleri taranmış, önceden belirlenmiş eşik değerinin üzerinde değer alanlar beyaz (255), altında olanlar ise siyah (0) olarak kaydedilmiştir. Referans noktalarını içeren resim aşağıda (Şekil 5.5) gösterilmiştir.



Şekil 5.5. Referans bölgelerinin tespit edilmesi

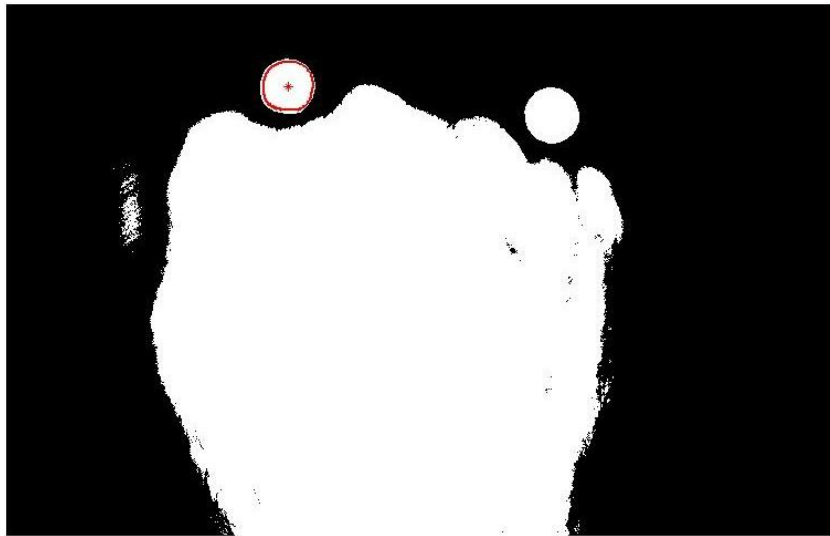
Resimde yer alan dairesel şekillerin merkez noktalarının belirlenmesi amacıyla resmin morfolojik yapısal bileşenlerine bakılmıştır. 7x7 boyutlarında dairesel maske

tüm resim üzerinde dolaştırılmış ve dairesel şekiller ve merkez noktaları tespit edilmiştir. Kullanılan maske aşağıda gösterilmiştir (Şekil 5.6). Burada R dairenin yarıçap bilgisini temsil etmektedir.



Şekil 5.6. Dairesel bölgeleri tespit eden 7x7 boyutlu maske

Referans noktalarından başparmağa yakın olanı baz alınarak damar bölgesinin yeri tespit edileceğinden yalnızca ilgili dairesel bölgenin merkez noktası işaretlenmiştir. Aşağıdaki şekilde (Şekil 5.7) siyah beyaz el görüntüsünün üzerinde merkez referans noktasının işaretlenmiş hali gösterilmiştir.




Şekil 5.7. Merkez referans noktasının bulunması

### 5.3. Resimden Kesitin Alınması


Referans merkez noktası belirlendikten sonra bu noktadan itibaren x-y koordinat sisteminde, 50 piksel aşağı ve 50 piksel sol yönde (-50px,-50px) ilerlenerek alınacak

dikdörtgensel kesitin sol-üst köşe koordinat noktası belirlenir. Bu noktadan başlayarak aşağı-sağ yönde 240x180 piksel boyutunda resim kırpılır (Şekil 5.8).



Şekil 5.8. Kesitin alınması

Alınan 240x180 piksel boyutundaki kesit resim, damar desenini içeren gri seviyeli görüntüdür (Şekil 5.9). Bir sonraki aşamada, bu görüntü üzerinde yer alan damar çizgileri belirlenerek sayısallaştırılacaktır.



Şekil 5.9. 240x180 piksel boyutunda elde edilmiş kesit

## 6. GÖRÜNTÜNÜN İYİLEŞTİRİLMESİ VE SAYISALLAŞTIRMA

Bu bölümde el damar görüntüsünün iyileştirilmesi ve sayısallaştırılması işlemleri anlatılacaktır. Görüntü iyileştirme amacıyla görüntüye ortalama filtre ve histogram eşitleme uygulanmıştır. Ardından otsu yöntemi ile gri seviye görüntü siyah-beyaz görüntüye dönüştürülmüş ve ortalama mutlak sapma yöntemi kullanılarak sayısallaştırma işlemi yapılmıştır.

### 6.1. Görüntüye Filtre Uygulanması


Elde edilen kesit el damar görüntüsünde yapı itibariyle kıllar, deri yüzeyindeki kırışıklıklar gibi çeşitli gürültüler yer almaktadır. Bu gürültülerin yok edilmesi amacıyla, görüntüye Ortalama Filtre (Mean Filter) uygulanmış ve görüntü bulanıklaştırılmıştır.

Ortalama filtre görüntünün yumuşatılması için kullanılan ve görüntüdeki gürültüleri azaltan görüntü işlemede sıkça kullanılan bir filtredir. Bu filtre gri seviyeli görüntüdeki her bir pikselin dikdörtgensel çevresindeki değerlere göre ilgili pikselin ortalamasını alarak yeni bir gri seviye değeri elde eder. 3x3'lük karesel bir filtre matrisi kullanıldığında her pikselin değeri şu şekilde hesaplanır;

$$\begin{pmatrix} a1 & a2 & a3 \\ a4 & \mathbf{a5} & a6 \\ a7 & a8 & a9 \end{pmatrix} \quad (3 \times 3 \text{ filtre matrisi})$$

$$\text{Filtrelenmiş piksel (a5)} = (a1+a2+a3+\dots+a9) / 9 \quad (6.1)$$

El damar kesit görüntüsüne ortalama filtre uygulandığında Şekil 6.1.b'de gösterilen görüntüyü elde edilmiştir.



Şekil 6.1 a) Orijinal görüntü, b) Filtre uygulanmış görüntü

## 6.2. Histogram Eşitlemesi

Elde edilen görüntüye, Histogram eşitlemesi (Histogram Equalization) uygulanarak damar yapısının daha belirgin hale gelmesi sağlanmıştır (Şekil 6.2). Histogram, sayısal bir resim içerisinde her renk değerinden kaç adet olduğunu gösteren grafikdir. Bu grafiğe bakılarak resmin parlaklık durumu ya da tonları hakkında bilgi sahibi olunabilir.

Histogram eşitleme ise renk değerleri düzgün dağılımlı olmayan resimler için uygun bir görüntü iyileştirme metodudur. Resmin tümüne uygulanabileceği gibi sadece belli bir bölgesine de uygulanabilir. Tüm resme uygulanırsa global histogram eşitleme, resmin belli bir bölgesine uygulandığında ise lokal histogram eşitleme adını alır.

Bu yöntem histogramı dar olan resimler ya da resim içindeki bölgeler için daha iyi sonuç verir. Öncelikle resmin histogramı bulunur. Histogramdan yararlanılarak kümülatif histogram bulunur. Kümülatif histogram, histogramın her değerinin kendisinden öncekiler ve kendisinin toplamı ile elde edilen değerleri içeren grafikdir. Kümülatif histogram değerleri yeni resimde olmasını istediğimiz max. renk değerleri ile çarpılıp resimdeki toplam nokta sayısına bölünerek normalize edilir. Normalize olmuş histogram değerleri ile resmin renk değerlerini tekrar güncellersek o resme histogram eşitleme metodunu uygulamış oluruz (Görüntüişleme, 2010).




**Şekil 6.2** Histogram eşitlenmiş görüntü

Elde edilen görüntüdeki damar yapısının, siyaha yakın bir koyulukta olduğu görülmektedir. Bu damar yapısının siyah-beyaz bir desen haline gelmesi için, Otsu Eşik Belirleme Algoritması kullanılmıştır.

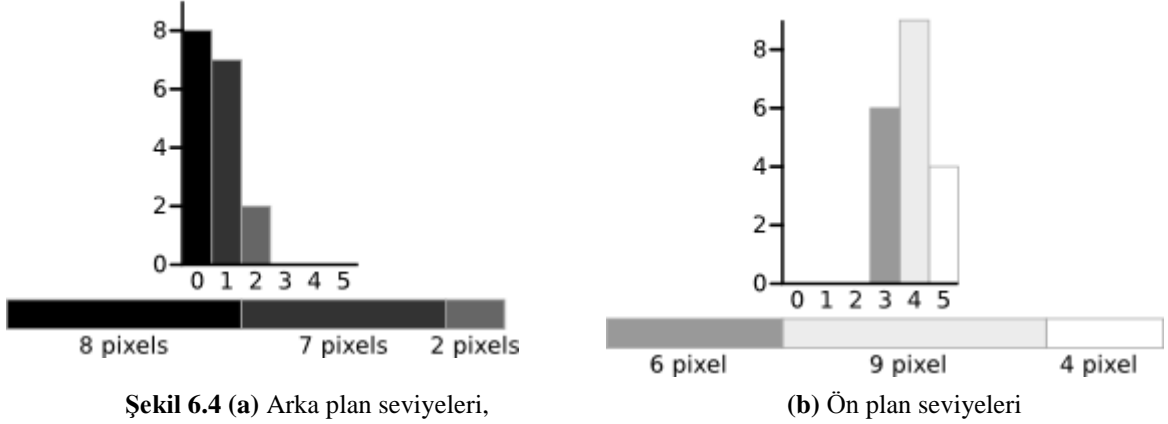
### 6.3. Otsu Eşik Belirleme Yöntemi

Otsu Algoritması, resimde görülen gri bölgeleri belirli bir eşik değerine kadar siyaha, geri kalanları ise beyaza dönüştürür. Algoritma daha iyi anlaşılması için basitçe 6x6 gri-ölçekli görüntü üzerinde açıklanmıştır (Şekil 6.3).



**Şekil 6.3** 6 seviye gri tonlama içeren resim ve histogram

Histogramda 3. seviye olarak görülen gri ton, eşik-değeri (T) olarak seçilirse, 8-7-2 seviyeleri arka plan seviyesi, 6-9-4 seviyeleri ise ön plan seviyesi olarak belirlenir (Şekil 6.4).



Arka plan için ağırlık (Denklem 6.2), ortalama (Denklem 6.3) ve varyans (Denklem 6.4) aşağıdaki görüldüğü gibi hesaplanmıştır. Ön plan seviyeler için ağırlık, ortalama ve varyans ise arka planda hesaplandığı gibi bulunur.

$$\text{Ağırlık} \quad W_f = \frac{6+9+4}{36} = 0.5278 \quad (6.2)$$

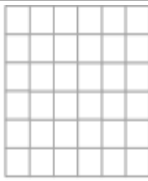

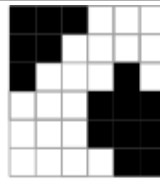
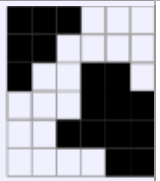

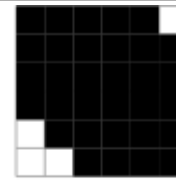
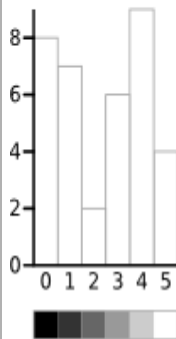
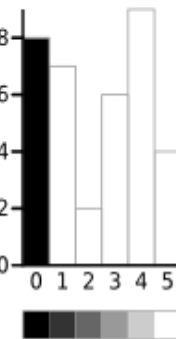
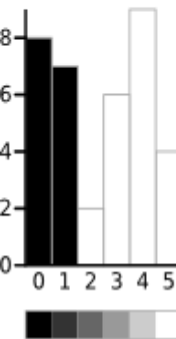
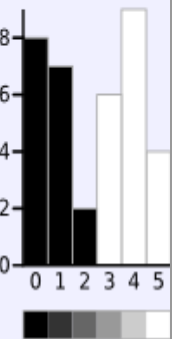
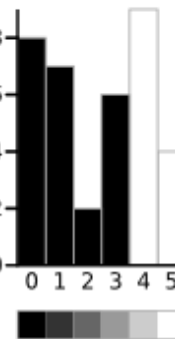
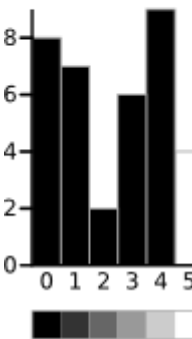
$$\text{Ortalama} \quad \mu_f = \frac{(3 \times 6) + (4 \times 9) + (5 \times 4)}{19} = 3.8947 \quad (6.3)$$

$$\text{Varyans} \quad \sigma_f^2 = \frac{((3-3.8947)^2 \times 6) + ((4-3.8947)^2 \times 9) + ((5-3.8947)^2 \times 4)}{19} \quad (6.4)$$


$$=0.5152$$

Eşik değeri  $T = 0,1,2,3,4,5$  için ağırlık, ortalama ve varyans ayrı ayrı hesaplanmıştır (Tablo 6.1). Otsu eşikleme yönteminde sınıflardaki (siyah ve beyaz) piksel sayıları ne kadar birbirine yakınsa (eşit olması durumunda varyans= 0,5 olmaktadır) o kadar tatminkar sonuç verdiği gözlemlenmektedir. (Otsu, 1979)

**Tablo 6.1.** Farklı eşik değerlerinde ağırlık, ortalama ve varyans sonuçları tablosu

T = 0	T = 1	T = 2	T = 3	T = 4	T = 5
					
					
Wb = 0	Wb = 0,222	Wb = 0,4167	Wb = 0,4722	Wb = 0,6389	Wb = 0,8889
Mb = 0	Mb = 0	Mb = 0,4667	Mb = 0,6471	Mb = 1,2609	Mb = 2,0313
$\sigma_{2b} = 0$	$\sigma_{2b} = 0$	$\sigma_{2b} = 0,2489$	$\sigma_{2b} = 0,4637$	$\sigma_{2b} = 1,4102$	$\sigma_{2b} = 2,5303$
Wf = 1	Wf = 0,7778	Wf = 0,5833	Wf = 0,5278	Wf = 0,3611	Wf = 0,1111
$\mu_f = 2,3611$	$\mu_f = 3,0357$	$\mu_f = 3,7143$	$\mu_f = 3,8947$	$\mu_f = 4,3077$	$\mu_f = 5,000$
$\sigma_{2f} = 3,1196$	$\sigma_{2f} = 1,9639$	$\sigma_{2f} = 0,7755$	$\sigma_{2f} = 0,5152$	$\sigma_{2f} = 0,2130$	$\sigma_{2f} = 0$

Bu tablodan da görüldüğü üzere T=3 seviyesinde varyans değeri 0,5 değerine en yakın değere sahiptir. Otsu Yönteminin küçük parçalı bir damar görüntüsü üzerindeki etkisi aşağıdaki şekilde görülmektedir (Şekil 6.5).

**Şekil 6.5** Otsu Yöntemi sonucu

Şekil 6.2 de verilen iyileştirilmiş damar görüntüsüne Otsu Algoritması uygulandığında aşağıdaki görüntü elde edilmiştir (Şekil 6.6.b).



Şekil 6.6 (a) Otsu uygulanmadan önce,

(b) Otsu uygulandıktan sonra


#### 6.4. Sayısallaştırma

Bu çalışmada damar deseninin sayısal verilerinin elde edilmesi amacıyla ortalama mutlak sapma yöntemi kullanılmıştır. Öznitelik vektörü elde etmede kullanılan ortalama mutlak sapma yönteminde görüntüde yer alan her bir pikselin, ortalama piksel değerine olan sapma değerinin hesaplanması işlemi gerçekleştirilir (Ma L. ve ark. 2002a).

Aşağıdaki denklem (6.5) ortalama mutlak sapma değerini hesaplamaktadır. Bu denklemde  $N$  görüntüde yer alan piksel sayısını,  $m$  ise görüntüde yer alan tüm piksel değerlerinin ortalamasını ifade etmektedir.  $a(x, y)$ ,  $(x, y)$  noktasındaki piksel değeridir.

$$F = \frac{1}{N} \left( \sum_{i=1}^N |a(x, y) - m| \right) \quad (6.5)$$

El damar deseni görüntüleri öncelikle 20x20 boyutlarında karesel pencereler kullanılarak alt görüntülere ayrılmıştır (Şekil 6.7).



**Şekil 6.7 (a)** Orijinal ikili kodlu görüntü,

**(b)** Alt görüntülere bölme işlemi

Elde edilen her bir alt görüntüye uygulanan ortalama mutlak sapma işlemi ile her bir alt görüntü için bir öznelik değeri hesaplanmıştır. Dolayısıyla 240x180 boyutlarındaki görüntü için 108 adet veriden oluşan bir öznelik vektörü elde edilmiştir. Bu vektörler bir sonraki aşama olan tanıma aşamasında YSA'na giriş olarak verilecektir.

## 7. YAPAY SİNİR AĞLARI İLE DAMAR TANIMA

Bu bölümde öncelikle yapay zeka ve yapay zekanın sınıflandırma için kullanılan alt yöntemi yapay sinir ağlarından bahsedilecektir. Kullanılan YSA mimarisi, öğrenme algoritmaları, aktivasyon fonksiyonları hakkında detaylı bilgi verilecek, ardından tanıma amacıyla yapılan deneysel çalışmalar ve elde edilen performans sonuçları sunulacaktır.

### 7.1. Yapay Zeka (YZ) ve Yapay Sinir Ağları (YSA)

Yapay zeka (YZ), bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlanmaktadır (Nabiyev 2005).

YZ konusunda ilk çalışma McCulloch ve Pitts tarafından 1940'lı yıllarda yapılmıştır. Bu araştırmacılar 1943 yılında yapay sinir sisteminin ilk matematiksel modelini geliştirmişlerdir (McCulloch ve Pitts 1943). Çalışmalarında herhangi bir hesaplanabilir fonksiyonun sinir hücrelerinden oluşan ağlarla hesaplanabileceğini göstermişlerdir. İlerleyen yıllarda bir çok araştırmacı YZ üzerine çalışmalar yapmış ve çeşitli YZ teknikleri geliştirmişlerdir. YZ araştırmalarının temel amacı insan gibi düşünen ve davranan ideal sistemleri oluşturmaktır. Bunun zorluğu fark edilince çalışmalar daha çok rasyonel düşünen ve davranan sistemler üzerine yoğunlaşmıştır.

Bu bölümde, YZ teknikleri içerisinde özellikle sınıflandırma problemlerinde tercih edilen Yapay Sinir Ağları (YSA) irdelenerek, YSA yönteminin teknik özellikleri, yapısı, kullanım alanları, avantaj ve dezavantajları, öğrenme algoritmaları anlatılmıştır.

Yapay Sinir Ağları, insan beyninin işleyişini taklit ederek yeni sistem oluşturulmaya çalışılan yaklaşımlardır. Beynimizdeki biyolojik sinir hücrelerinin yapısı temel alınarak YSA yapısı oluşturulur. YSA'nda aynen beynimizde olduğu gibi

öğrenme ve öğrenilen bilgilere göre karar verme mekanizmaları bulunur (Elmas 2003, Öztemel 2003, Sağıroğlu ve ark. 2003, Allahverdi 2002).

YSA alanında yapılan ilk çalışmalar McCulloch ve Pitts tarafından yapılmıştır (McCulloch ve Pitts 1943). Bu araştırmacıların yayınladığı “Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap” başlıklı makalede YSA konusunda ilk adım atılmıştır. İlerleyen zamanlarda Hebb (1949), Rosenblatt (1958), Widrow ve Hoff (1960), Hopfield (1982), Kohonen (1982), Rumelhart ve ark. (1986) ve daha birçok araştırmacı farklı YSA öğrenme algoritmaları geliştirmişlerdir.

Yapay Sinir Ağları, birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden (nöron) meydana gelmektedir. Temel olarak bir YSA'nın görevi, kendisine gösterilen giriş setine karşılık bir çıkış seti belirlemektir. Bunu gerçekleştirebilmek için ağ, ilgili problemin örnekleri ile eğitilerek (öğrenme), o problemle ilgili istenenleri çözebilme yeteneğine kavuşturulur. Literatürde birçok öğrenme algoritması ve sinir ağı modeli mevcuttur. Bu algoritmalar ve modeller bu bölümde ayrıntılı olarak bahsedilecektir.

### **7.1.1. YSA'nın genel özellikleri**

YSA'nın karakteristik özellikleri uygulanan ağ modeline göre değişebilmektedir. Bu değişik ağ modelleri ilerleyen kısımlarda anlatılacaktır. Genel karakteristik özellikler şunlardır (Öztemel 2003, Sağıroğlu ve ark. 2003, Allahverdi 2002):

- YSA öğrenme gerçekleştirirler. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.
- Bilgi geleneksel yöntemlere göre farklı biçimde saklanır. Bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Bir veritabanı yoktur.
- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.

- Görüntü tanıma ve sınıflandırma yapabilirler. Kendisine örnekler halinde verilen görüntüleri işleyerek öğrenme yapar ve daha sonra gelen bir örneğin hangi sınıfa dahil olduğuna karar verebilir.
- Kendi kendine organize olma yetenekleri vardır. Örnekler ile kendisine gösterilen durumlara adapte olup yeni olayları sürekli olarak öğrenebilmektedir.
- Eksik bilgi ile çalışabilir. YSA eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmamasına rağmen sonuç üretebilir.
- Hata toleransına sahiptir. Eksik bilgilerle çalışabilmesi hatalara karşı toleranslı olmasını sağlar.
- Dağıtık belleğe sahiptirler. YSA'nda bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir.
- Sadece sayısal bilgi ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin sayısal bilgilere çevrilmesi gerekir.

### 7.1.2. YSA'nın dezavantajları

YSA'nın birçok önemli dezavantajı vardır (Sağiroğlu ve ark. 2003, Haykin 1999). Bunlar:

- Probleme uygun ağ yapısının belirlenmesi zor bir süreçtir. Genellikle ağ yapısı belirlenirken deneme-yanılma metodu kullanılır. Bu da bazen çok uzun zaman almaktadır. Eğer problem için uygun ağ yapısı belirlenemezse, çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olmaktadır. Aynı zamanda bu durum bulunan çözümün en doğru çözüm olduğunun garantisini de vermez.
- Bazı ağlarda ağın parametre değerlerinin (örneğin öğrenme katsayısı, hücre sayısı v.b.) belirlenmesinde bir kural olmaması, çözümlere ulaşmada sorun oluşturur. Bu değerler kullanıcının tecrübesine bağlıdır ve her problem için farklı etkenlere dikkat etmek gerekir.
- Problemin ağa gösterimi çok önemli bir etkidir. YSA sadece sayısal bilgilerle çalışır ve problemin sayısal değerlere çevrilmesi gerekmektedir. Bu da kullanıcının becerisine bağlıdır. Uygun bir gösterim mekanizmasının kurulmamış olması problemin çözümünü engelleyebilir.

- Ağın eğitiminin ne zaman bitirileceğine dair kesin kurallar yoktur. Eğitimde hata toleransının belli bir değerin altına inmesi eğitimin tamamlanması için yeterli görülmektedir. Fakat neticede en iyi öğrenmenin gerçekleştiği söylenememektedir.

### 7.1.3. YSA'nın temel yapısı

YSA sinir hücrelerinin bir araya gelmesiyle oluşurlar. Tabi bu işlem rastgele olarak yapılmamaktadır. Genelde hücreler, 3 katman halindedir ve her katman içinde paralel halde ağı oluştururlar. Bu katmanlar;

- Giriş Katmanı: Bu katmandaki hücreler giriş bilgilerini gizli katmana ulaştırmakla görevlidir.
- Gizli Katman: Giriş katmanından gelen bilgiler işlenerek çıkış katmanına gönderilir. Bir ağda problemin durumuna göre, birden fazla gizli katman olabilmektedir.
- Çıkış Katmanı: Bu katmandaki hücreler gizli katmandan gelen bilgiyi çıkış katmanına gönderirler. Üretilen çıkışlar problemin çözümünü içermektedir.

**Gizli katman sayısının ve hücre sayısının belirlenmesi:** YSA'nın tasarımı sırasında ağdaki katman sayısına ve katmanlardaki hücre sayısına doğru bir şekilde karar vermek sistemin performansı açısından oldukça önemlidir. Birçok problemde iki veya üç katmanlı bir ağ istenen sonuçları üretebilmektedir (Haykin 1999). Katmanlar, hücrelerin aynı doğrultu üzerinde bir araya gelmeleriyle oluşmaktadır. Katmanların farklı şekilde birbirleriyle bağlanmaları ile farklı ağ yapıları oluşmaktadır. Giriş ve çıkış katmanlarının sayısı da, problemin yapısına göre değişmektedir (Freeman ve Skapura 1991).

Ağın bir diğer yapısal özelliği ise her bir katmandaki hücre sayısıdır. Gizli katmandaki hücre sayısının tespitinde de genellikle deneme-yanılma yöntemi kullanılır. Bunun için takip edilecek yöntem, başlangıçtaki rastgele olarak belirlenen hücre sayısını istenilen performansa ulaşıncaya kadar arttırmak veya tersi şekilde istenen performansın altına inmeden azaltmaktır. Gizli katmanda kullanılacak hücre sayısı ne kadar az olursa eğitim işlemi de o kadar kısa sürmektedir. Çünkü hesaplama adım sayısı kısalmaktadır.

Aynı zamanda hücre sayısının az olması sinir ağının “genelleme” yeteneğini arttırırken, gereğinden fazla olması ağın verileri ezberlemesine neden olmaktadır. Bununla birlikte hücre sayısının gereğinden az olması, ağın giriş verilerini öğrenememesi gibi bir sorun oluşturmalarına neden olabilir.


Gizli katman hücre sayısının belirlenmesinde kullanılan bir diğer yöntem ise tecrübeye dayalı (heuristic) arama yöntemidir. Tecrübeye dayalı arama yönteminde arama doğruluğu, son arama adımında denenen mimari ile bir önceki arasındaki arama kriteri ile belirlenir (Breiman 1994). Bununla birlikte ağın genel hata oranına bakılarak da ağ yapısı belirlenmesi işlemi gerçekleştirilebilmektedir. Ağdaki gizli katman sayısı arttıkça ağırlık sayısı da artacağından dolayı ağ yapısı karmaşık bir hale gelecektir. Bu yöntemde, her bir modelin en uygun olabilirlik fonksiyonunu bulunur. Olabilirlik fonksiyonunun değeri en küçük olan model, en uygun model olarak seçilmektedir (Schwarz 1978).

Yapılan son çalışmalarda (Dodd 1990, Kitano 1990, Happel 1992, Nan ve ark. 2003, Boers ve Kuiper 1992) sinir ağı yapısının belirlenmesinde genetik algoritmaların oldukça etkili olduğu görülmüştür. Genetik algoritmaların optimizasyon problemlerinde ne denli iyi performans verdikleri bilinmektedir. Olasılıksal karakterleri ve çoklu mümkün çözümleri araştırma gibi özelliklere sahip olan GA’ların sinir ağının yapısının belirlenmesinde çok iyi performans vereceği beklenmektedir.

#### **7.1.4. Yapay sinir ağı hücresi**

Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöron modeli Şekil 7.1’de görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar, net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur.

Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlinear) bir fonksiyondur (Haykin 1999).



Şekil 7.1 Temel yapay sinir ağı hücresi

Burada  $b$  bir sabittir, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Nöronun matematiksel modeli şöyledir.

Çıkış,

$$y = f(w \cdot x + b) \quad (7.1)$$

şeklinde nöron çıkışı hesaplanır. Buradaki  $w$  ağırlıklar matrisi,  $x$  ise girişler matrisidir.  $n$  giriş sayısı olmak üzere;

$$w = w_1, w_2, w_3, \dots, w_n \quad (7.2)$$

$$x = x_1, x_2, x_3, \dots, x_n \quad (7.3)$$

şeklinde yazılabilir. Buradan;

$$net = \sum_{i=1}^n w_i x_i + b \quad \text{ve} \quad y = f(net) \quad (7.4)$$

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (7.5)$$

şeklinde de yazılabilir. Yukarıdaki formülde görülen  $f$  aktivasyon fonksiyonudur. Genelde lineer olmayan olan aktivasyon fonksiyonunun çeşitli tipleri vardır. Eşik aktivasyon fonksiyonu eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında  $+1$  değeri verir. Eşik aktivasyon fonksiyonunun  $-1$  ile

+1 arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, net giriş değeri sıfırdan büyükse +1, sıfırdan küçükse -1, sıfıra eşitse sıfır değerini verir. Lineer aktivasyon fonksiyonunun çıkışı girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir (Bishop 1995).

$$f(x) = x \quad (7.6)$$

şeklinde ifade edilir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir. Böylece daha sonraki bölümlerde görülecek olan geri yayımlı ağlarda kullanmak mümkün olabilmektedir (Bishop 1995).

Fonksiyonu tanımlarsak,

$$f(x) = \text{lojistik}(x) = \frac{1}{1 + \exp(-\beta x)} \quad (7.7)$$

şeklinde ifade edilir. Buradaki  $\beta$  eğim sabiti olup genelde bir olarak seçilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer olmayan türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir (Haykin 1999, Bishop 1995).

$$f(x) = \text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7.8)$$

Bu aktivasyon fonksiyonlarından başka fonksiyonlar da vardır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir (Haykin 1999, Bishop 1995).

### 7.1.5. Performans fonksiyonunun seçimi

Performans fonksiyonu YSA' nın öğrenme performansını ölçmede kullanılan bir ölçüttür. (Rumelhart ve ark. 1986). İleri beslemeli ağlarda genellikle ortalama karesel hata (Mean Square Error - MSE) performans fonksiyonu olarak kullanılır. MSE fonksiyonu istenen sonuç ile hesaplanan sistem çıkışı arasındaki farkın kareleri toplamının ortalaması olup aşağıdaki formülle hesaplanır:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y'_i - y_i)^2 \quad (7.9)$$

Burada  $y$ , istenen çıkış değerini;  $y'$  ise sistem tarafından hesaplanan çıkış değerini ifade eder.  $N$  ise çıkış sayısını belirtmektedir. Hatanın sıfıra yaklaşması istenen çıkış değerine yakın çıkış değeri elde edilmiş olması demektir.

İleri beslemeli ağlarda kullanılan bir diğer performans fonksiyonu toplam karesel hata (Sum Square Error – SSE)'dir (Sağiroğlu ve ark. 2003). 7.10'da verilen denklem kullanılarak toplam karesel hata hesaplanır:

$$SSE = \sum_{i=1}^N (y'_i - y_i)^2 \quad (7.10)$$

Bunlardan başka performans fonksiyonu olarak kullanılan bir diğer hata hesaplama yöntemi ortalama karesel hatanın karekökü (Root Mean Square – RMS) fonksiyonudur ve aşağıdaki formül ile hesaplanır:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (y'_i - y_i)^2} \quad (7.11)$$

Sağiroğlu ve ark. (2003) 'na göre performans fonksiyonuna ağırlık biaslarının ve ağırlıklarının kareleri toplamının ortalama değerini ifade eden bir terim eklenerek genelleştirme daha da iyileştirilebilir. Böylece ağ daha hassas hale getirilir ve ağırlık eğitimi kümesi haricindeki veriler için sağlıklı bir genelleme yapmasını engelleyebilir.

Bunun yanı sıra genelleştirmeyi iyileştirmek için kullanılan yöntemlerden birisi de öğrenmeyi erken sonlandırmaktır (Sağıroğlu ve ark. 2003). Bu yöntemde, YSA'ya uygulanacak veri kümesi üç bölüme ayrılır. İlk küme YSA'nın eğitiminde kullanılarak ağırlıkların, biasın ve eğimin güncelleştirilmesinde kullanılır. İkinci bölüm veri kümesi ise doğrulama verisi olarak kullanılır. Eğitim süresince, eğitim verilerinden hesaplanan hata oranı düştüğü gibi test veri kümesine ait hata da normal şartlarda düşer.

#### **7.1.6. Çok Katmanlı Perseptron Modeli**

Yapay sinir ağları yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde modellenebilir.


İleri beslemeli modelde, bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir (Özbay ve Karlık 2001). Katmanlardaki hücrelerin sayısı tamamen uygulanan probleme bağlıdır. Hücreler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki hücrelere iletir. Giriş bilgileri, gizli ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Türkoğlu ve Arslan 1996).

İleri beslemeli ağlara örnek olarak, çok katmanlı algılayıcı (Multi Layer Perseptron – MLP), modüler sinir ağları (Modular Neural Networks – MNN), vektör kuantalamalı öğrenme (Learning Vector Quantization – LVQ), radyal tabanlı fonksiyon (Radial Basis Function – RBF) ve olasılık tabanlı (Probabilistic Neural Network – PNN) sinir ağları verilebilir.

Geri beslemeli sinir ağı modelinde ise çıkış katmanındaki ve gizli katmandaki çıkışlar, giriş katmanındaki hücrelere veya bir önceki gizli katmanlara geri besleme şeklinde iletilir (Öztemel 2003). Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu tip sinir ağlarının hafızaları dinamiktir ve çıkış hem anlık hem de önceki girişleri yansıtır. Bundan dolayı, bu tip sinir ağı modeli önceden tahmin uygulamaları için daha uygundur (Haykin 1999).

Geri beslemeli ağ modeline örnek olarak Hopfield, adaptif rezonans teori (ART), kendi kendine organize olabilen harita (Self Organizing Map – SOM) ağları, Elman ve Jordan ağları verilebilir.

Çok katmanlı perseptron (MLP), giriş, gizli ve çıkış katmanından oluşmuş ileri beslemeli bir ağıdır (Şekil 7.2) (Haykin 1999). Katmanlardaki nöronlar arasında ve bir katmandan önceki katmana geriye doğru bağlantı yoktur.



Şekil 7.2. Çok katmanlı perseptron ağ yapısı

Herhangi bir katmandaki  $j$ . birime gelen toplam giriş, önce ki katmandaki birimlerin  $y_i$  çıkışlarının ( $l$ . katman için girişlerin) bağlantılar üzerindeki  $w_{ij}$  ağırlıkları ile hesaplanmış bir ağırlıklı toplamıdır.

$$x_j = \sum w_{ij} \cdot y_i \quad (7.12)$$

Birimin çıkışı, bu toplam girişi bir lineer olmayan fonksiyondan geçirerek belirlenir. Bunun için birçok fonksiyon teklif edilmiştir. Ancak en çok kullanım göreni aşağıdaki sigmoid fonksiyondur.

$$y_j = \frac{1}{1 + e^{-x_j}} \quad (7.13)$$

Bu fonksiyon yakınsama şartını, yani “her birimin çıkışı, toplam girişin devamlı artan, türevi sınırlı bir fonksiyonu olmalıdır” şartını sağlar. Bu fonksiyon  $y_j$  çıkışını 0 ve 1 değerleri arasına sınırlar.

MLP’de, ilk katmana bir giriş vektör uygulanır. Daha sonra giriş ve 1. katman arasındaki ağırlıklar yardımıyla 1. katmandaki her birimin aldığı toplam giriş belirlenir. Her birim girişini bir lineer olmayan fonksiyondan geçirerek bir sonraki katmana göndereceği çıkış işaretini belirler. Bir katmandaki tüm birimlerin durumları paralel olarak belirlenir. Bu işlem çıkış katmanındaki birimlerin durumları belirleninceye kadar sırayla tekrar edilir.

MLP ağıının eğitilmesi danışmanlı öğrenmeye bir örnek oluşturabilir. Bu ağda girişe bir giriş vektörü uygulanır ve bir çıkış vektörü elde eder. Daha sonra bu çıkış vektörünü istenilen bir “hedef” vektörü ile karşılaştırır ve bu iki vektör arasındaki fark en küçük olacak şekilde ağ ağırlıklarını ayarlar. Amaç her giriş vektörü için, ağıın üreteceği cevabın istenilen çıkış vektörünün aynısı (veya yeterince yakını) olmasını sağlayan bir ağırlık kümesi bulmaktır.

Eğitme iki adımlı bir işlemdir. İlk adımda bir giriş vektörü uygulanır, ağ içindeki her birim için toplam giriş ve çıkış hesaplanır ve her birimin çıkışı daha sonra ağırlık ayarlamasında kullanılmak üzere saklanır. Çıkış vektörü oluşturulduktan sonra, eğitme işlemi çıkış hatasını hesaplar ve bu hatanın geriye doğru yayılımını sağlar. Birimlerin ağırlıkları bu hata işaretine göre ayarlanır. Bu iki adımlı işlem ağ istenilen cevapları üretinceye kadar, eğitme vektör çiftleri ile tekrar edilir (Bishop 1995, Haykin 1999).

Çıkış katmanını eğitmek bağıl olarak daha basittir. Sorun bir hedef vektörünün olmadığı ara katman ağırlıklarını eğitirken ortaya çıkar. Bunun çözümü, hata işaretinin çıkıştan daha iç katmanlar doğru yayılımını sağlamakla bulunur. Yani bir iç veya ara katman birimi, kendisinden sonraki katmanın hata işaretlerinin ağırlaştırmış toplamı olan bir hata işareti alır. Bu hata işareti her birim ağırlıklarını eğitmek için kullanıldıktan sonra; eğitme işlemi, oluşturulan yeni hata işaretinin daha önceki katmanlara doğru yayılımını sağlar.

Önceden belli, sonlu sayıda giriş-çıkış çifti için, belli bir ağırlık kümesine sahip ağın davranışındaki hata, her çift gerçek ve istenilen çıkış vektörlerini karşılaştırarak hesaplanabilir. E toplam hatası aşağıdaki şekilde tanımlanabilir.

$$E = \frac{1}{2} \cdot \sum_j \sum_k (y_{j,k} - d_{j,k})^2 \quad (7.14)$$

Burada k giriş-çıkış çiftlerinin, j çıkış birimlerinin indisidir y bir çıkış biriminin gerçek durumunu, d ise istenen durumunu göstermektedir. Verilen bir giriş-çıkış çifti için hata her ağırlığa göre iki adımda hesaplanır.

Geri yön adımı, her çıkış birimi için  $\partial E / \partial y$  büyüklüğünü hesaplayarak başlar. Belli bir k çifti için denklem (7.15) türetilirse ve k indisi yazılmazsa,

$$\frac{\partial E}{\partial y_j} = y_j - d_j \quad (7.15)$$

elde edilir. Daha sonra  $\partial E / \partial x_j$ 'yi hesaplamak için aşağıdaki zincir kuralı kullanılabilir.

$$\frac{\partial E}{\partial y_j} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{dx_j} \quad (7.16)$$

dy/dx'nin değerini bulmak için 7.14 denklemi türetilerek yukarıda yerine konursa,

$$\frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} \cdot y_j \cdot (1 - y_j) = (y_j - d_j) \cdot y_j \cdot (1 - y_j) \quad (5.17)$$

ifadesi elde edilir. Bu da, j. çıkış birimine toplam giriş büyüklüğündeki ( $X_j$ ) bir değişimin hatayı nasıl etkilediğini bildiğiniz anlamına gelir. Bu ifade çıkış katmanından bir birimden geriye doğru yayılımı yapılacak hata işaretidir. Bu toplam giriş, alçak katman birimlerinin  $y_j$  çıkışlarının bir lineer fonksiyonudur.  $x_j$  girişi aynı zamandaki ağırlıkların da bir lineer fonksiyonudur. Dolayısıyla ara katman çıkışlarındaki veya

ağırlardaki bir değişimin hatayı nasıl etkileyeceğini hesaplamak kolaydır.  $i$ . birimden,  $j$ . birime bir  $w_{ij}$  ağırlığındaki değişimin hataya etkisi,

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial x_j} \cdot \frac{dx_j}{dw_{ij}} = \frac{\partial E}{\partial x_j} \cdot y_i = (y_j - d_j) \cdot y_j \cdot (1 - y_j) \cdot y_i \quad (7.18)$$

ifadesinden bulunabilir. Sondan bir önceki katmandaki  $i$ . birimin çıkışı için,  $i$ 'nin  $J$  üzerindeki etkisi nedeniyle ortaya çıkan  $\partial E / \partial y_i$  katkısı,

$$\frac{\partial E}{\partial y_i} = \frac{\partial E}{\partial x_j} \cdot \frac{dx_j}{dy_i} = \frac{\partial E}{\partial x_j} \cdot w_{ij} \quad (7.19)$$

şeklindedir. Bu şekilde  $i$ . birimden çıkan tüm bağlantıları göz önüne alarak,

$$\frac{\partial E}{\partial y_i} = \sum_j \frac{\partial E}{\partial x_j} \cdot w_{ij} = \sum_j (y_j - d_j) \cdot y_j \cdot (1 - y_j) \cdot w_{ij} \quad (7.20)$$

elde edilir. Bu şekilde son katmandaki bu birimler için  $\partial E / \partial y$  verildiğinde, sondan bir önceki katmandaki herhangi bir birim için  $\partial E / \partial y$ 'nin nasıl hesaplanacağı gösterilmiş olmaktadır. Bu ifade sondan bir önceki katmandaki  $i$ . birime gelen hata işaretidir. Daha önceki katmanlarda bu terimi hesaplamak için burada yapılan işlem tekrar edilebilir.

Ağırlıkları ayarlamak için  $\partial E / \partial w_{ij}$  türevsel bilgisi kullanılır. Bu bilgiyi kullanmanın bir yolu ağırlıkları her giriş çıkış çiftinin uygulanmasından sonra değiştirmektir. Bu yöntemin  $\partial E / \partial w_{ij}$  türevlerini saklamak için hiç ayrı bellek ihtiyacı göstermemesi gibi bir avantajı vardır. Öte yandan ağırlıkları ayarlamanın bir başka yolu, tüm giriş-çıkış çiftlerinin uygulanması ile elde edilen  $\partial E / \partial w_{ij}$  değerlerini toplamak ve daha sonra bu bilgiyi  $w_{ij}$  ağırlığının değişiminde kullanmaktır. Eğim azalmasının en basit şekli, her  $w_{ij}$  ağırlığını  $\partial E / \partial w_{ij}$  değerine orantılı olacak şekilde değiştirmektir.


$$w_{ij} \cdot (n+1) = w_{ij} \cdot (n) - \varepsilon \cdot \frac{\partial E}{\partial w_{ij}} \quad (7.21)$$

Burada  $w_{ij}(n)$   $i$ . birimden  $j$ . birime olan ağırlığın hesaplamasının  $n$ .adımındaki değerini göstermektedir.  $\varepsilon$  ise 0 ile 1 arasında (tipik olarak 0,1'ler mertebesinde) değer alan bir kazanç terimidir.

Ağırlık değişimindeki bu yöntem, ikinci türevleri kullanan yöntemler gibi hızlı yakınsamaz, fakat daha basittir ve paralel donanımda lokal hesaplamalar ile kolayca gerçekleştirilebilir. Bu yöntem aşağıdaki şekilde geliştirilebilir.

$$w_{ij} \cdot (n+1) = w_{ij} \cdot (n) - \varepsilon \cdot \frac{\partial E}{\partial w_{ij}} + \alpha \cdot (w_{ij}(n) - w_{ij}(n-1)) \quad (7.22)$$

Burada  $\alpha$  ağırlıktaki değişimi önceki değişimin değerine bağlayan bir katsayıdır ( $0 < \alpha < 1$ ). Bu yeni öğrenme denklemi,  $\varepsilon$ 'nin daha büyük değerlerine imkan sağlayarak yakınsamayı hızlandırır. Geri yayılım algoritmasında çıkışın hesaplanması işlemi ileri yönde gerçekleşir. Ancak eğitim sırasında hatanın bulunması ve değiştirilmesi geri doğru gerçekleştirilir (Şekil 7.3).




Şekil 7.3. Eğitim işlemi

Geril yayılım algoritması uygulamada oldukça sık rastlanan bir algoritmadır. Bu algoritmada, hataların çıkıştan girişe geriye doğru azaltılmaya çalışılmasından dolayı geri yayılım ismini almıştır (Parker 1985).

### 7.1.7. Öğrenme Algoritmaları

Öğrenme algoritmalarının çoğunluğu matematik tabanlı olup YSA ağırlıklarının güncelleştirilmesi için kullanılırlar. Bu algoritmaların birçoğu Hebb (1949) kuralından türetilmiştir. Bu kuralın temelinde “bir nöron diğer bir nörondan giriş alıyorsa ve her iki nöron da aktif ise yani matematiksel olarak aynı işarete sahip ise nöronlar arasındaki ağırlıklar kuvvetlendirilir” ilkesi bulunmaktadır (Sağıroğlu ve ark. 2003). En çok tahmin ve sınıflandırma problemlerinde kullanılan YSA için en yaygın olarak kullanılan danışmanlı öğrenme algoritması ise geriyayılım algoritmasıdır. Geriyayılım algoritması, ileri beslemeli ve çok katmanlı bir ağ mimarisini gerektirmektedir. Bu algoritmada hata, ağdaki ağırlıkların bir fonksiyonu olarak görülür ve hataların kareleri ortalaması yöntemi kullanılarak minimize edilmeye çalışılır (Golden 1986). Bu algoritma, hataları çıkıştan girişe (geriye) doğru azaltmaya çalışmasından dolayı geriyayılım ismini almıştır (Parker 1985, Werbos 1974). Eğitime işlemi ve eğitimden sonraki test işlemi bu akışa göre gerçekleştirilir (Şekil 7.4). Geri yayılım algoritması, danışmanlı öğrenme yöntemini kullandığı için öncelikle veriler ağa öğretilir ve ağa hedef değeri verilir. Öğrenme, her veri için ağın çıktı değeri ile hedef değerini karşılaştırılmasıdır. Hata değeri, ağa tekrar geri besleme şeklinde verilir. Veri setindeki hata kareleri toplamını azaltmak için nöronlar arasındaki bağlantı ağırlıkları güncellenir (Curram ve Minger 1994). Burada, gizli katman sayısını tespit etmek zor bir işlemdir. Gizli katmanlar, lineer olmayan ya da değişkenler arasında etkileşim olduğu durumlarda kullanılır. Bu etkileşim ne kadar karmaşıkça, o kadar çok gizli katmana ihtiyaç duyulur. Eğer az sayıda gizli katman kullanılırsa ağ öğrenmeyi başaramayabilir. Gereğinden fazla sayıda gizli katman bulunması halinde ise, ağ ezberler. Bu da ağın, yeni örnekler için genelleme yeteneğini azaltır. Amaç, ağın genelleme yeteneğini optimum yapabilecek en az sayıda katmanı kullanmaktır (Saraç 2004).



Şekil 7.4 Geri yayılım algoritmasının akış şeması

Öğrenme algoritması olarak geriyayılım algoritması seçildiğinde iki parametre önem kazanmaktadır (McClelland ve Rumelhart 1986). Bunlar öğrenme katsayısı  $\eta$  ve momentum  $\alpha$ 'dır. Bu algoritma ile  $i$  ve  $j$  katman işlem elemanları arasındaki ağırlıklar değişimi olan  $\Delta w_{ij}(t)$  hesaplanır. Bu ifade aşağıdaki eşitlik ile gösterilir:

$$\Delta w_{ij}(t) = \eta \delta_j x_i + \alpha \Delta w_{ij}(t-1) \quad (7.23)$$

Burada  $\eta$ , öğrenme katsayısı olup ağırlıkların bir sonraki düzeltmede hangi oranda değiştirileceğini gösterir. Küçük öğrenme katsayıları, ağın sonuca ulaşmasını yavaşlatır. Büyük öğrenme katsayıları ise ağın sonuca daha kısa sürede ulaşmasını

sağlar. Öğrenme katsayısı için tipik değerler 0,01 ile 0,9 arasında değişir. Karmaşık ve zor çalışmalar için küçük öğrenme katsayıları seçilebilir.

$\alpha$  ise momentum katsayısını ifade eder. Momentum terimi, ağıdaki salınımları engellemeye ve ağı hata yüzeyindeki bölgesel minimum noktalardan kaçarak, daha dip noktalara ulaşmasına yardımcı olur.

$\delta_j$ , ara veya çıkış katmanındaki herhangi bir  $j$  nöronuna ait bir faktördür. Çıkış katmanı için bu faktör aşağıdaki eşitlikle verilir.

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j) \quad (7.24)$$

Burada,  $net_j = \sum x_j w_{ji}$  ve  $y_j^{(t)}$  ise  $j$  işlemci elemanın hedef çıkışıdır. Ara katmanlardaki nöronlar için herhangi bir hedef çıkış olmadığından bu eşitlik faktörü (7.25) ile ifade edilir:

$$\delta_j = \frac{\partial f}{\partial net_j} \sum w_{qi} \delta_q \quad (7.25)$$

Bu duruma bağlı olarak çıkış katmanından başlayarak  $\delta_j$  faktörü, bütün katmanlardaki işlemci elemanlar için hesaplanır. Daha sonra eşitlik (7.25)'deki formüle bağlı olarak, bütün bağlantılar için ağırlıkların güncelleştirilmesi gerçekleştirilir.

### 7.1.7.1. Hızlı yayılım algoritması

Hızlı yayılım (Quick propagation) algoritması, Scott Fahlman (1988) tarafından geliştirilen ve Newton metoduna dayanan, çok katlı algılayıcıların eğitilmesi için kullanılan bir sezgisel öğretim algoritmasıdır.

Sezgisel algoritmalar, tecrübeye ve eğitilmiş tahmine dayalı kurallar içermektedir (Moallemi 1991). Bu algoritmalar optimum çözümü garanti edemeyip sadece ona yakın çözümü bulmaktadırlar.

Sezgisel metotları kullanmanın sağladığı bazı avantajlar şöyle özetlenebilir (Sağiroğlu ve ark. 2003):

- Sezgisel metotlar karar verici mekanizma için sadeleştirici olabilir.
- Sezgisel metot, herhangi bir tam yöntemin parçası olarak öğrenme amacıyla kullanılabilir.
- Gerçek dünya problemleri için her zaman matematiksel formülasyon kurmak çok kolay olmayabilir. Bu basitleştirme sonucu oluşan hata, bir sezgisel metodun sağladığı optimale yakın çözümün sahip olduğu hatadan daha büyük olabilir.

Problem uzayında mümkün olan en kısa sürede, bir çözüm bulmak için ağırlık uzayında eğimi son derece azaltmak gerekebilir (Fausett 1994). Bunun yerine çözümden fazla uzaklaşmaksızın mümkün olan en büyük adımlarla kısa sürede çözüme ulaşmak arzu edilir. Hata fonksiyonunun eğim derecesi biliniyorsa, güvenli bir şekilde ağırlık uzayında daha büyük adımla çözüme ulaşılabilir. Bu algorithmada iki geleneksel yaklaşım (Sağıroğlu ve ark. 2003) birleştirilerek çözülmüştür. Bunlar;

- Hesaplamanın geçmişteki durumu hakkında genel veya her bir ağırlık için ayrı sezgilere dayanan dinamik olarak ağırlıkların ayarlanması,
- Her bir ağırlığa göre hatanın ikinci türevinin belirgin olarak kullanımıdır.

Hızlı yayılım algoritması bir ikinci dereceli metottan daha sezgiseldir ve çok az da olsa Newton metoduna dayanan bu metotta aşağıdaki kabuller kullanılır (Sağıroğlu ve ark. 2003):

- Her bir ağırlık için ağırlık hata eğrisi kolları, yukarı doğru açık olan bir parabol ile yaklaştırılabilir.
- Hata eğrisinin eğilimindeki değişim, diğer tüm ağırlıkların aynı andaki değişiminden etkilenmez.

Yukarıda bahsedilen parabol, birbirinden bağımsız her bir ağırlık için mevcut ve önceki hata eğimleri ve bu eğimlerin ölçüldüğü noktalar arasındaki değişim kullanılarak belirlenir. Daha sonra, algoritma doğrudan bu parabolün minimum noktasına dallanır.

Genellikle hızlı yayılım algoritmasının performans testleri diğer tekniklerle karşılaştırıldığında oldukça iyidir (Sağıroğlu ve ark. 1999). Hızlı yayılım algoritması gürültü seviyesi fazla olan verilerin kullanıldığı problemlerde çok iyi çalışır.

Bu algoritmada ağırlık hızlandırma ve kırılması ihmal edilerek  $t-1$  den  $t$ 'ye kadar ağırlıklardaki değişim aşağıdaki eşitlik ile ifade edilir (Fausett 1994).

$$\Delta w(t) = \varepsilon L(t) + \alpha Q(t) \quad (7.26)$$

Burada  $\varepsilon$ , öğrenme katsayısıdır.

$$L(t) = \begin{cases} h(t) & \text{eğer } h(t)h(t-1) \geq 0 \\ 0 & \text{diğer durumlarda} \end{cases} \quad (7.27)$$

ve

$$Q(t) = \begin{cases} \mu \Delta w(t-1) & \text{eğer } h(t) \left( h(t) - \left( \frac{\mu}{\mu+1} \right) h(t-1) \right) \geq 0 \\ \Delta q(t) & \text{diğer durumlarda} \end{cases} \quad (7.28)$$

eşitlikleri ile verilir.

Bu eşitliklerde  $\mu$ , momentum büyüme faktörünü;  $h(t) = \frac{\partial E}{\partial w(t)}$ , eğimi ve

$\Delta q(t) = \frac{\Delta w(t)h(t)}{h(t-1)h(t)}$  ise minimum adım miktarını göstermektedir (Haykin 1998).

Buradan ağırlık fonksiyonunu güncelleştirmek için, delta ağırlık fonksiyonu ve ağırlık hızlandırma katsayısı işleme dahil edilirse;

$$w(t) = (1 - \delta)w(t-1) + \Delta w(t) \quad (7.29)$$

eşitliği elde edilir. Burada  $\delta$ , hızlandırma katsayısıdır. Son olarak ağırlık çok küçük ise, 0 alınarak kırılır (Haykin 1998). Yani,  $|w(t)| < \kappa$  ise  $w(t)=0$  alınır. Burada,  $\kappa$ , ağırlık kırma faktörüdür.

### 7.1.7.2. Yığın geri yayılım

Geri yayılım algoritmasında bütün örnekler gösterildikten sonra eşikler ve ağırlıklar güncellenirse bu işleme “yığın güncelleme” adı verilir (Han ve Kamber 2000).

Teoride geri yayılıma ait matematiksel türevim, yığın güncellemeyi kullanır. Bu, geri yayılım algoritmasının gelişmiş bir çeşidi olarak ağ ağırlıklarının her epoktan sonra güncellendiği bir yapıdır. Epok, tüm eğitim verilerinin ağıdan geçmesi işlemidir.

Yığın geri yayılım prosedürü aşağıdaki şekilde ifade edilebilir:

1. Ağırlıkları başlangıç durumunda ayarla,
2. Aşağıdaki adımlara devam et,
3. Tüm eğitim verisini eğit,
4. Ağırlıkları güncelle
5. Hata oranı beklenenin altında ise dur, yoksa 2. adıma dön.

Yığın geri yayılım algoritmasını kullanan YSA'nın eğitimi, aşağıdaki durumlarda sonlandırılır:

- Bir önceki epoktaki bütün  $\Delta w_{ij}$  'ler belirli bir eşik seviyesinin altında olduğunda,
- Bir önceki epokta sınıflandırılmamış örnek sayısına ait yüzde, belirli bir eşik seviyesinin altında olduğunda,
- Önceden belirlenmiş bir epok sayısı aşıldığında eğitim sonlandırılır.

### 7.1.7.3. Online geri yayılım

Geri yayılım algoritmasının bir çeşidi olarak ağ ağırlıklarının her iterasyondan önce ve mevcut her bir durumdan sonra eğitim kümesinden güncellendiği bir yapıdır (Anthony ve Bartlett 1999). Geniş veri kümeleri için çok tercih edilir. Genellikle artışlı geri yayılım, yığın geri yayılım algoritmasına göre daha performanslıdır. Bu algortmada ağırlıkları güncelleme kuralı aşağıdaki gibidir:

$$\Delta w_{ji}(t) = -\eta \frac{\partial E(t)}{\partial w_{ji}(t)} + \alpha \Delta w_{ji}(t-1) \quad (7.30)$$

Burada  $\eta$ , öğrenme oranı ve  $\alpha$ , momentum terimidir.

Artışlı geri yayılım prosedürü aşağıdaki şekilde ifade edilebilir:

1. Ağırlıkları başlangıç durumunda ayarla,
2. Aşağıdaki adımlara devam et,
3. Bir eğitim durumunu eğit,
4. Ağırlıkları güncelle
5. Hata oranı beklenenin altında ise dur, yoksa 2. adıma dön.

## 7.2. Deneysel Sonuçlar

Bu tez çalışmasında damar tanıma amacıyla danışmanlı öğrenme tabanlı çok katmanlı perseptron YSA modeli kullanılmıştır. Öğrenme algoritmalarından olan hızlı yayılım, online geri yayılım (Bertsekas 1995) ve yığın geri yayılım (Bertsekas ve Tsitsiklis 1996) algoritmaları uygulanmıştır. Bununla birlikte aktivasyon fonksiyonu olarak lojistik ve tanjant hiperbolik fonksiyonları nöronların aktifleşmesini sağlamıştır.

Yapılan deneysel çalışmalarda damar deseni görüntüsünden elde edilen sayısal veriler, YSA'nın girişine uygulanabilecek formatta düzenlenmiştir. Her bir görüntü 240x180 pixel boyutunda olup, 20x20 pixel boyutunda bölündüğünde  $12 \times 9 = 108$  tane veri elde edilmiştir. Elde edilen veriler YSA'da eğitime tabi tutulmuştur. Daha sonra test aşamasına geçilerek doğru sınıflandırma oranları kaydedilmiştir. Tüm damar veri setlerinin %70 eğitim, %20 doğrulama ve kalan %10 test kümesi olarak belirlenmiştir. Eğitim ve testler 2 farklı veri kümesi için ayrı ayrı yapılmıştır. Veri kümesi setleri yukarıda belirtilen yüzde oranlarıyla rastgele olarak seçilmiştir.

Tüm deneysel çalışmalarda en yüksek iterasyon sayısı 10.000 olarak sınırlandırılmıştır. Eğitimi durdurma kriteri olarak kullanılan MSE değeri 0,0001 belirlenmiştir.

Gizli katman nöron sayısı deneme yanılma yöntemiyle belirlenmiştir. Gizli katman nöron sayısı 5'ten başlayarak 200'e kadar 3'er artırılarak her seferinde 100

iterasyon çalıştırılmış ve en düşük MSE oranına bakılmıştır. Bulunan en iyi sonuca göre giriş-gizli-çıkış katmanı nöron sayıları 108-101-103 olarak belirlenmiştir.


Eğitim aşamasında öğrenme metoduna bağlı olarak öğrenme oranı ve momentum parametreleri belirlenmelidir. Bu parametreler ağıın öğrenme hızını ve performansını etkilemektedir. Öğrenme oranı ağırlıkların değişim miktarını belirlemektedir. Eğer büyük değerler seçilirse o zaman yerel çözümler arasında ağıın dolaşması ve osilasyon yaşaması söz konusu olmaktadır. Küçük değerler seçilmesi ise öğrenme zamanını artırmaktadır. Tecrübeler genellikle 0,1 - 0,4 arasındaki değerlerin kullanıldığını göstermektedir. Fakat bu tamamen ilgili probleme bağlıdır. Bu değerler iyidir demek de doğru olmaz. Bazı uygulamalarda öğrenme katsayısının 0.6 değerini aldığı zaman en başarılı sonuçları verdiği görülmektedir. Benzer şekilde momentum katsayısı da öğrenmenin performansını etkiler (Sağıroğlu ve ark. 2003). Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesi olarak görülmektedir. Bu özellikle yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacı ile önerilmiştir. Bu değer küçük olması yerel çözümlerden kurtulmayı zorlaştırabilir. Çok büyük değerler için ise tek bir çözüme ulaşmada sorunlar yaşanabilir. Tecrübeler bu değer 0,6–0,8 arasında seçilmesinin uygun olacağını göstermektedir. Fakat bu da kesin denilemez. Problemin niteliğine göre kullanıcının belirlemesinde fayda vardır. Daha küçük değerler ile başarılı sonuçların alındığını gösteren örnekleri görmek de mümkündür (Sağıroğlu ve ark. 2003). Eğitim parametrelerinden olan öğrenme hızı ( $\alpha$ ) yapılan denemeler sonucunda 0,5 olarak belirlenmiştir. Momentum katsayısı ise 0,7 değerinde en iyi sonucu vermiştir.

Yapılan deneysel çalışmalar sonucu damar deseni görüntülerinin YSA ile sınıflandırılması işlemleri Alyuda Neuro Intelligence programı ile gerçekleştirilmiştir. Yapılan eğitimler sonucu kaydedilen iterasyon sayıları, eğitim süresi ve eğitim-doğrulama-test doğru sınıflandırma oranları kullanılan öğrenme algoritması ve aktivasyon fonksiyonlarına göre tablo halinde sunulmuştur (Tablo 7.2).

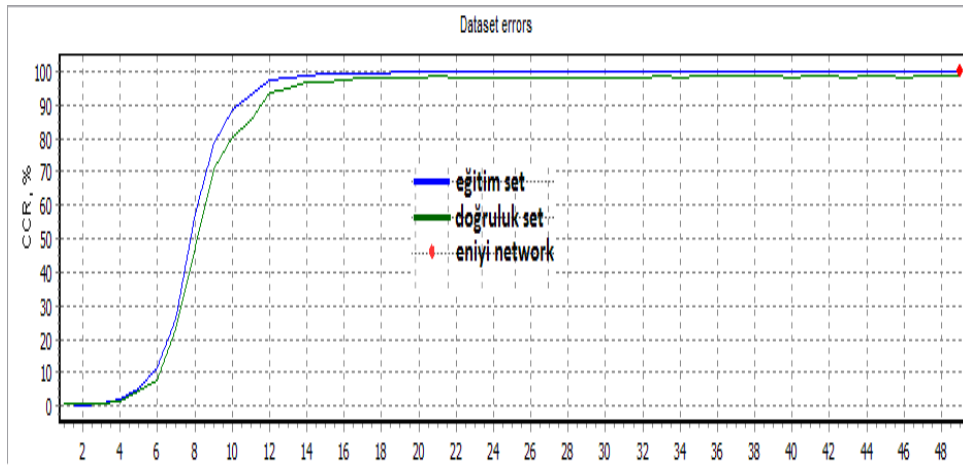
**Tablo 7.2** YSA eğitim sonuç karşılaştırma tablosu

		İterasyon Sayısı	Süre (sa:dk:sn)	Doğru Sınıflandırma Oranı (%)		
				Eğitim	Doğrulama	Test
<b>Hızlı Yayılım</b>	<b>Lojistik</b>	318	00:02:49	100	98,37	100
		49	00:00:33	100	98,37	96,73
	<b>Tanh</b>	307	00:02:42	100	97,29	98,91
		48	00:00:26	100	98,37	98,91
<b>Online Geriyayılım</b>	<b>Lojistik</b>	196	00:02:23	100	97,83	98,91
		182	00:02:10	100	98,92	97,82
	<b>Tanh</b>	204	00:02:25	100	97,83	98,91
		152	00:01:43	100	95,13	96,73
<b>Yığın Geriyayılım</b>	<b>Lojistik</b>	6009	01:09:42	100	98,92	100
		2008	00:21:59	100	98,92	100
	<b>Tanh</b>	3231	00:28:23	100	98,92	100
		1011	00:13:28	100	98,92	100


Tablodan da anlaşılacağı üzere yığın geriyayılım öğrenme algoritması test aşamasında hem lojistik hem de tanjant hiperbolik aktivasyon fonksiyonu için %100 doğru sınıflandırma oranlarıyla en iyi sonuçları vermiştir. Ancak yığın geriyayılım öğrenme algoritmasında iterasyon sayıları ve eğitim tamamlama süreleri oldukça yüksektir. Genel anlamda tüm öğrenme algoritmaları için lojistik aktivasyon fonksiyonunun daha iyi sonuç verdiği gözlenmiştir. Şekil 7.5-7.7’de hızlı, online ve yığın geriyayılım öğrenme algoritmasına ait MSE-İterasyon grafikleri verilmiştir.



Şekil 7.5 Yığın geriyayılım öğrenme algoritması MSE-iterasyon grafiği



Şekil 7.6 Hızlı yayılım öğrenme algoritması MSE-iterasyon grafiği



Şekil 7.7 Online geriyayılım öğrenme algoritması MSE-iterasyon grafiği

## 8.SONUÇLAR VE TARTIŞMA

Dünyada, teknolojinin getirmiş olduğu yenilikleri kullanan insanoğlu, birçok alanda gelişim gösteren güvenlik sistemlerinin yetersiz kalması sonucunda, daha yeni ve güvenilirliği yüksek teknolojilerin arayışı içerisine girmiştir. Teknoloji ilerledikçe yeni güvenlik açıkları gündeme gelmiştir. Güvenlik alanında birçok gelişme sağlanmış, fakat hep yetersiz kalmıştır. Bu sebeple biyometrik güvenlik sistemleri kullanılmaya başlanmıştır. Parmak izi, yüz tanıma, iris tanıma gibi güvenlik sistemleri günümüzde birçok alanda yerini bulmuştur. Fakat bu sistemlerin her birinin farklı açıkları bulunmaktadır. Örneğin parmak izi deseninin kopyalanabilir olması, yüz tanımada zamana bağlı olarak değişimlerin yaşanması veya bıyık-sakal gibi farklılıkların tanımayı negatif yönde etkilemesi, retina tanımda insanların gözlerine zarar gelmesi ihtimalinin olduğunu düşünmesi sebebiyle görüntü vermek istememesi gibi bir çok dezavantaj bu biyometrik özellikleri kullanan sistemlerin tercih edilmesini azaltmaktadır. Bu dezavantajların ortadan kaldırılması için yeni biyometrik tekniklerin araştırılması gündeme gelmektedir.

Bu çalışmada, el damar desenini kullanan bir biyometrik tanıma sistemi tasarlanmıştır. El damar deseninin tercih edilmesinin bir kaç sebebi vardır. En önemlisi el damar deseninin deri altında olması sebebiyle kopyalanamamasıdır. Ayrıca görüntünün alınması işlemi çok kolaydır ve kısa sürede alınabilir. Damar tanıma sistemlerinde çoğunlukla el ve parmaklarda yer alan damarlar kullanılmaktadır. Yapılan damar tanıma çalışmalarının bir kısmı işaret parmağında yer alan damar desenini kullanmaktadır. İşaret parmağında yer alan damarlar birbirine çok yakın yapıda kılcal damarlar içermektedir. Dolayısıyla damar deseninin elde edilmesi zordur ve birbirine benzeme oranı yüksektir. Bu da sistemin güvenilirliğini azaltmaktadır. Bir diğer damar tanıma çeşidi olan avuç içi damarlarının kullanılması üzerine de birçok çalışma yapılmıştır. Ellerin üstünde yer alan ağaç şekilli bu damarlar bir bireyin kimliğini tespit edebilecek geniş kapasiteli bilgiler içermektedir.

Bu çalışmada yakın kızılötesi monokrom kamera ile insan elinin üst bölgesinden görüntü alınmaktadır. Alınan görüntüden deri altında bulunan damarların şeklinin veya deseninin elde edilmesi amaçlanmıştır. Yapılan deneysel çalışmalarda görülmüştür ki,

elin yumruk şekline getirilmesi el üstünde yer alan damarların çok daha belirgin olarak alınmasını sağlamıştır. Bununla birlikte damar deseni içeren bölgenin doğru bir şekilde tespit edilmesi amacıyla referans noktası kullanılması düşünülmüş ve bu amaçla elin yerleşeceği çivi çubuklar tabla üzerine monte edilmiştir.

Alınan el görüntüleri incelendiğinde özellikle erkek deneklerde damar yollarının etrafında birçok kılın yer aldığı görülmüştür. Bununla birlikte yaşlı deneklerden alınan el görüntülerinde kırışıklıkların olduğu gözlenmiştir. Bu tür görüntülerin giderilmesi amacıyla görüntü işlemede kullanılan çeşitli filtre teknikleri uygulanmıştır. Deneysel çalışmalar sonucu 3x3 boyutlu maske kullanan ortalama filtre yönteminin bu tür görüntülerin yok edilmesinde en iyi sonuç verdiği gözlenmiştir. Bununla birlikte kontrast farklılıklarının azaltılıp damar yollarının daha belirgin hale getirilmesi amacıyla görüntüye histogram eşitleme işlemi uygulanmıştır. Histogram eşitleme sonucunda ışıklandırma kaynaklı oluşabilecek parlaklık değişimlerinin yok edildiği gözlenmiştir. Literatür araştırmasında görülmüştür ki Otsu algoritması desen çıkarmada en etkili yöntemlerden biridir. Bundan dolayı, el-damar görüntüsünde, damar yollarının desen şeklinde ortaya çıkmasını sağlamak amacı ile Otsu Kenar Bulma Algoritması kullanılmış ve başarılı sonuçlar verdiği görülmüştür.

Elde edilen el damar deseni görüntüsünün YSA ile tanınması amacıyla görüntünün sayısallaştırılması işlemi yapılmıştır. Bu amaçla çeşitli öznelik çıkarma tekniği araştırılmış, konu ile ilgili literatür taraması yapılmış ve ortalama mutlak sapma yöntemi tercih edilmiştir. Bu yöntemin uygulanması oldukça basittir ve etkili sonuçlar vermektedir. El damar görüntüsünde yer alan tüm piksellerin gri seviye değerleri boyut olarak çok büyük olduğundan YSA'na giriş olarak verilmesi hesaplamayı zorlaştıracaktır. Bundan dolayı resim 20x20 boyutlarda kare şeklinde alt görüntülere ayrılmış ve her alt görüntüye ortalama mutlak sapma işlemi uygulanmıştır. İşlem sonucunda 108 adet 0-1 aralığında veri kümeleri elde edilmiştir. Bu veri kümeleri YSA'na giriş olarak verilmiş ve tanıma işlemine geçilmiştir.

Tanıma amacıyla kullanılan YSA mimarisi, literatürde en çok karşılaşılan ileri beslemeli geri dönüşümlü çok katmanlı perseptron yapısına sahiptir. Gizli katman nöron sayısı ve öğrenme katsayısı deneme yanılma yoluyla belirlenmiştir. Kullanılan aktivasyon fonksiyonu lojistik ve hiperbolik tanjant fonksiyonudur. Çalışmamızda üç

farklı öğrenme algoritması kullanılmıştır. Bunlar; hızlı geriyayılım, online geriyayılım ve yığın geriyayılım algoritmalarıdır.

Bu tez çalışmasında el damar deseninin tespiti için 103 kişiye ait 927 el damar desen verisi kullanılmıştır. Dolayısıyla her bir kişiden 9 adet örnek el görüntüsü alınmıştır. Bu örneklerden %70'i eğitim,%20'si doğrulama ve kalan %10'u test için seçilmiştir. Eğitim ve test işlemleri iki farklı veri kümesi ile gerçekleştirilmiştir. Bunun sebebi rastgele seçilen veri kümelerinin farklı sonuçlar verebileceği ihtimalidir. Eğitim, doğrulama ve test girişlerinin seçim işlemi rastgele olarak yapılmıştır.

Yapılan deneysel çalışmaların sonucunda, el damar deseni kullanan bir biyometrik tanıma sisteminin, oldukça yüksek doğrulama oranı ile tanıma gerçekleştirdiği görülmektedir. Bu da, el damar deseninin yüksek ayırt edici özelliklere sahip olduğunu göstermektedir. Ayrıca geliştirilen damar tanıma sisteminin, 103 kişi gibi çok sayıda görüntü için %100 gibi tanıma oranına ulaşması sistemin yüksek başarısını göstermektedir. En iyi doğru sınıflandırma oranları yığın geriyayılım öğrenme algoritmasında elde edilmiştir. Ancak yığın geriyayılım öğrenme algoritması çok yüksek iterasyon sayısında ve uzun sürelerde eğitimi tamamlamıştır. Hem lojistik hem de tanjant hiperbolik aktivasyon fonksiyonlarında yakın doğrulama oranları elde edilmiştir.

İleriye yönelik el damar deseni çalışmalarında yapılabilecek uygulamalar şu şekilde sıralanabilir:

- El görüntüsü alınacak kişi sayısı artırılarak performans ölçümleri karşılaştırılabilir.
- Her denekten alınan görüntü sayısı yükseltilecek (örneğin her kişiye ait 30-40 adet örnek resim) sistemin eğitim süreleri ve doğrulama oranlarına bakılabilir.
- Farklı YSA mimarileri üzerinde sınıflandırma oranlarına bakılarak en iyi mimari belirlenebilir. Ayrıca mimari içerisinde gizli katman sayısı, eğitim parametreleri ve değişik öğrenme algoritmaları deneyerek performans değerlendirmeleri yapılabilir.
- Çeşitli öznitelik çıkarma teknikleri uygulanarak tanıma oranları analiz edilebilir.

Bununla birlikte görüntünün alınması için kullanılan yakın kızılötesi kamera yerine termal kamera kullanılması da sistemin güvenilirliğini artıracak bir öneri olarak sunulabilir. Ayrıca farklı sıcaklıklarda görüntülerin alınıp analiz edilmesi de damar tanıma sistemlerinde önemlidir. Örneğin, gerçek zamanlı uygulamalarda damar tanıma cihazı bina dışına yerleştirilebilir ve sıcaklığın düşük veya yüksek olması damar yollarının görüntülenmesini etkiler. Dolayısıyla bu tür farklı çevresel durumların analiz edilmesi damar tanıma sistemleri açısından faydalı olacaktır.

**KAYNAKLAR**

- Allahverdi, N. 2002. Uzman Sistemler Bir Yapay Zeka Uygulaması, Atlas Yayın Dağıtım, İstanbul.
- Anthony, M., & Bartlett, P. (1999). Neural network learning: Theoretical foundations. Cambridge University Press.
- Badawi A.M., 2007 “Hand Vein Biometric Verification Prototype:A Testing Performance and Patterns Similarity”, Biomedical Engineering Department,University of Tennessee, Knoxville, TN, USA
- Bertsekas, D. P. (1995). Dynamic Programming and Optimal Control, volume 1. Athena Scientific, Belmont, MA.
- Bertsekas D.P., Tsitsiklis J.N., Neuro-Dynamic Programming. Belmont, MA.: Athena Scientific. 1996.
- Biometrics Catalog, <http://www.biometricscatalog.org>, [26.08.2010]
- Bishop, C.M. 1995. Neural Network for Pattern Recognition, Oxford University Pres, England.
- Bhattacharyya D., Das P., Kim T.-h., Bandyopadhyay S.K,” Vascular Pattern Analysis towards Pervasive Palm Vein Authentication” Journal of Universal Computer Science, vol. 15, no. 5 (2009)
- Bishop, C.M. 1995. Neural Network for Pattern Recognition, Oxford University Pres, England.
- Boers, E.J.W. and Kuiper, H. 1992. Biological metaphors and the design of modular artificial neural networks, Master thesis, Departments of Computer Science and Experimental and Theoretical Psychology at Leiden University, the Netherlands.
- Bolle, R. M., Connell J. H., Pankanti S., Ratha N. K. and Andrew W. S. 2004. Guide To Biometrics, Springer-Verlag New York, Inc.
- Breiman, L. 1994. Heuristics of instability in model selection. Technical Report Statistics Department, University of California at Berkeley.
- Burge, M.J. and Burger, W. 2000. Ear biometrics in computer vision. Proceedings of the International Conference on Pattern Recognition, pp. 826-830.
- Campbell, J. 1999. Speaker Recognition. Biometrics: Personal Identification in Networked Society, pp. 165-190, Kluwer Academic Pres, Boston, MA.

- Chiang, C-C. and Fu, H-C. 1994. Divide-and-conquer methodology for modular supervised neural network design. In: Proceedings of the 1994 IEEE International Conference on Neural Networks. Part 1 (of 7). pp. 119-124. Orlando, FL, USA.
- Chung, L., Nixon, B., A., Yu, E., & Mylopoulos, J. (2000). Non-functional requirements in software engineering. Boston: Kluwer Academic.
- Cross J. M. and Smith C. L., “Thermographic imaging of the subcutaneous vascular network of the back of the hand for biometric identification”, Proceedings of 29th International Carnahan Conference on Security Technology, Institute of Electrical and Electronics Engineers, 20–35, 1995.
- Curram S.P., Minger J., 1994, Neural Networks, Decision .Tree Induction and Discriminant Analysis: Embrical Comprasion, p.441
- Dickinson, A., McPherson, R., Mendis, S., and Ross, P.C. 2000. Capacitive Fingerprint Sensor with Adjustable Gain, US Patent 6049620.
- Dodd, N. 1990. Optimization of network structure using genetic algorithms. Proceedings of the International Neural Network Conference, INNC-90-Paris, 693-696, B. Widrow and B. Angeniol (Eds.), Kluwer, Dordrecht.
- Doctus,2010, <http://www.doctus.org>, [Erişim Tarihi:26.08.2010]
- Elmas, Ç. (2003). Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama). Ankara: Seçkin Yayıncılık.
- Fahlman, S.E. 1988. An empirical study of learning speed in back-propagation networks. Technical report, Carnegie Mellon University.
- Fausett, L.V. 1994. Fundamentals of Neural Networks: Architectures, Algorithms And Applications, Prentice Hall Publ.
- Fine, T. L. 1999. Feedforward Neural Network Methodology. Springer, New York.
- Freeman, J., and Skapura, D. 1991. Neural Networks. Reading MA: Addison-Wesley Publ.
- Furui, S. 1997. Recent advances in speaker recognition. Audio and video- based Biometric Person Authentication, LNCS volume 1206, pp. 237-252, Germany.
- Golden, R.M., 1996. Mathematical Methods for Neural Network Analysis and Design. MIT Press, Cambridge
- Görüntüişleme,2010, <http://www.goruntuisleme.org> [Erişim Tarihi: 26.08.2010]
- Happel, B.L.M. 1992. Architecture and function of neural networks: designing modular architectures. In prep.

- Han, J. and Kamber, M. 2000. *Data Mining: Concepts and Techniques*, Morgan Kaufmann Publishers.
- Haykin, S. 1999. *Neural Networks A Comprehensive Foundation*, Prentice Hall publishing, New Jersey.
- Hebb, D.O. 1949. *The Organization of Behaviour: A Neuropsychological Theory*, New York: Wiley.
- Hill, R. 1999. Retina Identification. *Biometrics: Personal Identification in Networked Society*, pp. 123-142, Kluwer Academic Pres, Boston.
- Hong, L. and Jain A.K. 1998. Integrating Faces and Fingerprints for Personal Identification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, no. 12, pp. 1295-1307.
- Hopfield, J.J. 1982. Neural Networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences, USA*, vol. 79, pp. 2254-2258.
- Huang D.-S., Li K., and Irwin G.W. (Eds.), "Feature Extraction of Hand-Vein Patterns Based on Ridgelet Transform and Local Interconnection Structure Neural Network", *ICIC 2006, LNCIS 345*, pp. 870 – 875, 2006. Institute of Mathematics, Jilin University South Campus, 130012 Changchun, China
- Inglis, C., Manchanda, L., Comizzoll, R., Dickinson, A., Martin, E., Mandis, S., Silveman, P., Weber, G., Ackland, B., and O'Gorman, L. 1998. A Robust, 1.8 V, 250 mW, Direct Contact 500 dpi Fingerprint Sensor. *Proc. of IEEE Solid-State Circuits Conf*, pp. 284-285.
- Jain, L.C., Halici U., Hayashi I., and Lee S.B. 1999a. *Intelligent Biometric Techniques in Fingerprint and Face Recognition*, CRC Press, Boca Raton, FL.
- Jain, A. K., Ross, A., and Pankanti, S. 1999b. A Prototype Hand Geometry-Based Verification System. *2nd International Conference on Audio- and Video-based Biometric Person Authentication*, Washington D.C., pp. 166-171, March 22-24.
- Kim, K.K., Kim, K.I., Kim, J.B. and Kim, H.J., 2000, *Neural Networks for Signal Processing X*, 2000. *Proceedings of the 2000 IEEE Signal Processing Society Workshop*, Sydney, Vol. 2, 614-623.
- Kitano, H. 1990. Designing neural networks using genetic algorithms with graph generation system. *Complex Systems*, 4, 461-476, Champaign, IL.
- Kohonen, T. 1982. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, vol. 43, pp. 59-69.

- Kumar, A. and K.V. Prathyusha, 2009. Personal authentication using hand vein triangulation and knuckle shape. *IEEE Trans. Image Process.*, 18: 2127-2136.
- Kyun S. Im, Hyung-Man Park, Young-Woo Kim, Sang-Chan Han, Soo-Won Kim, Chul-Hee Kang and Chang-Kyung Chung, "An Biometric identification system by extracting hand vein patterns", *Journal of the Korean Physical Society*, 38(3): 268-272, March 2001.
- Lee, J.W., Min, P.I., Kim, I. and Kim, W. 1999. A 600 dpi Capacitive Fingerprint Sensor Chip and Image Synthesis Technique. *IEEE Journal of Solid-State Circuits*, vol. 34, no. 4, pp. 469-475.
- Lin C.L, K.C. Fan, "Biometric verification using thermal images of palm-dorsa vein patterns", *IEEE Trans Circuits Sys Video Tech*, 14(2): 199-213, Feb. 2004.
- Ma, L., Wang Y. and Tan T. 2002a. Iris recognition based on Multichannel Gabor Filtering, *The 5th Asian Conference on Computer Vision*, Australia.
- Ma, L., Wang, Y. And Tan, T. 2002b. Iris recognition using circular symmetric filters, *16th International Conf. on Pattern Recognition*, vol. II, pp. 414-417.
- Mira, J. and Mayer, J. 2003. Image Feature Extraction for Application of Biometric Identification of Iris – A morphological Approach. *Proc. of 16rd Brazilian Symposium on Computer Graphics and Image Processing*, Brasil.
- Miura N., 2004, "Feature extraction of finger-vein patterns based on repeated line tracking and its application to personal identification", *Machine Vision and Applications*, 25: 194-203.
- Moallemi C. (1991), 'Classifying Cells for Cancer Diagnosis using Neural Networks'. *IEEE Expert*, 8-12.
- Mohamed Shahin, Ahmed Badawi, and Mohamed Kamel, "Biometric Authentication Using Fast Correlation of Near Infrared Hand Vein Patterns", *International Journal of Biological and Medical Sciences*, vol 2, No.1, winter 2007, pp. 141-148.
- McClelland, J. L., Rumelhart, D. E., the PDP Research Group. (1986). *Parallel distributed processing: Explorations in the microstructure of cognition (Vol. 2, Psychological and biological models)*. Cambridge, MA:MIT Press.
- McCulloch, W. S. and Pitts, W. H. 1943. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:115-133.
- Nabiyev, V., 2005, *Yapay Zeka Problemler – Yöntemler – Algoritma*, Seçkin Yay.

- Nabiyev, V., Yavuz, Z., 2005, Vücut Dilinin Bilgisayarda Yorumlanması ve Bilgisayarlı Dudak Okuma, 4. Uluslar arası İleri Teknolojiler Sempozyumu, Konya.
- Nalwa, V.S. 1997. Automatic on-line signature verification. Proc. of IEEE, 85 (2): 215-239.
- Nan, J., Zhiye, Z. and Liqun, R. 2003. Design of structural modular neural networks with genetic algorithm, *Advances in Engineering Software*, 34:17-24.
- National Research Council(NRC) 1996. The evaluation of forensic DNA evidence. Technical report, National Academy Press, Washington D.C.
- Nixon, M.S., Carter, J.N., Cunado, D., Huang, P.S, and Stevenage, S.V. 1999. Automatic gait recognition. *Biometrics: Personal Identification in Networked Society*, pp. 231-248. Kluwer Academic Press, Boston, MA.
- NLPR 2007, <http://www.nlpr.ia.ac.cn/english/irids/irisdatabase.htm>, Son erişim tarihi: 13.03.2007
- Otsu, N., 1979. A threshold selection method from gray level histograms, *IEEE Transactions on Systems, Man, and Cybernetics*, 62-66.
- Öztemel, E. 2003. *Yapay Sinir Ağları*, Papatya Yayınevi, İstanbul.
- Özbay, Y., Karlık B. 2001. A Recognition of ECG Arrhythmia Using Artificial Neural Networks. 23rd Annual International Conference IEEE Engineering in Medicine and Biology Society, Istanbul, Turkey.
- Parker, D. B. (1985). *Learning-logic*. Technical Report TR-47, Center for Comp. Research in Economics and Management Sci., MIT.
- Prokoski, F.J. and Riedel, R. 1999. Infrared identification of faces and body parts. *Biometrics: Personal Identification in Networked Society*, pp. 191-212, Kluwer Academic Pres, Boston.
- R.I.T, 2010, <http://ce.rit.edu>, [26.08.2010]
- Robert J. Schalkoff, "Pattern Recognition: Statistical, Structural and Neural Approaches", John Wiley & Sons, 1992.
- Rosenblatt, F. 1958. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65:386-408.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. 1986. Learning representations by back-propagating errors. *Nature*, 323:533—536.
- Sağiroğlu, Ş., Beşdok, E. ve Erler, M. 2003. *Mühendislikte Yapay Zeka Uygulamaları-1 Yapay Sinir Ağları*, Ufuk Yayıncılık, Kayseri.

- Sang-Kyun Im, Hyung-Man Park, Young-Woo Kim, Sang-Chan Han, Soo-Won Kim and Chul-Hee Kang “Improved Vein Pattern Extracting Algorithm and Its Implementation” in Journal of the Korean Physical Society, 38/3/pp. 268-272 (2001).
- Saraç T.,2004,Yapay Sinir Ağları, Gazi Üniversitesi, endüstri mühendisliği bölümü
- Schwarz, G. 1978. Estimating the Dimension of a Model. The Annals of Statistics, 6, 2, 461-464.
- Sebastian,L. and G. Albano, 2003. Hand veins segmentation and matching under adverse conditions. Proc. SPIE, 5119: 166-177.
- Septimiu C., Ioan G.T., Titus E. C.,” Vein pattern recognition. Image enhancement and feature extraction algorithms.” Department of Electrical Measurement, Faculty of Electrical Engineering, Technical University of Cluj-Napoca, Str.C.Daicoviciu nr.15, 400020 Cluj-Napoca, Romania
- Siemens, 2010, <http://www.siemens.com.tr>, [Erişim Tarihi:26.08.2010]
- Shi Zhao, Yiding Wang and Yunhong Wang, “Extracting Hand Vein Patterns from Low-Quality Images: A New Biometric Technique Using Low-Cost Devices”, Fourth International Conference on Image and Graphics, 2007.
- Soni M., Gupta S., Gupta P.,2010, International Journal of Computer Science and Information Security, Vol. 8, No. 1
- Srihari, S.N., Cha, S., Arora, H. and Lee, S. 2002. Individuality of handwriting. Journal of Forensic Sciences, 47(4): 1-17.
- Syed, Y.A. and Sarfraz, M., 2005, Information Visualisation, 2005. Proceedings. Ninth International Conference, Issue Date : 6-8 July 2005, 227-232.
- Tan H.C. and Chen H., 2008, Machine Learning and Cybernetics, 2008 International Conference, Kunming, Vol. 7, 4034-4039.
- The Lab Book Pages, 2010, <http://www.labbookpages.co.uk>, [Erişim Tarihi:27.08.2010]
- Toshiyuki Tanaka , Kubo N., ”Biometric authentication by hand vein patterns” SICE, Annual Conference in Sapporo, 249-253, Aug. 2004.
- Tsitsiklis JN, Van Roy B. Feature-based methods for large scale dynamic programming. Machine Learning. 1996;22:59–94.
- Tsitsiklis JN, Van Roy B. An analysis of temporal-difference learning with function approximation. IEEE Transactions on Automatic Control. 1997;42(5):674–690.
- Türkoğlu, İ., Arslan, A. 1996. Yapay Sinir Ağları ile Bozuk Örüntü Tanıma, F.Ü. Fen ve Mühendislik Bilimleri Dergisi, 8, 147 – 158.

- Uludag, U., Günsel, B., and Ballan M. 2001. A spatial method for watermarking of fingerprint images. Proc. First Intl. Workshop on Pattern Recognition in Information Systems, Setúbal, Portugal, pp. 26-33.
- Quan J., Shuhai Q., Ying S. and Zhihua X., 2009, Image and Signal Processing, 2009. CISP '09. 2nd International Congress, Tianjin, 1-6.
- Watanabe M., Endoh T., Shiohara M., Sasaki S., "Palm vein authentication technology and its applications", Fujitsu Laboratories Ltd., 1-1, Kamikodanaka 4-chome, Nakahara-ku, Kawasaki, 211-8588, Japan
- Wang L., Leedham G., "A Thermal Hand Vein Pattern Verification System", School of Computer Engineering, Nanyang Technological University, N4-#2A-32 Nanyang Avenue, Singapore 639798 (2005).
- Wang L., Leedham G., Cho D. Siu-Yeung, "Minutiae feature analysis for infrared hand vein pattern biometrics" in Pattern Recognition 41/3/pp.920-929 (2008).
- Wei W., Li Y., Wang M. and Huang Z., 2001, Neural Networks for Signal Processing XI, 2001. Proceedings of the 2001 IEEE Signal Processing Society Workshop, North Falmouth, 529 - 538.
- Werbos, P. J. (1974). Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. PhD thesis, Harvard University.
- Widrow, B. And Hoff, M.E. 1960. Adaptive switching circuits. IRE WESCON Convention record, pp. 96-104.
- Wildes, R.P. 1997. Iris Recognition: An Emerging Bionetric Technology. Proceedings of the IEEE Vol. 85 No. 9.
- Wildes, R. P., Asmuth J. C., Green G. L., Hsu S. C., Kolczynski R. J., Matey J. R., Matey J. R. and McBride S. E. 1992. Iris recognition for security access control: Final report. National Information Display Laboratory, Princeton, NJ.
- Wildes, R., Asmuth, J., Green, G., Hsu, S., Kolczynski, R., Matey, J., McBride. S. 1994. A system for automated iris recognition. Proceedings IEEE Workshop on Applications of Computer Vision, Sarasota, FL, pp. 121-128.
- Wildes, R. P., Asmuth J. C., Green G. L., Hsu S. C., Kolczynski R. J., Matey J. R., and McBride S. E. 1996. A machine vision system for iris recognition. Mach. Vision Applicat., vol. 9, pp. 1-8.
- Wikipedia, 2010, <http://www.wikipedia.org>, [Erişim Tarihi:26.08.2010]
- Wu, J.D. and S.H. Ye, 2009. Driver identification using finger-vein patterns with Radon transform and neural network. Expert Syst, Appl., 36: 5793-5799.

- Yuhang D., Zhuang D., Wang K., 2005, "A Study of Hand Vein Recognition Method",  
The IEEE International Conference on Mechatronics & Automation Niagara Falls,  
Canada.
- Yüksel, A. Akarun, L. Sankur B., 2010, El Damar Örüntüleriyle Biyometrik Tanıma,  
Bilgisayar Mühendisliği Bölümü, Boğaziçi Üniv., İstanbul.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Hasan TUTUMLU  
**Uyruđu** : T.C  
**Dođum Yeri ve Tarihi** : Bozkır 1976  
**Telefon** : 532 270 75 06  
**Faks** : 332 426 14 44  
**e-mail** : htutumlu@selcuk.edu.tr

### EĐİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Bozkır Lisesi,Bozkır,Konya	1994
Üniversite	: Dumlupınar Ün.v. Elektrik-Elektronik Müh., Kütahya	2000
Yüksek Lisans :		
Doktora :		

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2000	Selçuk Üniversitesi	Öğretim Görevlisi

### UZMANLIK ALANI

Telekomünikasyon, Fiber Optik, Otomasyon(PLC), İşletim Sistemleri, Web Tasarımı, İnternet Programcılığı, Grafik Animasyon, Görüntü İşleme

### YABANCI DİLLER

İngilizce