

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

**PNN VE SVM KULLANARAK DWT TABANLI YÜZ
TANIMA**

YÜKSEK LİSANS TEZİ

Turhan R. BUNJAKU

**Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**

Tez Danışmanı : Yrd. Doç. Dr. Serap KAZAN

Şubat 2014

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

PNN VE SVM KULLANARAK DWT TABANLI YÜZ
TANIMA


YÜKSEK LİSANS TEZİ

Turhan R. BUNJAKU

Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ

Bu tez 24/02/14 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.


Doç.Dr. Cemil Öz
Jüri Başkanı


Yrd. Doç. Dr. Serap Katan
Üye


Doç.Dr. Yılmaz UYAROĞLU
Üye

TEŐEKKÜR

Tez alıŐmalarım sűresince, bana danıŐmanlık ederek, beni yűnlendiren ve her tűrlű olanađı sađlayan danıŐmanım Yrd. Do. Dr. Serap KAZAN'a teŐekkűrlerimi sunarım.

Őzellikle hayatım boyunca benim her zaman yanımnda bulunan ve bana eđitimimde ve baŐarılarımnda bu seviyeye gelmeme destek olan Babama ve Anneme en iten ve en samimi minnet borcu duygularım ile...

İÇİNDEKİLER

TEŞEKKÜR.....	ii
İÇİNDEKİLER	iii
SİMGELER VE KISALTMALAR LİSTESİ.....	vi
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	x
ÖZET.....	xi
SUMMARY	xii
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
BİLGİSAYAR GÖRMESİ VE ÖRÜNTÜ TANIMA.....	6
2.1. Bilgisayar Görmesi	6
2.2. Görüntü İşleme.....	7
2.3. İnsan Görme Sistemi.....	9
2.4. Görüntü Gösterimi	10
2.4.1. İkili görüntüler	10
2.4.2. Gri-skala görüntüleri	10
2.4.3. Renkli görüntüler	12
2.4.4. Çoklu tayfsal görüntüler	13
2.5. Örüntü Tanıma	13
2.5.1. Örüntü tanıma sistemleri.....	17
2.5.2. Tasarım döngüsü	18

BÖLÜM 3.

YÜZ TANIMA İŞLEMİNDE KULLANILAN YÖNTEMLER	20
3.1. Yüz Tanıma	20
3.1.1. Genel bir yüz tanıma sisteminin çalışma akışı.....	20
3.1.2. Yüz tanıma sisteminde karşılaşılan zorluklar	23
3.2. Viola ve Jones Yüz Tespit Algoritması	25
3.2.1. Tümlevsel görüntü	26
3.2.2. Öğrenme algoritması.....	28
3.2.3. Ardarda sıralı sınıflandırıcı	29
3.3. Ayrık Dalgacık Dönüşümü.....	32
3.4. Sınıflandırma İşleminde Kullanılan Yöntemler	34
3.4.1. Olasılıksal sinir ağı.....	35
3.4.1.1. Olasılıksal sinir ağı'nın tanımı ve matematiksel analizi .	35
3.4.1.2. Eğitime ve test etme	37
3.4.1.3. Uyarılama ve çalışma prensibi	38
3.4.1.4. Olasılıksal sinir ağı'nın avantajları ve dezavantajları	39
3.4.2. Destek vektör makineleri	39
3.4.2.1. Destek vektör makinelerinin tanımı	39
3.4.2.2. Destek vektör makinelerinin matematiksel analizi	41
3.4.2.3. Doğrusal ayrılabilen veriler için destek vektör makineleri	41
3.4.2.4. Doğrusal ayrılamayan veriler için destek vektör makineleri	45
3.4.2.5. Çekirdek (kernel) fonksiyonları	47
3.4.2.6. Çok sınıflı destek vektör makineleri	50
3.4.2.7. Destek vektör makinelerin avantajları ve dezavantajları	50

BÖLÜM 4.

PNN VE SVM KULLANILAN DWT TABANLI YÜZ TANIMA	52
4.1. Uygulamanın Gerçekleştirildiği Ortam.....	52
4.2. Geliştirilen Yüz Tanıma Sisteminin Çalışma Akışı ve Uygulamanın Gerçekleştirilmesi	53

4.3. Olasılıksal Sinir Ağı ve Destek Vektör Makinelerinin Başarı Performanslarının Karşılaştırılması	57
BÖLÜM 5.	
SONUÇLAR VE ÖNERİLER	60
KAYNAKLAR.....	63
ÖZGEÇMİŞ	68

SİMGELER VE KISALTMALAR LİSTESİ

TBA	: Temel Bileşenler Analizi
DAA	: Doğrusal Ayırtaç Analizi
ÇTBA	: Çekirdek Temel Bileşenler Analizi
ÇAA	: Çekirdek Ayırtaç Analizi
AKD	: Ayrık Kosinüs Dönüşümü
EÇE	: Esnek Çizge Eşleme
ARDB	: Antibiotic Resistance Genes Database
ORL	: Olivetti Research Laboratory
DNA	: Deoxyribonucleic acid (Deoksiribonükleik asit)
PET	: Pozitron Emisyon Tomografisi
BT	: Bilgisayarlı Tomografi
MRG	: Magnetik Rezonans Görüntüleme
nm	: Nanometre
bit	: Binary digit (ikili rakam)
byte	: 8 bitlik bir ünite
FAX	: Facsimile (Belgegeçer)
OCR	: Optical character recognition (Optik Karakter Tanımlamaları)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
CAT	: Computed Axial Tomography (Bilgisayarlı tomografi)
DWT	: Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
1-D	: 1-Dimension (1-Boyutlu)
2-D	: 2-Dimensions (2-Boyutlu)
HH	: High-High (Yüksek-Yüksek)
HL	: High-Low (Yüksek-Alçak)
LH	: Low-High (Alçak-Yüksek)
LL	: Low-Low (Alçak-Alçak)

PNN	: Probabilistic Neural Network (Olasılıksal Sinir Ađı)
ANN	: Artificial Neural Network (Yapay Sinir Ađları)
AI	: Artificial Intelligence (Yapay Zeka)
RTF	: Radyal Tabanlı Fonksiyon
YRM	: Yapısal Risk Minimizasyonu
PUK	: Pearson VII Kernel function (Pearson VII çekirdek fonksiyonu)
YSA	: Yapay Sinir Ađları
MATLAB	: Matrix Laboratory
GHz	: Gigahertz
RAM	: Random Access Memory (Rastgele Erişimli Hafıza)
GB	: Gigabyte
PCA	: Principal Component Analysis (Temel Bileşenler Analizi)
sn	: Saniye

ŞEKİLLER LİSTESİ

Şekil 2.1. Sayısal görüntünün yakalanması, gösterilmesi ve yorumlanması [23].....	8
Şekil 2.2. Siyah-beyaz görüntü.	11
Şekil 2.3. Sayısal görüntü piksellerinin ızgara şeklinde gösterilmesi [26].	12
Şekil 2.4. Örüntü tanıma kavramı [27].....	15
Şekil 2.5. Örnek el yazısı rakamları [21].	16
Şekil 2.6. Örüntü tanıma sistemlerinin çalışma akışı [28].	18
Şekil 2.7. Tasarım döngüsünün çalışma akışı [28].	19
Şekil 3.1. Genel bir yüz tanıma sisteminin çalışma akışı [30].	21
Şekil 3.2. Yüz görüntülerinin farklı durumları: (a) Orijinal yüz görüntüsü; (b) Oran değişmesi; (c) Oryantasyon değişmesi; (d) Aydınlatma değişmesi; (e) Ayrıntı bulunması [29].	25
Şekil 3.3. Dikdörtgen öznitelikler [32].	26
Şekil 3.4. Tümlevsel görüntünün (x, y) noktasındaki değeri [32].	27
Şekil 3.5. Tümlevsel görüntü değerinin hesaplanması [32].	27
Şekil 3.6. AdaBoost tarafından seçilen ilk iki öznitelik [32].	29
Şekil 3.7. Ardarda sıralı sınıflandırıcı [32].	29
Şekil 3.8. Dikdörtgen öznitelik çeşitlerinin farklı pozisyonlardaki prototipleri: (a) İki dikdörtgenli öznitelik; (a') İki dikdörtgenli özniteliğin tersi; (b) Üç dikdörtgenli öznitelik; (b') Üç dikdörtgenli özniteliğin tersi; (c) Dört dikdörtgenli öznitelik [37].	31
Şekil 3.9. İki seviyeli 1-D Ayrık Dalgacık Dönüşümü [38].	33
Şekil 3.10. İki seviyeli 1-D Ters Ayrık Dalgacık Dönüşümü [38].	33
Şekil 3.11. İki seviyeli 2-D Ayrık Dalgacık Dönüşümü [38].	33
Şekil 3.12. Bir görüntünün: (a) 1 seviyeli ve (b) 3 seviyeli ayrık dalgacık dönüşümündeki altbantları [39].	34
Şekil 3.13. Olasılıksal sinir ağı modeli [40].	36

Şekil 3.14. PNN sınıflandırıcısını uyarlama için algoritma [27].	38
Şekil 3.15. (a) İki sınıflı bir problem için hiper-düzlemler [44].	41
Şekil 3.15. (b) Optimum hiper-düzlem ve destek vektörleri [44].	42
Şekil 3.16. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi [44].	43
Şekil 3.17. (a) Doğrusal olarak ayrılamayan veri seti [44].	45
Şekil 3.17. (b) Doğrusal ayrılamayan veri setleri için hiper-düzlemin belirlenmesi [44].	46
Şekil 3.18. Çekirdek fonksiyonu ile verinin daha yüksek bir boyuta dönüştürülmesi [44].	47
Şekil 3.19. SVM için bire karşı hepsi örneği.	50
Şekil 4.1. Geliştirilen yüz tanıma sisteminin çalışma şeması.	54

TABLolar LİSTESİ

Tablo 3.1. Destek vektör makinelerinde kullanılan temel kernel fonksiyonları ve parametreleri [44].	48
Tablo 4.1. ORL veri tabanı örneđi.	53
Tablo 4.2. Kişilerden alınan görüntülerin Viola-Jones algoritması sonrası, Kesme işlemi sonrası, 1 seviyeli DWT sonrası, Küçültme işlemi sonrası, 3 seviyeli DWT sonrası görüntü değışiklikleri sonuçları.	56
Tablo 4.3. 1 seviyeli DWT uygulanması sonucu PNN ve SVM başarı performansları	58
Tablo 4.4. 3 seviyeli DWT uygulanması sonucu PNN ve SVM başarı performansları	58

ÖZET

Anahtar kelimeler: Yüz tanıma, Ayrık Dalgacık Dönüşümü, Olasılıksal Sinir Ağı ve Destek Vektör Makineleri.

Gelişen teknolojiyle birlikte insanların ihtiyaçlarının karşılanma oranı artmaktadır. Kişi ve kurumların güvenlik ihtiyacının karşılanması ile ilgili yöntemler de artmaktadır. Güvenlik ihtiyacının karşılanma yöntemlerinden birisi de biyometrik özelliklerin kullanılmasıdır. Göz retinası, parmak izi, imza, yüz, ses, DNA gibi özellikler biyometrik veri olarak kabul edilmektedir. Yüz tanıma, kişi tanımada kullanılan yaygın biyometrik yöntemlerden birisidir. Yüz tanıma, yapay görünün zorlu problemlerinden biridir. Bu çalışmada veri tabanından alınan gri seviyeli yüz görüntülerinin bilgisayar ile tanınması hızlı bir şekilde sağlanmaktadır. Bu sayede kişinin doğrulanması ve tanınması mümkün olmaktadır. Bu çalışmada, öncelikle görüntüdeki yüzler Viola-Jones (VJ) yöntemiyle tespit edilmiştir. Daha sonra tespit edilen yüzler öznitelik çıkarılması amacıyla Ayrık Dalgacık Dönüşümüne (DWT) tabi tutulmuştur. 3 seviyeli DWT işleminin sonucunda oluşan alçak frekans bölgesi, sınıflandırıcıların girişlerine gönderilmiştir. Bu çalışmada sınıflandırma için iki farklı yöntem kullanılmıştır. Birincisi; Olasılıksal Sinir Ağı (PNN) yöntemi, ikincisi ise Destek Vektör Makineleri (SVM) yöntemidir. Sonuçların yüzdelik performansları ile işlem süreleri tablolarla karşılaştırılmıştır. Yapılan uygulamalar sonucu Olasılıksal Sinir Ağı Yönteminin diğer yöntemlere göre daha iyi performans gösterdiği görülmüştür. Uygulama esnasında gri seviyeli görüntüler kullanılmıştır. Sisteme renkli görüntüler de uyarlanabilir.

DWT BASED FACE RECOGNITION USING PNN AND SVM

SUMMARY

Keywords: Face recognition, Discrete Wavelet Transform, Probabilistic Neural Network, Support Vector Machine.

The rate of satisfying the requirements of people have increased by development of technologies. Techniques for satisfying the needs of personal or institutional security are also increasing. In number one of the methods for ensuring the security needs are using biometric features. The features such as iris, fingerprint, signature, face, voice and DNA are utilized as biometric data. Face recognition is one of the commonly used biometric methods for person recognition. Nevertheless, one of the most difficult problems of artificial vision is face recognition. In this paper, the grey scale face image of the investigated person is searched among the face images in the database and matched using several techniques by means of computers. Through this way, it is possible to verify and recognize the person. In this study, first of all the faces within a picture are detected by Viola-Jones method. Then, the characteristics of detected faces are obtained by using Discrete Wavelet Transform (DWT) method. Low frequency zone which is obtained after the process of 3-Levels DWT is sent to the inputs of the classifiers. Herein, two different methods are used for classification. One of them is probabilistic neural network method and the other one is support vector machine method. The results of both methods are compared within tables according to performance percentage and process times. The results of the implementations indicate that probabilistic neural network method gives better performance than the other method. During the implementation grey scale images are used. Also, colored images can be adapted to the system.

BÖLÜM 1. GİRİŞ

İnsan yüzleri, insanların kimliklerini ve duygularını temsil ettikleri için insanların toplumsal dünyadaki hayatlarında oldukça önemli bir yere sahiptirler. İnsanların birbirlerinin yüzlerinde birbirlerine ait zeka, karakter, duygu ve düşünceleri algılamaları şüpheye açık, algılayanın yeteneklerine bağlı bir durum olsa da, insanların hemen hepsinin birbirlerinin yüzlerinde birbirlerinin kimliklerini algılayabiliyor olması gayet net ve tartışmasız bir gerçektir. İnsanlar hayatları boyunca binlerce yüz ile karşılaşır ve bu yüzleri öğrenirler ve öğrendikleri bu yüzleri aradan yıllarca zaman geçmiş olmasına rağmen hala tanıyabilirler. İnsanın bu yeteneği öylesine gelişmiş bir yetenektir ki, yaşlanma, yüz ifadesi, gözlük, sakal, bıyık, saç şekli gibi insan yüzlerindeki görsel özelliklerin değişimi bile insanın yüz tanıma yeteneğini engelleyememektedir.

İnsanların günlük yaşamında, belirli bir sesi veya görüntüyü tanımak için kullandıkları kuralları tanımlamak mümkün değildir. İnsanların pratikte karşılaştıkları bu örüntü tanıma olaylarını, makine tabanlı görüntü tanıma uygulamalarında belirli kriterlere oturtmak mümkündür.

Bu özelliklerden yararlanarak çokça gelişmelerin olduğu teknolojiyle paralel olarak kişi ve kurumların güvenlik ihtiyacının karşılanma yöntemleri de değişmektedir. Güvenliği artırmak için temel yöntemlerin yanında alternatif yöntemlere de ihtiyaç duyulmuştur. Her insanda birbirinden farklılık göstermesi nedeniyle güvenlik ihtiyacının karşılanma yöntemlerinden birisi de biyometrik özelliklerdir. Göz retinası, parmak izi, imza, yüz, ses, DNA gibi özellikler biyometrik veri olarak kabul edilmektedir. Biyometrik verilerin kaybedilme, unutulma ve çalınma risklerinin minimum düzeyde olması nedeniyle kişi ve kurumlar tarafından tercih edilmektedir [1].

Biyometrik sistemlerin karşılaştırılması yapıldığında parmak izi en yaygın ve eski olarak kullanılan bir biyometrik özellik olarak yer alır. Yaygın kullanım olarak ikinci sırada belli kullanım oranı ile yüz görüntüsü yer almaktadır [2]. Yüz tanıma diğer biyometriklerle karşılaştırıldığında farklılık ve performans açısından diğer biyometrik sistemlere göre düşük olsa da evrensellik, elde edilirlilik, kabul edilirlilik ve tuzağa düşürme bakımından yüksek niteliğe sahip olduğundan ikinci en fazla kullanılan biyometrik özellik olarak sıralanır [3]. Yüz tanıma başarılı biyometri uygulamalarından biridir.

Yüz tanıma, yapay görünün zorlu problemlerinden biridir. Yüz tanıma problemi statik veya video sahnesindeki bir ya da daha çok kişinin veritabanındaki yüzlerle karşılaştırılarak tanınması veya belirlenmesi olarak tanımlanmaktadır [4]. Yüz tanımanın kullanılabilceği pek çok alan bulunmaktadır. Bunlar kimlik saptama ve kimlik doğrulama şeklinde gruplandırılabilir. En yararlı olduğu uygulamalardan bazıları kalabalık izleme, video içerik indeksleme, kişisel kimlik (örneğin ehliyet) ve güvenlik olarak sıralanabilir. Son yıllarda askeri, ticari ve yasal uygulama alanlarının artması nedeniyle yüzlerin otomatik olarak tanınması çok popüler bir konu haline gelmiştir.

Yüz tanıma sistemlerinin performansını etkileyen poz açısı, ışıklandırma koşulları, yüz ifadesi, yaşlanma ve kapanma etkileri olarak gruplandırılabilcek 5 temel etmen bulunmaktadır. Yüz 3 boyutlu bir nesne olduğu için kullanılan açı görüntüde değişikliklere yol açmaktadır. Farklı ortamlarda alınan görüntülerde ışıklandırmanın farklılığı da alınan görüntüyü etkilemektedir. İnsanın o anki yüz ifadesi, kullandığı mimikler görüntüyü değiştirmektedir. Yaşlanma ya da kapanma olarak sayabileceğimiz gözlük, sakal, bıyık, baş örtüsü gibi yüzde kapanmalar da görüntüyü ve tanıma işlemini etkilemektedir [5].

Yüzlerin bilgisayarca tanınmasındaki pek çok çalışma, gözler, burun, ağız ve kafa planı gibi bireysel özellikleri algılama ve konum, büyüklük ve bu özellikler arasındaki ilişkiler ile bir yüzü tanımlama üzerine odaklanmıştır. Bu tür yaklaşımlar, çoklu görünümeleri genişletmek için zor olmuştur. Başarılı olması için başlangıçta iyi bir tahmin gerektirdiğinden dolayı çoğunlukla çok kırılğan olmuşlardır. Yüz tanımak

için insan stratejilerindeki arařtırmalarda, bireysel özellik iliřkileri yetişkin insan yüzü tanımlaması performansı için yetersiz bir temsil içerdii görülmüřtür. Yine de yüz tanınması ile ilgili bu yaklaşım bilgisayar görüş literatüründe en popüler olanıdır.

Günümüzde birçok yüz tanıma sistemi oluşturulmuş, veri tabanları için oldukça başarılı sonuçlar vermektedir. Yüz tanıma için kullanılan yöntemlerin başlıcaları; Temel Bileşenler Analizi (TBA) ile çıkarılan öz yüzler, Doğrusal Ayırtaç Analizi (DAA) ile üretilen fisher yüzler, Destek Vektör Makineleri, Çekirdek Temel Bileşenler Analizi (ÇTBA), Çekirdek Ayırtaç Analizi (ÇAA), Ayrık Kosinüs Dönüşümü (AKD), Esnek Çizge Eşleme (EÇE) olarak gösterilebilir. Bu alanda yapılan çalışmalardan bazıları aşağıda verilmiştir.

Yerel öznitelik tabanlı yüz tanıma sistemlerinde, tanıma başarımının artırılması için, yüzdeki belirgin noktaların bulunması gereklidir. Yüz tanımada kullanılan çoğu öznitelik çıkarımı algoritması her özniteliğin öneminin diğerlerinden bağımsızlığı ve öznitelik çıkarımının, yüzdeki göz, burun gibi organların belirli noktalarında yapılması varsayımına dayanır. Bu varsayımlar tanıma başarımını kısıtlamaktadır. Gökberk ve arkadaşları bu iki varsayımı gevşetmek için altküme seçim yöntemlerinin kullanıldığı çalışmalar yapmıştır [6].

Özdemir, ön cepheden çekilmiş insan yüzü görüntülerinin tanınmasında dalgacık dönüşümü kullanmıştır. Çalışma ile dalgacık dönüşümü yönteminin, görüntüye herhangi bir dönüşüm uygulanmaması durumuyla karşılaştırıldığında, doğru tanıma oranını artırırken tanıma süresini azalttığı gözlenmiştir [7,8].

Özkaya ve Sağırođlu tarafından sunulan çalışmada parmak izi, yüz, iris, retina ve el geometrisi gibi biyometrik özellikler arasında olabilecek herhangi bir ilişkinin varlığı tartışılmakta ve kişilerin yalnızca parmak izini kullanarak yüzlerini tahmin etmeye yönelik yapay sinir ađları temelli yeni ve zeki bir sistem tanıtılmaktadır [9].

Referans pikseller, görüntüdeki pikseller üzerinde kaydırılarak yüz bölgesinin bulunabilmesi için tüm görüntü taranır. Yüz olmayan yerlerin de taranması sebebiyle özellikle büyük boyutlu görüntülerde tarama zamanı çok fazla olabilir. Muhammad

ve arkadaşları yaptıkları çalışmada yüz algılama veya tanıma algoritmalarından önce bir ön-tarama kullanarak yüz olmayan veya yüze az benzer olan yerlerin elenerek tarama zamanının azaltılmasını amaçlamıştır [10].

Gümüş, yaptığı bir çalışmada özyüzler yöntemi için özyüz uzayı boyutunun, yapay sinir ağının saklı katmanındaki nöron sayısı ve eğitim hatasındaki değişimin ve kullanılan Kernel Fonksiyonlarının tanıma performansına etkilerini incelemiştir [11].

Ergezer, çalışmasında gerçek zamanlı yüz tanıma sistemlerinde kullanılabilirliğini test etmek amacı ile ARDB ve ORL veritabanında bu alanda yaygın algoritmalar olan öz yüzler, sinir ağları, Gabor dalgacık yöntemlerini kullanmıştır [12].

Anbarjafari, çalışmasında histogram eşleştirme tabanlı yeni bir yüz tanıma sistemi önermektedir. Önerilen sistem yüz görüntülerine ait farklı renk uzaylarında elde edilmiş histogramları tanıma işleminde öznitelik vektörleri olarak kullanmaktadır [13,14].

Gabor öznitelikleri tabanlı yaklaşımlar da yüz tanıma probleminin çözümünde kullanılmıştır. Kırtaç, Gabor öznitelik vektörlerine En Yakın Komşu Ayrışım Analizi uygulayarak yeni bir yüz tanıma sistemi önermiştir [15].

Topkaya, yüz tanıma problemini statik görüntüler yerine video görüntülerinde çalışmıştır. Sistem eğitiminde poz, açı ve dönme kısıtlaması olmadan yalnızca bir kişinin bulunduğu videolar kullanılmıştır. Tanıma işlemi de yine bir kişinin bulunduğu videolar üzerinden gerçekleşmiştir [16].

Yapılan bir başka çalışma ise haber videolarının etkin erişimi için, haberlerdeki en önemli öge olan kişilerin videolarda bulunmasına yönelik yüz bulma yöntemlerinin sistematik bir değerlendirmesidir [17].

Yapılan bazı çalışmalarda da yüz tanıma probleminin çözümü için alt uzay temelli yöntemler kullanılmıştır. Kern, Stiefelhamen ve diğerleri bu yöntemi çalışmalarına uygulamışlardır [18,19].

Bu tez çalışmasında, diğer çalışmalara farklı olarak Ayrık Dalgacık Dönüşümü tabanlı yüz tanıma işlemi gerçekleştirilmek için iki farklı sınıflandırma yöntemi kullanarak başarı performansları karşılaştırılıp değerlendirilmiştir. Bu yöntemlerden birincisi Olasılıksal Sinir Ağı; ikincisi ise Destek Vektör Makineleri yöntemidir.

Bu tezin amacı olasıksal sinir ağı ve destek vektör makinelerini kullanarak insan yüzünün bilgisayar ile tanınmasını hızlı bir şekilde sağlamaktır. Bu şekilde pek çok alanda kolaylıklar sağlanması, güvenlik sistemleri tarafından yüz tanıma ile kişisel bilgilere ulaşabilme daha kolay hale gelmesi amaçlanmıştır.

Bu tez çalışması beş bölümden oluşmaktadır. İkinci bölümde yapılan çalışmaya bağlı genel olarak bilgisayar görmesi, sayısal görüntü işleme ve örüntü tanıma konularından özel olarak bahsedilmiştir.

Üçüncü bölümde yüz tanıma bilgileri, görüntüleri dönüştürme işleminde kullanılan ayrık dalgacık dönüşümü, geliştirilen algoritmada kullanılan Viola-Jones yüz tespiti yöntemi ve geliştirilen algoritmanın başarı performansını ölçmek ve kıyaslamak için sınıflandırıcı olarak kullanılan olasıksal sinir ağı ve destek vektör makineleri geniş bir şekilde konu alınmıştır.

Dördüncü bölüm yapılan çalışmanın uygulama kısmını içerir. Bu bölümde geliştirilen algoritmanın çalışma sürecinde vermiş olduğu sonuçlara göre başarı performansı ve doğruluk oranı yüzdesel ve süre bakımından incelenmiş ve değerlendirilmiştir.

Beşinci bölüm yapılan uygulamanın sonuçlarını ve ileride geliştirilen algoritmanın performansını artıracak çalışmaların kısaca konu alındığı bir bölümdür.

BÖLÜM 2. BİLGİSAYAR GÖRMESİ VE ÖRÜNTÜ TANIMA

2.1. Bilgisayar Görmesi

Bilgisayar görmesi görsel çevrimde uygulamanın insanı kapsamadığı bilgisayar görüntülemesidir [20]. Diğer bir anlatımla görüntüler bilgisayar aracılığıyla incelenir ve değerlendirilir.

Görüntü analizi bir görüntü problemini çözmeye yardımcı olmak için görüntü verisinin incelenmesiyle ilgilenir. Görüntü analizi işlemi iki ayrı başlığı daha kapsar: Özellik çıkarımı ve örnek sınıflandırması. Özellik çıkarımı şekil veya renk bilgisi gibi yüksek seviyeli görüntü bilgisi elde etme işlemidir ve örnek sınıflandırması ise bu yüksek seviyeli bilgileri alıp görüntü içinde tanımlamaktır.

Bilgisayar görmesi en iyi değişik uygulamaların incelenmesiyle anlaşılabilir. Bu uygulamaların birçoğu insanlar tarafından uygulanması sıkıcı olan alışılmadık çevrede çalışmayı gerektiren yüksek işlem oranı veya geniş veri tabanının erişimi veya kullanımını gerektiren görevler içerir. Bilgisayar görüş sistemleri üretim sanayiinden hastane cerrahisine ve Mars yüzeyine kadar çok sayıda ve değişik alanlardaki uygulamalarda kullanılmaktadır. Örneğin üretim sisteminde bilgisayar görüş sistemi genellikle kalite kontrolde kullanılır. Burada bilgisayar görüş sistemi üretilmiş mamullerin hatalarını bulmak ve hatalı parçaları otomatik olarak elemek için robota sinyaller yollamak üzere sistemi tarar [21].

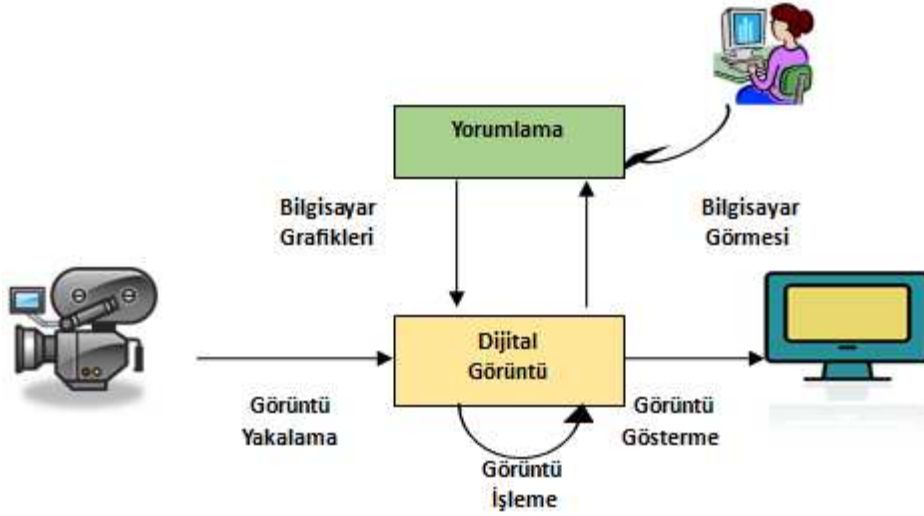
Bilgisayar görüş sistemi tıp alanında da birçok değişik kullanım imkanı bulmaktadır ve kesin olan şudur ki bu alandaki uygulama çeşitliliği gittikçe artmaktadır. Tıp alanındaki günümüz uygulamaları arasında; deri tümörlerinin otomatik olarak teşhis

edilmesini, beyin cerrahisinde nöro-cerrahiye yardımcı olan sistemleri ve klinik testleri otomatik olarak gerçekleyen sistemleri sayabiliriz. Sistemler ayrıca doku ve hücre analizinde de çoktan kullanıma geçmiştir. Örneğin belirli hücre çeşitlerinin tanımlanmasının ve sayımının gerektiği uygulamalarda kullanılmaktadırlar [22].

Kanun yürütülmesi ve güvenlik uygulamaları alanı, parmak izinin otomatik DNA analizi gibi uygulamalar da bilgisayar görüş sistemi için aktif bir alandır. İnsanları retinalarından tanımlamak, yüzlerinden tanımlamak ve elindeki damarlardan tanımlamak gibi uygulamalar geliştirilmiştir. Günümüzde otoyollarda bilgisayar görüş sistemleri hız yapanları tespit etmek için kullanılmaktadırlar. Gelecekte ise bilgisayar görüş sistemleri seyahat sistemimizi daha güvenli hale getirmek için tamamiyle otomatik bir kontrol sağlayabilir. Uygulamalar araçların otomasyonundan hedef takibi ve hedef tanımlanmasına kadar çeşitlilik göstermektedirler. Dünya yörüngesinde bulunan uydular her gün çok miktarda görüntü toplamaktadırlar ve bu görüntüler harita yapımında, hava tahmininde ve kendi gezegenimizde olan değişiklikleri anlamamıza yardımcı olmak üzere taranmaktadır.

2.2. Görüntü İşleme

Görüntü işleme görsel çevrimde insanoğlunu kapsayan uygulamaların bilgisayar görüntülemesidir. Görüntü işleme alanındaki ana başlıklar görüntü düzeltilmesi, görüntü iyileştirme ve görüntü sıkıştırmasıdır. Daha önce değinildiği gibi görüntü analizi genellikle görüntü işleme algoritmalarında ilk iş olarak kullanılır, fakat bilgisayar görüşü ve görüntü işlemedeki ana ayırım, çıkış görüntüsünün insan tarafından kullanılabilirliğidir [20]. Görüntü yakalama cihazları ile görüntü sayısallaştırılırken gerçek dünyadaki açılar, uzaklıklar, genellikle kalite kaybolmaktadır. Şekil 2.1’de sayısal görüntü işleme blok diyagramı gösterilmiştir.



Şekil 2.1. Sayısal görüntünün yakalanması, gösterilmesi ve yorumlanması [23].

Görüntü düzeltilmesi biraz bilinen ya da değeri olan ya da olmayan bir görüntüyü alıp orijinal görüntüsüne dönüştürmektir. Görüntü işleme genellikle fotoğrafçılıkta veya bir şekilde deforme olmuş ve basılması için iyileştirilmesi gereken görüntüleri kapsayan yayıncılıkta kullanılmaktadır.

Görüntü iyileştirme bir görüntüyü alarak onun görsel olarak kalitesinin artımını kapsamaktadır, tipik olarak insan görsel sisteminin karşılığının avantajını kullanmaktır. Görüntü iyileştirme tekniklerinden bir tanesi basitçe bir görüntünün kontrastının gerilmesidir. İyileştirme yöntemleri türe özgü yaklaşımlarda problem oluşturabilir. Örnek olarak uydusal bir görüntünün iyileştirilmesinde uygulanan bir yöntem tıp alanındaki bir görüntüde işe yaramayabilir. Amaç olarak görüntünün daha iyi görülmesi iyileştirmede ve düzeltmede aynı olsa da probleme yaklaşım biçimlerinde ayrılmaktadırlar.

Görüntü sıkıştırma bir görüntü betimlemek için gerekli olan çok miktardaki veriyi azaltmakla ilgilenir. Bu işlem görsel olarak gerekli olmayan ve her görüntünün doğasında bulunan boşluğun avantajı kullanılarak yapılır. Görüntü sıkıştırması her ne kadar bilgisayar görüş sistemlerinde kullanılsa da görüntü işlemenin problemidir. Çünkü yapılan işin büyük kısmı insanlar tarafından incelenecek görüntüleri sıkıştırmak istediğimiz alanda yapılır [20].

Tıp alanı görüntü işleme açısından genellikle değişik tiplerdeki teşhis uygulamasını kapsayan birçok önemli uygulamaya sahiptir. Teşhis görüntülemesinin güzelliği, PET (Pozitron Emisyon Tomografisi), BT (Bilgisayarlı Tomografi) ve MRG (Magnetik Rezonans Görüntüleme) taramasını kapsayan uygulamalar tıp profesyonellerinin vücudu kesmeye gerek kalmadan içine bakmalarına olanak sağlamaktadır. Görüntü işleme ayrıca geniş olarak birçok değişik tipteki biyolojik araştırmada da kullanılmaktadır. Eğlence endüstrisi görüntü işlemeyi özel efektleri toplamada, yayına hazırlamada ve yapay sahneler hazırlamada kullanmaktadır. Görüntü işleme insanların yeni bir saç şekliyle, bir gözlükle ve hatta yeni bir burunla nasıl görüneceklerine de yardımcı olmada kullanılmaya başlanmıştır. Görsel gerçeklik gelecek olasılıklarını örnekleyen bir sınırlamalardan bağımsız bir uygulamadır ve ortak alanlardaki gelişmelerle birleşmiş görüntü işleme teknikleri pek az tahmin edilebilen yollardan hayatımızı etkilemeye devam edecektir [22].

2.3. İnsan Görme Sistemi

İnsan görme sistemi optik sinirle birbirine bağlı iki ana bileşene sahiptir: Göz ve beyin. Yapısı hakkında en çok bilgiye sahip olduğumuz şey görüntü alma sensörü gözdür. Bilgisayar görüş sistemi insan beynine benzer bir bilgi işleme ünitesi olarak düşünülebilir. Bu ikisi alış sensöründen (göz) işleme ünitesine (beyin) yolculuk eden görsel bilgiyi taşıyan sinirler demeti ile birbirine bağlanmıştır. İnsan görsel sistemi şu şekilde çalışır: 1) Işık enerjisi retinadaki sensörlere lensler tarafından odaklanır 2) Bu sensörler bu ışık enerjisine optik sinirden beyine elektriksel sinyaller yollayan elektro-mekanik bir reaksiyonla cevap verirler 3) Beyin bu sinyalleri bizim görüntü olarak algıladığımız sinirsel bir modele çevirir. Görülebilir ışık enerjisi 380-825 nanometrelik dalga boyuna sahip bir aralığa denk düşmesine rağmen, 700 nanometrenin altında cevap minimaldir. Görüş sistemlerinde spektrum genellikle her biri dalga boylarında değişik uzaklıklarla tanımlanan bantlara bölünür. Örneğin, görsel spektrumu yaklaşık olarak mavi (400-500 nm), yeşil (500-600 nm) ve kırmızıya (600-700 nm) karşılık gelen alanlara bölebiliriz [24].


2.4. Görüntü Gösterimi

İnsan görsel sisteminin giriş görüntüsünü uzaysal dağıtılmış ışık enerjisi olarak aldığını görmüştük; bu form optik görüntü olarak adlandırılır. Optik görüntüler bizim her gün karşılaştığımız tiptendir. Kameralar onları yakalar, ekranlar onları gösterir ve biz onları görürüz. Biliyoruz ki bu optik görüntüler analog elektrik sinyalleri formunda olan video bilgisi olarak gösterilirler [25].

$I(r,c)$ sayısal görüntüsü, (r,c) noktasındaki görüntünün parlaklığına karşılık gelen her bir piksel değerine sahip iki boyutlu veri dizisi olarak gösterilir. Sayısal görüntü sonlu sayıda elemanlardan oluşur. Bunların her birinin koordinatlarda bir yerleri ve değerleri vardır ve bu elemanlara piksel adı verilir. Lineer cebir terimlerinde, bizim modelimiz $I(r,c)$ gibi iki boyutlu diziler matris olarak adlandırılır ve bir sütunu vektör olarak tanımlanır. Bu model mono-krom (tek renk, yani normalde siyah-beyaz denilen) görüntü verisidir. Fakat bu modele genişleme ya da ekleme yapmayı gerektiren değişik tipte başka görüntü verileri de vardır. Tipik olarak bunlar çoklu bant görüntülerdir ve her ayrı bandın parlaklık bilgisine karşılık gelen değişik bir $I(r,c)$ fonksiyonu ile modellenenir. İkilik, gri-skala, renk ve çoklu tayf olmak üzere dört tip görüntü aşağıda açıklanmıştır [20].

2.4.1. İkili görüntüler

İkili görüntüler en basit yapıları görüntülerdir ve siyah-beyaz ya da 0-1 olarak iki değer alabilir. İkili bir görüntü 1 bit/piksel görüntüye karşılık gelir. Çünkü her pikseli göstermek için bir ikili rakam kullanılır. Bu tip görüntüler sık olarak genel şekil veya taslak gibi bilgi gerektiren bilgisayar görüş uygulamalarında kullanılır. Bir nesneyi sürüklemek için robot sürükleyiciyi pozisyona getirmek için, üretilmiş bir mamulü hatalara karşı denetlemek için, kopya (FAX) görüntüleri veya optik karakter tanımlamaları (OCR) gibi uygulamalar örnek olarak verilebilir [20]. Şekil 2.2'de siyah-beyaz örnek görüntü gösterilmiştir.




Şekil 2.2. Siyah-beyaz görüntü.

İkili görüntüler genellikle eşik değeri üzerindeki her değer için pikselin beyaza ('1') ve altındakilerin siyaha ('0') döndüğü eşik işlemleriyle ilgili gri-skala görüntülerinden oluşturulur.

2.4.2. Gri-skala görüntüleri

Gri-skala görüntüleri mono-krom veya tek renk olarak adlandırılan görüntülerdir. Bunlar renk bilgisi değil, sadece parlaklık bilgisi içerirler. Her piksel için kullanılan bit sayısı kullanılacak değişik parlaklık bilgisini tanımlamaktadır. Tipik bir görüntü 256 (0-255) değişik parlaklık (gri) seviyesine sahip olmamıza olanak sağlayan 8 bit/piksel veri içerir. Bu gösterim insan görme sisteminin gereksinimleri açısından yeterli parlaklık çözünürlüğünden fazlasını ve ayrıca gerektiği kadar gri seviye sağlayarak gürültü toleransı sağlar. Birçok değişik tipteki gürültü (sinyaldeki yanlış bilgi) gerçek sistemlerin doğasında bulunduğundan, bu gürültü toleransı gerçek dünya uygulamalarında yararlıdır. Ek olarak 8 bit temsili tipik olarak 8 bit veriye karşılık gelen ve sayısal bilgisayarlar dünyasında küçük bir ünite olan byte kelimesiyle tanımlanır. Pikseller sayısal görüntüyü temsil etmek için ızgara şeklinde dizilirler (Şekil 2.3). Şekil 2.3'te $M \times N$ boyutlu bir sayısal görüntü için ilk indeks m satırın pozisyonunu, ikinci indeks n sütunun pozisyonunu gösterir. Bu iki noktanın kesiştiği koordinatın değeri ise gri seviye olarak adlandırılır [20].



Şekil 2.3. Sayısal görüntü piksellerinin ızgara şeklinde gösterilmesi [26].

Tıbbi görüntüleme ve astronomi gibi kesin uygulamalarda, 12 veya 16 bit/piksel gösterim kullanılmaktadır. Bu ekstra parlaklık seviyeleri sadece görüntünün küçük bir kısmı daha büyük yapıldığında işe yarar olmaktadır. Bu durumda bu ek parlaklık çözünürlüğü olmaksızın gözden kaçabilecek olan detayları görebiliriz. Tabii ki yararlı olabilmesi için, ayrıca yüksek seviyeli uzaysal çözünürlük (piksel sayısı) gerektirmektedir. Eğer bu parlaklık çözünürlüğü seviyelerinin ötesine geçerse ışık enerjisini görünebilir görüntü spektrumunun özel alt-bölümlerini oluşturan enerji bantlarına bölmüş oluruz.

2.4.3. Renkli görüntüler

Renkli görüntüler her veri bandının değişik bir renge karşılık geldiği üç-bant mono-krom görüntü verisi şeklinde modellenebilir. İçinde güncel bilginin saklandığı sayısal görüntü her spektral banttaki parlaklık bilgisidir. Görüntü görselleştirildiğinde buna karşılık gelen parlaklık bilgisi ilgili renge karşılık ışığı yayan görüntü elemanları tarafından görüntülenir. Tipik renk görüntüleri kırmızı, yeşil ve mavi ya da RGB görüntüleri olarak gösterilir. Model olarak 8 bit mono-krom standartlarını kullanarak, karşılık gelen renk görüntüsüne bir örnek teşkil etmektedir [20].

Birçok uygulama için, RGB renk bilgisi parlaklık bilgisi ve renk bilgisini birbirinden ayıran matematiksel forma dönüştürülebilir. Bu yapıldıktan sonra görüntü bilgisi tek boyutlu parlaklık, boşluk veya iki boyutlu renk uzayını içerir. Şu halde renk uzayı

herhangi bir parlaklık bilgisi içermez fakat deęişik renklerin göreceli miktarlarının bilgisini içermektedir. Bu bağlamda renk bilgisini modellemenin dięer bir yararı da renkleri tartışmanın daha insan odaklı bir yolunu oluřturmasıdır.

2.4.4. Çoklu tayfsal görüntüler

Çoklu tayfsal görüntüler normal insan algı menzili dışındaki bilgileri içerir. Bunlar kızıl ötesi, ultraviyole ışınlar, X-ışınları, akustik ve radar verileri gibi bilgilerdir. Gösterilen bilgi insan görme sistemi tarafından doğrudan görülemez. Bununla birlikte bilgi RGB bileşenleri cinsinden haritalanmak suretiyle görsel formda gösterilebilir. Eđer çoklu tayfsal gösterimde üçten fazla bilgi bandı varsa, boyutlandırma ana bileşenler dönüşümü uygulanarak azaltılır. Bu tip görüntülerin kaynakları uydu sistemlerini, sualtı sonar sistemlerini, deęişik tipteki havadan radar sistemlerini, kızılötesi görüntüleme sistemlerini ve tıbbi teşhis görüntüleme sistemlerini kapsar [20].

2.5. Örüntü Tanıma

Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir.

Örüntü tanıma (pattern recognition) nesnelerin ve olayların otomatik olarak tespiti ve sınıflandırılmasıdır. Örüntü tanıma nesnelerin özellikle makineler tarafından kategorilere ayrılması ile ilgilidir. Bu nesneler, uygulamaya göre görüntü, ses ya da sınıflandırılması istenen başka bir işaret olabilir ve genel olarak örüntü olarak adlandırılır [21].

Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. Aslında, örüntü tanıma biliminin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Aşağıda örüntü tanıma uygulamalarına örnekler verilmiştir.


1. Parmak izinden, el şeklinden ve büyüklüğünden, retinadan, ses karakteristiğinden, şekil çiziminden ve el yazısından kimlik tespiti.
2. İnsan konuşmasının bilgisayarlarla tanınması.
3. Çizilmiş desenlerin ve basılmış karakterlerin otomatik olarak tespiti ve el yazısı tanıma.
4. Çince el yazısı tanıma.
5. Montaj bandındaki parçaların otomatik olarak denetimi.
6. Mikroskop ve CAT tarayıcılarından elde edilen tıbbi görüntülerin, magnetik rezonans görüntülerinin, temiz olmayan tıbbi görüntülerin, X-ışını görüntülerinin ve fotoğrafların otomatik olarak analiz edilmesi.
7. Protein veya DNA örüntülerini tanıma.
8. Petrol ve mineral araştırmaları ve deprem tespiti için elde edilen sismik sinyallerin sınıflandırılması.
9. Hava durumunu, kar ve su rezervlerini ve mineralleri, tarım ürünlerinin durumu ve tipini tespit etmek için kullanılan uydu görüntülerinin otomatik analizi.
10. Menü listesinden uygun seçim yapma.
11. Elektrokardiyogramlar (solda) yardımıyla kalp hastalarının tıbbi kategorilerinin sınıflandırılması, elektroansefalogramlardaki (ortada ve sağda) dalgaların tespiti ve diğer tıbbi dalgaların analizi.
12. Kredi kartı uygulaması.

Örüntü tanıma olarak bilinen bu uygulamalar, makina öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır. Örüntü tanıma kavramı, Şekil 2.4'te gösterildiği gibi üç önemli birimden oluşmaktadır.

İşaret / Görüntü İşleme; Ön işlem aşamasıdır. İşaret veya görüntünün filtre edildiği, çeşitli dönüşüm ve gösterim teknikleri ile işlendiği, bileşenlerine ayrıldığı veya modellendiği kısımdır.

Özellik Çıkarma; İşaret ve görüntünün veri boyutunun indirildiği ve tanımlayıcı anahtar özelliklerinin tespit edildiği ve aynı zamanda normalizasyona tabii tutulduğu aşamadır. Sistemin başarımında en etkili rolü oynar.


Sınıflandırma; Çıkarılan özellik kümesinin indirgendiği ve formüle edildiği tanımlayıcı karar aşamasıdır [27].



Şekil 2.4. Örüntü tanıma kavramı [27].

Nesneleri sınıflandırmak için kullanılan ölçümler ve nitelikler özellik (features) ve bunların gruplandırıldıkları tip ve kategoriler sınıf (classes) olarak adlandırılır. Sınıflandırılacak olan bireysel parçalar nesne ve durumlar örnek (samples) veya bazen örüntü (patterns) olarak adlandırılır.

Şekil 2.5'te gösterilen el yazısı ile yazılmış rakamları göz önünde bulunduralım. Her rakam 28x28 piksellik görüntüye karşılık gelir ve böylece 784 rakamlı bir x vektörü ile temsil edilir. Hedef böyle bir vektörü giriş olarak alarak, 0,..9 rakamlarını çıkış olarak üreten bir makine inşa etmektir. Bu, el yazısının çeşitliliğinden dolayı önemli bir problemdir. Bu rakamları ayırt etmek için desendeki vuruş şekillerini temel alan el sanatı kurallarını veya sezgi kullanılabilir, fakat pratikte böyle bir yaklaşım kuralların ve istisnaların artmasına neden olur ve değişmeyen yetersiz sonuçlar verir [21].



Şekil 2.5. Örnek el yazısı rakamları [21].

Daha iyi sonuçlar makine öğrenmesi yaklaşımının benimsenmesi ile elde edilebilir. Bu yaklaşımda, adaptif bir modele ayarlamak için eğitim seti (training set) olarak adlandırılan N tane rakamın serisi $\{x_1, \dots, x_n\}$ kullanılır. Eğitim setindeki rakamların tipik olarak her birinin incelenmesi ve el ile etiketlenmesi ile kategorileri önceden bilinir. Hedef vektör (target vector) t kullanılarak bir rakama karşılık gelen rakamı temsil eden kategoriye belirleyebiliriz.

Çalışan bir makine öğrenme algoritmasının sonucu yeni rakam görüntüsü x 'i giriş olarak alan ve hedef vektörü olarak şifrelenmiş y çıkış vektörünü üreten $y(x)$ fonksiyonu olarak açıklanabilir. $y(x)$ fonksiyonunun kesin biçimi eğitim (training) fazı esnasında tespit edilir. Bu, öğrenme (learning) fazı olarak da bilinir. Model bir kere eğitildiğinde artık test seti olarak isimlendirilen yeni rakam görüntülerinin kimliklerini de tespit edebilir. Yeni örnekleri eğitim yapmadan doğru olarak sınıflandırma kabiliyetine genelleştirme (generalization) denir.

Daha pratik yaklaşımlar için orijinal giriş değişkenleri yeni uzaya dönüştürülmek üzere tipik olarak ön işleme (pre-process) tabi tutulur. Böylelikle örüntü tanıma problemi daha kolay çözülebilir. Bu ön işlem basamağı bazen özellik çıkartma (feature extraction) olarak adlandırılır.

Giriş vektörlerinin ve bunlara uyan hedef vektörlerin verildiği örneklerden oluşan eğitime uygulamaları eğitimci öğrenme (supervised learning) problemi olarak adlandırılır. Rakam tanıma örneğindeki durumlardaki gibi, her bir giriş vektörünün ayrık kategorideki sonlu sayılardan birine tahsis edildiği problemler, sınıflandırma (classification) problemi olarak bilinir. Eğer istenen çıkış bir veya daha fazla değişken içeriyorsa, o zaman görev regresyon (regression) olarak adlandırılır.


Örüntü tanıma problemlerinde eğitim verisi herhangi bir hedef vektörü olmadan bir x giriş vektörü dizisinden oluşursa bu tip problemlere eğitimsiz öğrenme (unsupervised learning) problemi denir. Eğitimsiz öğrenme verilerdeki benzer örnekleri bulmaya çalışır ve buna kümeleme (clustering) denir.

Son olarak takviyeli öğrenme (reinforcement learning) tekniği verilen durumda ödülü maksimuma çıkarmak için uygun davranışı bulma problemi ile ilgilidir. Burada, eğitimsiz öğrenmenin aksine, öğrenme algoritmasına en iyi sonuçların örnekleri verilmez, deneme yanılma işlemiyle bunları keşfetmesi beklenir.

2.5.1. Örüntü tanıma sistemleri

Örüntü tanıma sistemleri gözlenen veya ölçülen verileri tanımlanmasında bir çok uygulamanın merkezinde yer alır. Bu sistemler aşağıda açıklanan ana başlıkları kapsar. Şekil 2.6'da örüntü tanıma sistemlerinin çalışma akışı verilmiştir [28].

Algılama; Algılama için bir dönüştürücü kullanılır (kamera, mikrofon v.b.). Örüntü tanıma sistemleri band genişliğine dayanır, dönüştürücünün çözünürlük duyarlılığı bozulmalara sebep olabilir. Parçalara ayırma ve gruplandırma; Örüntüler iyi dağılmış olmalı ve üst üste gelmemelidir. Özellik çıkartma; Ayırimsal özellikler kullanılmalıdır. Bunlar öteleme, dönme ve ölçeklendirmeye karşı dayanıklı özellikler olmalıdır. Sınıflandırma; Nesneyi kategorilerine ayırmak için özellik çıkarıcıdan gelen özellik vektörü kullanılır. Son işlem; Performansı arttırmak için çıkışlar hedef örüntüsünden farklı olarak girişten bağımsız bilgiler halinde düzenlenebilir.

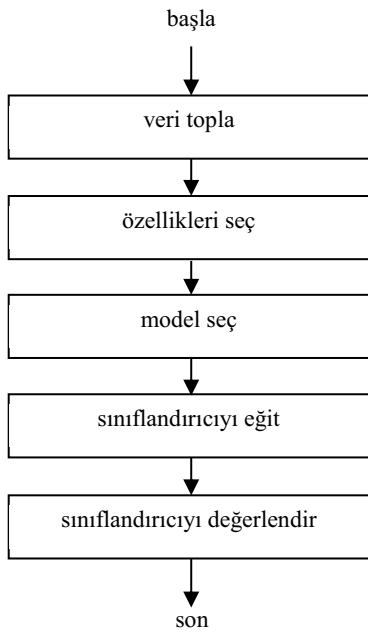


Şekil 2.6. Örüntü tanıma sistemlerinin çalışma akışı [28].

2.5.2. Tasarım döngüsü

Tasarım döngüsü kapsamında bulunan ana başlıklar aşağıda açıklanmıştır. Şekil 2.7’de sistemin çalışma akışı verilmiştir [28].

Veri Toplama; Sistemi eğitme ve test etme için yeterli şekilde geniş ve temsili örnek seti toplanmalıdır. Özellik seçme; Problem alanının karakteristiklerine dayanır. Çıkarması kolay, gürültüye hassas olmayan, önemsiz dönüşümlere dayanıklı özellikler seçilmelidir. Model seçme; Performanstan tatmin olunmadığında diğer sınıflandırma modeline geçilmelidir. Eğitme; Sınıflandırıcıyı tespit etmek için veri kullanılır. Sınıflandırıcıları eğitmek ve modelleri seçmek için çok farklı işlemler uygulanabilir. Değerlendirme; Hata oranı (veya performansı) ölçülür ve bir özellik setinden diğerine geçilir.



Şekil 2.7. Tasarım döngüsünün çalışma akışı [28].

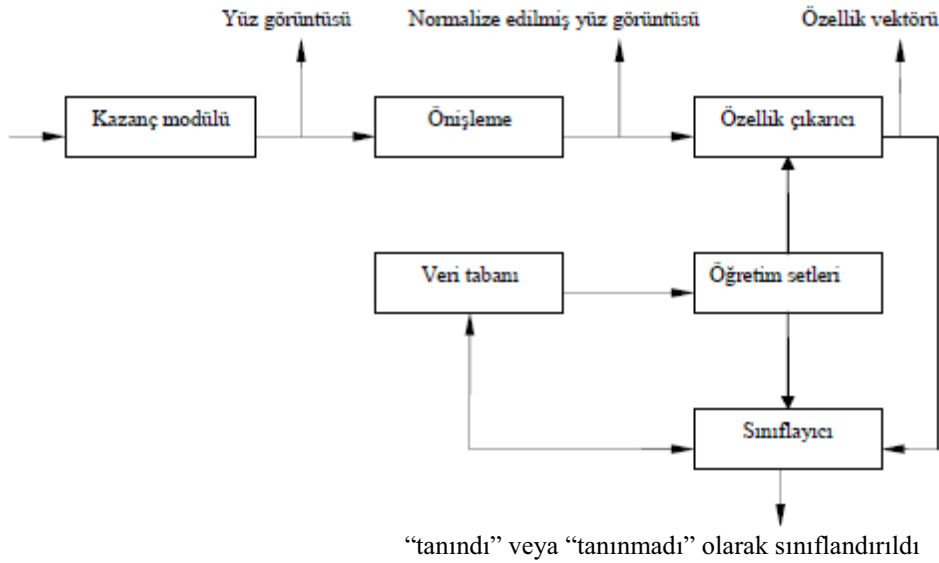
BÖLÜM 3. YÜZ TANIMA İŞLEMİNDE KULLANILAN YÖNTEMLER

3.1. Yüz Tanıma

Yüz tanıma (face recognition), özel olarak yüz üzerinde yapılan bir görüntü tanıma görevidir. Kayıtlı bilinen bireylerle karşılaştırdıktan sonra, bir yüzü “tanındı” veya “tanınmadı” olarak sınıflayan bir görev olarak tarif edilebilir. Ayrıca, bilinmeyen yüzleri tanımayı öğrenme kabiliyetine sahip bir sisteme sahip olmak da istenir. Yüz tanımanın sayısal modelleri, pek çok zor modelleri ele almak zorundadır. Bu zorluk yüzlerin, özel bir yüzü, diğer tüm yüzlerden ayırt etmek için mevcut yüz bilgisini en iyi kullanacak şekilde temsil edilmesi zorunluluğundan kaynaklanır. Tüm yüzler, gözler, burun, ağız gibi aşağı yukarı aynı tarzda düzenlenmiş, aynı özniteliklere sahip olmaları noktasında birbirlerine benzedikleri için zor bir problem oluşturur [29].

3.1.1. Genel bir yüz tanıma sisteminin çalışma akışı

Genel bir yüz tanıma sisteminin çalışma akışı Şekil 3.1’de verilmiştir. Sunulan şekilden görüldüğü gibi yüz tanıma sisteminin altı adet ana işlevsel modülü vardır ve bunların işlevleri aşağıda verilmiştir.



Şekil 3.1. Genel bir yüz tanıma sisteminin çalışma akışı [30].

Kazanç modülü; Bu, yüz tanıma işleminin giriş noktasıdır. Sisteme verilmesi istenen görüntülerin farklı ortamlardan çekilmesi işlemidir. Başka bir deyişle, bu modülde, kullanıcıdan yüz tanıma sistemine bir yüz görüntüsü sunması istenir. Kazanç modülü çok farklı ortamlarda bir yüz görüntüsü talep edebilir. Yüz görüntüsü manyetik bir diskte bulunan bir görüntü olabilir, bir görüntü yakalayıcı tarafından alınabilir veya bir tarayıcı yardımıyla kağıttan taranabilir [30].

Önişleme modülü; Bu modülde erken görüş teknikleri aracılığıyla yüz görüntüleri normalleştirilir ve istenirse sistemin tanıma performansını iyileştirmek üzere zenginleştirilir. Aşağıdaki önişleme adımlarının bazıları veya tamamı, bir yüz tanıma sisteminde uygulanabilir.

Görüntü boyutu normalleştirme; Elde edilen görüntü boyutunu, yüz tanıma sisteminin çalıştığı örneğin 112x92 gibi var sayılan bir görüntü boyutuna değiştirmek için kullanılır. Bu durum, bu tezde önerilen yüz tanıma biçiminde sıklıkla karşılaşılr.

Histogram eşitleme; Genellikle çok koyu veya çok parlak görüntüler üzerinde görüntü kalitesini artırmak ve yüz tanıma performansını geliştirmek için yapılır. Görüntünün dinamik aralığını (kontrast aralığını) değiştirir ve sonuç olarak bazı önemli yüz özellikleri daha belirgin hale gelir.

Medyan filtreleme; Özellikle bir kameradan veya bir görüntü yakalayıcıdan elde edilen gürültülü görüntüler için medyan filtreleme, bilgi kaybetmeden görüntüyü temizleyebilir.

Yüksek geçişli filtreleme; Yüz hatlarına dayalı özellik çıkarıcılar, bir kenar algılama programından elde edilen sonuçlardan istifade edebilir. Yüksek geçişli filtreleme, kenar algılama performansını büyük ölçüde geliştirebilen konturlar gibi, bir görüntünün ayrıntılarını vurgular.

Arka plan kaldırma; Özellikle yüz bilgisini ele almak için yüz arka planı kaldırılabilir. Tüm bilginin kullanılan görüntüde yer aldığı yüz tanıma sistemleri için bu durum özellikle önemlidir. Arka plan kaldırma için, önışleme modülünün yüz planını belirleyebilir olması gerektiği açıktır.

Çevrimsel ve rotasyonel normalleştirmeler; Bazı durumlarda, kafanın bir şekilde kaymış veya dönmüş olduğu bir yüz görüntüsü üzerinde çalışmak mümkündür. Kafa, yüz özelliklerinin belirlenmesinde önemli rol oynar. Özellikle, yüzlerin ön görünümüne dayalı yüz tanıma sistemleri için kafa konumundaki kaymaları ve dönmeleri önışleme modülünün belirlemesi ve mümkünse normal hale getirilmesi istenebilir.

Aydınlatma normalleştirme; Farklı aydınlatmalar altında alınan yüz görüntüleri, özellikle, tüm yüz bilgisinin tanıma için kullanıldığı ana bileşen analizine dayalı yüz tanıma sistemleri için tanıma performansını düşürebilir. Bir görüntü yansıtırlık dizisi $r(X)$ 'e eşit gibi görülebilir. Bu nedenle aynı aydınlatma I altında ilgili görüntü şu formülle verilir.

$$\Phi(X) = Ir(X) \quad (3.1)$$

Normalleştirme işlemi görüntü üzerindeki bir X_0 referans noktasında sabit bir I_0 aydınlatma düzeyini empoze ederek yapılır. Normalleştirilmiş görüntü şu formülle verilir.

$$\Phi(X) = \frac{I_0\Phi(X)}{I(X_0)} \quad (3.2)$$

Gerçek uygulamada, her gözün altında bir tane olmak üzere 2x2 piksel dizisinden oluşan iki referans noktasının ortalaması kullanılabilir.

Özellik çıkarıcı modülü; Bir miktar gerekli ön işleme yaptıktan sonra, normalleştirilmiş yüz görüntüsü, sınıflandırma için kullanılacak ana özellikleri bulmak için özellik çıkarma modülüne sunulur. Başka bir deyişle, bu modül yüz görüntüsünü temsil edecek kadar iyi bir öznitelik vektörünün oluşturulmasından sorumludur.

Sınıflandırma modülü; Bu modülde, bir görüntü sınıflandırıcısının yardımı ile yüz görüntüsünün çıkarılmış özellikleri, bir yüz veri tabanında kayıtlı olanlarla karşılaştırılır. Bu karşılaştırmayı yaptıktan sonra yüz görüntüsü, tanındı veya tanınmadı olarak sınıflandırılır.

Eğitim seti modülü; Eğitim setleri yüz tanıma sürecinin “öğrenme aşaması” sırasında kullanılır. Özellik çıkarma ve sınıflandırma modülleri, eğitim setlerini kullanarak optimum tanıma performansına ulaşmak için parametrelerini ayarlar.

Yüz veri tabanı; “tanınmadı” olarak sınıflandırıldıktan sonra yüz görüntüleri, daha sonra karşılaştırmak için öznitelik vektörleri ile birlikte bir veri tabanına eklenebilir. Sınıflandırma modülü yüz veri tabanını doğrudan kullanır [29].

3.1.2. Yüz tanıma sisteminde karşılaşılan zorluklar

Yüz görüntülerinin dinamik özelliği nedeniyle, bir yüz tanıma sistemi işlem sırasında çeşitli zorluklarla karşılaşır. Bu şartlar altında bir yüz tanıma sistemini tanıma performansına dayalı olarak “sağlam” veya “zayıf” olarak sınıflandırmak mümkündür [29]. Sağlam yapılmış bir yüz tanıma sisteminin hedefleri aşağıda verilmiştir.

Oran deęişmezlięi; Aynı yüz, Şekil 3.2. (b)'de gösterildięi gibi sisteme farklı oranlarda sunulabilir. Bu yüz ve kamera arasındaki fokal mesafe nedeniyle olabilir. Bu mesafeye yakınlaştıkça yüz görüntüsü büyür.


Kayma deęişmezlięi; Aynı yüz, Şekil 3.2. (c)'de gösterildięi gibi sisteme farklı perspektiflerde ve yönelimlerde sunulabilir. Örneęin, aynı kişinin yüz görüntüleri, ön ve profil görünümünden alınabilir. Ayrıca kafa yönelimi, çevrimler ve rotasyonlar nedeniyle deęişebilir.

Aydınlatma deęişmezlięi; Aynı kişinin yüz görüntüleri, konum gibi farklı aydınlatma koşullarında alınabilir ve ışık kaynaęının gücü Şekil 3.2. (d)'de gösterildięi gibi deęiştirilebilir.

Duygusal ifade ve ayrıntı deęişmezlięi; Aynı kişinin yüz görüntüleri gülerken veya ağlarken ifade olarak farklı olabilir. Ayrıca Şekil 3.2. (e)'de gösterildięi gibi koyu gözlükler, sakal veya bıyık gibi bazı detaylar bulunabilir.

Gürültü deęişmezlięi; Sağlam yapılı bir yüz algılama sistemi, görüntü yakalayıcılar veya kamera tarafından üretilen görüntüye duyarlı olmamalıdır. Ayrıca kısmen kapalı görüntüler ile de çalışabilmelidir.

Yapı olarak sağlam bir yüz tanıma sistemi, eęer yüz, veri tabanında kayıtlı ise, yukarıdaki şartlar altında dahi bir yüz görüntüsünü “tanındı” olarak sınıflandırabilmelidir.




Şekil 3.2. Yüz görüntülerinin farklı durumları: (a) Orijinal yüz görüntüsü; (b) Oran değişmesi; (c) Oryantasyon değişmesi; (d) Aydınlatma değişmesi; (e) Ayrıntı bulunması [29].

3.2. Viola ve Jones Yüz Tespit Algoritması

Viola ve Jones yüz tespit algoritması hızı ve yüksek başarısı nedeniyle en popüler yüz algılama yöntemlerinden biridir [31]. Viola ve Jones algoritmasında üç ana özellik bulunur: Görüntü detektörünün kullanacağı özniteliklerin çok hızlı hesaplanmasını sağlayan “tümleysel görüntü (integral image)” gösterimi, AdaBoost algoritması temel alınarak büyük veri setlerinden küçük sayılarda görsel özniteliklerin seçilerek verimli sınıflandırıcılar türeten bir öğrenme algoritması ve türetilen sınıflandırıcıların ardarda sıralı bir şekilde birleştirilmesiyle daha karmaşık sınıflandırıcıların elde edilmesidir.

Çalışmada üç çeşit dikdörtgen öznitelik değeri kullanılır. İki dikdörtgenli özniteliğin değeri iki dikdörtgen bölgedeki pikseller toplamının birbirinden çıkarılması ile elde edilir (Şekil 3.3. (a) ve (b)). Dikdörtgen bölgeler aynı boyutlu, aynı şekle sahip ve yatay veya dikey olarak birbirine bitişik (adjacent) olmalıdır. Üç dikdörtgenli öznitelik değeri, dıştaki dikdörtgenlerin piksel toplamından merkezde bulunan dikdörtgenin piksel toplamının çıkarılmasıyla elde edilir (Şekil 3.3. (c)). Dört dikdörtgenli öznitelik değeri ise çapraz dikdörtgenlerin piksel değerlerinin toplamı birbirinden çıkarılarak hesaplanır (Şekil 3.3. (d)) [32].



Şekil 3.3. Dikdörtgen öznitelikler [32].

Pikselleri doğrudan kullanmaya ziyade öznitelikleri kullanmak için birçok sebep vardır. Bunun en sık sebebi ise özellik - tabanlı sistem bir piksel - tabanlı sisteme karşı çok daha hızlı çalışır. Buradan, matematiksel hesaplamalarda pikseller kullanılırken sınıflandırma sistemlerinde öznitelikler kullanılır.

3.2.1. Tümlevsel görüntü

Dikdörtgen özniteliklerin hesap edilmesi için tümlevsel görüntü gösterimi kullanılır. Görüntünün x, y noktasındaki tümlevsel görüntü değeri x, y noktasının solunda ve üstünde kalan tüm piksel değerlerinin toplamıdır (Şekil 3.4).


$$ii = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (3.3)$$

Denklem (3.3)'te $ii(x, y)$ tümlevsel görüntü değerini, $i(x, y)$ değeri de orijinal görüntünün x, y noktasındaki değerini göstermektedir. Aşağıdaki özyineli işlemler sayesinde tümlevsel görüntü değeri hesaplanır:

$$s(x, y) = s(x, y-1) + i(x, y) \quad (3.4)$$

$$ii(x, y) = ii(x-1, y) + s(x, y) \quad (3.5)$$


Denklem (3.4) ve (3.5)'teki $s(x, y)$ kümülatif satır toplamını gösterir, $s(x, -1)$ ve $ii(-1, y)$ değerleri 0 olarak kabul edilir [33].



Şekil 3.4. Tümevsel görüntünün (x, y) noktasındaki değeri [32].

Tümevsel görüntü gösterimi ile dikdörtgen bir bölgeye ait piksel toplamı referans dört nokta kullanılarak hesaplanır. Örneğin, Şekil 3.5'te D olarak isimlendirilen bölgedeki piksellerin toplamını hesaplamak için 1'den 4'e kadar belirtilen noktalar referans olarak alınır. 1 numaralı noktadaki tümevsel görüntü değeri A olarak adlandırılan bölgenin piksel toplamıdır. 2 numaralı noktadaki değer $A + B$, 3 numaralı noktadaki değer $A + C$ ve 4 numaralı noktadaki değer ise $A + B + C + D$ 'dir. Tüm bilgiler bir araya getirilerek, D bölgesindeki piksel toplamı $4 + 1 - (2 + 3)$ şeklinde tümevsel görüntü değerleri kullanılarak hesaplanır [32].

İki dikdörtgenli öznitelik değerinin hesabı için referans altı nokta, üç dikdörtgenli öznitelik değerinin hesabı için referans sekiz nokta ve dört dikdörtgenli öznitelik değeri için ise referans dokuz nokta kullanılarak istenen değerler hesaplanır.



Şekil 3.5. Tümevsel görüntü değerinin hesaplanması [32].


Tümlevsel görüntü fonksiyonun kullanımı sayesinde özniteliklerin çok hızlı bir şekilde değerlendirilmelerine olanak sağlar. Bu özellik tümlevsel görüntü sistemin en önemli amaç ve avantajlarından biri haline gelir.

3.2.2. Öğrenme algoritması

AdaBoost öğrenme algoritmasının bir versiyonu daha küçük öznitelik setlerinin seçilmesinde ve sınıflandırıcıların eğitiminde kullanılır. Orijinal biçiminde, AdaBoost öğrenme algoritması basit bir öğrenme algoritmasının sınıflandırma performansını artırmak için kullanılır (örneğin, basit bir perseptronun performansını artırmasında kullanılır). Bunu gerçekleştirmek için zayıf sınıflandırma fonksiyonlarını bir koleksiyon şeklinde birleştirerek güçlü bir sınıflandırıcı oluşturur. AdaBoost dilinde basit öğrenme algoritması zayıf öğrenci olarak ifade edilir. Zayıf öğrenci ifadesinin kullanım sebebi ise en iyi sınıflandırma fonksiyonun eğitim verilerini iyi sınıflandırması beklenilmez [34]. “Zayıf öğrenci (weak learner)” her bir öznitelik için optimal eşik sınıflandırıcı fonksiyonunu belirler. Basit bir sınıflandırıcı $h_j(x)$, böylece f_j öznitelik değeri, θ_j eşik değeri ve p_j polarite değerleri kullanılarak elde edilir. Buradaki x değeri bir görüntünün 24x24'lük bir alt görüntü penceresidir.

$$h_j(x) = \begin{cases} 1 & \text{eğer } p_j f_j(x) < p_j \theta_j \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.6)$$

Yüz tespiti için AdaBoost algoritması tarafından seçilen ilk iki öznitelik Şekil 3.6'da verilmiştir. İlk öznitelik göz bölgesindeki pikseller burun ve yanaklara göre daha koyu renklidir özelliğini kullanırken, ikinci öznitelik gözler burun kıvrımına göre daha koyudur özelliğini temel almıştır [32].




Şekil 3.6. AdaBoost tarafından seçilen ilk iki öznelik [32].

AdaBoost algoritmanın, bir öznelik seçme mekanizması gibi, diğer rakip metotlarına (wrapper metodu) karşı en önemli avantajı öğrenme hızıdır.

3.2.3. Ardarda sıralı sınıflandırıcı

Karar alma sürecinde ardarda sıralı sınıflandırıcılar (detection cascade) kullanılır. İlk sınıflandırıcıdan gelen pozitif (true) sonuç, ikinci bir sınıflandırıcıyı çalıştırır [35,36]. Benzer şekilde ikinci sınıflandırıcıdan gelen pozitif bir sonuç üçüncü sınıflandırıcıyı tetikler ve çalıştırır. Bu şekilde bu işlem böyle devam eder. Herhangi bir anda negatif (false) sonuç gelmesi durumunda alt pencere sınıflandırıcılar tarafından reddedilir (Şekil 3.7).




Şekil 3.7. Ardarda sıralı sınıflandırıcı [32].

AdaBoost tarafından eğitilen ardarda sıralı sınıflandırıcılarda bir dizi sınıflandırıcı her alt pencereye uygulanır. Amaç çoklukla bulunan negatif sonuçları alt pencereleri (sub-windows) reddederek iptal etmek.

Ardarda sıralı sınıflandırıcılar yapısı sayesinde detektörün işlem hızı artar. Dolayısı ile bu özellik bu tekniğin en önemli amaç ve avantajlarından biridir.

Görüntülerdeki yüzler her zaman merkezde ve düzgün şekilde olmayabilir. Farklı pozlardan çekilmiş yüzlerin görüntülerde pozisyonlarının değişime uğrayacağı kesin bir gerçektir. Dolayısı ile yüzler daha sağa ya da sola, daha yukarıya ya da aşağıya, daha çapraz kayma ya da daha büyük veya küçük şekillerde olabilir. Bununla birlikte dikdörtgen öznitelik çeşitlerinin pozisyonları ve boyutları değişir. Bu durumlarda görüntü detektörünün kullanacağı özniteliklerin hesaplanmasını sağlayan “tümlevsel görüntü (integral image)” gösterimi, hesaplamada karmaşığa uğrayabilir. Buda detektörün işlem hızını negatif yönde etkileyebilir. Bu durumda ardarda sıralı sınıflandırıcılar negatif sonuçların artmasıyla bazen çıkışta hiç sonuç vermeyebilir. Şekil 3.8’de dikdörtgen öznitelik çeşitlerinin farklı pozisyonlardaki prototipleri verilmiştir.



Şekil 3.8. Dikdörtgen öznitelik çeşitlerinin farklı pozisyonlardaki prototipleri: (a) İki dikdörtgenli öznitelik; (a') İki dikdörtgenli özniteliğin tersi; (b) Üç dikdörtgenli öznitelik; (b') Üç dikdörtgenli özniteliğin tersi; (c) Dört dikdörtgenli öznitelik [37].

Kısaca belirterek, eğitim setindeki görüntüler üzerinde yüz tespit işlemin gerçekleştirilmesi için Haar tabanlı sınıflandırıcılar kullanılır [32]. Viola-Jones yüz tespiti yönteminde haar benzeri öznitelikler kullanılarak yüz görüntüsü olan ve yüz görüntüsü olmayan veri üzerinde eğitim işlemi gerçekleştirilir. Sonrasında elde edilen model kullanılarak test edilecek görüntü üzerinde yüz tespiti yapılır.

3.3. Ayrık Dalgacık Dönüşümü

Ayrık dalgacık dönüşümü (Discrete Wavelet Transform-DWT) yöntemi son çeyrek asırda oldukça popüler olarak kullanılan bir yöntemdir. En geniş uygulama alanını görüntü sıkıştırma bulmuştur. Ayrıca görüntüler içerisindeki cisimlerin bulunup tanınması v.b. pek çok uygulama içinde etkin bir şekilde kullanılmaktadır.


Bir fonksiyonun dalgacık dönüşümünün alınması, o fonksiyonun değişik çözünürlüklere ayrılarak dalgacık katsayılarının belirlenmesi ile olur. Bu işlem için ana dalgacık adı verilen bir fonksiyon farklı zaman ve genişliklerde dönüşümü yapılmak istenen fonksiyon ile korelasyona tabi tutularak karşılık gelen dalgacık katsayıları elde edilir [20].

Şekil 3.9, bir boyutlu (1-D) bir ayrık-zaman işareti $x[n]$ 'nin iki seviyeli DWT'sinin nasıl elde edildiğini göstermektedir. Giriş işareti, yüksek geçiren ve alçak geçiren $g[n]$ ve $h[n]$ analiz filtrelerine uygulanır. Filtrelerin çıkışı iki ile alt-örneklenerek $x_H[n]$ ve $x_L[n]$ ile verilen dönüştürülmüş işaretler elde edilir. İşlem bu aşamada durdurulursa $x[n]$ 'nin bir seviyeli DWT'si elde edilmiş olur. $x[n]$ 'e uygulanan ayrıştırma işlemi ikinci bir analiz filtre çifti kullanılarak $x_L[n]$ için tekrarlanırsa Şekil 3.9'da gösterildiği gibi $x_H[n]$, $x_{LH}[n]$ ve $x_{LL}[n]$ işaretlerinden oluşan iki seviyeli DWT elde edilir. Bu işlem gerektiği kadar tekrarlanabilir. Filtreleme ve alt örnekleme kaç kez yapıldığı dönüşümün seviyesini belirler [38].


Şekil 3.10, 1-D ayrık-zaman $x[n]$ işaretinin iki seviyeli DWT'sinden nasıl geri elde edildiğini açıklamaktadır. $x_{LH}[n]$ ve $x_{LL}[n]$ işaretleri yüksek geçiren ve alçak geçiren sentez filtreleri $\tilde{g}[n]$ ve $\tilde{h}[n]$ 'den geçirilir ve filtrelerin çıkışları iki ile üst-örneklenir. Üst-örnekleyicilerin çıkışındaki işaretler toplanarak $x_L[n]$ oluşturulur. Bu işlem $x[n]$ 'yi elde etmek için ikinci bir sentez filtre çifti kullanılarak $x_H[n]$ ve $x_L[n]$ işaretleri için tekrarlanır.

Sayısal görüntüler gibi iki boyutlu işaretlerin DWT'sinin hesaplanması için 1-D DWT yatay ve dikey yönlerde arka arkaya uygulanır. Analiz ve sentez filtreleri iki boyutludur ve bir yerine iki üst indis yatay ve dikey yönleri göstermek için kullanılır


(Şekil 3.11). Ayrıca, alt-örnekleme ve üst-örnekleme her iki yönde de uygulanır. Sonuç olarak, her seviyede 1-D DWT durumunda iki altbant elde edilirken, 2-D DWT durumunda dört altbant elde edilir [20]. Her filtreleme görüntüye ait farklı bir çözünürlükte özet ve detay katsayıları elde edilmesini sağlar. Bu işlem görüntü tek piksele indirgenene kadar devam ettirilebilir.



Şekil 3.9. İki seviyeli 1-D Ayrık Dalgacık Dönüşümü [38].




Şekil 3.10. İki seviyeli 1-D Ters Ayrık Dalgacık Dönüşümü [38].



Şekil 3.11. İki seviyeli 2-D Ayrık Dalgacık Dönüşümü [38].

Bir görüntüye uygulanan 2-D filtreleme ve alt-örnekleme işlemlerinin sayısını belirtmek için *seviye* terimi kullanılacaktır. *Yön* terimi mümkün alçak geçiren ve

yüksek geçiren filtreleme kombinasyonunu belirtmektedir. Yön $\{0, 1, 2, 3\} = \{LH, HH, HL, LL\}$ olarak belirtilir. İlk terim yatay yönde, ikinci terim ise dikey yönde uygulanan filtre türünü belirtir. I_l^θ çözünürlük seviyesi, l 'de $\theta \in \{0,1,2,3\}$ yönünde altbandı belirtsin. Bu notasyon kullanıldığında, Şekil 3.12. (a) ve (b) bir görüntünün 1 seviyeli ve 3 seviyeli 2-D DWT'sini göstermektedir [39].



Şekil 3.12. Bir görüntünün: (a) 1 seviyeli ve (b) 3 seviyeli ayrık dalgacık dönüşümündeki altbantları [39].

Şekil 3.12'de gösterilen $I_l^3, I_l^0, I_l^1, I_l^2$ değerleri görüntünün θ çözünürlüğündeki özet, yatay, diyagonal ve dikey dalgacık katsayılarına karşılık gelmektedir. Özet dalgacık katsayılarını görüntünün düşük çözünürlüklü bir kopyası olarak, yatay, dikey ve diyagonal katsayıları ise görüntünün yatay, dikey ve diyagonal özelliklerini gösteren birer görüntü olarak düşünülebilir.

3.4. Sınıflandırma İşleminde Kullanılan Yöntemler

Yapılan çalışmalarda elde edilen görüntülerin ne kadar iyi ya da ne kadar düşük düzeyde bir sonuç verdiklerini araştırıp bulmak çalışmada önemli bir yere sahiptir. Bu sorunu çözmek için görüntüleri ilk önce eğiterek sonra test kısmına tabi tutarak istenilen sonuca yüzdesel olarak yaklaşılır. Bu nedenle işlemlerin gerçekleşmesi için en uygun ve kullanışlı bir sinir ağı bulup onun üzerinden eğitim ve test işlemleri ve sonuçları elde edilebilir. Bu çalışmada amaca yönelik Olasılıksal Sinir Ağı (Probabilistic Neural Network-PNN) ve Destek Vektör Makineleri (Support Vector Machine-SVM) ağları kullanımına yer verilmiştir. Aşağıda her iki yöntemden detaylı bir şekilde bahsedilmiştir.


3.4.1. Olasılıksal sinir ağı

Olasılıksal sinir ağı (Probabilistic Neural Network-PNN), temelleri geri yayılım algoritmasından biraz farklı ve kullanışlı bir sinir ağı mimarisidir. PNN'nin tanımlanması ilk olarak 1990 yıllarında Specht tarafından yapıldı. PNN, Yapay Sinir Ağları'nın (Artificial Neural Network-ANN) bir alt koludur. Dahası eğitici öğrenme, statik bir ağıdır [27].

3.4.1.1. Olasılıksal sinir ağı'nın tanımı ve matematiksel analizi

Olasılıksal sinir ağı sınıflandırma konusunda sıkça kullanılan bir sınıflandırma yöntemidir. Olasılıksal sinir ağı, Parzen penceresi olasılık yoğunluk fonksiyonu kestirimcisi ile yakından alakalıdır. Bir olasılıksal sinir ağı birkaç alt ağdan oluşur. Bu alt ağın her biri her bir sınıf için Parzen penceresi kestirimcisidir. PNN'nin temelini teşkil eden fikir Parzen pencerelerini kullanarak bilinmeyen olasılık yoğunluklarını tahmin etmektir. Böylece verilen bir kategorinin her bir eğitim vektörü çevresinde m -boyutlu bir Gauss fonksiyonu merkezlenir [27].

Bir olasılıksal sinir ağı (PNN) üç katmandan oluşmaktadır. Giriş katmanı, her biri bir özniteliği temsil eden m adet öznitelik vektörü içermektedir. Giriş katmanında bulunan ve öznitelikleri temsil eden bu düğümler; her saklı düğüm giriş öznitelik vektörü olan x 'i tamamen alacak şekilde saklı (orta) katmandaki her düğüme bağlanır. Saklı düğümler her biri bir sınıfı gösterecek şekilde kümelere ayrılmaktadır. Giriş katmanındaki düğümlerin ağırlık vektörleri eğitim kümesi olarak verilen öznitelik vektörleri olarak belirlenir. Aşağıda verilen Şekil 3.13'te j adet sınıfı tanıyan bir PNN'nin yapısı görülmektedir [40].



Şekil 3.13. Olasılıksal sinir ağı modeli [40].

l sınıfının kümesindeki her saklı düğüm l . sınıftaki kendisine ait öznitelik vektörüyle belirlenen bir Gauss işlevi ile ilişkilidir ve her öznitelik vektörüne ilişkin bir Gauss işlevi bulunmaktadır. Bir sınıfa ait kümedeki bütün Gauss işlevleri, işlevsel değerlerini sadece bu sınıfa ait olan çıkış katmanına yollar. Sonuç olarak çıkış katmanında l çıkış düğümü bulunur.

l sınıfının çıkış düğümünde, l sınıfı için bütün Gauss değerleri toplanır ve toplam ölçeklenir. Bu sayede toplam işlevi, birim işlev olur ve toplam bir olasılık yoğunluk işlevi haline gelir. Herhangi bir l giriş vektörü için j . sınıfın i . öznitelik vektörü ile ilgili Gauss denklemleri m vektör boyutu olmak üzere aşağıdaki şekilde verilebilir;

$$y_j(x) = [1/\sqrt{(2\pi\sigma^2)^m}]e^{\{-\|x-x_j^i\|^2/(2\sigma^2)\}} \quad (3.7)$$

Denklemdaki σ değeri aynı kümedeki öznitelik vektörleri arasındaki ortalama mesafenin yarısı olarak veya her bir örnek için, ilgili örnekten bu örneğe en yakın diğer bir örnek vektöre olan uzaklığın yarısı olarak alınabilir. j . çıkış düğümü, j . kümedeki saklı düğümlerden alınan değerleri toplar, buna karışık Gausslar veya

Parzen penceresi denmektedir. Bu toplamlar aşağıdaki denklemde verilen şekilde tanımlanabilir;

$$y_j(x) = \left[1/\sqrt{(2\pi\sigma^2)^m} \right] 1/i \sum_i e^{\{-\|x-x_j^i\|^2/(2\sigma^2)\}} \quad (3.8)$$

Bu ifade de x girişe verilen bir öznitelik vektörüdür, σ Gauss işlevi için ayarlanabilen bir yumuşatma parametresidir (standart sapma), öznitelik vektörlerinin birbirinden ne kadar farklılaştığının bir ölçütüdür. Herhangi bir giriş vektörü x çıkış katmanındaki her bir Gauss toplam işlevine uygulanır ve işlevlerden en büyük değere sahip olanı seçilerek giriş vektörünün sınıfına karar verilir. Bu formülasyonun avantajı şudur ki, birkaç örnek olasılık yoğunluk fonksiyonun temelini teşkil eden, esnek bir tahmin yapmak için gereklidir. PNN bu tahmin etme sürecinin paralel bir uygulamasıdır.

Uygulamalarda x , bir grid araştırması ile sayısal olarak bulunabilir. Bu, yanlış sınıflandırma oranını minimize eden optimal bir çözümdür. Grid araştırmasında x için başlangıç değeri verilerek çıkış değerleri kontrol edilir ve y_1, y_2, \dots, y_j birbirine eşit oluncaya kadar iterasyon halinde x değeri değiştirilir.

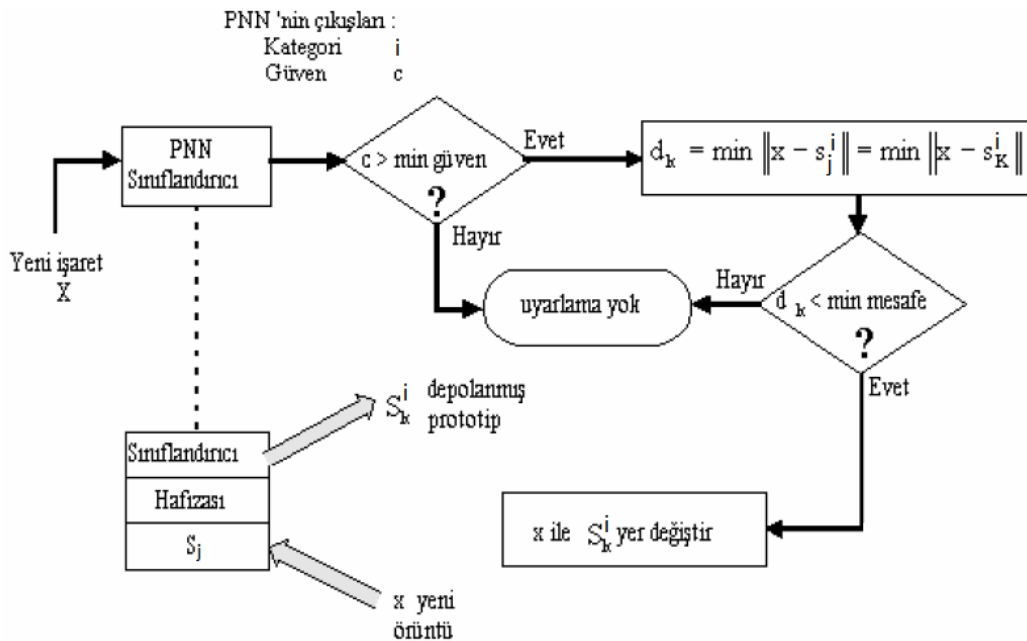
3.4.1.2. Eğitim ve test etme

Eğitim, öznitelik (örüntü) vektörlerinin saklı katman birimlerine doğrudan pay edildiği andır. Kodlamanın meydana gelmediği basit durumdur. PNN eğitim verisinin temel dağıtımına göre hiç bir varsayımın yapılmadığı serbest model (modelden bağımsız) bir tahmin edici olarak düşünülebilir.

Bir test vektörü PNN'ye verildiğinde, kararda güvenilir bir tahmin kadar iyi olan kazanan kategori çıkışı oluşturur. Bu güvenilir tahmin Bayes karar kuralı kullanılarak, tahmin edilen olasılık yoğunluklarından hesaplanan sonrasal olasılık ile verilir [27]. Tekrar belirtmek gerekir ki denk önceseller, karar maksimum olabilirlik kriteri temelindedir ki, o da olasılık yoğunluklarıdır.

3.4.1.3. Uyarılma ve çalışma prensibi

PNN algoritması uyarlamada kullanılmaktadır. Tüm eğitim kümesi sıkıştırılmaksızın tutulur, bu sınıflandırıcı türü çevrim içi uyarlamaya olanak sağlar. Basit bir algoritma, uyarılma yeteneği ile bu sınıflandırıcıyı oluşturarak kurulabilir. Uygulamada, iki önemli noktayı göz önünde tutmak gereklidir. İlki, sınıflandırıcı doğru olmayan ani değişimleri öğrenir ve gerçek eğilimleri kestirmek için yavaşça uyarlanmalıdır. İkincisi, sınıflandırıcı önemsiz bilgi ile yararlı bilginin yerini almamalıdır. Bu iki önemli nokta ancak yeni örüntü depolanmış prototipler ile yeterince kapalı ise ve ancak sınıflandırıcı kararında yeterince kendinden emin ise sağlama uyarlamaya göre başarılı olduğu söylenir. PNN test örüntüsü ve en yakın saklanan prototip arasındaki uzaklık çıkış olmadığından, bazı ilave hesaplamalar bu minimum uzaklığı bulmak için gereklidir. Eğitici uyarılma nedeniyle, sınıflandırıcının yararlı bilgisinin azalan riski vardır. Bu nedenle, önemli olan başlangıç kümesidir. Minimum güven seviyesi %80 de kurulur [27]. PNN sınıflandırıcısının uyarılma işlemi aşağıdaki şekilde betimlenmiştir (Şekil 3.14).



3.4.1.4. Olasılıksal sinir ağı'nın avantajları ve dezavantajları

Her algoritmanın farklı yapısı, çalışma düzeni, farklı uygulama alanları olduğundan başarımlar ölçümlerinde vereceği sonuçlarda farklı olacaktır. Her algoritmanın olduğu gibi olasıksal sinir ağı'nın da avantajları ve dezavantajları var. Aşağıda olasıksal sinir ağı'nın birkaç avantajı ve dezavantajı verilmiştir.

PNN'nin en büyük avantajı eğitiminin hızlı ve çıkışların olasıksal olmasıdır. Bir başka avantajıda formülasyonudur. Böylece birkaç örnek olasılık yoğunluk fonksiyonun temelini teşkil eden, esnek bir tahmin yapmak için gereklidir. PNN bu tahmin etme sürecinin paralel bir uygulamasıdır. Dezavantajı ise bütün eğitim kümesini düğüm olarak içerir ve bundan dolayı ağ boyutu büyür. Bu yüzden büyük boyutlu vektörler ile işlem yapar. Diğer dezavantajları, özellik uzayını sınıflandırma uzayına dönüştürürken, bir gürültünün çıkması ve her bir sınıf için hata kriterinin belli olmamasıdır.

3.4.2. Destek vektör makineleri

Sınıflandırma problemlerinde kullanılan basit ve oldukça etkili ve farklı sınıflandırma yöntemlerinden biride destek vektör makineleridir (Support Vector Machine-SVM). Temel olarak, istatistiksel öğrenme algoritmalarından biri olan ve Vapnik-Chervonenkis tarafından tanımlanan SVM, birçok gerçek problemde başarılı sonuçlar vermiştir. SVM'nin dayandığı teori, Vladimir Vapnik ve Alexey Chervonenkis tarafından 1960'lı yıllarda başlatılıp 1970'li yıllarda gelişen başarılı bir çalışmanın ürünüdür. Ancak, ilk başarılı uygulamaları 1990'lı yıllarda gerçekleştirilmiş olup, bu uygulamalardan sonra matematikçilerin ve Yapay Zeka (Artificial Intelligence-AI) bilim adamlarının ilgi odağı olmuştur [41]. Bazı kaynaklarda Karar Destek Makineleri ifadesiyle de geçer.

3.4.2.1. Destek vektör makinelerinin tanımı

Destek vektör makineleri (SVM) istatistiksel öğrenme teorisine dayalı bir kontrollü sınıflandırma algoritmasıdır. Destek vektör makineleri, istatistiksel tekniklerin

olasılık dağılımının temel alındığı eğitime algoritması olarak bilinir. Birçok pratik durumda, istatistiksel tekniklerin temelini oluşturan dağıtma yasalarının hakkında yeterli bilgi ve dağılım bulunmamaktadır. Bu işlem gerçek dünya uygulamalarında ortak olan çok ciddi bir kısıtlamadır [41,42].

Destek vektör makinelerin (SVM) çalışma prensibi veriyi sınıflandırırken sınıfların birbirlerine en yakın örneklerini bularak bu örneklerin (iki sınıfı ayıracak olan) ayırıcı düzleme, başka bir ifadeyle hiper-düzleme olan dik uzaklıklarını maksimize etmeyi amaçlar. Böylece hem eğitim setindeki, hem test setindeki verinin yanlış sınıflandırılma hatası en küçültülmüştür [42].

Ayırıcı düzlemin, veri kümesi üzerindeki başarısı değişmeden birçok farklı alternatifi olabilir. SVM sayesinde ayırıcı düzlem her iki sınıfa da aynı mesafede ve maksimum uzaklıktadır. SVM'nin temel mantığı doğrusal olarak ayrıştırılabilen veri yapıları için en iyi ayırıcı düzlemin belirlenmesidir. Doğrusal olarak ayrıştırılamayan veri yapıları dönüşüm tekniği ile farklı bir boyuta taşınarak çözülür [42,43].

SVM polinomial modellerde, yapay sinir ağlarında, bulanık mantıkta ve RTF sınıflandırıcılarda sıkça kullanılan yeni bir metottur. SVM'yi, yapısal risk minimizasyonu (YRM) olarak bulunan yeni öğrenim teknikleri ve Vapnik-Chervonenkis teorisi temsil eder. En basit desen tanıma görevlerinde, vektör makinelerinin azami kenarla bir sınıflandırıcıyı yaratması için doğrusal ayıran bir yüksek düzlemi kullanır. Bunu gerçeklemek için, öğrenen problem, doğrusal olmayan bir optimizasyon problemi olarak alınır. Verilmiş sınıflar uzayının olduğu orijinal girişte doğrusal olarak ayrılamadığı zaman SVM önce doğrusal olarak, daha yüksek boyutlu bir özellik uzayını orijinal giriş uzayına dönüştürür. Bu dönüşüm, çeşitli doğrusal olmayan eşleştirmeleri kullanarak başarılabilir: Polinomial, çok katmanlı algılayıcıda olduğu gibi sigmoidal, radyal olarak simetrik görevler Gaussian olduğu esas görevlere sahip olması için RTF (Radyal Tabanlı Fonksiyon) eşleştirmeleri olabilir. Doğrusal olmayan dönüşüm adımı yapıldıktan sonra, doğrusal optimal ayrımı bulmak SVM'nin görevidir. Yani, optimizasyon problemini çözmesi, doğrusal ayrılabilir sınıflar için orijinal giriş uzayında ayırıcı düzlem hesabı olarak

aynı türden olur. Özellik uzayında sonuç veren yüksek düzlem, azami bir kenar sınıflandırıcısı olduğunda optimal sonucu verir [41].


3.4.2.2. Destek vektör makinelerinin matematiksel analizi

SVM'nin sahip olduğu matematiksel algoritmalar başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir.

3.4.2.3. Doğrusal ayrılabilen veriler için destek vektör makineleri

Destek vektör makineleri ile sınıflandırmada genellikle $\{-1, +1\}$ şeklinde sınıf etiketleri ile gösterilen iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır. Söz konusu karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiper-düzlem bulunur.

Şekil 3.15. (a)'da gösterildiği üzere iki sınıflı verileri birbirinden ayırabilen birçok hiper-düzlem çizilebilir.




(a)

Şekil 3.15. (a) İki sınıflı bir problem için hiper-düzlemler [44].

Ancak SVM'nin amacı kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkaran hiper-düzlemi bulabilmektir. Şekil 3.15. (b)'de görüldüğü üzere sınırı maksimuma çıkararak en uygun ayrımı yapan hiper-düzleme optimum hiper-düzlem ve sınır genişliğini sınırlandıran noktalar ise destek vektörleri olarak adlandırılır [44].

Bu şekilde iki sınıf iki boyutlu bir düzlem üzerinde gösterilmiştir. Bu düzlemi ve boyutları birer özellik olarak düşünmek mümkündür. Yani basit anlamda sisteme giren her girdinin (input) bir özellik çıkarımı (feature extraction) yapılmış ve sonuçta bu iki boyutlu düzlemde her girdiyi gösteren farklı bir nokta elde edilmiştir. Bu noktaların sınıflandırılması demek, çıkarılmış olan özelliklere göre girdilerin sınıflanması demektir.



(b)

Şekil 3.15. (b) Optimum hiper-düzlem ve destek vektörleri [44].

Yukarıda her iki sınıf arasında oluşan aralığa tolerans (offset) demek mümkündür [45].


Doğrusal olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde SVM'nin eğitimi için k sayıda örnekten oluşan eğitim verisinin $\{x_i, y_i\}$, $i = 1, \dots, k$ olduğu kabul edilirse, optimum hiper-düzleme ait eşitsizlikler aşağıdaki şekilde olur:

$$w \cdot x_i + b \geq 1 \quad \text{her } y = +1 \quad \text{için} \quad (3.9)$$

$$w \cdot x_i + b \leq -1 \quad \text{her } y = -1 \quad \text{için} \quad (3.10)$$

Bu modelde $x \in \mathbb{R}^N$ olup N -boyutlu bir uzayı, $y \in \{-1, +1\}$ ise sınıf etiketlerini, w ağırlık vektörünü (hiper-düzlemin normalini) ve b eğilim değerini göstermektedir [46]. Optimum hiper-düzlemin belirlenebilmesi için bu düzleme paralel ve sınırlarını oluşturacak iki hiper-düzlemin belirlenmesi gerekir (Şekil 3.16). Bu hiper-düzlemleri

oluşturan noktalar destek vektörleri olarak adlandırılır ve bu düzlemler verilen eşitlik $w \cdot x_i + b = \pm 1$ şeklinde ifade edilirler.



Şekil 3.16. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi [44].

Tahmin edileceği üzere iki sınıf arasındaki hiper-düzlemin (hyperplane) tek yönlü olması mümkün değildir. İki farklı hiper-düzlem olasılığı bulunmasına karşılık SVM yönteminde bu olasılıklardan en büyük toleransa (offset) sahip olanı alınır.

Optimum hiper-düzlemin sınırının maksimuma çıkarılması için $\|w\|$ ifadesinin minimum hale getirilmesi gerekir. Bu durumda en uygun hiper-düzlemin belirlenmesi aşağıdaki sınırlı optimizasyon probleminin çözümünü gerektirir.

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (3.11)$$

Buna bağlı sınırlamalar ise;

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad \text{ve} \quad y_i \in \{1, -1\} \quad (3.12)$$

şeklinde ifade edilir [42]. Bu optimizasyon problemi Lagrange denklemleri kullanılarak çözülebilir. Bu işlem sonrasında;

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i (y_i (w \cdot x_i + b) - 1) \quad (3.13)$$

eşitliği elde edilir.

α_i deęişkenleri, Lagrange katsayılarını göstermek üzere $\alpha_i \geq 0$ olmalıdır.

Yukarıdaki Lagrange denkleminin bazı veri kümeleri için geleneksel çözümü belki de çok kolay olabilir. Fakat bu denkleme bilgisayar destekli bir çözüm üretebilmek için farklı bir yol izlenmelidir.

$$\frac{\partial L(w,b,\alpha)}{\partial w} = 0 \quad (3.14)$$

$$\frac{\partial L(w,b,\alpha)}{\partial b} = 0 \quad (3.15)$$

$$\frac{\partial L(w,b,\alpha)}{\partial \alpha} = 0 \quad (3.16)$$

Lagrange denkleminin geleneksel uygulamasına göre yukarıdaki üç eşitlięi ortak bir hesaplamada deęerlendirmek gerekmektedir. Bunun yerine teorik olarak ortak bir ilişki keşfedilerek çözüm yöntemindeki üç deęişkene baęımlılık bire indirgenebilir.

Klasik çözüm uygulanarak Lagrange denklemi tek deęişkene baęımlı hale getirilmelidir. Böylece

$$\frac{\partial L(w,b,\alpha)}{\partial w} = 0 \quad \Rightarrow \quad w = \sum_i \alpha_i y_i x_i \quad (3.17)$$

$$\frac{\partial L(w,b,\alpha)}{\partial b} = 0 \quad \Rightarrow \quad \sum_i \alpha_i y_i = 0 \quad (3.18)$$

bulunur. Bu ifadeler Lagrange denkleminde yerine yazılır. Lagrange denklemi bu sayede tek deęişkene baęımlı hale getirilir [47].

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i (y_i (w \cdot x_i + b) - 1) \quad (3.19)$$

$$L(\alpha) = \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i x_j. \quad (3.20)$$


Sonuç olarak, doğrusal olarak ayrılabilen iki sınıflı bir problem için karar fonksiyonu aşağıdaki şekilde yazılabilir [46].

$$f(x) = \text{sign}\left(\sum_{i=1}^k \lambda_i y_i (x \cdot x_i) + b\right) \quad (3.21)$$

λ_i değişkenleri, Lagrange katsayılarını göstermek üzere $\lambda_i \geq 0$ olmalıdır.

3.4.2.4. Doğrusal ayrılamayan veriler için destek vektör makineleri


Birçok problemde verilerin doğrusal olarak ayrılması mümkün değildir (Şekil 3.17. (a)). Bu durumda doğrusal olmayan bir çizgiye ihtiyaç duyulur. Veriye doğrusal olmayan eğrilerle uymaktansa SVM'yi başka bir uzaya çekirdek (kernel) fonksiyonu aracılığıyla taşıyarak daha tutarlı bir şekilde ayırım sağlanmış olunur. Çekirdek fonksiyonu, sınıflandırmanın yapılabilmesi için veriyi daha yüksek boyutlara taşıyabilir. Çekirdek fonksiyonunun üst boyuta taşınma işlemi güçlü bir yaklaşımdır. Çok karmaşık sınırlarla ayrılan durumlarda bile SVM modellerine izin verir.



(a)

Şekil 3.17. (a) Doğrusal olarak ayrılabilen veri seti [44].

Bu durumda eğitim verilerinin bir kısmının optimum hiper-düzlemin diğer tarafında kalmasından kaynaklanan problem pozitif bir yapay değişkenin (ξ_i) tanımlanması ile çözülür (Şekil 3.17. (b)) [48].



(b)

Şekil 3.17. (b) Doğrusal ayrılamayan veri setleri için hiper-düzlemin belirlenmesi [44].

Sınırın maksimum hale getirilmesi ve yanlış sınıflandırma hatalarının minimum hale getirilmesi arasındaki denge pozitif değerler alan ve C ile gösterilen bir düzenleme parametresi ($0 < C < \infty$) tanımlanmasıyla kontrol edilebilir [49]. Düzenleme parametresi ve yapay değişken kullanılarak doğrusal olarak ayırım yapılamayan veriler için optimizasyon problemi:


$$\min = \left[\frac{\|w\|^2}{2} + C \cdot \sum_{i=1}^r \xi_i \right] \quad (3.22)$$

şeklini alır. Buna bağlı sınırlamalar ise;

$$y_i(w \cdot \phi(x_i) + b) - 1 \geq 1 - \xi_i \quad (3.23)$$

$\xi_i \geq 0$ ve $i = 1, \dots, N$ şeklinde ifade edilir.

Eşitlik (3.22) ve (3.23)'te ifade edilen optimizasyon probleminin çözümü için Şekil 3.18'de görüleceği üzere girdi uzayında doğrusal olarak ayrılamayan veri, özellik uzayı olarak tanımlanan yüksek boyutlu bir uzayda görüntülenir. Böylece verilerin doğrusal olarak ayırımı yapılabilmekte ve sınıflar arasındaki hiper-düzlem belirlenebilmektedir.



Şekil 3.18. Çekirdek fonksiyonu ile verinin daha yüksek bir boyuta dönüştürülmesi [44].

3.4.2.5. Çekirdek (kernel) fonksiyonları

Çekirdek fonksiyonları sınıflandırmanın daha yüksek boyutlarda yapılabilmesi için taşıma işleminde kullanılabilir. Uygulamaların büyük çoğunluğunda birçok çekirdek fonksiyonu iyi sonuçlar verir. Sık kullanılan çekirdek fonksiyonları aşağıda verilmiştir.

1. Polinomial (Polynomial),
2. Radyal Tabanlı (Radial Based),
3. Pearson VII (PUK) ve
4. Normalleştirilmiş Polinom Kerneli (Normalized Polynom Kernel) fonksiyonları [50].

Destek vektör makineleri matematiksel olarak $K(x_i, x_j) = \varphi(x) \cdot \varphi(x_j)$ şeklinde ifade edilen bir kernel fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayırılmasına imkan sağlamaktadır. Sonuç olarak, kernel fonksiyonu kullanarak doğrusal olarak ayıramayan iki sınıflı bir problemin çözümü ile ilgili karar kuralı aşağıdaki şekilde yazılabilir [46]:

$$f(x) = \text{sign}(\sum_i \alpha_i y_i \varphi(x) \varphi(x_i) + b) \quad (3.24)$$

Destek vektör makineleri ile gerçekleştirilecek bir sınıflandırma işlemi için kullanılacak kernel fonksiyonu ve bu fonksiyona ait optimum parametrelerin belirlenmesi esastır.

Literatürde kernel fonksiyonu olarak en sık kullanılan polinom, radyal tabanlı fonksiyon, Pearson VII (PUK) fonksiyonu ve normalleştirilmiş polinom kernelleri Tablo 3.1’de formülleri ve parametreleriyle birlikte sunulmuştur. Tablodan görüleceği üzere her kernel fonksiyonu için bazı parametrelerin kullanıcı tarafından belirlenmesi gerekir. PUK kerneli için belirlenmesi gereken parametre sayısı iki iken, diğer fonksiyonlar için sınıflandırmaya esas olacak model oluşumunda bir parametrenin belirlenmesini gerektirmektedir.

Tablo 3.1. Destek vektör makinelerinde kullanılan temel kernel fonksiyonları ve parametreleri [44].

Kernel fonksiyonu	Matematiksel ifadesi	Parametre
Polinom Kerneli	$K(x, y) = ((x \cdot y) + 1)^d$	Polinom derecesi (d)
Normalleştirilmiş Polinom Kerneli	$K(x, y) = \frac{((x \cdot y) + 1)^d}{\sqrt{((x \cdot x) + 1)^d ((y \cdot y) + 1)^d}}$	Polinom derecesi (d)
Radyal Tabanlı Fonksiyon Kerneli	$K(x, y) = e^{-\gamma \ x - x_i\ ^2}$	Kernel boyutu (γ)
Pearson VII (PUK) Kerneli	$\frac{1}{\left[1 + \left(\frac{2\sqrt{\ x - y\ ^2 \sqrt{2^{(1/\omega)} - 1}}}{\sigma} \right)^2 \right]^\omega}$	Pearson genişliği parametreleri (σ, ω)

Kernel fonksiyonları karşılaştırıldığında polinom ve radyal tabanlı kernellerin daha sade ve anlaşılabilir olduğu ifade edilebilir. Matematiksel olarak basit görünse de, polinomun derecesindeki artış algoritmanın karmaşık bir hal almasına neden olmaktadır. Bu da hem işlem süresini önemli ölçüde artırmakta hem de bir noktadan sonra sınıflandırma doğruluğunu düşürmektedir. Buna karşın radyal tabanlı fonksiyonun kernel boyutu (γ) olarak ifade edilen parametresindeki değişimlerin

sınıflandırma performansına etkisinin daha az olduğu görülmüştür [51]. Normalleştirilmiş polinom fonksiyonu ise veri setinin normalleştirilmesi yerine polinom kernele ait matematiksel ifadenin normalleştirilmesi amacıyla Arnulf vd. (2001) tarafından önerilmiştir. Normalleştirilmiş polinom kernelinin polinom kernelinin genelleştirilmiş bir hali olduğu söylenebilir. Diğer taraftan, PUK kerneli Pearson genişliği olarak bilinen (σ, ω) iki parametresi ile diğer kernel fonksiyonlarına göre daha karmaşık bir matematiksel yapıya sahiptir. Bu iki parametre sınıflandırma doğruluğuna etki etmekte ve hangi parametre çiftinin en iyi sonuç vereceği önceden bilinmemektedir. Bu nedenle PUK kernelinin kullanımında en uygun parametre çiftinin belirlenmesi önemli bir aşamadır.


Kernel fonksiyonuna özgü parametrelerin yanında tüm destek vektör makineleri için düzenleme parametresi C 'nin kullanıcı tarafından belirlenmesi gerekir. Bu parametre için olması gerekenden çok küçük veya çok büyük değerler seçilmesi durumunda optimum hiper-düzlem doğru belirlenemeyeceğinden sınıflandırma doğruluğunda ciddi düşüş beklenir. Diğer taraftan $C = \infty$ olması durumunda SVM modeli sadece doğrusal olarak ayrılabilen veri setleri için uygun hale gelir. Buradan da görüleceği üzere parametreler için uygun değerlerin seçimi SVM sınıflandırıcısının performansını direkt olarak etkileyen bir faktör durumundadır [52,53]. Genellikle deneme ve hata stratejisi kullanılmasına karşın, çapraz doğrulama yaklaşımı başarılı sonuçlara ulaşılmasına olanak sağlamaktadır. İdeal olarak bir SVM analizi, tamamen iki ayrı sınıflandırma sonucunu ve özellik vektörlerini ayıran çok boyutlu düzlemi üretmelidir. Yine de, mükemmel sınıflandırma mümkün olmayabilir. Modelin veriyi iyi bir şekilde genellemediği ve çok fazla özellik vektörleri üreterek sonuca ulaştığı zamanlar olabilir. Bundan dolayı çapraz geçerli kılma kesinliği, doğru şekilde sınıflandırılmış olan verinin yüzdesi olur. Çapraz geçerli kılma prosedürü, uygunsuzluk problemini engelleyebilir. Çapraz doğrulama yaklaşımında amaç oluşturulan sınıflandırma modelinin performansının belirlenmesidir. Bu amaçla veri seti iki kısma ayrılır. Birinci kısım sınıflandırmaya esas olan model oluşumunda eğitim verisi olarak kullanılırken ikinci kısım modelin performansının belirlenmesi amacıyla test verisi olarak işleme konur. Eğitim seti ile oluşturulan modelin test veri setine uygulanması sonucunda doğru sınıflandırılan örneklerin sayısı sınıflandırıcının performansını gösterir [44]. Dolayısı ile çapraz geçerlilik yöntemi kullanılarak en iyi

sınıflandırma performansının elde edildiği kernel parametrelerinin belirlenmesi ve sınıflandırmaya esas olacak model oluşturulmuştur.

3.4.2.6. Çok sınıflı destek vektör makineleri

Destek vektör makineleri yönteminin, diğer sınıflandırma yöntemlerinden en temel farkı, sadece iki sınıfı birbirinden ayırabilmesidir. İki'den fazla sınıfın olduğu bir sistemde, SVM yöntemini kullanabilmek için çeşitli algoritmalar geliştirilmiştir. Bu algoritmaların en çok kullanılanları şunlardır: bire karşı hepsi ve bire karşı bir. Bu çalışmada uygulamanın SVM ile gerçekleştirilmesinde bire karşı hepsi algoritması kullanılmıştır.

Bire karşı hepsi; Bu yöntemde eğitim aşamasında sınıflardan biri (+) kabul edilirken, kalan diğer tüm sınıflara ait bilgiler (-) olarak kabul edilerek M sınıf için, M adet SVM oluşturulur. Tanınması istenilen örnek hangi SVM tarafından (+) sınıflandırılırsa o sınıfa aittir [54]. Bire karşı hepsi yönteminin örnek uygulaması Şekil 3.19'daki gibidir.



Şekil 3.19. SVM için bire karşı hepsi örneği.

3.4.2.7. Destek vektör makinelerin avantajları ve dezavantajları

Destek vektörü öğrenme, basit fikirler üzerine kurulma ve pratik uygulamalarda yüksek performans göstermesi bakımından oldukça kullanışlıdır. SVM'lerde kullanılacak örnek sayısı önemli değildir. SVM eğitim esnasında görülmemiş verileri de sorunsuz olarak sınıflandırır. Bu SVM'nin genelleştirebilme yeteneğini gösterir. Genelleştirebilme özelliği SVM'yi diğer tekniklere göre (YSA, karar ağacı vs.) iyi bir alternatif yapmaktadır ve avantaj sağlamaktadır. Son zamanlarda ise örüntü

tanıma, yüz bulma ve tanıma, veri madenciliği, dil yapısını inceleyen mantıksal programlamalarda, uçak alt basınç profillerinin modellenmesi, biyoloji ve diğer biyoinformatik uygulamalarda, gen analizlerinde ve proteinlerin sınıflandırılmasında SVM kullanılmaya başlanmıştır [41].

Bazı durumlarda Lagrange Optimizasyon fonksiyonunun hesaplanması sorunlu ve karmaşık hal alabilir. Kernel fonksiyonları karşılaştırıldığında polinom ve radyal tabanlı kernellerin daha sade ve anlaşılabilir olduğu ifade edilebilir. Matematiksel olarak basit görünse de, polinomun derecesindeki artış algoritmanın karmaşık bir hal almasına neden olmaktadır. Bu da hem işlem süresini önemli ölçüde artırmakta hem de bir noktadan sonra sınıflandırma doğruluğunu düşürmektedir. Bu durum algoritmaya bir dezavantaj sağlamaktadır. Öte yandan genelleme işlemini iyi gerçekleştirse de veri çiftlerini eğitmede o kadar iyi model olamayabiliyor. Öznitelikleri istatistiksel olarak modelleyen bir öğrenme modeli olduğundan doğrudan yüz görüntüleri üzerinde çalışırsa başarısız oluyor. Bu da algoritmanın başka bir dezavantajıdır [51].

BÖLÜM 4. PNN VE SVM KULLANARAK DWT TABANLI YÜZ TANIMA

Dördüncü bölüm yapılan çalışmanın uygulama kısmını içerir. Bu bölümde geliştirilen algoritmanın çalışma sürecinde vermiş olduğu sonuçlara göre başarı performansı ve doğruluk oranı yüzdesel ve süre bakımından incelenmiş ve değerlendirilmiştir. Ayrıca, sonuçlar tablolar halinde verilmiş ve başarı performansları karşılaştırılmıştır.


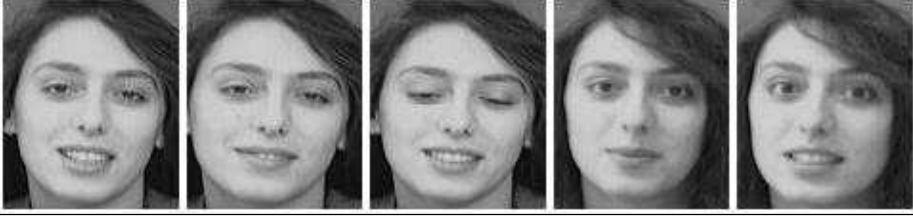

4.1. Uygulamanın Gerçekleştirildiği Ortam

Uygulama MATLAB, R2013a, 32-bit (win 32) programlama versiyonunda geliştirildi.

Uygulama bu özelliklere sahip bilgisayarda çalıştırıldı; İşlemci Intel(R) Core(TM) 3.2 GHz; RAM 6.00 GB; Sistem türü 64-bit işletim sistemi.

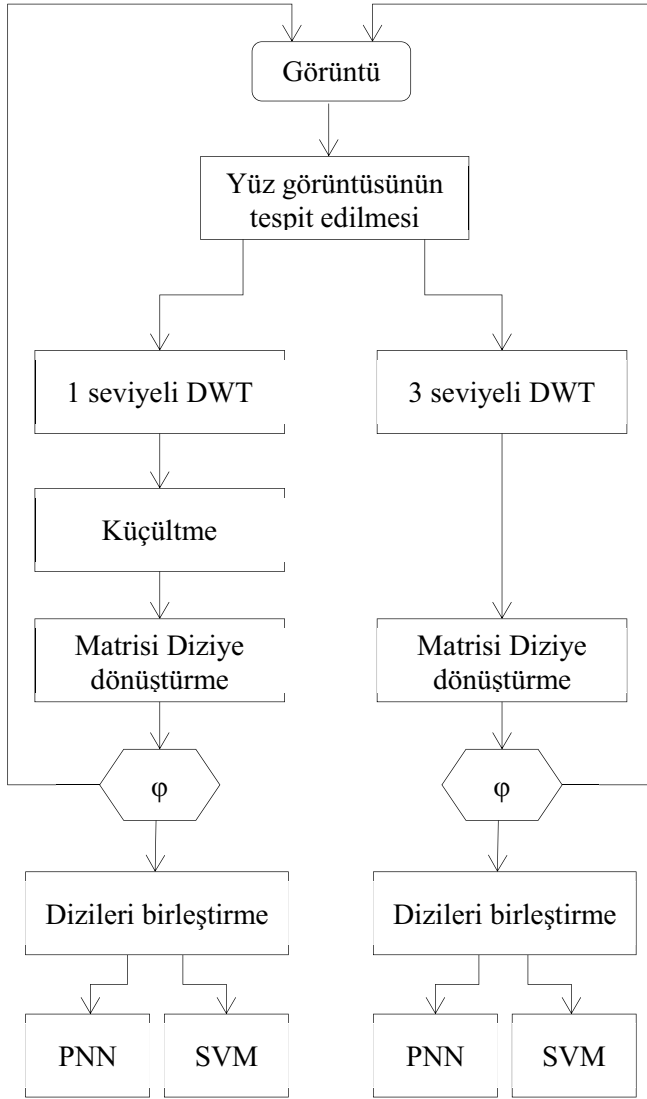
Çalışmada veri tabanı olarak Cambridge ORL kullanıldı. Veri tabanı oldukça yüksek derecede ifade değişikliği, poz ve yüz ayrıntıları içerir. Veri tabanında 40 kişinin 5'er farklı görüntüsü bulunur. Dolayısı ile yüz veri tabanı, 112x92 boyutunda, mevcut 200 görüntüden oluşmaktadır. Veri tabanındaki görüntüler gri seviyeli görüntülerdir. Aşağıda tablo görünümünde ORL veri tabanı örneği sunulmuştur.

Tablo 4.1. ORL veri tabanı örneği.

Kişi	ORL veri tabanındaki görüntüler	Sayı
1.		5
2.		5
...
40.		5
		$\Sigma=$ 200

4.2. Geliştirilen Yüz Tanıma Sisteminin Çalışma Akışı ve Uygulamanın Gerçekleştirilmesi

Aşağıda geliştirilen sistemin çalışma akışı ve uygulamanın gerçekleştirilmesi aşama aşama açıklanmıştır. Şekil 4.1’de geliştirilen yüz tanıma sisteminin çalışma şeması verilmiştir.























Şekil 4.1. Geliştirilen yüz tanıma sisteminin çalışma şeması.

İlk önce sisteme girdi olarak bir kişinin görüntüsü verilmiştir. Yüzün tanınması için öncelikle yüz görüntüsünün tespit edilmesi gerekir. Bu yüz algılama aşamasında Viola-Jones yüz tespit algoritması kullanarak yüz belirlenmiştir. Bu sayede, öncelikle yüz detektörü yüzün olduğu bölgeye odaklanır. Tablo 4.2’de Viola-Jones yüz tespit algoritması sonrası oluşan görüntüler verilmiştir. Bu aşamada görüntüde yüz detektörünün kapsam altına aldığı büyüklükteki yüz bölgesi kesilir. Bu sayede arka plan elimine edilerek sisteme sadece kişinin yüz görüntüsü sunulur. Tablo 4.2’de kesme işlemi sonrası elde edilen görüntüler verilmiştir. Burada ifade etmek gerekir ki Viola-Jones yüz tespiti algoritmasını kullanmadan önce korelasyon yöntemi denenmiştir. Fakat düşük düzeyde sonuç vermesinden dolayı korelasyon yöntemi tercih edilmemiştir. Bir sonraki aşamada elde edilen yüz görüntüsü küçültme

işlemine tabi tutulur. Amaç yüz detektöründen elde edilen görüntülerin boyutlarının farklı büyüklükte olabilme olasılığını göz önünde bulundurarak bütün görüntüleri aynı boyuta getirmektir. Böylece sistemde olası hatalar en aza indirgenmiş olur. Yapılan denemelerde kesme işlemi sonrasında kenar bulma ve eşikleme işlemleri de denenmiştir. Kenar bulmadan sonra görüntü küçültme işlemine tabi tutulduktan sonra elde edilen görüntü sıfır piksellerinden oluşurken, oysa eşiklemeden sonra görüntü küçültme işleminden geçirildikten sonra elde edilen görüntü kalitesi çok düşük olduğu sonucuna varılmıştır ve bu yöntemler tercih edilmemiştir. Bir sonraki aşamada öznitelik çıkartmak amacı ile yüz görüntüsü DWT işlemine tabi tutulur. Bu aşamada sistem iki tür dönüşüm yapacaktır. Birincisi 1 seviyeli DWT, ikincisi ise 3 seviyeli DWT. Bundan sonraki aşamalarda işlemler iki yönde olacaktır. Birinci yöndeki işlemler 1 seviyeli DWT'den aldıkları sonuçları değerlendirirken, ikinci yöndeki işlemler 3 seviyeli DWT'den aldıkları sonuçları değerlendirirler. İleriki aşamada birinci yöndeki işlemler 1 seviyeli DWT dönüşümü sonrası aldıkları sonuçları küçültme işleminden geçirirler. Tablo 4.2'de 1 seviyeli DWT dönüşüm sonrası ve küçültme işlemi sonrası alınan görüntüler verilmiştir. Bu şekilde görüntülerin küçültülmüş halleri ileriki işlemlerde kullanılır. Amaç görüntüleri daha az piksel değerleriyle işlemlerden geçirip sistemin işlem süresini azaltmaktır. Bundan sonraki adımda görüntülerin matris şeklindeki değerlerini diziye dönüştürme işlemi yer alır. Bir sonraki adım eğitim veri setini ve test veri setini oluşturma aşamasıdır. Veri tabanında bulunan 200 görüntüden 140 tanesi eğitim veri seti için, diğer 60 görüntü ise test veri seti için ayrılmıştır. Eğitim veri setini oluşturmak için her görüntü için yukarıda belirtilen adımlar tekrarlanmalıdır. Bunu gerçekleştirmek için bir döngü kurarak veri setine 140 defa erişilir. Sonuç olarak 140 tane ayrı dizi oluşturulur. Aynı işlem test veri seti için de geçerli olup yalnız bu durumda döngü 60 kez tekrarlanır. Bu işlem sistemin çalışma şemasında ϕ olarak kısaca ifade edilmiştir (Şekil 4.1). İkinci yöndeki işlemler 3 seviyeli DWT dönüşümü sonrası aldıkları sonuçları küçültme işlemine tabi tutmadan doğrudan matrisi diziye dönüştürme işlemine geçirirler. Bunun sebebi görüntüye 3 kez dönüşüm işlemi uygulandığında piksel değerleri büyük oranda azaltılmış ve boyutu küçültülmüş olacaktır. Dolayısı ile 3 seviyeli DWT'den alınan görüntü sonucu birinci yöndeki küçültme işleminden geçirilen görüntü boyutu ile yakın olacaktır. Tablo 4.2'de 3 seviyeli DWT işlemi sonrası elde edilen görüntüler verilmiştir.

Tablo 4.2. Kişilerden alınan görüntülerin Viola-Jones algoritması sonrası, Kesme işlemi sonrası, 1 seviyeli DWT sonrası, Küçültme işlemi sonrası, 3 seviyeli DWT sonrası görüntü değişiklikleri sonuçları.

Kişi Yöntem	1. Kişinin	1. Kişinin	2. Kişinin	2. Kişinin
	1. Görüntüsü	2. Görüntüsü	1. Görüntüsü	2. Görüntüsü
Viola-Jones algoritması sonrası görüntüler				
Kesme işlemi sonrası görüntüler				
1 seviyeli DWT sonrası görüntüler				
Küçültme işlemi sonrası görüntüler				
3 seviyeli DWT sonrası görüntüler				

Bir sonraki adım oluşan dizileri birleştirme adımdır.

$$\begin{bmatrix} 102 & 56 & 74 & \cdots & 62 \\ 85 & 71 & 67 & \cdots & 55 \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ 64 & 72 & 85 & \cdots & 19 \end{bmatrix} \begin{matrix} 1. \text{kişiyeye ait yüz bilgileri} \\ 2. \text{kişiyeye ait yüz bilgileri} \\ \cdots \\ 140. \text{kişiyeye ait yüz bilgileri} \end{matrix} \quad (4.1)$$

Böylece çıkışlar $a \times 140$ (a sistemde görüntünün küçültme boyutuna göre değişir, Tablo 4.2) boyutundaki matris şeklinde sistemin son aşaması olan sınıflandırma aşamasına verilir. Bu aşama yüz tanıma işlemi aşamasıdır. Bu aşamada iki farklı sınıflandırıcı kullanılmıştır. Birincisi PNN, ikincisi ise SVM sınıflandırıcılarıdır. Dizilerden oluşan matris her sınıflandırıcının girişine ayrı ayrı verilir. Test için

sisteme verilen yüz görüntülerinin eğitim setindeki görüntülerle benzerlikleri sınıflandırıcılar tarafından hesaplanır ve sistem en yakın görüntü ile çıkış verir. Uygulamalardan alınan sonuçlar ve yapılan değerlendirmeler sonucu iki yöntemin başarı performanslarının farklılık gösterdiği görülmüştür. Dolayısı ile yüz tanıma sistemi çalışmasında, kullanılan iki yöntemden PNN daha iyi performans gösterirken, SVM ise daha düşük bir performans göstermiştir. PNN ve SVM yöntemlerinin başarı performansları Tablo 4.3 ve Tablo 4.4'te gösterilmiştir. 2 seviyeli ve 4 seviyeli DWT işlemi de kullanılmış fakat sonuçların düşük performans vermesinden dolayı tablolarda gösterilmesine gerek duyulmamıştır.

4.3. Olasılıksal Sinir Ağı ve Destek Vektör Makinelerinin Başarı Performanslarının Karşılaştırılması

Aşağıda 1 seviyeli ve 3 seviyeli DWT'nin uygulanması sonucu elde edilen sonuçların değerlendirilmesi yapılmış ve PNN ve SVM'nin başarı performansları tablolarla karşılaştırılmıştır.

Tablo 4.3'te görüldüğü gibi ilk yöntemde görüntüye 1 seviyeli DWT uygulandıktan sonra küçültme işleminden geçirilmeden diğer işlemlere tabi tutulur. $m \times n$ (40x38) boyutundaki görüntüye PNN uygulandığında, sistemin çalışma süresi $t=0.7150$ sn, yüz tanıma başarı performansı %85'e ulaşmıştır. PNN kullanıldığında elde edilen bu sonuç bu çalışmada kaydedilen en yüksek sonuç olmuştur. Oysa aynı görüntüye SVM uygulandığında, sistemin çalışma süresi $t=1.4565$ sn ve başarı performansı sadece %68.333'e kadar ulaşmıştır. Dolayısı ile sonuçlardan da anlaşılacağı üzere ilk yöntemde PNN'nin başarı performansının SVM'ye göre daha iyi olduğu görülmüştür. İkinci yöntemde küçültme işleminden geçirilen görüntüye (20x19) uygulanan PNN ve SVM yöntemlerinin başarı performansları verilmiştir. PNN, $t=0.0825$ sn sürede, %83.333 oranında başarı göstermiştir. SVM, $t=0.8081$ sn sürede, %71.666 oranında başarı göstermiştir. İkinci yöntemde de PNN'nin başarı üstünlüğü olduğu görülmüştür. Üçüncü yöntemde de ikinci kez küçültme işleminden geçirilen görüntüye (10x10) uygulanan PNN ve SVM yöntemlerinin başarı performansları açıklanmıştır. Burada PNN, $t=0.0541$ sn sürede, %78.333 oranında başarı gösterirken, SVM ise $t=0.7531$ sn sürede, %70 oranında başarı göstermiştir. Sonuç

olarak bu sistemde PNN'nin başarı performansının SVM'ye göre daha yüksek olduğu kanıtlanmıştır.

Tablo 4.3. 1 seviyeli DWT uygulanması sonucu PNN ve SVM başarı performansları.

1 seviyeli DWT			PNN	SVM
küçültme yapmadan	m=40, n=38	%	85	68.333
		t[sn]	0.7150	1.4565
küçültme	m=20, n=19	%	83.333	71.666
		t[sn]	0.0825	0.8081
küçültme	m=10, n=10	%	78.333	70
		t[sn]	0.0541	0.7531

Tablo 4.4'te de Tablo 4.3'teki gibi PNN ve SVM yöntemlerinin uygulama sonuçları açıklanmış ve başarı performansları karşılaştırılmıştır. Burada görüntüye 3 seviyeli DWT uygulanmıştır. Bir görüntünün 3 seviyeli DWT'den geçirildikten sonra boyutu istediğimiz ölçülerde küçüldüğünden küçültme işlemine tabi tutulmaya gerek duyulmamıştır. Çıkış görüntüsüne (11x10) PNN ve SVM yöntemleri uygulandıktan sonra Tablo 4.4'te gösterilen değerler elde edilmiştir. PNN uygulandığında t=0.570 sn sürede %83.3333 başarı performansı göstererek, SVM uygulandığında ise t=0.9205 sn sürede sadece %70'e kadar başarı performansına ulaşmıştır. Bu uygulamada da PNN'nin başarı performansının SVM'ye göre daha yüksek olduğu görülmüştür.

Tablo 4.4. 3 seviyeli DWT uygulanması sonucu PNN ve SVM başarı performansları.

3 seviyeli DWT			PNN	SVM
küçültme yapmadan	m=11, n=10	%	83.3333	70
		t[sn]	0.6394	0.9205

Yapılan deęerlendirmelerden sonra zet olarak řu sonuca varılmıřtır: PNN daha kısa sre iin daha yksek bařarı performansı gsterirken, SVM daha uzun sre iin daha dřk performans gstermiřtir. Ayrıca, PNN'nin bařarı performansı grnt kldke byk bir oranda dřerken, SVM'nin bu konuda daha sabit olduęu sonucuna varılmıřtır.

BÖLÜM 5. SONUÇLAR VE ÖNERİLER

Biyometrik tanımlama yöntemleri günümüzde önemi hızla artan bir uygulama ve araştırma konusu haline gelmiştir. Tanımlamada kullanılan biyometrikler yüz, parmak izi, el geometrisi, retina, iris, ses, DNA olarak sıralanabilir.

Bu çalışmanın amacı, iki sınıflandırıcı yöntemi kullanarak insan yüzünün bilgisayar ile tanınmasını hızlı bir şekilde sağlamaktır. Bu şekilde pek çok alanda kolaylıklar sağlanacak, güvenlik sistemleri tarafından yüz tanıma ile kişisel bilgilere ulaşılma daha kolay hale gelecektir.

Yapılan çalışmalardan, gerçekleştirilen uygulamalardan, elde edilen sonuçlardan, yapılan incelemelerden ve değerlendirmelerden şu sonuçlara varılmıştır.

Yüz tanıma ve doğrulama sistemlerinin en önemli aşaması, görüntüde yer alan yüzlerin bulunmasıdır. Bulunan yüzlerin sayısı ve kalitesi, yüz tanımanın başarısını doğrudan etkilediği sonuçlanmıştır.

Kullanılan sınıflandırıcıların performansları karşılaştırılmıştır. Sınıflandırıcı olarak iki farklı yöntem kullanılmıştır. Birincisi; Olasılıksal Sinir Ağı (PNN) yöntemi, ikincisi ise Destek Vektör Makineleri (SVM) yöntemidir. Özellik çıkarıcı olarak Ayırık Dalgacık Dönüşümü (DWT) kullanılmıştır. Sonuçlar tablolarla gösterilmiştir. Çalışmada 1 seviyeli ve 3 seviyeli DWT uygulanarak ve 1 seviyeli DWT işleminden sonra görüntü farklı boyutlarda küçültülerek değişik denemeler yapılmıştır. 1 seviyeli DWT dönüşümü sonrası 40x38 boyutundaki görüntülere PNN uygulandığında, $t=0.7150$ sn için başarı performansı %85'e ulaşmıştır. Görüntüler 20x19 boyutunda küçültüldüğünde ve PNN uygulandığında $t=0.0825$ sn sürede başarı oranı %83.333 olarak tespit edilmiştir. SVM uygulandığında ise $t=0.7531$ sn'lik işlem süresinin

altına inmezken başarı oranı ise %71.666'yı geçememiştir. Yapılan değerlendirmelerden sonra özet olarak şu sonuca varılmıştır. 3 kere DWT uygulandığında elde edilen doğruluk oranları, 1 kere DWT uygulandığında elde edilen doğruluk oranları ile aynı olduğunda işlem süreleri daha fazladır. Dolayısı ile görüntüye 3 kere DWT uygulanması yerine 1 kere DWT uygulanarak küçültme yapılmasının daha avantajlı olduğu tespit edilmiştir. Ayrıca PNN daha kısa sürede daha yüksek başarı performansı gösterirken SVM ise daha uzun sürede daha düşük performans göstermiştir. Görüntü küçüldükçe PNN'nin başarı performansı ve işlem süresi büyük oranda düşerken, SVM'nin bu konuda daha sabit olduğu sonucuna varılmıştır.

Sistemde başka yöntemler de denenmiştir. Viola-Jones yüz tespiti algoritması ile birlikte köşe tespit yöntemi de kullanılmıştır. Bir sürü denemelere rağmen düşük düzeyde sonuçlar alındığından bu yöntem tercih edilmemiştir. Kenar bulma yöntemi sonrası görüntüler küçültme işlemine tabi tutulduktan sonra sonuç sıfır çıkmıştır. Bu yöntem kullanımdan çıkarılmıştır. Eşikleme sonrası görüntüler küçültme işleminden geçirildikten sonra sonuç çok düşük çıkmıştır. Bu yöntemin kullanımına yer verilmemiştir.

Çalışmalarda 200 görüntüden (112x92) oluşan ORL veri tabanı kullanılmıştır. Buna ilişkin verilerin sayısı arttıkça başarı performansının yükseldiği, fakat çalışma süresinin de arttığı sonuçlanmıştır.

Bu alanda yapılan çalışmalar incelendiğinde, yüz tanımanın başarı oranı, diğer yöntemlere göre düşük kalsa da, kullanım açısından diğer biyometrik yöntemlere göre avantajlı olduğu noktaların da bulunduğu görülmüştür. Örneğin, yüz tanıma için kişiden örnek almak diğerlerine göre çok daha kolaydır. İris veya retina taraması yapmak için; kişinin göz tarayıcısına bakması veya parmak izi tanımda kişinin parmağını gerekli cihazın üzerinde tutması gibi zorunluluklar vardır. Oysa yüz tanıması için uygun açı ve mesafeden bir görüntü almak yeterlidir. Böylece kişiler rahatsız olmadan örnek biyometri görüntüsü toplanabilmektedir. Ayrıca yüz tanımda kullanılan veri, daha okunabilir ve anlaşılabilir olduğu sonucuna varılmıştır.

Uygulamada yüz tanıma ile gerçekleştirilen güvenlik sistemlerinde, yanlış tanımların görevliler tarafından göz ile de kontrol edilmesi mümkündür. Diğer yöntemler için bu kontrol işlemi yüz tanımaya göre oldukça zor olduğu görülmüştür.

Yüz tanıma konusu, üzerinde uzun yıllardır çalışılan bir alan olmasına rağmen henüz istenilen başarı düzeyine erişilememiştir. Elde edilen başarılı tanıma oranları kontrollü ortamlarda çekilmiş görüntüler içeren veri tabanlarıyla sınırlı kalmaktadır. Üç boyut poz farklılıkları, değişik yüz ifadeleri, aydınlatma farklılıkları, makyaj, saç stili, arka plan farklılıkları, gürültü ve ölçek farklılıkları gibi dış faktörler yüz tanıma işleminin başarısını oldukça düşürdüğü sonucuna varılmıştır. Özellikle video gibi poz ve aydınlatmanın çeşitlilik gösterdiği ve görüntü çözünürlüğünün düşük olduğu veri tabanlarında yüz tanımak çok daha zor bir problem haline gelmektedir. Gerçek zamanlı ortamları daha iyi yansıtan görüntü, video, ses, müzik gibi farklı verileri bir arada içeren ortamlarda yüz tanıma problemini incelemek, kontrollü ortamlarda elde edilmiş görüntüleri incelemekten çok daha farklı ve geniş kullanım alanlarına sahip olduğu görülmüştür. Bu ortamlarda etkin bir erişim ve değerlendirme yapabilmenin ana koşulu, anlamsal bilgilerin çıkarılması ve ulaşılabilir hale getirilmesi neticesine varılmıştır.

Aşağıda çalışma ile ilgili bazı öneriler verilmiştir;

Sistemde Karmaşık DWT kullanılabilir. DWT'nin yerine farklı yöntemler de kullanılabilir. Örneğin Gabor filtresi. İleride yapılacak çalışmalarda Karmaşık DWT ve Gabor filtreleri kullanımlarına yer verilecek, böylece başarı performansına sağladıkları katkılar değerlendirilecektir.

Sistem statik sahnedeki kişinin yüz görüntüsünü alıp tanıma imkanı vermektedir. İleride yapılacak çalışmalarda, bazı eklemelerle sistem aynı zamanda video sahnesindeki yüz görüntülerini tanıma imkanı sağlayabilir.

KAYNAKLAR

- [1] JAIN, A.K., BOLLE, R.M., PANKANTI, S., EDS., Biometrics: Personal Identification in a networked Society, Norwell, MA:Kluwer, 1999.
- [2] PANKANTI, S., PRABHAKAR, S., JAIN, A.K., ULUDAĞ, U., Biometric cryptosystems: issues and challenges, In Proceedings of the IEEE Special Issue on Enabling Security Technology for Digital Rights Management, 92 (6): 948-960, 2004.
- [3] SINGH, P.K., SARMA, G., Internet banking: risk analysis and applicability of biometric technology for authentication, Int. J. Pure Appl. Sci. Technol., 1 (2): 67-78, 2010.
- [4] TOLBA, A.S., EL-BAZ, A.H., EL-HARBY, A.A., Face recognition: a literature review, International Journal of Signal Processing, 2(2): 88-103, 2005.
- [5] ABATE, A.F., NAPPI, M., RICCIO, D., SABATINO, G., 2D and 3D face recognition: A survey, Pattern Recognition Letters, 28: 1885–1906, 2007.
- [6] GÖKBERK, B., İRFANOĞLU, M.O., AKARUN, L., ALPAYDIN, E., Optimal gabor kernel selection for face recognition, Proceedings of the IEEE International Conference on Image Processing, Barcelona, 677-680, 2003.
- [7] ÖZDEMİR, A., Dalgacık dönüşümünü kullanarak ön cepheden çekilmiş insan yüzü resimlerinin tanınması, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş, 5-32, 2007.
- [8] ÖZDEMİR, A., ARTIKLAR, M., İki boyutlu dalgacık dönüşümü kullanarak ön cepheden çekilmiş insan yüzü resimlerini tanıma üzerine yaklaşımlar, KSÜ Mühendislik Bilimleri Dergisi, 12(1): 6-9, 2009.
- [9] ÖZKAYA, N., SAĞIROĞLU, Ş., Parmak izinden yüz tanıma, Gazi Üniv. Müh. Mim. Fak. Der., 23(4): 785-793, 2008.
- [10] MUHAMMAD, İ., TELATAR, Z., TÜZÜNALP, Ö., Yüz algılama algoritmalarında tarama zamanının azaltılması için bir hızlı ön tarama algoritması, IEEE 9. Sinyal İşleme ve Uygulamaları Kurultayı, Gazimağusa-Kıbrıs, 565-570, 2001.

- [11] GÜMÜŞ, E., Yüz tanıma problemine karma yöntemlerin uygulanması, Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-15, 2008.
- [12] ERGEZER, H., Yüz tanıma: Öz yüzler, yapay sinir ağları, gabor, dalgacık dönüşümü yöntemleri, Yüksek Lisans Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 1- 4, 2003.
- [13] ANBARJAFARI, G., A new face recognition system based on colour statistics, Yüksek Lisans Tezi, Doğu Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Gazimağusa, 1-4, 2008.
- [14] DEMİREL, H., ANBARJAFARI, G., Renkli histogram eşleştirme tabanlı yeni bir yüz tanıma sistemi, IEEE 16. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Didim, 609-612, 2008.
- [15] KIRTAÇ, K., Gabor feature based face recognition using nearest neighbor discriminant analysis, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-14, 2008.
- [16] TOPKAYA, İ.S., Video görüntülerinden yüz tanıma, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 4-5, 2008.
- [17] ACAR, C., ATLAS, A., ÇEVİK, K., ÖLMEZ, İ., ÜNLÜ, M., ÖZKAN, D., DUYGULU, P., Systematic evaluation of face detection algorithms on news videos, IEEE 15. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Eskişehir, 1200-1203, 2007.
- [18] GÜNDÜZ, H., Altuzay temelli yaklaşımlar kullanarak gerçek zamanlı yüz tanıma”, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir, 11-22, 2010.
- [19] KERN, D., EKENEL, H.K., STIEFELHAGEN, R., Illumination subspaces based robust face recognition, 14th IEEE Signal Processing and Communications Applications Conference, Antalya, 1-4, 2006.
- [20] GONZALEZ, C., WOODS, R., Digital Image Processing, 2, Pentice Hall, New Jersey, 2012.
- [21] DUDA, R.O., HART, P.E., STORK, D.G., Pattern Classification, 2nd ed., Wiley Interscience, U.S.A., 2000.
- [22] BISHOP, C.M., Neural Networks for Pattern Recognition, Clarendon Press, Oxford, 1996.
- [23] BAYKAN, N., Robotik bir mikroskop sisteminden elde edilen görüntülerin görüntü işleme ve yapay zekâ yöntemleri ile analizi, Doktora, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Ağustos, 2010.

- [24] JAEHNE, B., Practical Handbook on Image Processing for Scientific Applications, CRC Press, ISBN:0-8493-8906-2, 1997.
- [25] JOHN C.R., The Image Processing Hand Book, Third Edition, CRC Press, ISBN:0-8493-2532-3, 1999.
- [26] JAEHNE, B., Digital Image Processing, p.598., 2002.
- [27] TÜRKOĞLU, İ., Örüntü Tanıma Sistemleri, Ders Notları, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2003.
- [28] ALPAYDIN, E., Yapay Öğrenme, Boğaziçi Üniversitesi Yayınevi, İstanbul, 2011.
- [29] YAMAN, B., Özyüz kullanarak yüz tanıma, Y.Lisans, Sakarya Üniversitesi, Temmuz, 2006.
- [30] KONAK, E.S., Bilgisayar destekli yüz tanıma, Y.Lisans, İstanbul Üniversitesi, Haziran, 2006.
- [31] VIOLA, P., JONES, M., Rapid object detection using a boosted cascade of simple features, IEEE Computer Vision and Pattern Recognition I-511- I-518., 2001.
- [32] VIOLA, P., JONES, M., Robust Real-Time Face Detection, International Journal of Computer Vision 57: 2137-154, 2004.
- [33] CROW, F., Summed-area tables for texture mapping, In Proceed-ings of SIGGRAPH, 18(3): 207- 212, 1984.
- [34] FREUD, J., SCHAPIRE, R.E., A decision-theoretic generalization of on-line learning and an application to boosting, In Computational Learning Theory: Eurocolt 95, Springer-Verlag, pp. 23-37, 1995.
- [35] AMIT, J., GEMAN, D., A computational model for visual selection, Neural Computation, 11: 1691-1715, 1999.
- [36] FLEURET, F., GEMAN, D., Coarse-to-fine face detection, Int. J. Computer Vision, 41: 85-107, 2001.
- [37] XU, L., Face Detection by Boosting, CS559 Machine Learning Course Project, April 30, 2009.
- [38] POLKAR, R., The story of wavelets, IMACS/ IEEE CSCC 99, pp. 5481-5486, 1999.

- [39] ROTHE, I., SUSSE, H., VOSS, K., The Method of Normalization to determine Invariants, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 18, No. 4, April, 1996.
- [40] ÇEKLİ, S., UZUNOĞLU, C.P., Olasılıksal Sinir Ağları İle Kaotik Devre Çıkışı Örüntülerinin Sınıflandırılması, IEEE 19th Signal Processing and Communications Applications Conference (SIU 2011), pp. 170-173, 2011.
- [41] KECCMAN, V., Learning and Soft Computing: support vector machines, neural networks, and fuzzy logic models, II. Series, A brandford book, Massachusetts Institute of Technology, USA, 2001.
- [42] VAPNIK, V.N., The Nature of Statistical Learning Theory, Springer-Verlag, New York, 1995.
- [43] VAPNIK, V.N., The Nature of Statistical Learning Theory, 2. Baskı, Springer-Verlag, New York, 2000.
- [44] KAVZOĞLU, T., ÇÖLKESEN, I., A Kernel Functions Analysis for Support Vector Machines for Land Cover Classification, International Journal of Applied Earth Observation and Geoinformation, 11(5): 352-359, 2009.
- [45] SADİ, E.Ş., İş Zekası ve Veri Madenciliği, Cinius Yayınları, 2013.
- [46] OSUNA, E.E., FREUND, R., GIROSI, F., Support Vector Machines: Training and Applications, A.I. Memo No. 1602, C.B.C.L. Paper No. 144, Massachusetts Institute of Technology and Artificial Intelligence Laboratory, Massachusetts, 1997.
- [47] BERTSEKAS, D.P., Nonlinear Programming, Massachusetts Institute of Technology, Belmont, 1999.
- [48] BURGESS, C.J.C., A Tutorial on Support Vector Machines for Pattern Recognition. Data Mining and Knowledge Discovery, Vol.2, no.2, pp. 121-167, 1998.
- [49] CORTES, C., VAPNIK, V., Support-Vector Network, Machine Learning, 20(3): 273–297, 1995.
- [50] HAYKIN, S., Neural Networks: A Comprehensive Foundation, Prentice-Hall, New Jersey, 1999.
- [51] HSU, C.W., CHANG, C.C., LIN, C.J., A Practical Guide to Support Vector Classification, <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>, 2010.
- [52] LIN, S.W., YING, K.C., CHEN, S.C., LEE, Z.J., Particle swarm optimization for parameter determination and feature selection of support vector machines. Expert Systems with Applications, Vol. 35, no. 4, pp. 1817-1824, 2008.

- [53] IVANCIUC, O., Applications of support vector machines in chemistry, in *Reviews in Computational Chemistry*, 23, p. 291-400, Eds. Lipkowitz, K.B.Lipkowitz and Cundari, T.R., Wiley-VCH, Weinheim, 2007.
- [54] HEISELE, B., HO, P., WU, J., POGGIO, T., Face recognition: component-based versus global approaches, *Academic Press, Computer Vision and Image Understanding* 91(2003) 6–21, 2003.

ÖZGEÇMİŞ

Turhan R. BUNJAKU 27 Eylül 1986'da Kosova'da doğdu. İlköğretim ve liseyi Kosova'da tamamladı. 2005 yılında liseyi tamamladıktan sonra Priştine Üniversitesi Bilgisayar Mühendisliği bölümünde Lisans eğitimine başladı. Mezun olduktan sonra, Türkiye'de Yüksek Lisans yapma hakkını kazandı. Seçtiği Sakarya Üniversitesinde Yüksek Lisans eğitimine Eylül 2012 yılında başladı.