

T.C.  
TRAKYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**DESTEK VEKTÖR MAKİNELERİNİ  
KULLANARAK YÜZ BULMA**

**Fatih KARAGÜLLE**  
Yüksek Lisans Tezi  
Bilgisayar Mühendisliği Anabilim Dalı

**Danışman: Yrd. Doç. Dr. Rembiye KANDEMİR**

**EDİRNE-2008**

T.C.  
TRAKYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

DESTEK VEKTÖR MAKİNELERİNİ  
KULLANARAK YÜZ BULMA

Fatih KARAGÜLLE  
Yüksek Lisans Tezi  
Bilgisayar Mühendisliği Anabilim Dalı

Bu tez **12/09/2008** tarihinde aşağıdaki jüri tarafından kabul edilmiştir.

Yrd.Doç.Dr Rembiye KANDEMİR  
(Danışman)

Yrd.Doç.Dr.Yılmaz KILIÇARSLAN  
(Üye)

Yrd.Doç.Dr.Tahir ALTINBALIK  
(Üye)

## TEŐEKKÜR

Çalıőmalarım sırasında bilimsel katkıları ile beni yönlendiren tez danışman hocam Sayın Yrd. Doç Dr. Rembiye KANDEMİR'e çok teşekkür ederim.

Tezime katkılarından dolayı Yrd. Doç. Dr. Yılmaz KILIÇASLAN ve Yrd. Doç. Dr. Tahir ALTINBALIK hocalarıma teşekkür ederim.

Araştırma süresince büyük yardımlarını gördüğüm, bilgi ve araőtırmacı kişiliğini benden esirgemeyen arkadaşım Tahir KILIÇ'a teşekkürlerimi sunarım.

Yüksek lisans, tez sürecinde bana maddi manevi destek veren aileme en içten teşekkürlerimi sunarım.

## ŞEKİL LİSTESİ

Şekil 2.1 Sayısal bir resmin negatifinin alınması .....	5
Şekil 2.2 Kontrast Genişletme .....	5
Şekil 2.3 Orjinal resmin histogramı .....	6
Şekil 2.4 Kontrast genişletmeden sonraki resmin histogramı .....	6
Şekil 2.5 Eşik Değer Tekniği.....	6
Şekil 2.6 Sayısal bir resme eşik tekniğinin uygulanması.....	7
Şekil 2.7 Farklı histogramlar .....	8
Şekil 2.8 Sayısal bir resme histogram eşitleme işleminin yapılması .....	10
Şekil 2.9 Bölgesel İşlemler.....	11
Şekil 4.1 Modelleme hatasının eğitim veri kümesi boyutu ilişkisi.....	18
Şekil 4.2 Veri görevlerinden öğrenme işleminin standardı.....	19
Şekil 4.3 Eğiten veri takımını toplarken öğrenmenin rastgele gösterimi.....	20
Şekil 4.4 Öğrenen makinenin modeli.....	20
Şekil 4.5 Gösterge fonksiyonunun gösterimi .....	22
Şekil 4.6 Gösterge fonksiyonunun doğrusal gösterimi .....	22
Şekil 4.7 Gösterge fonksiyonunun doğrusal olmayan gösterimi .....	23
Şekil 4.8 Gösterge fonksiyonunda 10 noktanın ayrılması .....	24
Şekil 4.9 Gaussian RTF kullanılarak ikili sınıflandırma.....	25
Şekil 4.10 Destek Vektör Makine Algoritması .....	26
Şekil 4.11 Sınıflandırma örneği.....	26
Şekil 4.12 Destek Vektörleri ve Sınırlar .....	27
Şekil 4.13 Doğrusal Olmayan Sınıflandırma .....	28
Şekil 4.14 Çekirdek fonksiyonları ile üst boyuta taşıma işlemi .....	28
Şekil 4.15 Haritalama işlemi .....	29
Şekil 4.16 Örnek DVM modeli.....	29
Şekil 4.17 2 Boyutlu Örnek Uzayında Doğrusal Fonksiyon Gösterimi.....	30
Şekil 4.18 Doğrusal ve Doğrusal Olmayan Sınıflandırma Gösterimi .....	31
Şekil 4.19 2 Boyutlu Örnek Uzayında Polinomial Fonksiyon Gösterimi.....	31
Şekil 4.20 RTF ile Sınıflandırılarak Farklı Boyuta Taşınması.....	31
Şekil 4.21 2 Boyutlu Örnek Uzayında Radyal Tabanlı Fonksiyon Gösterimi .....	32
Şekil 4.22 Sigmoid Fonksiyon.....	32
Şekil 4.23 Hatalı Sınıflandırma Örneği.....	33

Şekil 4.24 Fazla Sınıflandırma ve İyi sınıflandırma .....	35
Şekil 6.1 Yüz Bulma Uygulamasının Genel Yapısı .....	40
Şekil 6.2 Eğitim Verisini Oluştururken Kullanılan Yüz Resimleri ve Yüz Olmayan Resimler .....	41
Şekil 6.3 Giriş resminin DVM düğümlerine dönüştürülmüş hali.....	43
Şekil 6.4 DVM Kullanıldıktan Sonra Resim Formatına Dönüştürülmüş Resim.....	44
Şekil 6.5 Uygulamanın Sınıf Yapısı Gösterimi .....	45
Şekil 7.1 Üçüncü Dereceden Polinomial Çekirdek Kullanıldığında Doğru ve Hatalı Bulunan Resimlerin Grafikselsel Gösterimi.....	48
Şekil 7.2 Radyal Tabanlı Çekirdek Kullanıldığında Doğru ve Hatalı Bulunan Resimlerin Grafikselsel Gösterimi.....	49
Şekil 7.3 Doğrusal Çekirdek Kullanıldığında Doğru ve Hatalı Bulunan Resimlerin Grafikselsel Gösterimi .....	50
Şekil 7.4 Sigmoid Çekirdek Kullanıldığında Doğru ve Hatalı Bulunan Resimlerin Grafikselsel Gösterimi .....	51
Şekil 7. 5 Tek Yüzlü Resimde Uygulama Sonuçları-1 .....	53
Şekil 7. 6 Tek Yüzlü Resimde Uygulama Sonuçları-2 .....	54
Şekil 7. 7 (a),(b),(c),(d) Çok yüzlü resim üzerinde uygulamanın ürettiği sonuçlar-1 .....	55
Şekil 7.8 (a),(b),(c),(d) Çok yüzlü resim üzerinde uygulamanın ürettiği sonuçlar-2 .....	56
Şekil 7. 9 Uygulamanın ürettiği eksik yüz bulma sonuç.....	57
Şekil 7. 10 Uygulamanın ürettiği hatalı sınıflandırma sonucu .....	57

**TABLO LİSTESİ**

Tablo 7.1 Polinomial Çekirdek Uygulama Sonuçları.....	48
Tablo 7.2 RTF Çekirdek Uygulama Sonuçları.....	49
Tablo 7.3 Doğrusal Çekirdek Uygulama Sonuçları.....	50
Tablo 7.4 Sigmoid Çekirdek Uygulama Sonuçları.....	51
Tablo 7.5 Çoklu Resim Uygulama Sonuçları.....	52

**ÖZET**

Yüz bulma ve yüz tanıma, yapay görünün zorlu problemlerinden biridir. Son yıllarda askeri, ticari ve yasal uygulama alanlarının artması nedeniyle yüzlerin otomatik olarak tanınması çok popüler bir konu haline gelmiştir. Yüz bulma problemi için bir bilgisayar modeli kurmak oldukça zordur. Bu yüzden doğru, güvenilir, gerçek zamanlı yüz tanıma sistemi için yüz bulma işleminin doğru olması gereklidir. Bu zorluk yüzlerin çok boyutlu, karmaşık ve anlamlı görsel objeler olmalarından kaynaklanmaktadır.

Bu çalışmada Destek Vektör Makineleri(DVM) kullanılarak yüz tespiti ele alınmış ve sınıflandırmanın daha hızlı yapılabilmesi için bir yöntem önerilmiştir.

Temel olarak, istatistiksel öğrenme algoritmalarından biri olan ve Vapnik - Chervonenkis tarafından tanımlanan DVM, aynı zamanda, yapay sinir ağları ve karar ağacı gibi metotların da bir alternatifi olarak bir çok uygulamada ortaya konulmuştur. Son zamanlarda ise DVM, örüntü tanıma, yüz bulma ve tanıma, veri madenciliği gibi alanlarda kullanılmaya başlanmıştır ve birçok gerçek problemde başarılı sonuçlar vermiştir.

Çalışmanın ilk aşamasında, yüze ait ve ait olmayan şekillerden seçilen eğitim seti ile eğitim verisi oluşturulmuştur. Eğitim sonucunda oluşan veri, eğitim setinin renk bilgilerinden yararlanılarak elde edilmiştir. Sisteme verilen resimlerden 20x20, 40x40, 60x60 piksel boyutlarında parçalama işlemi yapılarak, her bir parçalama işlemi sonrasında eğitim verisine göre öznitelik düğümleri belirlenmiştir.

DVM alt yapısının daha hızlı çalışabilmesi için düğüm değerleri üzerinde belirli oranlarda azaltma işlemi yapılmıştır. Yapılan azaltma çalışmaları doğrultusunda, hız ve elde edilen sonuç üzerinden en etkin oranlar; yüz olan düğümler için 1/4, yüz olmayan düğümler için 1/6 olarak belirlenmiştir.

## VII

Destek Vektör Makinelerini farklı çekirdekler ve parametreler için kullanarak performans deęerlendirmesi yapılmıřtır. Ayrıca, sınıflandırma sonucu elde edilen imgelerde başarı oranını artırılması için yüzün řekil bilgisinden yararlanılarak maskeleme iřlemi yapılmıřtır.

**Anahtar Kelimeler:** Yüz bulma, Destek Vektör Makineleri, Sınıflandırma

Yıl : 2008

Sayfa: 63



**ABSTRACT**

Face finding and face recognition is one of the robust problems of artificial view. In recent years, because of raising military, commercial and legitimate application areas automatically recognition of faces becomes a popular subject. Setting up a computer model for face finding problem is pretty difficult. So face finding process has to be right for exact, reliable, real time face recognition system. This complexity arises from the fact that faces are multi dimensional, complex and meaningful visual objects.

In this work, face detection by Support Vector Machines is discussed and a method is proposed for quicker classification.

Basically, SVM that is one of the statistical learning algorithms and defined by Vapnik-Chervonenkis, is produced in many applications as an alternative of methods like synthetic neural network and decision tree. Recently SVM, is started to be used for areas like pattern recognition, face finding and recognition, data mining and it succeeded on many real problems.

At first stage of this work, training data is made up with training set that was chosen from shapes that belongs face and does not belong any face. The data that is made up from training, is obtained under cover of color information of training set. By fragmentation process of pictures has sizes 20x20, 40x40, 60x60, attribute nodes according to training set is determined after each fragmentation process.

Reduction process is done on node values in specific ratios to make substructure of SVM working fast. On direction of reduction process, most effective ratios derived from speed and results are determined as 1/4 for nodes that includes a face and 1/6 for nodes that does not include any face.

Performance evaluation is done by using support vector machine with different seeds and parameters. According to results, Polynomial seed results better than other seeds.

Furthermore mask process by using of shape information of face is done on images obtained from classification.

**Keywords:** Face Detection, Support Vector Machines, Classification

**KISALTMA LİSTESİ**

DVM	: Destek Vektör Makinesi
VC Boyutu	: Vapnik-Chervonenkis Boyutu
RTF	: Radyal Tabanlı Fonksiyon
YSA	: Yapay Sinir Ağları
YRM	: Yapısal Risk Minimizasyonu
DTU	: Dağıtım Tabanlı Uzaklık
ÇBAP	: Çekirdek Bileşen Analiz Prensipli
DVAT	: Destek Vektör Alan Tanımlaması
HYM	: Holistik Yüz Modeller
RGB	: RGB Renk Uzayı
YCbCr	: YCbCr Renk Uzayı

## İÇİNDEKİLER

TEŞEKKÜR .....	II
ŞEKİL LİSTESİ.....	III
TABLO LİSTESİ.....	V
ÖZET .....	VI
ABSTRACT .....	VIII
KISALTMA LİSTESİ.....	X
1. GİRİŞ .....	1
2. DİJİTAL İMGE İŞLEME.....	3
2.1. Dijital İmge İşleme Nedir? .....	3
2.2. Dijital İmge Üzerinde Yapılan Temel İşlemler.....	4
2.2.1. Negatifleştirme .....	4
2.2.2. Kontrast Genişletme .....	5
2.2.3. Eşik Tekniği .....	6
2.2.4. Histogram İşlemleri .....	7
2.2.5. Bölgesel İşlemler .....	10
3. YÜZ BULMA.....	12
3.1. Bilgi Tabanlı Yüz Bulma.....	12
3.2. Özellik Tabanlı Yüz Bulma .....	14
3.3. Şablon Eşleme Yöntemi ile Yüz Bulma.....	14
3.4. Görünüm Tabanlı Yüz Bulma.....	15
3.5. Doku Tabanlı Yüz Bulma Yöntemi .....	16
4. DESTEK VEKTÖR MAKİNELERİ – DVM (SUPPORT VECTOR MACHINES - SVM) .17	
4.1. Destek Vektör Makinelerinde Öğrenme.....	17
4.2. Vapnik Chervonenkins (VC) Boyutu .....	21
4.3. Destek Vektör Makine Algoritması .....	25
4.4. DVM de kullanılan Çekirdek Fonksiyonları .....	30
4.4.1. Doğrusal Fonksiyon.....	30
4.4.2. Polinomial Fonksiyon.....	30
4.4.3. Radyal Tabanlı Fonksiyon .....	31
4.4.4. Sigmoid Fonksiyon.....	32
4.5. Çekirdek ve Parametre Seçimi.....	33
4.5.1. Çekirdek Tipi.....	33
4.5.2. Çapraz Geçerli Kılma ve Hücre Arama.....	34
5. LİTERATÜR ÇALIŞMALARI.....	36
6. DESTEK VEKTÖR MAKİNELERİNİ KULLANARAK YÜZ TESPİTİ UYGULAMASI .39	
6.1. Eğitim Verisinin Elde Edilmesi .....	41
6.2. Giriş Resminin Parçalara Bölünmesi .....	42
6.3. DVM Düşümlerinin Belirlenmesi.....	42
6.4. Parametrelerin Seçimi .....	43
6.5. Resmin DVM Alt Yapısına Gönderilmesi.....	43
6.6. Sınıflandırma Sonrası Parçaların Birleştirilmesi.....	44
6.7. İyileştirme İşlemlerinin Yapılması.....	44
6.8. Uygulamanın Sınıf Yapısı .....	45
7. UYGULAMA SONUÇLARI.....	47
8. SONUÇ .....	58
KAYNAKLAR.....	60
ÖZGEÇMİŞ.....	63

## 1.GİRİŞ

Yüz bulma, yapay görünümün zorlu problemlerinden biridir. Yüz bulma probleminin amacı, bir tek veya ardışık görüntü verildiğinde, yüz içeren bölgeleri 3 boyutlu dönüşüm ve ışıklandırma koşullarına bağımlı olmadan belirlemektir.

İnsan yüzleri, insanların kimliklerini ve duygularını temsil ettikleri için insanların sosyal 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 yeteneği 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 imge tanıma uygulamalarında belirli kriterlere oturtmak mümkündür.

Bu tezin amacı destek vektör makinelerini kullanarak insan yüzünün bilgisayar ile tespitini hızlı bir şekilde sağlamaktır. Bu şekilde pek çok alanda kolaylıklar sağlanacak, güvenlik sistemleri tarafından yüz tespiti ile kişisel bilgilere ulaşabilme daha kolay hale gelecektir.

Çalışmanın ikinci bölümde dijital imge işleme ve resimler üzerinde yapılan temel işlemlerden bahsedilmiştir.

Üçüncü bölümde yüz bulma, yüz bulma teknikleri ve bu tekniklerin avantaj ve dezavantajlarından bahsedilmiştir.

Yüz tespitinde kullandığım yöntem olan Destek Vektör Makinelerinin (DVM) genel yapısı, formülleştirilmesi, kullanım alanları, destek vektör makine algoritması, çekirdek fonksiyon çeşitlerinden dördüncü bölümde söz edilmiştir.

Beşinci bölümde, yüz bulma konusunda daha önceden ve günümüzde devam eden çalışmalar incelenip literatür çalışmaları başlığı altında toplanmıştır.

Yüz bulmaya yönelik geliştirilen uygulama programının yapısı, eğitim verisinin elde edilme yöntemi, çekirdek fonksiyonlarının seçiminde dikkat edilecek hususlar altıncı bölümde verilmiştir.

Uygulama sonrasında elde edilen sonuçlar yedinci bölümde değerlendirilmiştir.

Tezin değerlendirilmesi Sonuç Bölümü olan sekizinci bölümde irdelenmiştir.

## 2. DİJİTAL İMGE İŞLEME

### 2.1. Dijital İmge İşleme Nedir?

İmge, iki boyutlu  $f(x,y)$  fonksiyonu olarak tanımlanabilir ve herhangi bir  $(x,y)$  koordinatı için  $f$  fonksiyonunun genliği, o noktada imgenin yoğunluğu olarak adlandırılır. Bütün  $x,y$  ve fonksiyon genlikleri sonlu ve tamsayı ise bu imge, dijital imge olarak adlandırılır.

Dijital imge işleme, dijital imgelerin dijital bilgisayar ile işlenmesi anlamını taşır. Her dijital imge sonlu sayıda elemandan oluşur ve her bir elemanın kendine özel bir yeri ve değeri vardır [1]. Bu elemanlar, en yaygın kullanımı ile piksel olarak adlandırılır. Dijital imge işlemenin iki önemli uygulama yöntemi vardır:

- Görüntü kalitesinin artırımı
- İmgenin depolama, iletim ve otomatik makine algılaması için hazırlanması

İnsan algılaması için görüntü kalitesindeki iyileştirme amacına yönelik uygulamalara tıp, uzay programları, nükleer tıp, biyoloji, jeoloji, arkeoloji, astronomi, savunma ve endüstriyel uygulamalar örnek olarak verilebilir.

İmge işlemenin nerede bittiği ve imge analizi ya da bilgisayar görüşü gibi ilgili diğer konuların ne zaman başladığı hakkında tam bir görüş birliği oluşmamıştır. Bazen hem giriş hem de çıkışı imge olan işlemlerin imge işleme olduğu ayrımı yapılır. Ancak bu her zaman doğru olmayabilir. Örneğin bir imgenin ortalama yoğunluğunun hesaplanması, çıkışta tek bir sayı vermesine rağmen, imge işlemede çok sıradan bir görevdir. Bilgisayar görüşü insan görme duyusunu taklide çalışan bir alandır. İmge analizi ise imge işleme ile bilgisayar görüşü arasında bir yerdedir. İmge işleme ile diğer alanlar arasında kesin çizgiler olmamakla birlikte bilgisayarlarla gerçekleştirilen işleme üç farklı seviyede incelenebilir: düşük, orta ve yüksek seviyede işleme.

- Düşük seviyede işleme, gürültü azaltma, kontrast artırımı ve imge keskinleştirme gibi saha giriş seviyesi işlemlerdir. Düşük seviye işlemede hem giriş hem de çıkış bir imgedir.
- Orta seviyede işleme, segmentasyon ve nesnelerin sınıflandırılması gibi işlemleri ifade eder. Orta seviyede işlemede giriş bir imge iken çıkış genellikle

bu girişten elde edilen, giriş imgesinin kenarları, dış sınırları veya nesnelerin benzerlik durumları gibi özellikleridir.

- Yüksek seviyede işleme ise tanınan nesnelerin gruplandırılması gibi işlemleridir.

## 2.2. Dijital İmge Üzerinde Yapılan Temel İşlemler

Görüntü İşleme, ölçülmüş veya kaydedilmiş olan dijital (elektronik) görüntü verilerini, elektronik ortamda (bilgisayar ve yazılımlar yardımı ile) amaca uygun şekilde değiştirmeye yönelik yapılan bilgisayar çalışmasıdır. Görüntü işleme daha çok kaydedilmiş mevcut görüntüleri işlemek yani mevcut resim ve grafikleri değiştirmek, yabancılaştırmak ya da iyileştirmek için kullanılır. Resim işlemede kullanılan temel işlemleri aşağıdaki gibi gösterilebilir. [2]

### 2.2.1. Negatifleştirme

Negatif imgeler biyomedikal görüntüler, monokromatik resimleri görüntüleme gibi birçok uygulamada oldukça yararlıdır.

Burada yapılan işlem görüntülerdeki gri seviye değerlerini ters döndürmektir. Yani eğer imge 8 bitlik ise 0 değeri yerine 255, 255 değeri yerine 0 gelecek şekilde değerler ters döner. Buradan da anlaşılacağı gibi bir resmi negatifi ile toplarsak ortaya beyaz bir resim çıkar, yani resim içerisindeki tüm piksellerin değeri 255 olur. (Şekil 2.1)

Bu tip işleme özellikle siyah bölgelerin çoğunlukta olduğu imgelerde, ilgilenilen detaylar beyaz veya açık renk bölgeler ise faydalıdır. [2]






(a) Orjiinal resim

(b) Negatifi alınmış resim.


Şekil 2.2 Sayısal bir resmin negatifinin alınması

### 2.2.2. Kontrast Genişletme


Kontrast genişletmenin mantığı, işlenen resimdeki gri ton değerlerinin dinamik sahasını artırmaktır. Düşük kontrastlı resimler zayıf aydınlatma gibi durumda oluşabilir. Şekil 2.2(b)' deki resme Şekil 2.2(a) dönüşüm fonksiyonu uygulanarak kontrast genişletme işlemi yapılmıştır ve Şekil 2.2(c) gri ton değerleri 0-255 arasına dağılmıştır. [2]



a- Dönüşüm Fonksiyonu




b-Orijinal Resim




c- Kontrast Genişletmeden Sonraki Resim

Şekil 2.3 Kontrast Genişletme

Şekil 2.3'de orijinal resim histogramı, Şekil 2.4'de kontrast genişletme işleminden sonraki histogramları görülmektedir. [2]



Şekil 2.4 Orjinal resmin histogramı

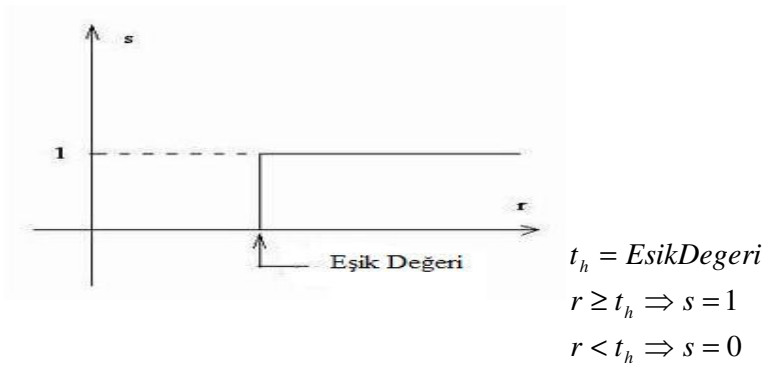


Şekil 2.5 Kontrast genişletmeden sonraki resmin histogramı

Görüldüğü gibi gri ton değerleri daha çok 0-150 arasında değişmektedir. Kontrast genişletme ile bu değerleri 0-255 arasına dağıtılsa resimdeki kullanılmayan gri ton değerleri de kullanılarak resimdeki kötü aydınlatmanın getirmiş olduğu bu dezavantaj kaldırılmış olur.

### 2.2.3. Eşik Tekniği

Eşik tekniği değişik gri ton seviyelerine sahip bir resmi ikili hale; yani, 0 siyah, 1 beyaz rengi göstermek üzere resmi, 0 ve 1 lerden oluşan bir matris haline getirir. [2] Eşik tekniği uygulanırken bir eşik değeri belirlenir ve bu değer üstündeki değerler için çıktı resimdeki ilgili piksele 1 altındaki değerler içinde 0 değeri atanır. Şekil 2.5’de eşik değeri tekniği görülmektedir. [2]



Şekil 2.6 Eşik Değer Tekniği

Şekil 2.6'da 128 değeri eşik alınarak uygulanmış resim gösterilmektedir.



(a) Orijinal resim




(b) Eşik tekniği uygulanmış resim.

Şekil 2.7 Sayısal bir resme eşik tekniğinin uygulanması

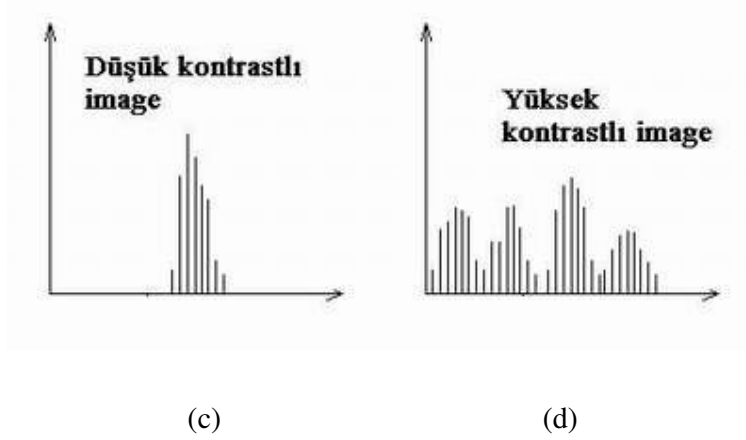
#### 2.2.4. Histogram İşlemleri

Histogram eşitliği gri ton değerine sahip piksellerin kaç tane olduğunu verir.  $r_k$ ,  $k$ . gri ton,  $n_k$  görüntüdeki bu gri ton değerine sahip piksel sayısı,  $n$  görüntüdeki toplam piksel sayısı ve  $k = 0, 1, 2, 3, \dots, L-1$  gibi değerler olmak üzere gri ton değerleri  $[0, L-1]$  sahasında değişen bir dijital görüntünün histogramı  $p(r_k) = n_k / n$  ayrık fonksiyonudur. Şekil 2.7.'de 4 farklı özellikteki resimlerin histogramları görülmektedir. [2]



(a)

(b)



Şekil 2.8 Farklı histogramlar

Şekil 2.7(a)'daki histogramda gri ton değerler 0'a yakın değerlerde fazlalaşmaktadır. Yani karanlık bir resimdir. (b)'de ise bu durumun tersine gri ton değerleri görülmektedir. Bu da resmi çok fazla aydınlık bir hale getirir. (c)'de ise gri ton değerler belli bir sahada sıkışmıştır. Resmin düşük kontrasta sahip olduğu anlaşılmaktadır. (d)'de ise gri ton değerlerinin dengeli bir biçimde dağıldığı görülmektedir.

#### 2.2.4.1. Histogram Eşitleme

Histogram, sayısal bir resim içerisinde her renk değerinden kaç adet olduğunu gösteren grafikdir. Bu grafiğe bakılarak resmin parlaklık durumu ya da tonları hakkında bilgi sahibi olunabilir. [2]

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

Resimdeki işlenen pikselin gri ton değerleri  $r$  olsun. Piksel değerleri normalize edildikten sonra  $[0,1]$  aralığında değişen değerler alabilen sürekli niceliklerdir ve bu değerleri ayrık olarak işleyip bir şekilde formüleştirdikten sonra piksel değerleri  $[0, L-1]$  arasında değişir. Değeri  $[0,1]$  arasında değişen  $r$  değerlerinin dönüşümünü şu şekilde ifade etmiştik:  $s = T(r)$ .

Bu eşitliğin şu şartları sağladığı kabul edilir:

(a)  $T(r)$  tek değerlidir ve  $r$  değerinin  $0 \leq r \leq 1$  olarak değişmesiyle monoton olarak artar.

(b).  $0 \leq r \leq 1$  için  $0 \leq T(r) \leq 1$ 'dir .

Ters dönüşümü ise  $T^{-1}(s) = r$   $0 \leq s \leq 1$  ,  $T^{-1}(s)$  fonksiyonu da  $s$ 'ye bağlı olarak (a) ve (b) şartlarını sağlar.

Resim içerisindeki gri ton değerleri  $[0,1]$  aralığında rasgele değişen değerlerdir. Eğer sürekli değişkenlerse orijinal ve dönüşüme uğramış gri ton değerleri  $P_r(r)$  ve  $P_s(s)$  olasılık yoğunluk fonksiyonları ile karakterize edilebilirler.

Olasılık teorisinden  $P_r(r)$  ve  $T(r)$  biliniyor ve  $T^{-1}(s)$  (a) şartını sağlıyorsa dönüştürülmüş gri ton değerinin olasılık yoğunluk fonksiyonu şöyledir:

$$P_s(s) = [P_r(r) d_r / d_s]_r = T^{-1}(s)$$

Aşağıdaki teknikler  $T(r)$  dönüşüm fonksiyonu aracılığı ile olasılık yoğunluk fonksiyonunun kontrol edilmesiyle resmin görüntüsünü değiştirmeye dayanır.

$$s = T(r) = \int_0^r P_r(w) dw \quad 0 \leq r \leq 1$$

Yukarıdaki integral sonucu kümülatif dağılım fonksiyonu elde edilir. Bu fonksiyon (a) ve (b) şartlarını sağlamaktadır. Çünkü  $P_r$  bir olasılık fonksiyonudur ve bir olaya ilişkin tüm olasılıkların toplamı her zaman 1'dir. Bu eşitlikten  $ds/dr = P_r(r)$  bulunur. Bu eşitlikte  $P_s(s) = [P_r(r) dr / ds]_r = T^{-1}(s)$  eşitliğinde yerine yazılırsa;

$$P_s(s) = [P_r(r) \cdot 1 / P_r(r)]_r = T^{-1}(s)$$

$$= [1]_r = T^{-1}(s)$$

$$= 1 \quad 0 \leq s \leq 1$$

Şekil 2.8’de histogram eşitleme işlemi görülmektedir.



(a) Orijinal Resim



(b) Histogram eşitleme uygulanmış resim

Şekil 2.9 Sayısal bir resme histogram eşitleme işleminin yapılması

### 2.2.5. Bölgesel İşlemler

Histogram kullanmak yerine resmin gri ton değerlerinin ortalaması, varyansı (yada standart sapması) gibi başka özellikleri ile de bölgesel işlemler yapılabilir. Bölgesel işlemlerde belirlenen komşu piksellerle bir dizi işlemler yapılır ve elde edilen sonuç ilgili piksele atanır. [2]


$(x, y)$  koordinatındaki bir piksele şu dönüşümün uygulanmasıyla  $f(x, y)$  giriş fonksiyonu  $g(x, y)$  değerine dönüşür.

$$g(x, y) = A(x, y)[f(x, y) - m(x, y)] + m(x, y)$$

$$A(x, y) = k \cdot M / \sigma(x, y) \quad 0 < k < 1$$

Bu formüllerdeki  $m(x, y)$  ve  $\sigma(x, y)$  ilgilenilen piksel ve bu pikselin komşu piksellerinin ortalama ve standart sapma değerleridir.  $M$  tüm görüntünün ortalama değeri,  $k$  da bir sabittir.

Şekil 2.9’da (a)giriş resmi, (b) global histogram eşitleme yapılan çıktı resmi ve (c) bölgesel işlemler kullanılarak histogram eşitlemeye ihtiyaç duyulmadan elde edilen çıktı resmi gösterilmiştir. [2]



Şekil 2.10 Bölgesel İşlemler  
a) Giriş resmi b) Global histogtam eşitleme uygulanmış resim c) 7x7 lik komşuluk  
kullanılarak yapılan bölgesel işleme elde edilen resim

### 3. YÜZ BULMA

Son yıllarda askeri, ticari ve yasal uygulama alanlarının artması nedeniyle yüzlerin otomatik olarak tanınması çok popüler bir konu haline gelmiştir. Yüz tanıma, en kabul edilebilir biometriklerden birini karşılar. Genellikle yüz tanıma 3 parçadan oluşur. Bunlar; yüz tespiti, özellik çıkarımı ve tanımadır. Yüz bulma problemi için bir bilgisayar modeli kurmak oldukça zordur. Bu yüzden doğru, güvenilir, gerçek zamanlı yüz tanıma sistemi için yüz bulma işleminin doğru olması gereklidir. Bu zorluk yüzlerin çok boyutlu, karmaşık ve anlamlı görsel objeler olmalarından kaynaklanmaktadır. [3]

Oysa insan beyni, bir an gördüğü bir yüzü yıllar sonra bile yaşlanma, saç uzaması gibi değişikliklere rağmen birkaç saniye içerisinde hatırlayabilmektedir. Yüz bulma, insan gözüne göre basit bir olay olmasına rağmen, bir bilgisayara süreci otomatikleştirmek için çeşitli görüntü işleme tekniklerinin kullanımını gerektirir.

Yüz bulma verilen bir resimdeki veya resim dizisindeki, ayrı sahnelerdeki yüz veya yüzlerin yerini bulma işlemidir. Yüz bulma tekniklerinden başlıcaları aşağıdaki gibidir.

- Bilgi Tabanlı Metot
- Özellik Tabanlı Metot
- Şablon Eşleme Metodu
- Görünüm Tabanlı Metot
- Doku Tabanlı Metot

#### 3.1. Bilgi Tabanlı Yüz Bulma

1994 yılında Yang ve Huang tarafından ilk bilgi tabanlı yüz bulma uygulaması gerçekleştirilmiştir. Bu metotta daha önce tanımlanan kişinin yüz bilgisi, ilgili kurallar ile yüzün özellikleri arasındaki ilişkiyi karşılaştırır. [4]

Çeşitli kurallar tanımlanıp elde varolan bilgiler kullanılarak sonuca yaklaşılr. Bu kurallar yüzün karakteristiğinin özeti ile yüzün özellikleri arasındaki ilişkilidir. Bu kurallara



en basit örnek, kişinin yüzünde her zaman iki göz, bir burun ve bir ağız bulunmasıdır. Ancak biz yüz ile ilgili daha yeterli ve kompleks kurallara ihtiyaç duyulur.

Bu kuralları tanımlama bu yöntemin en büyük zorluğudur. Örneğin, kişi bilgilerinin iyi bir koda dönüştürülerek ifade edilmesi oldukça zordur. Eğer kurallar basit olarak tanımlanırsa, genellikle yüzün yanında diğer objelerde tespit edilir. Eğer kuralları daha kesin ve özel tanımlarsak büyük olasılıkla sadece bir tane ve doğru yüz bulunabilir. Genellikle kullanılan iki yöntem bulunmaktadır:

1. Farklı çözünürlüklerde odaklanma
2. Yukarıdan Aşağıya yaklaşımı

Farklı çözünürlüklerde odaklanma, çözüm olarak kullanılan resimde düşük çözünürlükte yüzün merkez ve çevresini renk yoğunluklarını ayarlar ve belirgin hale getirir.

Yukarıdan aşağı yaklaşımda kurallar yüksek bilgili olanlardan düşüklere doğru sıralanarak belirlenir. Bu yüzden yöntemin adı Yukarıdan Aşağıya yöntem olarak kabul edilmiştir.

Bilgi tabanlı yüz bulma metodunun diğer yöntemlere göre avantajları şunlardır:

- Yüze ait kuralları belirlemek oldukça kolaydır.
- Kodlanarak elde edilen test verisinden özellikler çıkarılarak aday yüzlerin tanımlanması oldukça kolaydır.
- Karmaşık olmayan arka plan resimlerde başarılı sonuçlar verir.

Dezavantajları aşağıdakilerdir:

- Yüze ait bilgileri kurallara çevirmek zor bir iştir. Çok fazla detaya inilirse yüzü bulmak zor olurken, genel bilgilerle de birden fazla yüz bulunabilir.
- Yüzün ışık, poz durumuna göre bulma işlemi zorlaşır.

### 3.2. Özellik Tabanlı Yüz Bulma

Özellik tabanlı yüz bulma yöntemi, insan yüzünde bulunan değişmeyen özellikleri kullanarak hedefe ulaşmayı amaçlayan yaklaşımdır. Bu işlem, aşağıdan yukarıya yöntemi kullanarak gerçekleştirir. [5]

Öncelikle yüze ait karakteristik özellikler belirlenir ve yüz bulma işlemi gerçekleştirilir.

Avantajları şunlardır:

- Yüze ait karakteristik bilgiler pozdan bağımsız olduğundan bulma işlemi bundan etkilenmez.
- Farklı yüz bulma yöntemleri ile bütünleşik olarak çalışabilir.

Dezavantajları ise şunlardır:

- Resimlerde bulunan gürültü, ışığın şiddeti bu yöntemi olumsuz olarak etkiler.
- Uygulama yapılan resim karışık arkaplana sahip olduğunda bu yaklaşım optimum sonucu vermekte zorlanır.

### 3.3. Şablon Eşleme Yöntemi ile Yüz Bulma

Şablon eşleme yöntemi yüz tespitinde etkin kullanılan yöntemlerden biridir. Yüzün tespiti için hazır yüz şablonları kullanılır. Şablon eşleme tekniği, bir görüntüde şablon görüntüsüne benzeyen küçük parçaların bulunması esasına dayanmaktadır. Şablon görüntüsü büyük görüntü üzerinde dolaştırılır ve her pikselde eşleme yapılarak benzerlik ölçülür. Benzer şekillerin piksel koordinatları kaydedilir. Şablon ön cepheden çekilmiş insan yüzleri için oluşturulur temel olarak yüz, burun, göz kısımları belirlenir. [6]

Avantajı şudur:

- Diğer metotlara göre gerçekleştirilmesi kolaydır.

Dezavantajları ise şunlardır:

- Şablonlar yüze yakın seçilmelidir.

- Farklı döndürülmüş pozlarda sonuca ulaşmak oldukça zordur. Ön cepheden çekilmiş pozlarda başarıya ulaşırlar.

### 3.4. Görünüm Tabanlı Yüz Bulma

Görünüm tabanlı yaklaşımda daha önceden tanımlı yüz şablonu ya da öznitelik şablonların özelliklerinden faydalanarak yapılan yüz bulma işlemi çok yaygın olarak kullanılır. Yüzün görünüşünü örnek eğitim setiyle birlikte öğrenebilen yüz bulma yöntemidir.

[7]

Metodun aşamaları şunlardır:

- Eğitim verilerinin belirlenmesi
- Sınıflama ve eğitim metotları
- Sunuş
- Önişleme
- Eğitim
- Arama stratejisinin belirlenmesi
- Yüzün tespiti

Görünüm tabanlı yüz bulma yöntemi eğitim verilerinin belirlenmesi aşamasında pozitif ve negatif örneklerle gerçekleşir. Pozitif örnekler yüz olan resimleri negatifler ise yüz olmayanları temsil eder.

Sınıflama ve eğitim metotları dağıtım tabanlı, ağ tabanlı ya da diğer istatistik tabanlı metotlardır. Dağıtım tabanlı metotta girilen kişinin yüz resimleri tüm resim uzayının alt uzayı olarak belirlenir. Temel Bileşen Analizi bu yöntemi kullanır. Ağ tabanlı yaklaşımda yapay ağlar kullanılarak yüz tespitinde bulunulur. Yapay sinir ağları yaklaşımı bu yöntemi kullanır. İstatistikî yöntemde güçlü matematik yapısı kullanılarak yapılan yaklaşımdır. Destek vektör makineleri örnek olarak verilebilir.

Önişlemede maskeleme, aydınlık seviyesinin belirlenmesi, histogram eşitliği işlemleri yapılır. Eğitim kısmında ise eldeki verilerle ilgili eğitim metotları kullanılarak eğitim tamamlanır.

Temel Bileşen Analizi, destek vektör makinesi, adaboost sıkça kullanılan görünüm tabanlı yüz bulma yöntemlerindendir. [7]

### **3.5. Doku Tabanlı Yüz Bulma Yöntemi**

Doku tabanlı yüz bulma yöntemi, yüz belirlemede dokusal özellikleri kullanır. Yüzün yapısal belirgin özelliklerini kullanır. Eğitim için az sayıda örnek kullanarak sonuca giden yöntem olarak bilinir. Özellik uzayını yüksek boyutlardan daha alt seviyelere indirir ve algoritmada bulunan karmaşık hesaplamaları azaltır. [8]

#### **4. DESTEK VEKTÖR MAKİNELERİ – DVM (SUPPORT VECTOR MACHINES - SVM)**

Temel olarak, istatistiksel öğrenme algoritmalarından biri olan ve Vapnik-Chervonenkis tarafından tanımlanan DVM, birçok gerçek problemde başarılı sonuçlar vermiştir. DVM'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. DVM'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. Destek vektörü öğrenme, basit fikirler üzerine kurulma ve pratik uygulamalarda yüksek performans göstermesi bakımından oldukça kullanışlıdır. DVM'lerde kullanılacak örnek sayısı önemli değildir. DVM eğitim esnasında görülmemiş verileri de sorunsuz olarak sınıflandırır. Bu DVM'nin genelleştirebilme yeteneğini gösterir. Genelleştirebilme özelliği DVM'yi diğer tekniklere göre (YSA, karar ağacı vs..) iyi bir alternatif yapmaktadır. Son zamanlarda ise örüntü tanıma, yüz bulma ve tanıma, veri madenciliği, dil yapısını inceleyen mantıksal programlamalarda, uçak alt basınç profillerinin modellenmesi, biyoloji ve diğer bioinformatik uygulamalarda, gen analizlerinde ve proteinlerin sınıflandırılmasında DVM kullanılmaya başlanmıştır. [9]


Bu bölümde Destek Vektör Makineleri hakkında genel bilgi, öğrenme işlemi ve Vapnik- Chervonenkis (VC) teorisinden bahsedilecektir.

##### **4.1. Destek Vektör Makinelerinde Öğrenme**

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. [9]

Sahip olduğumuz yüksek boyutlu olan desenleri eğitmek günümüze ait uygulamalarda güçlükle kaydedilir. Öğrenen makine algoritmaları yüksek boyutlu uzaylarda çalıştırabilmeli ve az sayıda veriden öğrenme işlemini yapabilmelidir. Boyut indirgeme işlemi sağlanırsa veri


çiftleri kolay bir şekilde elde edileceğinden daha iyi sonuçlar verilmiş olur. Klasik istatistiksel tekniklerin temel performansı Şekil 4.1'de verilmiştir. [9] Pratik koşullarda rasgele bir veri takımından alınan küçük örnek boyutu güvenilmezdir, genellikle hata ile sonuçlanır.



Şekil 4.1 Modelleme hatasının eğitim veri kümesi boyutu ilişkisi


DVM polinomial modellerde, yapay sinir ağlarında, bulanık mantıkta ve RTF sınıflandırıcılarda sıkça kullanılan yeni bir metottur. DVM'yi, yapısal risk minimizasyonu (YRM) olarak bulunan yeni öğrenim teknikleri ve VC teorisi temsil eder. Geliştirilen Vapnik teorisi düşük seviyeli model VC boyutu, görünmeyen veriler üzerinde iyi bir genelleme yaparak hatanın düşük olasılıkta olduğunu gösterir. Bu özellik, tüm hesaplayan alana özeldir. Veri çiftlerini eğitmede o kadar iyi model olmasa da genelleme işlemi iyi gerçekleştiren modeldir. Bazı kısıtlamalar altında DVM'nin usulüne uydurma teori yapısında, istatistiksel öğrenen teori veya yapısal riskten ziyade minimizasyon türetilmesi vardır. Buradan, DVM'nin istatistiksel öğrenen teori ve yapısal risk teorisinin minimizasyonunu çıkaran, yani, öğrenen bir teknik olduğu söylenebilir. Tümevarım prensibini ve VC sınırının teorisini temel alan verilerle bu yaklaşımlarda öğrenme işlemi gerçekleşir. 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 DVM önce doğrusal olarak, daha yüksek boyutlu bir özellik uzayını orijinal giriş uzayına dönüştürür. Bu dönüşüm, çeşitli doğrusal olmayan eşleştirmeleri kullanarak başarılabilir: Polinomial, çok katmalı algılayıcıda olduğu gibi

sigmoidal, radyal olarak simetrik görevler Gaussian olduğu esas görevlere sahip olması için RTF eşleştirmeleri olabilir. Doğrusal olmayan dönüşüm adımı yapıldıktan sonra, doğrusal optimal ayrımı bulmak DVM'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. Standart öğrenme durumu, Şekil 4.2'de gösterilmektedir. [9]



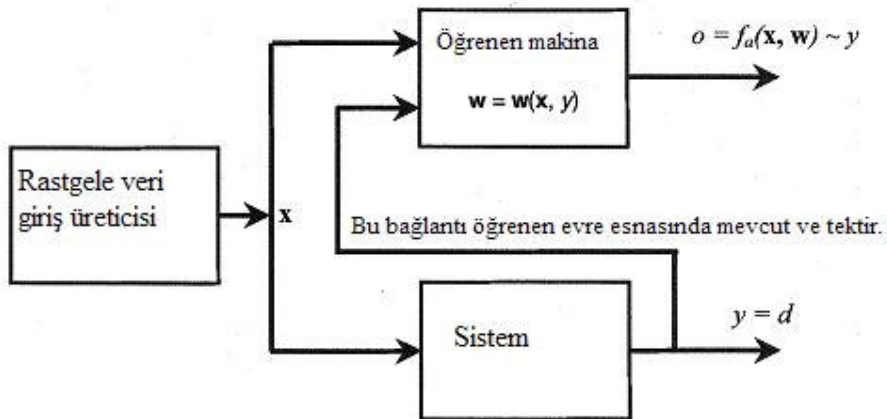
Şekil 4.2 Veri görevlerinden öğrenme işleminin standardı

Öğrenme, stokastik bir süreçtir. Şekil 4.3'te rasgele eğitim gösterilmektedir. [9] Eğitim takımı, rasgele değişken takımlarından oluşturularak, giriş değişkeni, rasgele değişken  $x_i$  'dir. Girişten  $P(x_i)$  olasılıkla çekilmiş, çıktıya ait olan  $y_i$  'nin, olasılığı  $P(y_i | x_i)$  'dir. Bu özellik eğitim fazı sırasında  $d_i$  (istek) tarafından  $y_i$  yanıtını gösterir. Bu yüzden  $P(d_i | x_i) = P(y_i | x_i)$  olarak ifade edilebilir. Y burada, sadece basitlik için kullanılan çıktı değişkeninin yönsüz değeridir. Bütün kökler, temelde aynı vektör çıktısı  $y$ 'den türer. Toplanan  $(x, d)$  veri noktalarının olasılıkları  $P(x, d) = P(x)P(y | x)$  şeklindedir.



Şekil 4.3 Eğiten veri takımını toplarken öğrenmenin rastgele gösterimi

İstatistiksel ayarda, veri öğrenmede üç temel bileşen vardır. Bunlar;  $x$  rasgele girişlerin bir üretici, eğitim sisteminin yanıtları  $y$  ve  $x$  girişleri ile  $y$  sistem çıkışlarını kullanarak öğrenmeye çalışan makinedir. Şekil 4.4, çeşitli alanlarda ortak olan öğrenimi gösterir. [9] Özellikle, sistem teşhisini kontrol eder ve işleme tabi tutmaya çalışır. Kullanılan X ve Y verisinin arasındaki ilişkiyi geri dönüşte D başarılı şekilde bulması için eğiten evre esnasında öğrenen bir makine görevleri ya da bir fonksiyonu ile sınıflandırma görevlerinde veriyi ayırır. Öğrenme işleminin yaklaşık fonksiyonel sonucu  $f_a(x, w)$ 'dir. Bu fonksiyon, yaklaşık (veya doğru) temeli oluşturmayı, giriş ve gerileme veya karar sınırında çıktının arasında bağımlı durumları tahmin eder.



Şekil 4.4 Öğrenen makinenin modeli



Genel olarak "Fonksiyonu tahmin etmek" ismi altında ,girişleri ve buna karşı oluşan çıktıları haritaya döken herhangi bir matematiğe ait yapı kullanılmıştır. Böylece,"Fonksiyonu tahmin etmek", kabarik bir modelin olduđu bir çok katmanlı perceptron, yapay sinir ađı, RTF şebekesi, bir DVM'yi ifade edebilir. Parametrelerin bir takımını  $w$ , öğrenmenin konusudur ve genellikle bu parametreler, ađırlıklar ile çağırılır. Bu parametreler, geometrik fark veya fiziksel anlamlara sahip olur. Görevlerin hipotez uzayı üzerinde  $H'$ 'ye bađlı olan  $w$ 'nin genellikle olduđu sistemler;

- Gizli ve çıkış katmanının ađırlıkları çok katmanlı algılayıcılar
- Bulanık alt kümelerin şekil ve pozisyonlarındaki tanımlamalarda kurallar ve parametreler
- Bir polinomial veya Fourier dizisinin katsayıları
- RTF şebekesinin çıktı tabaka ađırlıklarına ek olarak Gaussian esas fonksiyonlarının merkezleri ve varyansları veya kovaryansları.


Ana problem, çok küçük giriş ve çıktı deđişkenlerinin arasında mümkün temeli oluşturan görevdir. Erişilebilen eğitim veri kümesi, bađımsız uzayın bazı bilinmeyen olasılık dağılımına göre etiketlenen örnekleri koyar. Takip eden kısımlar, temel fikirler ve küçük numunelerle öğrenmek için gelişmiş öğrenmenin ilk etraflı teorisi olan Vapnik ve Chervonenkis tarafından geliştirilen istatistiksel öğrenen teorisinin tekniklerini sunar.

#### 4.2. Vapnik Chervonenkins (VC) Boyutu

Vapnik Chervonenkins Boyutu  $h$ , istatistiksel öğrenme teorisinin önemli sonuçlarının kullanıldığı tahmin setinin özelliđidir. VC boyutu, çok önemli olmasına karşın, analitik tahminleri, sadece basit takımları için kullanılabilir. VC boyutunun temel düşüncesi, ikili sınıf desen tanıma olayı ve sonrasında genelleme olduđundan, gerçek tahmin etme görevlerinin bazı takımlarını önceden sunmuş olur.

İlk olarak  $i_F(w,x)$  gösterge fonksiyonunu tanımlarız.  $i_F(w,x)$ ,  $\{0,1\}$  veya  $\{-1,1\}$  arasında deđer alır. Şekil 4.5'de gösterge fonksiyon görölmektedir. [9]






Şekil 4.7 Gösterge fonksiyonunun doğrusal olmayan gösterimi

VC boyutu  $h$  ise giriş uzayında ayrılabilen bir takımdır. Bu,  $h$  noktalarının her takımı, gösterge fonksiyonlarının verilmiş bir takımı ile ayrılabilmesini ifade etmez. Şekil 4.6'da gösterilen  $2^3$ , 8 mümkün halin etiketlenmesi için gösterge fonksiyonu  $i_f(x, w) = \text{sign}(u)$  ile ayrılamayan ortak doğrusal noktalar. Şekil 4.7'de  $i_f(x, w) = \text{sign}(u)$  ile ayrılamayan dört noktayı gösterir. Gerçekte, mümkün etiketlemeleri gösterge fonksiyonu ile ayrılabilen iki boyutlu  $(x_1, x_2)$ 'nin giriş uzayında dört noktanın hiçbir düzenlemesi yoktur. Bir başka deyişle bu gösterge fonksiyonu 2 boyutlu uzayda 3 nokta ile düzenlenebilir. Bunu genelleştirirsek  $n$  boyutlu bir uzayda  $h = n + 1$  şeklinde ifade edilir,  $n$  adet  $w$  ağırlık vektörü kullanılır. Bu son ifade VC boyutunun ağırlık vektör parametrelerinin sayısını arttırdığını gösterir. Bir başka deyişle, öğrenme yüksek boyutlarda fazla parametreyle düşük boyutlarda az parametreyle gerçekleşir. Bu ifade, gerçekten uzaktadır.

Bir VC boyutu, gösterge fonksiyonlarının bir takımı ile ayrılabilen  $\ell$  noktalarından oluşması gerekir. Böylece,  $\ell$  noktalarını seçersek,  $x_i = 10^{-i}$ ,  $i=1, 2, \dots, \ell$ . Buna göre,  $y_i$ 'den  $y_\ell$ 'ye kadar etiketleme  $y_i \in \{-1, +1\}$  ve gösterge fonksiyonu;

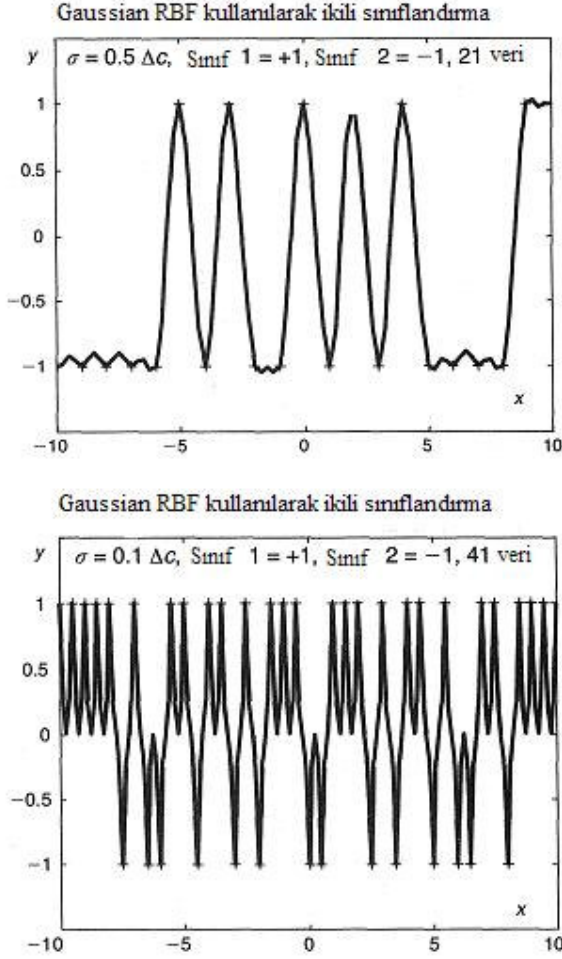
$$i_f(x, w) = \text{sign}(\sin(wx)) \quad w = \pi \left( 1 + \left( \sum_{i=1}^{\ell} (1 - y_i) 10^i / 2 \right) \right) \text{ olur.}$$

Bu durum Şekil 4.8'de ifade edilmiştir. [9]



Şekil 4.8 Gösterge fonksiyonunda 10 noktanın ayrılması


Bir RTF şebekesinin VC boyutu, nispeten nöron sayısını artırır. Bu, teorik olarak bir şebekenin, sınırsızca büyük bir VC boyutu veya ona sahip olabildiğini ifade eder. İkili sınıflandırma problemi için bir F şebekesi,  $\ell$  eğitim verisinin mümkün bir şekilde etiketlemesini ayırabilir. Bunu göstermek kolaydır. Saklanan tabakada  $\ell$  nörona sahip olması için bir RTF şebekesini tasarlanarak, veriyi eğitmede RTF fonksiyonu ve şekil parametreleri kullanılarak yapılır. Şekil 4.9'da , 21 üst kısımda ve 21 alt kısımda olmak üzere toplam 42 veri çiftinin bir boyutlu girişte iki farklı rastgele etiketlenmesini gösterir. [9] Esas görevi yerleştiren  $x_i$ 'ye uyarak Gaussian bir şekilde yapmaktır.



Şekil 4.9 Gaussian RTF kullanılarak ikili sınıflandırma


### 4.3. Destek Vektör Makine Algoritması

DVM temelinde, öncelik değişkenini bir özelliğe çağırıp, çok boyutlu düzlemde kullanılan niteliğe dönüştürür. En uygun temsili seçmenin amacı, özellik seçimi olarak bilinir. Özellikler doğru seçilirse iyi temsiller elde edilerek doğru sonuçlara ulaşılabilir. Bir olayı tanımlayan özellik takımı bir vektör ile çağırılır. Bundan dolayı DVM modelinin amacı, hedef değişkeninin bir kategorisiyle olayların vektör kümelerini ayıran optimal aşkın düzlemi bulmaktır. Aşırı düzlemin yanındaki vektörler destek vektörleridir. Şekil 4.10'da destek vektör algoritmasının genel yapısı görülmektedir. [10]



Şekil 4.10 Destek Vektör Makine Algoritması

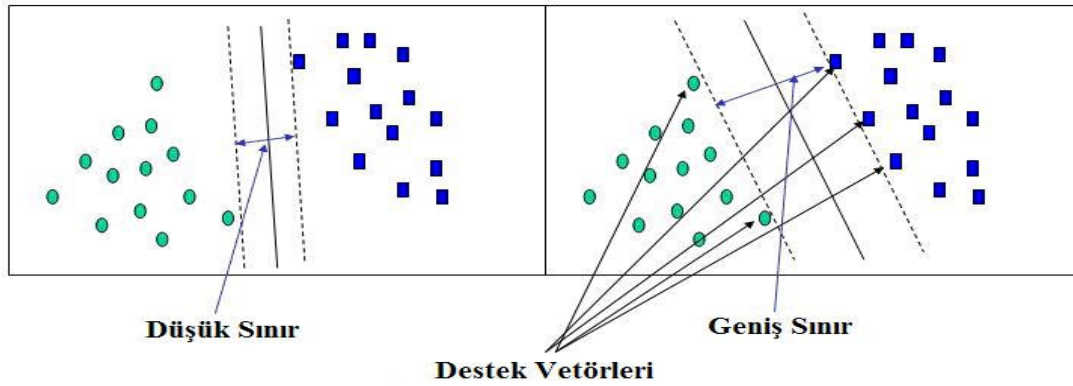
N boyutlu aşırıdüzlemi düşünmeden önce basit 2 boyutlu bir örnek üzerinde algoritmanın çalışmasını inceleyelim. Sınıflandırma için 2 kategorili hedef değişkeni ele alalım. Devamlı değerlerle iki öncelik değişkeni olduğunu varsayalım. X ekseninde öncelik değişkenlerinden birini Y ekseninde diğerini kullanarak veri noktalarını oluşturursak aşağıdaki şekli elde ederiz. Hedef değişkeninin bir kategorisini dikdörtgenler ile, diğer kategorileri ovalar ile temsil ederiz. Şekil 4.11’de sınıflandırma örneği görülmektedir. [10]



Şekil 4.11 Sınıflandırma örneği

Bu örnekte durumlar tamamen farklı köşelerde toplanıp tamamen ayrıştırılmıştır. DVM analizi, olayları ayıran 1-boyutlu aşkın düzlemi hedef kategorilerini temel olarak bulmaya çalışır. Mümkün çizgilerin sınırsız sayısı vardır. İki aday çizgi yukarıdaki gibi gösterilir. Hangi çizginin, daha iyi olduğunu ve optimal çizgiyi nasıl bulacağımız önemlidir. Noktalı gösterilen çizgiler en yakın vektörler arasında mesafeyi ayıran çizgiye paralel olarak çekilir. Noktalı çizgilerin arasındaki mesafe kenarı çağırır. Kenarın genişliğini zorlayan

vektörler, destek vektörleridir. Şekil 4.12’de destek vektörleri ve elde edilen maksimum sınırlar gösterilmiştir. [10]




Şekil 4.12 Destek Vektörleri ve Sınırlar

DVM analizi, destek vektörlerinin arasındaki kenarı azami dereceye çıkararak yön verilen çizgileri bulur. Eğer bütün analizler, iki öncelik değişkeniyle iki kategori hedef değişkenine dayansaydı noktalar kümesini düz bir çizgi ile bölmüş olurdu.


Yüksek boyutlara geçerse; Yukarıdaki örnekte 2 boyut için iki öncelik değişkeni kullanılıp, düzlem üzerinde çözüm bulunmuştur. Bu işlem 1 boyut için çizgi şeklindedir. 3 boyutlu bir örnek ele alınırsa 3. öncelik değişkeni devreye girerek bir küp elde edilmiş olur.

Ekstra öncelik değişkenleri eklenildiği gibi, veri noktaları N boyutlu uzayda temsil edilebilir ve (N-1) ayırıcı düzlem, onları ayırabilir. İki grubu bölmek için en basit yol, düz bir çizgi veya N-boyutlu bir düzlemdir. Ama noktalar doğrusal çizgiyle ayıramayacak şekilde bulunursa bu işlem yapılamaz. Şekil 4.13’de doğrusal olmayan sınıflandırma örneği görülmektedir. [10]



Şekil 4.13 Doğrusal Olmayan Sınıflandırma


Bu durumda doğrusal olmayan bir çizgiye ihtiyaç duyulur. Veriye doğrusal olmayan eğrilerle uymaktansa DVM'yi başka bir uzaya çekirdek fonksiyonu aracılığıyla taşıyarak daha tutarlı bir şekilde ayırım sağlanmış olunur. Şekil 4.14'de çekirdek fonksiyonlarının üst boyuta taşınması gösterilmektedir. [10]



Şekil 4.14 Çekirdek fonksiyonları ile üst boyuta taşıma işlemi


Çekirdek fonksiyonu, sınıflandırmanın yapılabilmesi için veriyi daha yüksek boyutlara taşıyabilir. Şekil 4.15'de verinin yüksek boyutlara taşınarak yapılan haritalama işlemi gösterilmektedir. [10]





Şekil 4.15 Haritalama işlemi

Çekirdek fonksiyonunun üst boyuta taşınma işlemi güçlü bir yaklaşımdır. Çok karmaşık sınırlarla ayrılan durumlarda bile Şekil 4.16 resimde görüldüğü gibi DVM modellerine izin verir. [10]



Şekil 4.16 Örnek DVM modeli

#### 4.4. DVM de kullanılan Çekirdek Fonksiyonları

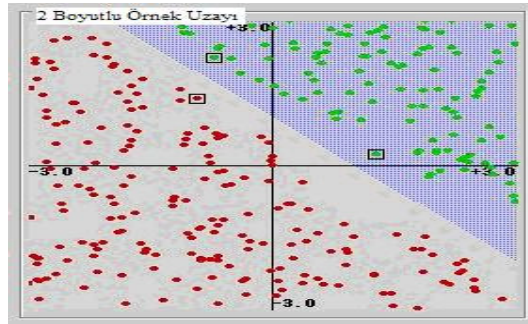
Çekirdek fonksiyonları sınıflandırmanın daha yüksek boyutlarda yapılabilmesi için taşıma işleminde kullanılabilir. Uygulamaların büyük çoğunluğunda birçok çekirdek fonksiyonu iyi sonuçlar verir.

Sık kullanılan çekirdek fonksiyonları Doğrusal, Polinomial, Radyal Tabanlı ve Sigmoid Fonksiyonlarıdır.

##### 4.4.1. Doğrusal Fonksiyon

Doğrusal sınıflandırma işlemi, doğrular çizilerek yapılır ve dikdörtgen, kare gibi şekillerin sınıflandırılmasında daha etkilidir.

Doğrusal sınıflandırmada kullanılan fonksiyon,  $(u \cdot v)$  formülü ile temsil edilir. Şekil 4.17'de gösterildiği gibi doğrusal olarak sınıflandırma yapar. [10]




Şekil 4.17 2 Boyutlu Örnek Uzayında Doğrusal Fonksiyon Gösterimi


##### 4.4.2. Polinomial Fonksiyon

Polinomial fonksiyon ile sınıflandırma,  $(\gamma \cdot u \cdot v + katsayı_0)^{derece}$  formülü kullanılarak yapılmaktadır.

Şekil 4.18'de doğrusal ve doğrusal olmayan sınıflandırma birlikte gösterilmektedir. Şekil 4.19'da ise 2 boyutlu örnek uzayında Polinomial fonksiyonun sınıflandırılması gösterilmektedir. [10]




Şekil 4.18 Doğrusal ve Doğrusal Olmayan Sınıflandırma Gösterimi



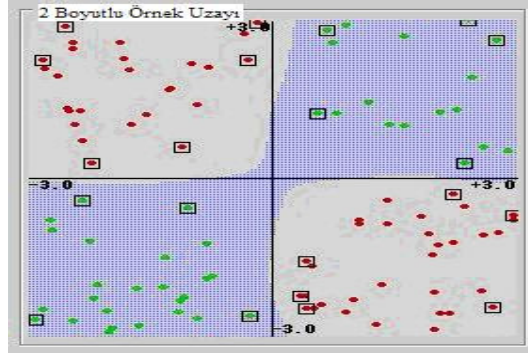
Şekil 4.19 2 Boyutlu Örnek Uzayında Polinomial Fonksiyon Gösterimi

#### 4.4.3. Radyal Tabanlı Fonksiyon

Radyal Tabanlı sınıflandırma işlemi, doğrusal olmadığından örneği daha yüksek boyutlu bir uzaya taşıyarak gerçekleştirir. Bu işlem için  $\exp(-\gamma \cdot |u - v|^2)$  fonksiyonu kullanılır. Şekil 4.20, Radyal tabanlı fonksiyon kullanılarak farklı bir boyuta taşınma ve sınıflandırma sonucunu göstermektedir. Şekil 4.21'de, 2 boyutlu örnek uzayında sınıflandırma gösterilmektedir. [10]




Şekil 4.20 RTF ile Sınıflandırılarak Farklı Boyuta Taşınması



Şekil 4.21 2 Boyutlu Örnek Uzayında Radyal Tabanlı Fonksiyon Gösterimi

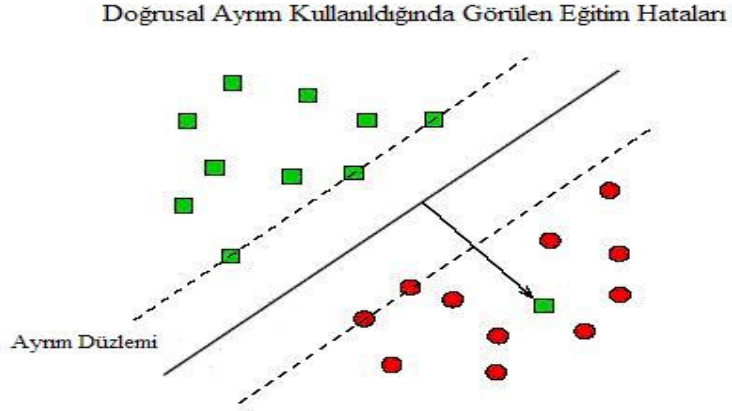
#### 4.4.4. Sigmoid Fonksiyon

Sigmoid fonksiyon ile sınıflandırma,  $\tanh(\gamma.u.v + katsayı_0)$  formülü kullanılarak yapılmaktadır. Şekil 4.22’de sigmoid fonksiyon yapısı gösterilmiştir. [10]



Şekil 4.22 Sigmoid Fonksiyon

İdeal olarak bir DVM 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. Şekil 4.23’de hatalı sınıflandırma örneği görülmektedir. [10]



Şekil 4.23 Hatalı Sınıflandırma Örneği

Kategorileri ayırma işleminde esnekliğe izin vermek için  $C$  parametresi kullanılır. Bu parametre hataları kontrol altına almak için kullanılır. Örneğin sert kenarlara yumuşaklık kazandırarak daha iyi sınıflandırma yapılmasını sağlar.  $C$ 'nin değerini artırmak, iyi bir şekilde genellenemeyen kaçan noktaların sınıflandırmasını sağlar. [11]

#### 4.5. Çekirdek ve Parametre Seçimi

Sadece dört ortak çekirdek olmasına rağmen ilk aşamada birinin seçilmesi gerekmektedir. Genellikle kullanılan RTF tipi çekirdektir. Daha sonra ceza parametresi  $C$  ve çekirdek parametrelerinin seçilmesi gerekmektedir. [12]

##### 4.5.1. Çekirdek Tipi

Doğrusal çekirdek, sınıflandırma işlemini doğrular çizerek tanımlar. Bu yüzden dikdörtgen ve kare olan şekillerin sınıflandırılmasında daha etkilidir.

RTF çekirdeği, sınıflandırma işlemini doğrusal olmayan, örneği daha yüksek boyutlu bir uzaya taşıyarak gerçekleştirir. Doğrusal olmadığından dolayı sınıf etiketleri ve nitelikler arasındaki ilişkileri duruma göre tutabilir. RTF, doğrusal çekirdek ile ceza parametresinin birleşmiş halidir.

Polinomial çekirdek, RTF'ye göre daha fazla parametre içerir. Bu yüzden, RTF çekirdeğinin daha az sayısal zorlukları bulunmaktadır. 1 anahtar noktası olmak üzere  $0 < K_{ij} < 1$  polinomial çekirdeklerle mukayese edersek, polinomial çekirdeğin derecesi büyük ise  $((\gamma)x_i^T x_j + r > 1)$  sonsuza veya  $((\gamma)x_i^T x_j + r < 1)$  sifıra gider.

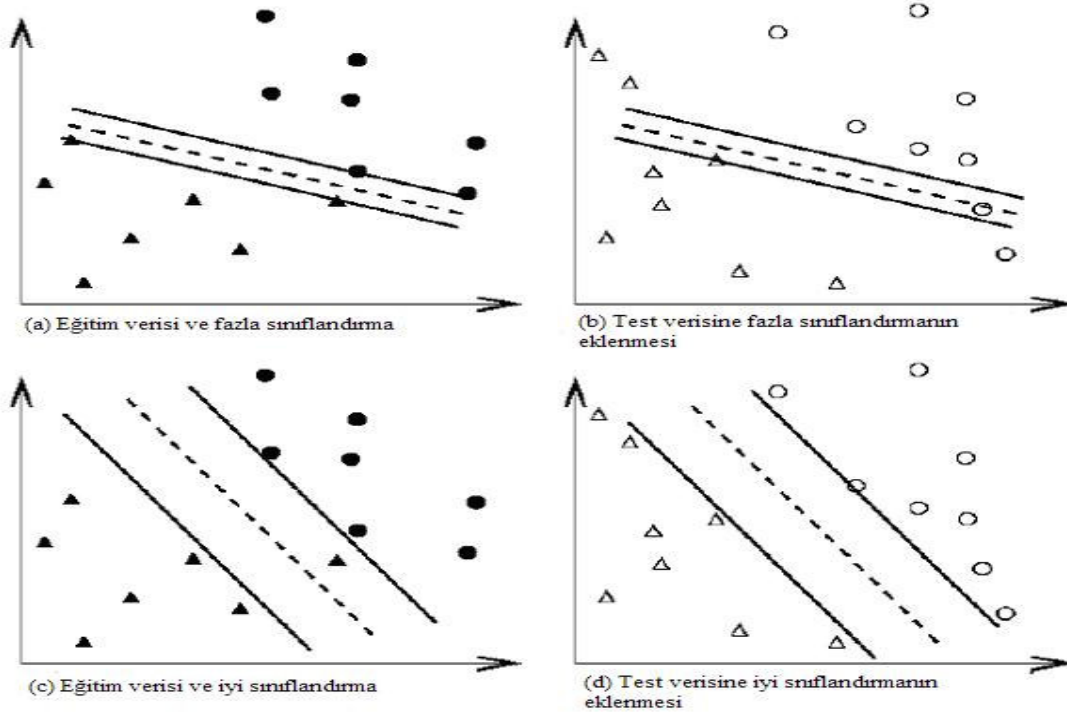
Sonuç olarak, düşük derecelerde polinomial çekirdek ile iyi sonuçlar alınabiliyorsa polinomial çekirdek, sınıflandırmada kaçan kısımlar oluyorsa (C hata parametresini içerdiğinden dolayı) RTF çekirdek kullanılmalıdır. Doğrusal çekirdek, özellik sayısının çok fazla olduğu durumlarda daha iyi sonuçlar vermektedir.

#### 4.5.2. Çapraz Geçerli Kılma ve Hücre Arama

RTF çekirdeğini kullanırken iki parametre bulunmaktadır: C ve  $\gamma$ . Hangi C ve  $\gamma$ 'nın, bir problem için en iyi sonucu vereceği önceden bilinmez. Sonuç olarak model seçimi (parametre araması) yapılmalıdır. Bu işlemdeki amaç, sınıflandırmayı iyi yapacak ve doğru olarak bilinmeyen veriyi tahmin edecek (C ve  $\gamma$ ) parametrelerini seçmektir. Ortak bir yol olarak sınıflandırıcıyı eğitme işlemi iki parça şeklinde yapılmalıdır. Sonra, bu takıma, tahmini kesinliği bilinmeyen veriyi sınıflandırma performansı yansıtılabilir. Bu prosedürün geliştirilen bir uyarlaması, çapraz geçerli kılmadır. Çapraz geçerli kılma yaklaşımında öncelikle eğitim takımı eşit boyutta  $v$  adet parçalara bölünür. Sırayla bir alt takım, kalan  $v-1$  alt takımla eğitilen sınıflandırıcıyı kullanmak için test edilir. Böylece, tüm eğitim takımının her örneği, bir defa tahmin edilmiş olur. Bundan dolayı çapraz geçerli kılma kesinliği, doğru şekilde sınıflandırılmış olan verinin yüzdesi olur. Çapraz geçerli kılma prosedürü, uygunsuzluk problemini engelleyebilir.

Şekil 4.24'de ikili sınıflandırma problemi (üçgen ve daireler ile) gösterilmiştir. [12] Doldurulan çemberler ve üçgenler eğitim verisidir, delik çemberler ve üçgenler test verisidir. Şekil 4.24(a) ve Şekil 4.24(b) eğitim verisine fazla benzediğinden test kesinliği iyi değildir. Eğer, Şekil 4.24(a) ve Şekil 4.24(b)'deki verilerin eğitime ve test etme işlemlerini düşünürsek, çapraz geçerli kılma işleminde geçerli kılma takımları çok iyi sonuç vermez. Diğer taraftan,

Şekil 4.24(c) ve Şekil 4.24(d)'de sınıflandırıcı veriyi eğitmeye fazla uymadığından kesinliği ve ek olarak daha iyi çapraz geçerli kılmayı verir.



Şekil 4.24 Fazla Sınıflandırma ve İyi sınıflandırma

Çapraz geçerli kılmada  $C$  ve  $\gamma$ 'yı bulmak için "Hücre arama" yöntemi tavsiye edilir. Temelde  $(C, \gamma)$  çiftleri denenerek en iyi çapraz geçerli kılma kesinliği ile biri seçilir. (Örneğin,  $C = 2^{-5}, 2^{-3}, \dots, 2^{15}$ ,  $\gamma = 2^{-15}, 2^{-13}, \dots, 2^3$ ). Ters geçerli kılma oranı sabit hesaplanarak saklanan birkaç ileri metod gibidir. Hücre aramada iyi parametre değerleri bulunabilmesi için hesaplama zamanı iki parametre değeri için de diğer metotlardan daha az sürer. Üstelik, hücre arama ile  $C$  ve  $\gamma$  birbirinden bağımsız olduğundan kolayca paralelleştirilebilir. İleri metotların birçoğu tekrarlayıcı süreçlerdir bu yüzden paralelleştirilebilmesi oldukça zordur. [12]

## 5. LİTERATÜR ÇALIŞMALARI

K Jonsson, J Kittler, YPL ve J Matas (1999)'a göre DVM yaklaşımı, eğitim verisinden yüz bulma ile ilgili farkı çıkaran hipotezi destekler. Bu işlem yüksek performans gerektiren bir işlemdir. Temsil uzayını yakaladığı zaman ve fark gözetken bilgiyi Fisherface yöntemine uyguladığı zaman DVM'ye üstünlüğünü kaybeder. [13]

Matthias Ratsch, Sami Romdhani ve Thomas Vetter (2002)' e göre bütün şekilde bulunan pikseller potansiyel olarak bir nesnenin merkezini ifade edebileceğinden, bir şekilde özel bir nesneyi bulmak zor bir hesaplamadır. Bu yüzden bütün pikselleri sınıflandırıp, *kaba kuvvet* yaklaşımını nesne bulma algoritmaları ile birleştirmişlerdir. Pikseller arasında kolay bir şekilde ayırım gözetmek için basit olarak ilgili nesneye benzeyen daha karışık ve yavaş filtreler ile sınıflandırma yapmışlardır. Bu işlem, karmaşıklığı artıran sınıflandırıcının bir çağlayanını oluşturarak gerçekleştirilir. Yüz bulma işleminde, bir pixel, herhangi bir durumda yüz olmayan kısımda sınıflandırılırsa piksel daha sonra geri çevrilir ve o piksel daha fazla işleme tabi tutulmaz. Romdhani, bir destek vektör makinesinin taşırılmış vektör kümesini kullanır. [14] Taşmanın her durumunda 20 x 20 piksellik filtre, sınıflandırıcıya eklenir. [15] Filtreleme için AdaBoost algoritması kullanılmıştır. Sınıflandırma işlemi bu filtreleri kullanarak gerçekleştirilir. [16]

Peichung Shih ve Chengjun Liu (2005), dağıtım (yaygın) tabanlı uzaklık ölçüsü ve DVM'yi kullanan yeni bir yöntem geliştirmişlerdir. Bu yöntemde ilk olarak giriş resminden özellik vektörünün farkı tanımlanır, bu Haar dalgacıklarını temsil eder ve geniş bir izdüşümdür. Nesne tanımlaması için elde edilen etkin Haar dalgacığı ile insan yüzünün dikey karakteristikleri ve yatay simetrikleri elde edilmiştir. İkinci olarak yüz sınıflandırmaları ve yüz olmayan sınıflandırmalar için Dağıtım Tabanlı Uzaklık (DTU) ölçüleri ve olasılık yoğunluk fonksiyonu kullanılarak yüz sınıf modelleri tanımlanmıştır. [17] Üçüncü olarak giriş örneklerinden elde edilen DTU'lar üç sınıfa ayrılmıştır. Bunlar; Yüz sınıfları(Kapalı yüz örnekleri), Yüz olmayan sınıflar(Yüz örneklerinden uzak sınıflar) ve kararlaştırılmamış sınıflardır. [18]

Hyungkeun Jee, Kyunghye Lee ve Sungbum Pan (2004) çalışmalarında kişisel doğruluk için renk, kenar, ikili bilgi ve destek vektör makinelerini kullanan gerçek zamanlı yüz tespit sistemi geliştirilmiştir. Geliştirilen metotta yüz bölgelerinin tespitinde ten rengi ve



eş zamanlı bir şekilde renk bilgisinin eksikliğini gidermek için kenar bilgilerini kullanır. Metotta yüz ile ilgili bölgede kenar ve ikili bilgi kullanılarak aday göz çiftleri bulunur sonra göz çiftinin merkezinden döndürme ve normalleştirme işlemleri ile gerçek zamanlı yüz tespiti gerçekleştirilmiştir. Deneysel sonuçlar sonunda %99,2 gibi yüksek doğruluk elde edilmiştir. [19]

Guang Dai ve Changle Zhou (2003) çalışmalarında, yerel özellik olarak yüz şekillerinin Gabor dalgalarını temel alarak, yüzle ilgili ifade ve pozdaki değişikliklere karşı sağlam olarak büyütülen Gabor yüz vektörlerini elde etmişlerdir. Bu vektörlerden, çekirdek bileşen analiz prensibi (ÇBAP) kullanılarak elde edilen özellikleri sınıflandırmak için bir yüz tanıma yöntemi olan destek vektör makineleri kullanmışlardır. [20]

Diedrick Marius, Sumita Pennathur ve Klint Rose (2003)'un çalışmasında kullanılan yaklaşım, bir kırmızı plan algoritmasına benzer. [21] İlk adım yüz olmayan bölgeleri geri çevirme, renk eşiği ve ten bölünmesini temel alır. Sonraki adım, bu bölgelerde daha açık çizimleri oluşturarak ikili şekli kullanmaktır. Eğitim resmi ve özyüzlerin ikisi de şablon eşlenerek denk hale gelir ve özyüzleri yüz olmayan resimlerden bulma için Sirovich Kirby kullanılmaktadır. [22]

Jin Seo ve Hanseok Ko (2004) çalışmalarında, Destek Vektör Alan Tanımlaması (DVAT) yöntemini kullanmışlardır. [23] DVAT eğitim için sadece yüz olan şekilleri kullanır. DVAT algoritması kolay bir şekilde sınıflandırma yapan algoritmadır. Temel düşünce, veri içerisinde minimal yarıçap ve merkezle bir küreyi bulmaktır. Yarıçap ve merkez, DVAT'ı eğitme sonuçları olan destek nesnesi ve destek vektöründen elde edilir. Bir test verisi, merkezden olan mesafenin, yarıçaptan daha küçük olduğu zaman kabul edilir. Giriş uzayında, yarıçap yalnız veriyi temsil edemediğinde sınıflandırma iyi yapılamaz. Yüz aday bölgelerinde yüzle ilgili özelliği çıkarmak için *Entropic* eşiğini kullanan renk kenarları kullanılmıştır. [24] Aday bölgeler, YCbCr renk uzayında ve Gaussian yoğunluğunun modelinden elde edilmiştir. [25][26] İşlemin yapılacağı şekilde arka plan piksellerinde kayan pencere ile bulma işlemi gerçekleştirilir.

Gianluca Antonini, Vlad Popovici ve Jean-Philippe Thiran (2002) çalışmalarında yüz ile ilgili özellik çıkarımına odaklanmışlardır. Bütün mevcut yüz bulma algoritmalarının mümkün sınıflandırmaları arasında, Holistik Yüz Modelleri (HYM) kullanarak yerel

özellikler elde etmişlerdir. Bütün yüzü içeren HYM yaklaşımında resim bölgesi elle seçilip ve yüz modelinin bir temsili örneklerden öğrenmesi sağlanmıştır. Açık bir şekilde bu yaklaşımda yüz ile sınıf uyumsuzluğunu yakalanmak istenmiştir. [27]

Maya Choueiri, Nassib El-Sayegh, Wassim Said (2005) çalışmalarında ilk olarak ten piksellerinin tespitinde renkli resmi ten renk filteresinden geçirmişlerdir. Daha sonra yüz özellik vektörleri elde etmek için bir algoritma geliştirmişlerdir. Eğitim esnasında yüz şekillerinin seçimi için yapay sinir ağlarını kullanmışlardır. [28]

## 6. DESTEK VEKTÖR MAKİNELERİNİ KULLANARAK YÜZ TESPİTİ UYGULAMASI

Bu bölümde geliştirilen yüz bulma uygulamasından bahsedilmiştir. Uygulama MS Windows işletim sistemi üzerinde, MS Visual Studio 2005 platformunda C# 2.0 programlama dili ile geliştirilmiştir.

Uygulama genel olarak 4 ana katmandan oluşmaktadır:

- Giriş Katmanı
- Temel Katman
- DVM Katmanı
- Dış Katman

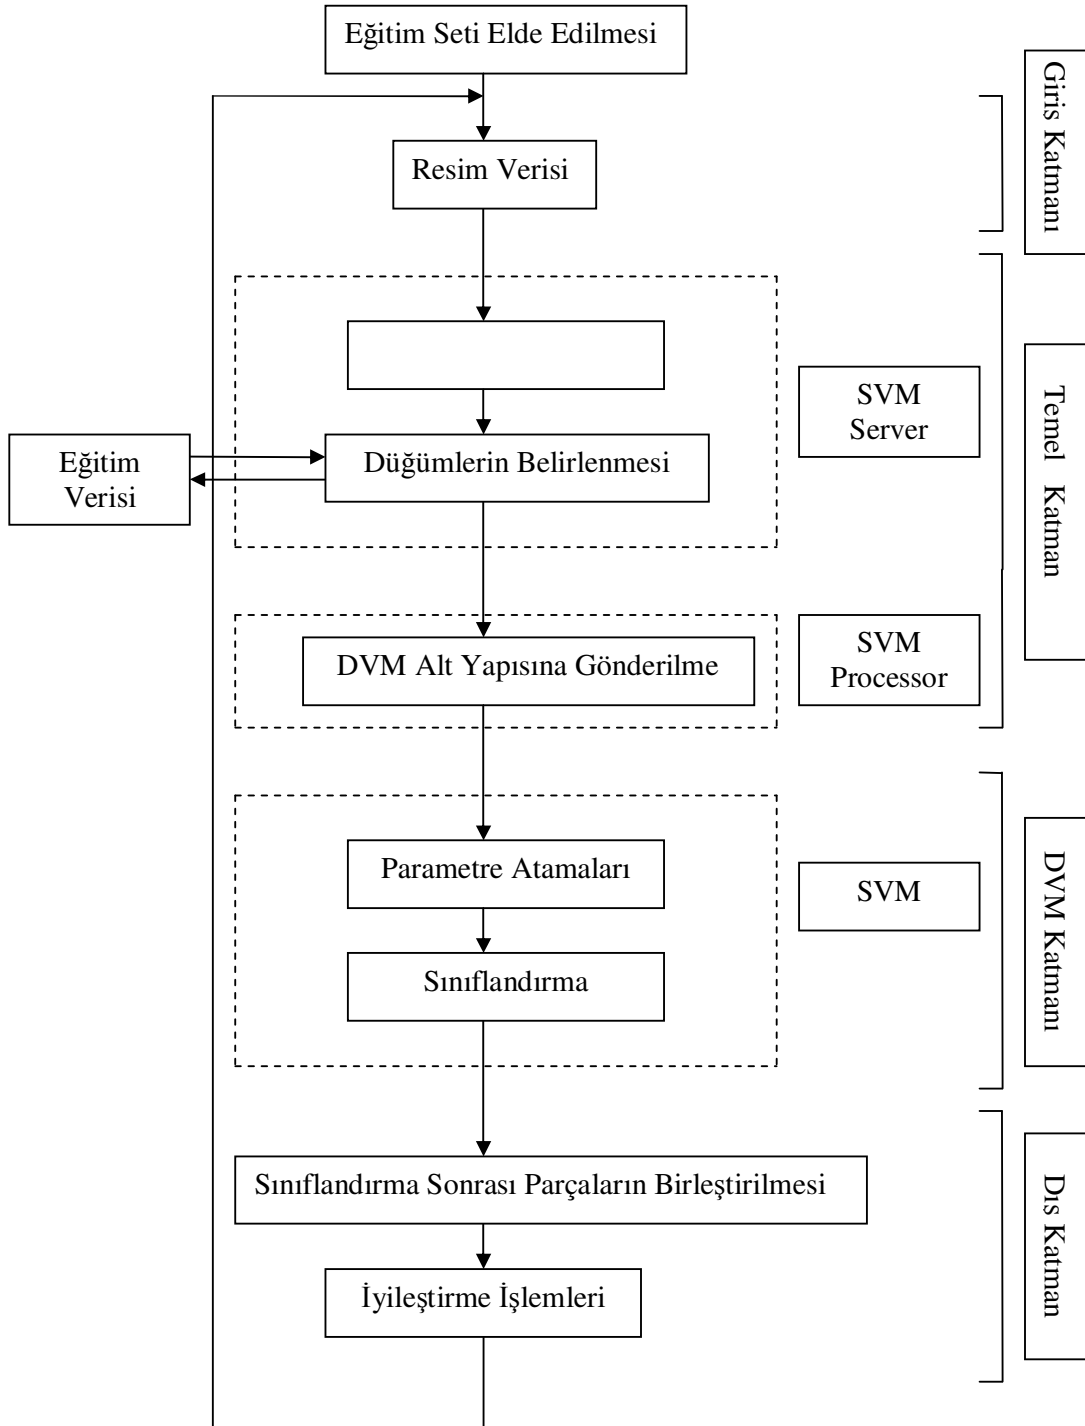
Giriş katmanında, eğitim seti elde edilerek, kullanıcıdan alınan giriş resmi ile birlikte temel katmana gönderilir.

Temel katmanda, giriş resmi üzerinde temel bölümlenme işlemi ve alınan eğitim verisine göre düğümlerin belirlenme işlemi yapılarak elde edilen bilgiler DVM katmanına iletilir.

DVM Katmanında, kullanılacak çekirdek tipleri ve genel parametre atamaları yapılarak DVM sınıflandırma işlemi yapılır. Sınıflandırma sonrası çıkan sonuçlar dış katmana gönderilir.

Dış katman, DVM katmanından aldığı sınıflandırılmış parçaları birleştirir. Sınıflandırma sonucunda oluşacak gürültüleri azaltmak için iyileştirme çalışmalarını gerçekleştirir.

Şekil 6.1'de yüz bulma uygulamasının genel yapısı görülmektedir.



Şekil 6.1 Yüz Bulma Uygulamasının Genel Yapısı

## 6.1. Eğitim Verisinin Elde Edilmesi

Eğitim verisi yüz resimleri ve yüz olmayan resimlerden elde edilmiştir. Eğitim verisinin elde edilmesi için ayrı bir uygulama kullanılmıştır. Bu uygulama da MS Visual Studio C# 2.0 platformunda geliştirilmiştir. Uygulamada sayısal üç boyutlu, 256 elemanlı dizi kullanılmıştır. Burada dizinin her boyutu bir rengi (Red, Green, Blue - RGB) temsil etmektedir. R, G, B değerleri 0-255 arasında değer aldığından dolayı dizinin boyutu 256 olarak kabul edilmiştir. Eğitim resimlerinin her bir pikseli, RGB değerleri alınarak eğitim veri dizimize kaydedilmiştir. Yüz olan resimlerin RGB değerlerine 1, olmayanlarınkine 0 değeri atanmıştır. Daha sonra istatistik yöntemiyle genel eğitim verisi elde edilip metin dosyasına kaydedilmiştir.

Eğitim Verisini oluşturmak için, internet ortamı ve Georgia Tech yüz veritabanı kullanılmıştır. [30] Bu veritabanında 50 farklı kişiye ait ve her kişi için 15 farklı poz olmak üzere toplam 750 adet renkli resim bulunmaktadır. Resimlerin her biri 640 x 480 boyutundadır. Ten rengini belirlemek için resimler üzerinde işlem yapılarak boyut düşürülmüş ve sadece yüz kısımları alınarak eğitim verisinde kullanılmıştır. Eğitim verisi için 40 yüz resminden, 30 yüz olmayan resimden faydalanılmıştır.

Eğitim için kullanılan yüz ve yüz olmayan resimlere örnekler Şekil 6.2'de gösterilmiştir.



Şekil 6.2 Eğitim Verisini Oluştururken Kullanılan Yüz Resimleri ve Yüz Olmayan Resimler

## 6.2. Giriş Resminin Parçalara Bölünmesi

Alınan giriş resmi öncelikle uygulamadaki SVM Processor adı verilen sınıfa gönderilerek, resmin parçalara bölünme işlemi yapılır. Bölme işlemi giriş resminin boyutuna bakılmaksızın öncelikle 20x20 piksellik parçalara ayrılarak sınıflandırılmıştır. Elde edilen sonuçlar 40x40 piksellik parçalara bölünüp tekrar DVM tarafından sınıflandırılmış ve en son olarak geri dönen sonuçlar 60x60 piksellik parçalara bölünüp tekrar DVM tarafından sınıflandırılmıştır. Parçalara ayırmadaki amaç sınıflandırma işleminin daha hızlı yapılması içindir. Ancak, eğer tek boyutlu bir parçalama yapılırsa, parçalanma sonrasında yüz (veya yüzler) farklı parçalarda bulunabilir. Aynı zamanda yakından veya uzaktan çekilmiş resimlerde farklı boyutlarda yüzler olabilir. Böyle bir durumda sınıflama işlemi yanlış olabilir. Farklı boyutta parçalara bölmedeki amaç, hem farklı boyuttaki yüzler kaçırılmamış, hem de parçalanmış resim kullanıldığından sınıflandırma daha hızlı yapılmış olur. Parçalama işlemi sırasında parçaların herbiri bir diziye kaydedilir ve her biri geriye değer döndürür. Bu değerler DVM düğümlerinin belirlenmesinde kullanılır.


## 6.3. DVM Düğümlerinin Belirlenmesi

SVM Processor sınıfından döndürülen dizisinin elemanları tek tek alınarak eğitim verisi ile karşılaştırılır. Bu karşılaştırma ile DVM düğümleri belirlenir. DVM düğümleri belirlenirken eğitim verisinden çok fazla düğüm değeri döneceğinden sınıflandırma işlemi uzun sürecektir. DVM alt yapısının daha hızlı çalışabilmesi için düğüm değerleri üzerinde belirli oranlarda azaltma yapılarak bu sorunun giderilmesine çalışılmıştır. Yapılan azaltma çalışmaları doğrultusunda, hız ve elde edilen sonuç üzerinden en etkin oranlar; yüz olan düğümler için 1/4 , yüz olmayan düğümler için 1/6 olarak belirlenmiştir. Şekil 6.3'te orijinal resmin ve düğümlerin elde edilmesinden sonra oluşan resim gösterilmiştir.

Sınıflandırılma yapılmak istenen resimde, parçalama ve düğümlerde azaltma işlemi yapılmadan sınıflandırma sonucu yaklaşık 10 dakika elde edilirken, uygulanan yeni yöntemle sonuç 4 saniye civarlarına kadar düşürülmüştür.



a) Orijinal resim



b) Resminin DVM Düğümlerine Dönüştürülmüş Hali

Şekil 6.3 Giriş resminin DVM düğümlerine dönüştürülmüş hali

#### 6.4. Parametrelerin Seçimi

DVM alt yapısının kullanacağı parametreler belirlenmelidir. DVM parametreleri şunlardır:

- DVM tipinin seçimi
- Çekirdek tipinin seçilmesi
- $\gamma$  operatörünün belirlenmesi
- Polinomial çekirdek kullanıldıysa derecesinin atanması
- C sınırı, hata değerlerinin belirlenmesi,

Uygulamada her çeşit çekirdek tipi ve parametreler seçilerek genel başarı oranları hesaplanmıştır ve sonuç bölümünde yorumlanmıştır.

#### 6.5. Resmin DVM Alt Yapısına Gönderilmesi

Resim üzerinde parçalama ve düğüm belirleme işlemleri gerçekleştirildikten sonra DVM alt yapısına gönderilerek, destek vektör makine algoritması uygulanır. DVM'de

belirlenen düğüm arasında sınıflandırma işlemi yapılır. Resim bölgelerinde en fazla hangi düğüm değeri varsa sınıflandırma işlemi ona göre yapılır. [29]

### 6.6. Sınıflandırma Sonrası Parçaların Birleştirilmesi

Bölünen parçalar .Net içerisinde bulunan Rectangle (Dikdörtgen) sınıf türünden listeye alınıp sırayla SVM sınıfına gönderilmiş ve sınıflandırma sonucu dönen her sonuç yine liste sırasına göre birleştirilmiştir. Şekil 6.4'te sınıflandırmaya örnek verilmiştir.



a) Orijinal resim



b) DVM Kullanıldıktan Sonra  
Resim Formatına Dönüştürülmüş  
Resim

Şekil 6.4 DVM Kullanıldıktan Sonra Resim Formatına Dönüştürülmüş Resim

### 6.7. İyileştirme İşlemlerinin Yapılması

Sınıflandırma sonucunda her zaman istenen sonuç elde edilemeyebilir, yüz dışında farklı bölgeler bulunarak yanlış sınıflandırmalar olabilir. Bu tür hataları önlemek için iyileştirme işlemleri yapılmıştır. Bunlar kısaca şöyle açıklanabilir:

- **Sınıflandırılan alanların resim içerisindeki yerlerinin tespiti:**  
Sınıflandırılmış resim içerisinde piksel taraması yapılarak sınıflandırılmış

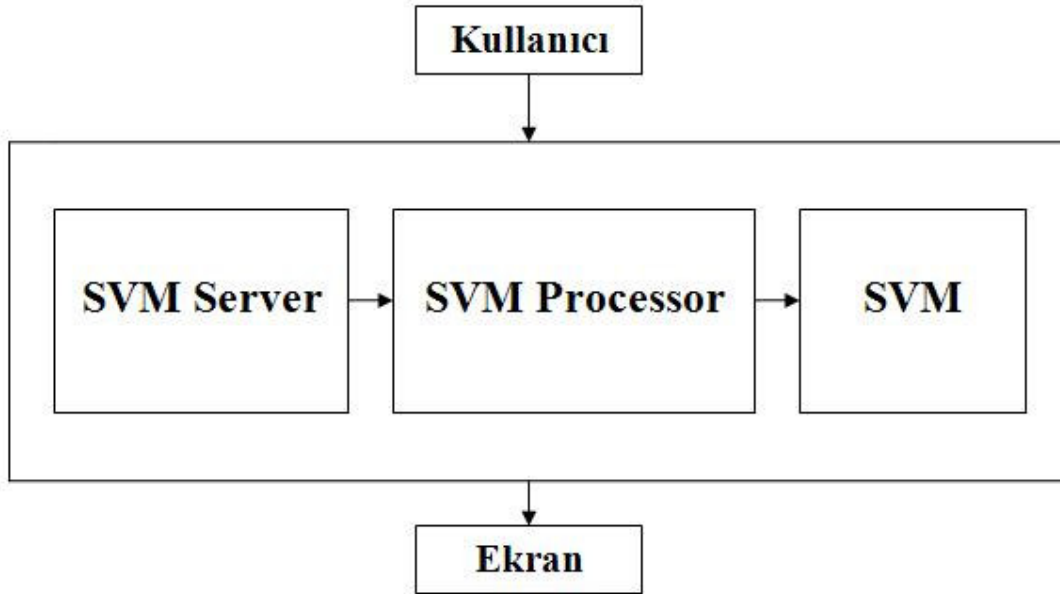


alanlar tespit edilir. Bu işlem RGB değeri beyaz renkten farklı olan kısımların çıkarılması şeklinde olur.

- **Tespit edilen alanlara boyut kontrolünün yapılması:** Yüz boyutunun genellikle 3000 pikselden fazla olamayacağı kabul edilip tespit edilen alanlara yüz boyut kontrolü yapılır.
- **Oran kontrolünün yapılması:** Yüzün genişlik ile yükseklik oranı değerleri arasında eşitlikler kullanılarak, alanların yüz olup olamayacağına karar verilir.
- **Eğitim verisinin standart sapmasının hesaplanması:** Ten renginin standart sapması çıkartılarak aday yüz alanlarına uygulama işlemi yapılmıştır.

### 6.8. Uygulamanın Sınıf Yapısı

Geliştirilen yüz bulma uygulaması 3 sınıftan oluşmaktadır. Şekil 6.5'te uygulamanın sınıf yapısı gösterilmektedir.



Şekil 6.5 Uygulamanın Sınıf Yapısı Gösterimi

**SVM Server:** SVM Server sınıfında kullanıcıdan alınan giriş resmi ile eğitim verisi karşılaştırılarak resim noktalar haline dönüştürülür.

**SVM Processor:** SVM Processor sınıfı resmi 20, 40, 60 piksellik parçalara böler, *thread* işlemi kullanarak parçaların işlemcide eş zamanlı çalışmasını sağlar. Düğüm sayısı fazla olduğunda DVM sınıflandırma işlemini uzun sürecektir, ancak parçalara bölünmüş resimler sayesinde bu işlem daha kısa zamanda yapılmış olacaktır.

**SVM:** Bu sınıfta, DVM düğümleri, parametre seçimi yapılarak sınıflandırma işlemi gerçekleştirilir.

## 7. UYGULAMA SONUÇLARI

Bu tez çalışması kapsamında destek vektör makineleri kullanılarak yüz tespiti işlemini gerçekleştiren uygulama geliştirilmiştir. Sınıflandırma için yüze ait ten rengi özellik çıkarımı yaklaşımından yararlanılmıştır. Bu bağlamda ten rengi eğitim verisini elde etmek için, hem internet ortamından resimler alınmış, hem de Georgia Tech yüz veritabanı kullanılmıştır. Eğitim verisini elde etmek için ayrı bir program geliştirilmiştir ve eğitim setini oluşturmak için 40 yüz resminden, 30 yüz olmayan resimden faydalanılmıştır.

Destek Vektör Makineleri ile sınıflandırma işlemi sırasında elde edilen öznetelik düğümlerinin fazla olması nedeniyle sınıflandırma işlemi uzun sürmektedir. Sınıflandırmanın daha hızlı olması için giriş verisi olarak verilen resim üzerinde 20x20, 40x40, 50x50 piksellik boyutlarında parçalama işlemi yapılmıştır. Parçalama işlemi sonrasında elde edilen öznetelik düğümlerinde azaltama yoluna gidilerek sınıflandırma işleminin daha hızlı çalışması sağlanmıştır.


Sınıflandırma işleminin performansını değerlendirmek için farklı çekirdek ve parametreler için denemeler yapılmış ve sonuçlar irdelenmiştir. Performans değerlendirilmesi, tek yüz ve çoklu yüz bulunan resimler üzerinde Polinomial, Radyal Tabanlı, Doğrusal ve Sigmoid çekirdekleri kullanılarak yapılmıştır.

Giriş resimden sadece bir yüzün bulunduğu durumlarda performans değerlendirilmesi aşağıda verilmiştir.

Farklı dereceler için Polinomial çekirdek kullanıldığında elde edilen sonuçlar Tablo 7.1'de, verilmiştir. En iyi sonucu veren üçüncü dereceden polinomial çekirdek için doğru ve hatalı bulunan yüzlerin grafiksel gösterimi Şekil 7.1'de gösterilmektedir. Üçüncü dereceden polinomial çekirdek kullanımında başarı oranı %92.1 olarak elde edilirken, polinomial çekirdekte derece arttırıldıkça başarının düştüğü, zamanın arttığı gözlenmiştir. Derece arttırıldığında yapılan işlemler daha karmaşık olduğundan işlem süresi artmış ve polinomial çekirdek sınıflandırmanın üst sınırını aştığından başarı oranı düşmüştür.

Tablo 7.1 Polinomial Çekirdek Uygulama Sonuçları

Kullanılan Çekirdek Tipi ve Parametreler	Süre	Başarılı Yüz Tespi Oranı (%)	Yanlış Yüz Tespit Oranı (%)
Polinomial Çekirdek (derece=3)	3.8 sn	92.1	12.8
Polinomial Çekirdek (derece=5)	3.8 sn	92.0	13.2
Polinomial Çekirdek (derece=10)	4.2 sn	86.4	17.6
Polinomial Çekirdek (derece=15)	6.3 sn	82.3	21.4
Polinomial Çekirdek (derece=20)	7.8 sn	78.6	26.8




Şekil 7.1 Üçüncü Dereceden Polinomial Çekirdek Kullanıldığında Doğru ve Hatalı Bulunan Resimlerin Grafikselleştirilmesi

Radyal tabanlı çekirdek kullanıldığında %88.3 başarı oranı sağlanmıştır. Radyal tabanlı çekirdek, polinomial çekirdekten sonra yüzün hatlarının oval biçimde çıkmasını sağlayan çekirdek tipidir. Radyal çekirdekte,  $\gamma$  parametresi ve C katsayısı üzerinde değişiklikler yapılarak sonuçlar Tablo 7.2’de verilmiştir.  $\gamma$  0,01 değerinde en iyi sonuç elde edilmiştir. C parametresinin değeri artırıldıkça hata oranının arttığı gözlenmiştir. C parametresi destek vektörleri arasındaki sınırı belirlediğinden, sınır belirli değer üzerinde artırıldığında yanlış sınıflandırmalara sebep olmuştur. Radyal tabanlı çekirdek kullanıldığında en iyi sonucu veren  $\gamma =0.01$ , C=1 için doğru ve hatalı bulunan yüzlerin grafiksel gösterimi Şekil 7.2’de verilmiştir.

Tablo 7.2 RTF Çekirdek Uygulama Sonuçları

Kullanılan Çekirdek Tipi ve Parametreler	Süre	Başarılı Yüz Tespi Oranı (%)	Yanlış Yüz Tespit Oranı (%)
RTF ( $\gamma =0.01, C=1$ )	3.8 sn	88.3	14.6
RTF (C=10)	3.9 sn	85.2	16.7
RTF (C=20)	3.9 sn	82.7	19.8
RTF (C=50)	3.9 sn	79.6	21.6
RTF (C=100)	4 sn	76.7	24

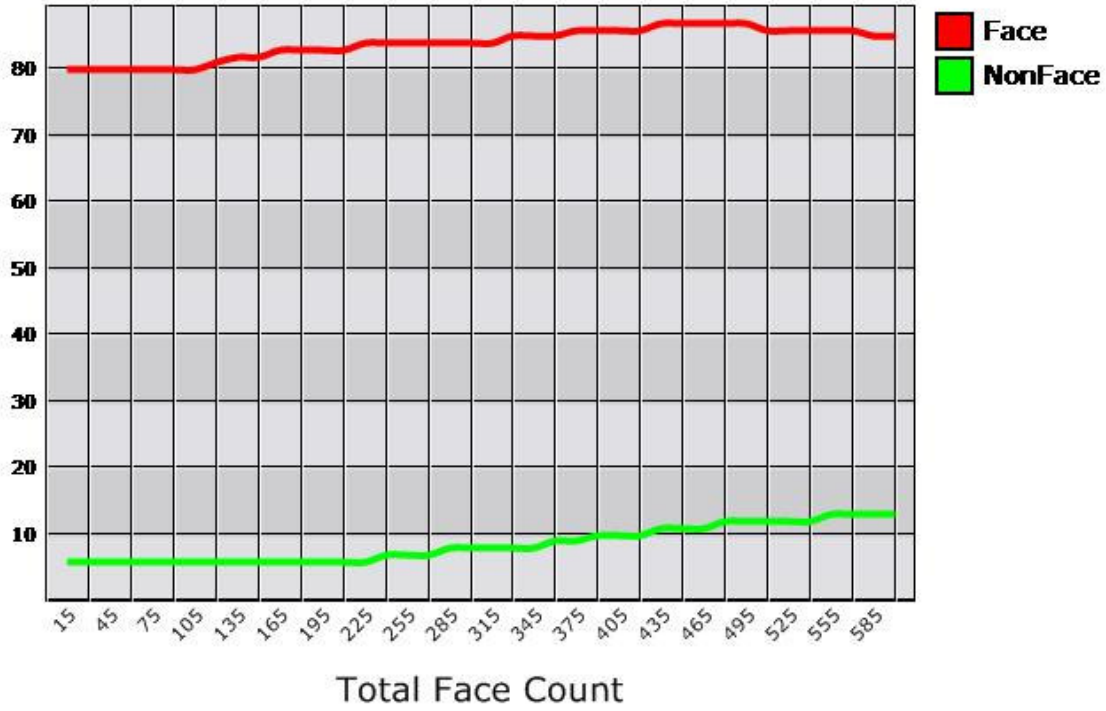


Şekil 7.2 Radyal Tabanlı Çekirdek Kullanıldığında Doğru ve Hatalı Bulunan Resimlerin Grafiksel Gösterimi

Doğrusal çekirdek kullanıldığında, %86.3 başarı oranı elde edilmiştir. Bu çekirdek tipi kullanımında yüz bulma işleminde sonuçlar daha keskin ve doğrusal olarak meydana gelmiştir. Bu da bazı resimlerde yüz kayıplarına neden olmuştur. Doğrusal çekirdek uygulama sonuçları Tablo 7.3’de, doğru ve hatalı bulunan yüzlerin grafiksel ifadesi Şekil 7.3’de gösterilmiştir.

Tablo 7.3 Doğrusal Çekirdek Uygulama Sonuçları

Kullanılan Çekirdek Tipi ve Parametreler	Süre	Başarılı Yüz Tespi Oranı (%)	Yanlış Yüz Tespit Oranı (%)
Doğrusal Çekirdek	3.8 sn	86.3	12.1



Şekil 7.3 Doğrusal Çekirdek Kullanıldığında Doğru ve Hatalı Bulunan Resimlerin Grafiksel Gösterimi

Sigmoid çekirdek kullanıldığında %85 oranında bir başarı gözlenmiştir. Sigmoid çekirdek uygulama sonuçları Tablo 7.4’de, doğru ve hatalı bulunan yüzlerin grafiksel ifadesi Şekil 7.4’de gösterilmiştir.

Tablo 7.4 Sigmoid Çekirdek Uygulama Sonuçları

Kullanılan Çekirdek Tipi ve Parametreler	Süre	Başarılı Yüz Tespi Oranı (%)	Yanlış Yüz Tespit Oranı (%)
Sigmoid Çekirdek	3.8 sn	85	14



Şekil 7.4 Sigmoid Çekirdek Kullanıldığında Doğru ve Hatalı Bulunan Resimlerin Grafiksel Gösterimi

Tek yüz bulunan resimlerdeki en iyi sonucu veren parametreleri çoklu yüz resimlerine uygulayarak performans değerlendirilmesi yapılmıştır. Elde edilen değerlendirme sonuçları Tablo 7.5'de gösterilmiştir.

Tablo 7.5 Çoklu Resim Uygulama Sonuçları


<b>Kullanılan Çekirdek Tipi ve Parametreler</b>	<b>Süre</b>	<b>Başarılı Yüz Tespit Oranı (%)</b>	<b>Yanlış Yüz Tespit Oranı (%)</b>
Polinomial Çekirdek (derece=3)	4.2 sn	90.1	12.8
RTF Çekirdek ( $\gamma=0.001, C=1$ )	4.2 sn	91.2	14.5
Doğrusal Çekirdek	4.2 sn	88.2	12.8
Sigmoid Çekirdek	4.2 sn	85	14

Grup resimlerinde Radyal Tabanlı Fonksiyon çekirdek kullanıldığında, %91.2 yüz bulma oranı ile diğer çekirdek türlerine göre daha iyi sonuç elde edilmiştir. RTF çekirdek oval fonksiyon yapısına sahip olduğundan yakın plandan çekilmiş yüzlerin bulunmasında daha iyi sonuçlar vermiştir. Sınıflandırma süresinde, dört çekirdek tipi için de bir değişiklik gözlenmemiştir.

Farklı çekirdekler kullanılarak, hem tek yüz bulunan resimler, hem de çok yüz bulunan resimler için uygulama sonuçlarına ait örnekler aşağıda verilmiştir.



Tek yüz bulunan resimler üzerine uygulamanın ürettiği sonuçlar Şekil 7.5 ve Şekil 7.6'da görülmektedir.



(a) Orijinal Resim



Polinomial Çekirdek Kullanımı



Doğrusal Çekirdek Kullanımı



RBF Çekirdek Kullanımı



Sigmoid Çekirdek Kullanımı

(b) Farklı çekirdek fonksiyonlarının uygulama sonucu  
Şekil 7.5 Tek Yüzlü Resimde Uygulama Sonuçları-1



(a) OrijinalResim



Polinomial Çekirdek Kullanımı



Doğrusal Çekirdek Kullanımı



RBF Çekirdek Kullanımı




Sigmoid Çekirdek Kullanımı

(b) Farklı çekirdek fonksiyonlarının uygulama sonucu  
 Şekil 7.6 Tek Yüzlü Resimde Uygulama Sonuçları-2

Değişik çekirdek fonksiyonları kullanılarak elde edilen uygulama sonuçları Şekil 7.7 ve Şekil 7.8'de görülmektedir.




(a) Orijinal Resim



(b) Polinomial çekirdek kullanıldığında uygulama sonucu



(c) RTF çekirdek kullanıldığında uygulama sonucu



(d) Doğrusal çekirdek kullanıldığında uygulama sonucu

Şekil 7.7 (a),(b),(c),(d) Çok yüzlü resim üzerinde uygulamanın ürettiği sonuçlar-1




(a) Orijinal Resim



(b) Polinomial çekirdek kullanıldığında uygulama sonucu



(c) RTF çekirdek kullanıldığında uygulama sonucu



(d) Doğrusal çekirdek kullanıldığında uygulama sonucu

Şekil 7.8 (a),(b),(c),(d) Çok yüzlü resim üzerinde uygulamanın ürettiği sonuçlar-2



Radyal Tabanlı Çekirdek fonksiyonu kullanılarak eksik yüz bulma için örnek Şekil 7.9'da , uygulamanın ürettiği hatalı sınıflandırma örneği Şekil 7.10'da görülmektedir.



(a) Orijinal Resim



(b) Uygulama Sonucu Resim

Şekil 7. 9 Uygulamanın ürettiği eksik yüz bulma sonuç



(a) Orijinal Resim



(b) Uygulama Sonucu Resim

Şekil 7. 10 Uygulamanın ürettiği hatalı sınıflandırma sonucu

## 8. SONUÇ

Bu tezde Destek Vektör Makineleri kullanılarak hızlı bir şekilde yüz tespiti amaçlanmıştır ve sınıflandırmanın daha hızlı yapılabilmesi için bir yöntem önerilmiştir.

Yüze ait ve ait olmayan şekillerden eğitim seti ve bu setin renk bilgilerinden yararlanarak eğitim verisi oluşturulmuştur. Destek Vektör Makinelerinin sınıflandırma için kullanacağı öznitelik düğümlerini elde etmek için sisteme verilen resimlerden 20x20, 40x40, 60x60 piksel boyutlarında parçalama işlemi yapılmıştır. Her bir parçalama işlemi sonrasında eğitim verisine göre öznitelik düğümleri belirlenmiştir.

Elde edilen öznitelik sayısının fazla olması sınıflandırma işleminin uzun sürmesine neden olmaktadır. Bu nedenle DVM alt yapısının daha hızlı çalışabilmesi için düğüm değerleri üzerinde belirli oranlarda azaltma işlemi yapılmıştır. Hız ve elde edilen sonuç üzerinden en etkin oranlar; yüz olan düğümler için 1/4, yüz olmayan düğümler için 1/6 olarak belirlenmiştir. Böylece parçalama ve düğüm sayısındaki azaltma işlemleri yapılarak, DVM ile sınıflama işlem süresinde %67 oranında azalma sağlanmıştır.

Düğüm sayısındaki azaltma işleminin sınıflama işlemi üzerinde performansını değerlendirmek için farklı çekirdek tiplerini tek yüz ve çok yüz bulunan resimler üzerinde test edilmiştir. Destek Vektör Makinelerini farklı çekirdekler ve parametreler için uygulanması sonucunda tek yüz içeren resimlerde üçüncü dereceden polinomial çekirdek kullanımında, %92.1 başarı oranı ile diğer çekirdek türlerine göre daha iyi sonuç vermiştir. Polinomial çekirdekte derece arttırdıkça başarının düştüğü gözlenmiştir. Derece artırıldığında yapılan işlemler daha karmaşık olduğundan işlem süresi artmış ve polinomial çekirdek sınıflandırmanın üst sınırını aştığından başarı oranı düşmüştür.

Radyal tabanlı çekirdek kullanıldığında %88.3 başarı oranı sağlanmıştır. C parametresinin değeri artırıldıkça hata oranının arttığı gözlenmiştir. C parametresi destek vektörleri arasındaki sınırı belirlediğinden, sınır değeri belirli bir değer üzerinde artırıldığında yanlış sınıflandırmalara sebep olmuştur.

Doğrusal çekirdekte %86,3 başarı oranı elde edilmiştir. Doğrusal çekirdek kullanımında yüz bulma işleminde sonuçlar daha keskin doğrusal olarak meydana gelmiştir. Bu da bazı resimlerde yüz kayıplarına neden olmuştur.

Sigmoid çekirdek kullanıldığında %85 oranında bir başarı gözlenmiştir.

Çok yüz içeren resimlerde radyal tabanlı çekirdek kullanıldığında diğer çekirdek türlerine göre daha iyi sonuçlar vermiştir. Radyal tabanlı çekirdek kullanıldığında %91.2 başarı oranı sağlanmıştır. Üçüncü dereceden polinomial çekirdek kullanımında başarı oranı %90.1 civarında olmuştur. Doğrusal çekirdekte %88,2 başarı oranı elde edilirken, Sigmoid çekirdek kullanıldığında %85 oranında bir başarı gözlenmiştir. RTF çekirdek oval fonksiyon yapısına sahip olduğundan yakın çekilmiş yüzlerde daha iyi sonuçlar vermiştir.

Tezin genel bir değerlendirilmesi yapıldığında, giriş resminin parçalara ayrılması ve düğüm sayısındaki azaltma işleminin yapılması sonucunda, Destek Vektör Makineleri ile sınıflamanın %67 oranında daha kısa sürede yapılması sağlanmıştır. Bunun yanı sıra, önerilen yöntem ile farklı çekirdekler üzerinde yapılan performans değerlendirilmesi küçümsenmeyecek kadar iyi sonuçlar vermiştir.

İleriki çalışmalarda, yüzün şekil özelliklerinden yararlanarak öznelik düğümlerinin oluşturulması, farklı çekirdek tipleri ve parametreler için performansın arttırılması üzerine çalışmalar devam edecektir.

**KAYNAKLAR**

- [1] Oya Örnek, Görüntü İşleme Ders Notları
- [2] <http://www.teknohaber.net/makale.php?id=50801>
- [3] Face Recognition Using Eigenhills Thesis by Alper YILMAZ
- [4] GERÇEK ZAMANLI VİDEO GÖRÜNTÜLERİNDEN YÜZ BULMA VE TANIMA SİSTEMİ, 2006, Erkan Sütçüler Yüksek Lisans Tezi
- [5] Ziyou Xiong, An Introduction to Face Detection and Recognition
- [6] Ming-Hsuan Yang, David J. Kriegman, Narendra Ahuja, 2002 ,Detecting Faces in Images: A Survey
- [7] Detecting Faces in Images; Jiyoung Park
- [8] A Texture-based Approach to Face Detection, Arun Ross ve Vidya Manian
- [9] Learning And Support Vector Machines Neural Networks And Fuzzy Logic Models – Vosijlav Kecman
- [10] <http://www.dtreg.com/svm.htm>
- [11] <http://www.statsoft.com/textbook/stsvm.html>
- [12] <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>
- [13] K Jonnson, J Kittler, Y P Li, J Matas, BMVC99, Support Vector Machines for Face Authentication
- [14] V. Vapnik. Statistical Learning Theory. Wiley, N.Y., 1998



- [15] S. Romdhani, P. Torr, B. Scholkopf, and A. Blake. Computationally efficient face detection. In Proceedings of the 8th International Conference on Computer Vision, July 2001
- [16] Matthias Ratsch, Sami Romdhani, Thomas Vetter, Efficient Face Detection by a Cascaded Support Vector Machine using Haar like Features
- [17] C. Liu and H. Wechsler. Robust coding schemes for indexing and retrieval from large face databases. *IEEE Trans. on Image Processing*, 9(1):132–137, 2000
- [18] Peichung Shih, Chengjun Liu, 2005 , Face Detection Using Distribution based Distance and Support Vector Machine
- [19] Hyungkeun Jee, Kyunghee Lee, Sungbum Pan, 2004, Eye and Face Detection using SVM
- [20] Guang Dai, Changle Zhou, 2003, Face Recognition Using Support Vector Machines with the Robust Feature
- [21] Diedrick Marius, Sumita Pennathur, Klint Rose, Face Detection Using Color Thresholding and Eigenimage Template Matching
- [22] L. Sirovich and M. Kirby, “Low-dimensional procedure for the characterization of human faces”, *Journal of Optical Society of America*, vol. 4, pp. 519, 1987
- [23] Jin Seo, Hanseok Ko, 2004, FACE DETECTION USING SUPPORT VECTOR DOMAIN DESCRIPTION IN COLOR IMAGES
- [24] J Fan, D. K. Y. Yau, A. K. Elmagarmid and W. G. Aref, “ Automatic Image Segmentation by Integrating Color-Edge Extraction and Seeded Region Growing,” *IEEE Trans. on Image Processing*, Vol. 10, No. 10, Oct. 2001
- [25] M. H. Yang and N. Ahuja. “Detecting Human Faces in Color Images,” *IEEE Int’l Conference Image and Video Processing*, Vol.1, pp.127-130,1998

[26] Y, W.Lu, and A.Waibel, "Skin-color modeling and adaptation," Technical Report CMUCS-97-146, School of Computer Science, Carnegie Mellon University,1997

[27] Gianluca Antonini, Vlad Popovici, Jean-Philippe Thiran, Independent Component Analysis and Support Vector Machine for Face Feature Extraction

[28] Maya Choueiri, Nassib El-Sayegh, Wassim Said, Real Time Face Detection and Recognition

[29] <http://www.matthewajohnson.org/software/svm.html>

[30] [http://www.anefian.com/face\\_reco.htm](http://www.anefian.com/face_reco.htm)

**ÖZGEÇMİŞ**

Doğum Tarihi	14.01.1984	
Doğum Yeri	Malkara, TEKİRDAĞ	
Lise	1997-2001	Edirne Lisesi (YDA)
Lisans	2001-2005	Trakya Üniversitesi, Mühendislik - Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü
Yüksek Lisans	2006-2008	Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Bölümü
Çalıştığı Kurumlar	2006-2007	MN Kartlı Sistemler – Yazılım Uzman Yardımcısı
	2007-Devam	Senkron Bilgi Teknolojileri – Yazılım Uzmanı