

Temel Bileşen Analiziyle Öznitelik Seçimi Ve Görsel Nesne Sınıflandırma

Zühal Kurt

**YÜKSEK LİSANS TEZİ**

Matematik Ve Bilgisayar Bilimleri Anabilim Dalı

Temmuz 2013

Feature Extraction and Visual Object Classification with Principal Component Analysis

Zühal Kurt

**MASTER OF SCIENCE THESIS**

Department of Mathematics And Computer Sciences

June 2013

Temel Bileşen Analiziyle Öznitelik Seçimi Ve Görsel Nesne Sınıflandırma

Zühal Kurt

Eskişehir Osmangazi Üniversitesi  
Fen Bilimleri Enstitüsü  
Lisansüstü Yönetmeliği Uyarınca  
Matematik Ve Bilgisayar Bilimleri Anabilim Dalı  
Bilgisayar Bilimleri Bilim Dalında  
YÜKSEK LİSANS TEZİ  
Olarak Hazırlanmıştır

Danışman: Yard. Doç. Dr. Kemal ÖZKAN

Bu Tez Tübitak tarafından 2210-Yurt İçi Yüksek Lisans Burs Programı kapsamında desteklenmiştir.

Temmuz 2013

## ONAY

Matematik Ve Bilgisayar Bilimleri Anabilim Dalı Yüksek Lisans öğrencisi Zühal Kurt'un YÜKSEK LİSANS tezi olarak hazırladığı "Temel Bileşen Analiziyle Öznitelik Seçimi Ve Görsel Nesne Sınıflandırma" başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.

**Danışman** : Yard. Doç. Dr. Kemal ÖZKAN

**İkinci Danışman** : -

**Yüksek Lisans Tez Savunma Jürisi:**

**Üye** : Yard. Doç. Dr. Kemal ÖZKAN

**Üye** : Yard. Doç. Dr. Erol SEKE

**Üye** : Yard. Doç. Dr. Selçuk CANBEK

**Üye** : Yard. Doç. Dr. Alper ODABAŞ

**Üye** : Yard. Doç. Dr. Semih ERGİN

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ..... tarih ve ..... sayılı kararıyla onaylanmıştır.

Prof. Dr. Nimetullah BURNAK

Enstitü Müdürü

## ÖZET

İmgeleri tanımlayan en önemli görsel özelliklerden bir tanesi imgedeki nesnelere konturlarıdır. İmgedeki nesnelere az sayıda öğe ile betimleyebilmek için nesne şekillerine konik veya doğru uyarlanır, öyle ki bu uyarlamalar için başlangıç ve bitim noktalarına ihtiyaç vardır. Bu başlangıç ve bitim noktaları imgedeki nesnenin anlamlı noktalarıdır. Bu çalışmada imgelerdeki şekillerin konturlarındaki noktalar Canny kenar detektörü ile belirlenmiş olup, bu noktalara temel bileşen analizi (TBA) metodu uygulanarak köşe ve büküm noktaları bulunmuştur. Bu noktalar daha sonra baskın, köşe, yumuşak köşe ve büküm noktası olarak sınıflandırılmıştır. Şeklin konturunda ardarda gelmiş olan anlamlı noktaların arasına konik veya doğru oturtulmuş, böylece imgedeki nesne uyarlanmış konik eğrileriyle ve doğru parçaları ile betimlenmiştir.

Literatürdeki en başarılı görsel nesne sınıflandırma teknikleri imgeleri betimlemek için “kelimeler çantası” (bag of words) yöntemini kullanmaktadır. Bu yöntemde dijital imgelerden seçilen yamalar SIFT, LBP, LTP ve SURF gibi farklı şekil ve doku betimleyicilerle vektörel değerlere dönüştürülmektedir. Bu çalışmada biz TBA’ya dayalı betimleyicinin ağırlıklandırılmış açılarının histogramlarını kullanan yeni bir betimleme tekniği önerdik. Önerdiğimiz betimleme tekniğini kullanan kelimeler çantası tabanlı görsel nesne sınıflandırma yönteminin başarısını literatürdeki diğer betimleme tekniklerini kullanan nesne sınıflandırma yöntemleriyle Caltech-4 ve Coil-100 veri tabanları üzerinde karşılaştırdık. Deneysel sonuçlar TBA’ya dayalı betimleyicinin oldukça iyi sonuçlar verdiğini göstermektedir. Ayrıca önerilen betimleyicinin literatürdeki diğer detektörlerin bulduğu ilgi noktalarından elde edilen karesel çerçevenin üzerinde kullanılmasıyla birlikte sınıflandırma başarımının daha da arttığı gözlenmiştir. Bu da TBA’ya dayalı betimleyicinin diğer betimleyicilerden farklı bilgiler taşıdığını göstermektedir.

Anahtar Kelimeler: Kontur, temel bileşen analizi, anlamlı nokta, büküm ve baskın nokta, konik eğri, betimleyici, görsel nesne sınıflandırma, kelimeler çantası modeli.

## SUMMARY

One of the most visually descriptive features for images is the contour of the object(s). In order to describe objects with lesser number of descriptors, linear or cubic curves are fitted to the contours of the objects. The end points of these finite length curves are usually meaningful spots on the contours. In the work presented here, edges are found by the Canny edge detector, followed by Principal Component Analysis (PCA) for determining corners and inflection points. These points are classified as dominant, corner, soft corner or inflection points. Curves are fitted to the sub-contours between successive such descriptive points on the object contour.

Most of the state-of-arts visual object classification methods use bag of words model for image representation. In this method, patches extracted from images are described by different shape and texture descriptors such as SIFT, LBP, LTP, SURF, etc. In this paper we introduce a new descriptor based on weighted histograms of phase angles of local based PCA transform. We compare the classification accuracies obtained by using the proposed descriptor to the ones obtained by other well-known descriptors on Caltech-4 and Coil-100 data sets. Experimental results show that our proposed descriptor provides good accuracies indicating that PCA based local descriptor captures important characteristics of images that are useful for classification. When we described image representations obtained by PCA based descriptor with the representations obtained by other detection of keypoints, results even get better suggesting that tested descriptors encode differential complementary information.

Keywords: Contour, PCA, meaningful point, inflection and dominant point, conic arcs, descriptor, visual object classification, bag of words model .

## TEŞEKKÜR

Yüksek lisans çalışmalarımda, gerek derslerimde ve gerekse tez çalışmalarımda, bana danışmanlık ederek, beni yönlendiren danışmanım Yrd. Doç. Dr. Kemal ÖZKAN'a teşekkür ederim. Değerli fikirlerine başvurduğum ve gerektiğinde yardımını esirgemeyen hocalarım Prof. Dr. İdris DAĞ ve Doç. Dr. Hakan ÇEVİKALP'e, bilimin ve bilim insanının destekçisi olan TÜBİTAK'a teşekkürlerimi sunarım.

Ayrıca, yüksek lisans eğitimim süresince benden desteklerini esirgemeyen sevgili ailemin tüm fertlerine ve arkadaşlarıma teşekkür ederim.

# İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖZET</b> .....	<b>v</b>
<b>SUMMARY</b> .....	<b>vi</b>
<b>TEŞEKKÜR</b> .....	<b>vii</b>
<b>İÇİNDEKİLER</b> .....	<b>viii</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>x</b>
<b>TABLolar DİZİNİ</b> .....	<b>xii</b>
<b>SİMGELER VE KISALTMALAR DİZİNİ</b> .....	<b>xiii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Örüntü.....	1
1.2. Örüntü Tanıma .....	1
1.3. Örüntü Tanıma Süreci .....	2
1.4. Öznitelik Çıkarımı.....	3
1.5. Öznitelik Seçimi.....	3
1.6. Görüntünün Öznitelikleri Ve Betimleyicileri.....	4
1.7. Sınıflandırma .....	6
1.8. Tez Çalışması .....	7
<b>2. ŞEKLİN FONKSİYON HALİNE GETİRİLMESİ</b> .....	<b>9</b>
2.1. Kompleks Koordinatlar .....	10
2.2. Merkez Uzaklığı Fonksiyonu .....	10
2.3. Tanjant Açısı Fonksiyonu .....	11
2.4. Kontura Dayalı Eğrilik Fonksiyonu .....	12
2.5. Alan Fonksiyonu .....	12
2.6. Üçgen – Alan Gösterimi.....	13
2.7. Kiriş Uzunluk Fonksiyonu .....	14
2.8. Önerilen Fonksiyon Betimlenmesi.....	15
<b>3. ŞEKİL BETİMLEYİCİLERİNE GENEL BİR BAKIŞ</b> .....	<b>20</b>
3.1. Kontura Dayalı Şekil Betimleyicileri.....	23
3.1.1 Global Şekil Betimleyicileri.....	23
3.1.2 Yapısal Şekil Betimleyicileri .....	27
3.2. Konik Eğrilerin Sınıflandırılması.....	37
3.3. Ölçü Kriterleri .....	38
3.4. Deneysel Sonuçlar.....	39
<b>4. BÖLGEYE DAYALI ŞEKİL BETİMLEYİCİLERİ</b> .....	<b>46</b>
4.1. Noktalar Arası Uzamsal İlişkiler.....	46
4.1.1. Şekil Bağlamı.....	46
4.1.2. Ölçekleme İle Değişmeyen Öznitelik Çıkarımı (SIFT).....	48
4.1.3. Önerilen Bölgeye Dayalı Betimleyici.....	50
4.2. Sınıflandırma .....	56
4.2.1. Destek Vektör Makineleri.....	56
4.2.2. Çok-Sınıflı Problemlerde İkili Sınıflandırma Yöntemlerin Kullanılması .....	62
4.2.3. Sonuç Karşılaştırma Yöntemleri.....	63
4.3. Deneysel Sonuçlar.....	63



4.3.1. Caltech-4 Veritabanı Üzerindeki Deneysel Sonuçlar .....	64
4.3.2. Coil-100 Veritabanı Üzerindeki Deneysel Sonuçlar.....	66
4.3.3. Caltech-4 Veritabanı Üzerindeki İlgili Noktası Deneysel Sonuçları .....	67
<b>5. SONUÇ VE ÖNERİLER .....</b>	<b>69</b>
<b>6. EKLER .....</b>	<b>71</b>
6.1. Temel Bileşen Analizi .....	71
6.2. Kelimeler Çantası Modeli .....	74
6.3. Lokal İkili ve Üçlü Örüntü Betimleyicileri .....	76
6.4. Surf Betimleyicisi.....	78
<b>KAYNAKLAR DİZİNİ.....</b>	<b>80</b>
<b>ÖZGEÇMİŞ.....</b>	<b>89</b>

# ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1. Örüntü tanıma süreci .....	2
Şekil 2.1. Dijital eğri ve tanjant uzayında basamak fonksiyonu ile tanımlanması .....	11
Şekil 2.2. Eğrilik Fonksiyonu.....	12
Şekil 2.3. Alan fonksiyonu .....	13
Şekil 2.4. Şeklin Üçgen Alan Gösterim fonksiyonu ile betimlenmesi.....	14
Şekil 2.5. Kiriş Uzunluk Fonksiyonu .....	15
Şekil 2.6. Dijital Tırtıklı yapı .....	18
Şekil 2.7. Şeklin TBA'ya dayalı fonksiyon ile betimlenmesi .....	19
Şekil 3.1. Şekil betimleme tekniklerine genel bir bakış .....	22
Şekil 3.2. Şekil Betimleme Tekniklerinin Sınıflandırılması .....	24
Şekil 3.3. Fourier tanımlama ve helikopter şeklinin fourier betimleyicisi ile yeniden oluşturulması .....	26
Şekil 3.4. Wavelet betimleyicisi.....	27
Şekil 3.5. E. Atteneave' in kedisi .....	28
Şekil 3.6. Baskın nokta çıkarım tekniklerinin sınıflandırılması .....	29
Şekil 3.7. Dinazor şekli üzerindeki poligonal yakınsama .....	31
Şekil 3.8. Büküm noktası gösterimi .....	33
Şekil 3.9. $m_b > thresh1$ olacak şekilde baskın nokta türleri .....	33
Şekil 3.10. $thresh1 > m_b > thresh2$ olmak üzere zayıf anlamlı noktalar .....	35
Şekil 3.11. Baskın nokta analizi .....	35
Şekil 3.12. Şeklin TBA'ya dayalı fonksiyon ile betimlenmesi .....	36
Şekil 3.13. Konik bölgeler için rehber üçgen modeli.....	38

Şekil 3.14. (a) Kromozom eğrisi, (b) Yaprak eğrisi, (c) Yarım Daire eğrisi .....	38
Şekil 3.15. (Nquyen'in, 2005) metodu ile önerilen metodun karşılaştırılması .....	42
Şekil 3.16. (a) orijinal imge, (b) eğri 1, (c) eğri 2 .....	43
Şekil 3.17. Verilen şeklin anlamlı noktaları ve bölütlenmesi .....	43
Şekil 3.18. (a) (Hu ve ark. 1999) nin sonuçları (b) Önerilen yöntem sonuçları.....	44
Şekil 3.19. Çoklu-primitif bölütleme örnekleri .....	45
Şekil 4.1. Şekil Bağlamı yöntemi örneği.....	48
Şekil 4.2. SIFT ilgi bölgesi baskın yönelim hesabı ve betimleyicinin oluşturulması .....	51
Şekil 4.3. Görüntüye TBA uygulanarak bulunmuş ve gradyant uygulanarak elde edilmiş değişim oranı .....	54
Şekil 4.4. TBA'ya dayalı betimleyicinin hesaplanması .....	55
Şekil 4.5. Kelimeler çantası modeli kullanılarak görsel nesne sınıflandırması.....	56
Şekil 4.6. DVM ile sınıflandırılmış durumlar .....	56
Şekil 4.7. Caltech-4 veritabanı (uçaklar, arabalar, yüzler ve motorsikletler).....	64
Şekil 4.8. İlgi noktalarına göre örneklendirilmiş görüntü .....	65
Şekil 4.9. Yoğun bir şekilde örneklendirilmiş görüntü .....	65
Şekil 4.10. Coil 100 veritabanından seçilmiş 40 adet sınıfa ait örnek görüntüler.....	66
Şekil 6.1. Kelimeler çantası modeli .....	75
Şekil 6.2. Kelimeler çantası modeli kullanılarak herbir nesne için oluşturulan histogramlar ve son olarak elde edilen görsel sözlük.....	76
Şekil 6.3 Lokal ikili örüntü betimleyicisinin oluşturulması süreci.....	77
Şekil 6.4 Lokal üçlü örüntü betimleyicisinin oluşturulması süreci .....	78
Şekil 6.5 Surf betimleyicisi oluşturulma süreci .....	79

## TABLolar DİZİNİ

	<u>Sayfa</u>
Tablo 3.1. Sarkar kriterlerine göre karşılaştırma.....	40
Tablo 3.2. (Carmona ve ark. 2005) ile karşılaştırılan sonuçlar .....	41
Tablo 3.3. Diğer metodlar ile önerilen metodu ölçü kriterlerini kullanarak karşılaştırma.....	44
Tablo 4.1. Caltech-4 veri kümesine uygulanan farklı betimleyicilerinin sınıflandırma (%) oranı.....	65
Table 4.2. Coil 40 veri kümesine uygulanan farklı betimleyicilerinin sınıflandırma (%) oranı .....	67
Tablo 4.3. Caltech 4 veri kümesine uygulanan farklı ilgi detektörlerine ve betimleyicilere göre sınıflandırma (%) oranı .....	67

## SİMGELER VE KISALTMALAR DİZİNİ

<b>BoW</b>	Bag Of Words Model (Kelimeler Çantası Modeli)
<b>DB</b>	Destek Bölgesi (Support Region)
<b>DP</b>	Baskın Nokta (Dominant Point)
<b>DoG</b>	Difference Of Gaussians
<b>DVM</b>	Destek Vektör Makineleri (Support Vector Machine)
<b>Enb</b>	En Büyükleme (Maximization)
<b>Enk</b>	En Büyükleme (Minimization)
<b>LBP</b>	Lokal İkili Örüntü (Local Binary Pattern)
<b>LTP</b>	Lokal Üçlü Örüntü (Local Ternary Pattern)
<b>MP</b>	Anlamlı Nokta (Meaningfull Point)
<b>SURF</b>	Speed Up Robust
<b>SIFT</b>	Ölçeklemeyle Değişmeyen Öznitelik Çıkarımı (Scale Invariant Feature Transform)
<b>TBA</b>	Temel Bileşen Analizi (Principal Component Analysis)
<b>ÜAG</b>	Üçgen Alan Gösterimi
<b>1e1</b>	Bire Karşı Bir (One Against One)
<b>1eh</b>	Bire Karşı Hepsi (One Against All)

## BÖLÜM 1

### GİRİŞ

Görüntü ve videolarda nesne tanıma, son yıllarda bilgisayarla görü ve örüntü tanıma alanlarında büyük ilgi görmektedir. Nesne tanıma probleminin birçok potansiyel uygulamaları vardır. Bu bölümde otomatik nesne tanıma ve yerselleştirmesinin nasıl olduğuna dair genel bir bakış açısı ele alınacaktır. Nesne tanıma:

- Öznitelik vektörleri ve görüntü betimleyicilerinin çıkarımı ve kullanımı
- Görüntü betimleyicilerinin detektör algoritmalarıyla nasıl oluşturulduğu

konularına ihtiyaç duyan alan olarak sınıflandırılabilir. Bu bölümde bu konuların geçmiş yıllarda nasıl işlendiğine dair bilgi verilecektir.

#### 1.1 Örüntü

‘Görüntü binlerce kelimedenden daha çok şey ifade eder.’ Konfüçyus. Bu sözden çıkarım yapacak olursak, herhangi bir görüntü karmaşık bir hikayeyi anlatabilmektedir. Örüntü, olay veya nesnelerin düzenli bir biçimde birbirini takip ederek gelişmesi şeklinde tanımlanır (Türk Dil Kurumu, 2008). Örüntünün tanımı gereği, örüntü görüntünün anlattığı hikayenin ana parçalarından biri olduğu söylenebilir. Başka bir ifadeyle örüntü, kendini tekrarlayan olay veya nesnelere karşılık gelir. Ses sinyali, uzaktan algılama verisi, insan yüzü, retina, parmak izi, bir metin içerisindeki karakterler ve biyomedikal cihazlardan elde edilen görüntüler, örüntüye dair bazı örneklerdir.


#### 1.2 Örüntü Tanıma

Makine öğrenimi alanında, giren değerlerin/verilerin etiketlenmesi veya tanınması örüntü tanıma ile yapılmaktadır. Örneğin mail kutusuna gelen bir mailin spam veya spam

olmadığı bir örüntü tanıma uygulamasıdır. Kısacası örüntü tanımının asıl amacı farklı sınıflardaki veya kategorilerdeki nesnelere sınıflandırmaktır. Örüntü tanıma alanı uzun bir çalışma tarihine sahiptir ve 1960' ların öncesine kadar da istatistik alanında teorik olarak çalışılmıştır. Son yarım yüzyılda bu alanda, ortak özelliğe sahip veya aralarında bir ilişki kurulabilen karmaşık olayları ve nesnelere çeşitli yöntemler vasıtasıyla tanıma ve sınıflandırmanın sağlanabilmesi için "makina ortamında örüntü tanıma" kavramı ortaya çıkmıştır. Konuşma, konuşmacı, insan yüzü, parmak izi, el yazısı, imza ve biyomedikal görüntü tanıma, örüntü tanıma uygulamalarının yaygın örnekleridir. Yarım yüzyılı aşkın süredir üzerinde çalışılmakta olan bu bilim kolunun önemi, her geçen gün ortaya çıkan yeni uygulama alanlarıyla birlikte giderek artmaktadır.

### 1.3 Örüntü Tanıma Süreci

Örüntü tanıma sürecinde verilen veri gereksiz bölümlere sahip ve algoritmanında uzun olduğu zaman ön işlemlere ihtiyaç duyulur ve boyutu indirmek için veriye öznitelik çıkarımı uygulanabilir. Dolayısıyla, örüntü tanıma sürecinin temel öğeleri, öznitelik çıkarımı, öznitelik seçimi ve sınıflandırmadır, Şekil 1.1'de resmedilmektedir. Bu temel öğelerin yanında, bazı durumlarda birtakım ön işlem (gürültü azaltma, önvurgulama, v.b.) ve son işlemlerde süreç içerisinde yer alabilir.



Şekil 1.1. Örüntü tanıma süreci

## 1.4 Öznitelik Çıkarımı

Öznitelik, temel olarak örüntüye dair ölçülebilir ya da gözlenebilir bilgidir. Örüntü tanıma ve görüntü işleme alanlarında, öznitelik çıkarımı verilen verideki boyutu indirgemenin özel bir formudur. Bu formda, ilgisiz ve fazla bilgi elenerek örüntüye ait karakteristik özelliklerin elde edilmesi sağlanır. Gereksiz bilgilerin elenmesi, tanıma işleminin süresini kısaltmak açısından da büyük önem taşımaktadır. Eğer bir örüntü birden fazla öznitelik ile temsil ediliyorsa, tek bir öznitelik yerine bir “öznitelik kümesi” söz konusudur.  $d$  adet özneliğe sahip öznitelik kümesi ise  $d$ -boyutlu “öznitelik vektörü” ile temsil edilir. Özniteliklerin içinde bulunduğu  $d$ -boyutlu  $R^d$  uzayı ise “öznitelik uzayı” olarak isimlendirilir (Kuncheva, 2004). Örüntülere ait öznitelikler, nicel (sayısal) ya da nitel (kategorik) olabilir. Örneğin, bir otomobilin maksimum hız bilgisi nicel, model bilgisi ise nitel bir özniteliktir. İstatistiksel örüntü tanıma daha çok nicel özniteliklerden faydalanırken, sözdizimsel örüntü tanıma ağırlıklı olarak nitel öznitelikleri kullanılır.

## 1.5 Öznitelik Seçimi

Makine öğrenimi ve istatistikte öznitelik seçimi, değişken seçimi veya değişkenlerin alt küme seçimi olarak bilinmektedir, aynı zamanda model oluşturmada kullanılan özniteliklerin seçim işlemidir. Öznitelik seçim teknikleri ile modellerde üç adet yarar sağlanmaktadır :

- modelin anlaşılabilirliğini geliştirir
- eğitim süresini kısaltır
- tekrarlamaları azaltır.

Dolayısıyla, öznitelik çıkarma işleminde, örüntü hakkındaki ilgisiz bilgilerin elenip karakteristik özelliğin elde edilmesiyle belli oranda boyut indirgeme sağlanır. Öznitelik seçiminde ise çıkarılmış olan özniteliklerin ayırdedicilikleri çeşitli yöntemlerle incelenerek mevcut öznitelik kümesinden daha ayırdedici bir altküme bulunması amaçlanır. Bu işlem, boyut indirgeme oranını artırmanın yanı sıra “boyutun laneti” (Bellman, 1961; Theodoridis ve Koutroumbas, 2003; Jain ve Zongker, 1997) etkisini de azaltmaya yarar.



## 1.6 Görüntünün Öznitelikleri Ve Betimleyicileri

Nesne tanıma veya sınıflandırmada, ışık şiddetinin değişiminden, farklı bakış açılarından elde edilen görüntüden ve nesne konturlarının ötelenmesinden etkilenmeyecek öznitelikler kümesi oluşturacak öznitelikler vektörüne ihtiyaç duyulur. Görüntüdeki bu varyasyonları aşabilmek için görüntünün yoğunluğa sahip olduğu bölgeleri veya gradyanları (görüntünün değişim oranlarını, değişim yönlerini), kullanan lokal görüntü betimleyicileri kullanılır. Bu özellikteki öznitelikler görüntünün anlamlı noktalarına (Harris ve Stephens 1988, Mikolajczyk ve Schmid 2002), baloncuklara (Laplacian of Gaussian) (Lindeberg 1998) veya Difference of Gaussian (Lowe 2001), yoğunluklarına (Kadir ve Brady 2001, Ullman ve ark.. 2001, Vidal-Naquet ve Ullman 2003), gradyant vektörlerine (Ronfard ve ark. 2002, Mikolajczyk ve ark. 2004), rengine, içerdiği desenlerine, veya bunların kombinasyonuna (Martin ve ark. 2004) bağlı olarak bulunur. Öznitelik kümesinin elde edilmesi sonucunda oluşturulan betimleyicilerin görüntüyü iyi bir şekilde detekt etmesi ve sınıflandırması gerekir.

Betimleyici ve öznitelik çıkarımı ile ilgili çeşitli yaklaşımları iki kategoride inceleyebiliriz: ilgi noktalarına bağlı olarak örneklendirilmiş veya görüntünün yoğunluğu veya gradyantına bağlı olarak yoğun örneklendirilmiş tanımlanmalardır.

### 1.6.1 Seyrek Lokal Tanımlamalar

Görüntünün seyrek tanımlanması görüntünün lokal bölgelerinden elde edilen lokal betimleyicilere bağlıdır. Bu bölgeler ilgi nokta detektörlerine veya parça detektörlerine bağlı olarak seçilir.

#### 1.6.1.1 Nokta Detektörleri

Seyrek lokal noktaların veya bölgelerin nesne tanımada kullanımı uzun bir hikayeye sahiptir (Schiele ve Crowley 1996a,b,c, Schmid ve Mohr 1997, Weber ve ark.. 2000, Lowe 2001, Agarwal ve Roth 2002, Fergus ve ark.. 2003, Dork'o ve Schmid 2003, Lowe 2004, Opelt ve ark. 2004, Leibe ve ark. 2005, Mikolajczyk ve ark. 2005). Bu yaklaşımlarda seyrek görüntü noktalarından, bu noktalara ilgi noktası veya anahtar noktalar olarak adlandırılır, lokal örüntü öznitelikleri çıkartılır. Öznitelik vektörlerinden hesaplanan ilgi noktası betimleyicilerine dayalı detektörler elde edilir. Bu hipotezle, ilgi noktası detektörlerinin stabil

ve güvenilir görüntü bölgelerinden ilgi noktalarını bulması gerekir, öyleki bu noktaların içeriğiyle ilgili bilgiye sahip olması gerekir. Dolayısıyla detektörlerin performansının iyiliği, elde edilen ilgi noktalarının nesne sınıfındaki güvenilirliğine, oranına ve tekrar edilebilirliğine bağlıdır. Yaygın olarak kullanılan ilgi noktası detektörleri F<sup>o</sup>rstner-Harris (F<sup>o</sup>rstner ve Pertl 1986, F<sup>o</sup>rstner ve G<sup>u</sup>lch 1987, Harris ve Stephens 1988), Laplacian (Lindeberg 1998) veya Difference of Gaussians (DoGs) (Lowe 2004), ve ölçeklemeyle değişmeyen Harris-Laplace (Mikolajczyk and Schmid 2004) şeklindedir.

İlgi noktaları üzerinden alınan görüntü bölgeleri üzerinde hesaplanan öznitelik vektörleri ve betimleyicilerine dayalı birçok yaklaşım geçmiş yıllarda önerilmiştir. Bu yaklaşımların en popüler olanları , görüntünün gradyantına dayalı olan ölçeklemeyle değişmeyen öznitelik dönüşümü (SIFT) (Lowe 1999, 2004) ve şekil bağlamı (Belongie ve ark. 2001, 2002). Her iki yaklaşımda da betimleyici vektör görüntünün gradyantlarına veya kenarlarına bağlı oluşturulmaktadır.

### **1.6.1.2 Parça veya Uzun Detektörleri**

Lokal parçaya dayalı detektörler genel olarak nesne ve insan tanıma sistemlerinde kullanılmaktadır. İnsanın vücut bölgelerini (alt kol, üst kol, alt bacak, üst bacak, gövde vs. ) silindiriklerle tanımlayan betimleyiciler (Forsyth ve Fleck 1997, Ioffe ve Forsyth 1999, Schneiderman ve Kanade 2000, Ronfard ve ark. 2002, Ramanan ve Forsyth 2003, Sigal ve ark. 2003, Schneiderman ve Kanade 2004), (Ioffe ve Forsyth 1999, 2001a,b) tarafından önerilmiştir. Üç boyutlu uzun detektörü de (Sigal ve ark. 2003) tarafından önerilmiştir.

### **1.6.2 Görüntü Bölgelerinin Yoğun Bir Şekilde Tanımlanması**

Başka bir yaklaşım olarakta tüm görüntüyü detekt ederek elde edilmiş görüntü öznitelikleri ve bu öznitelikleri niceleyerek elde edilen yüksek boyutlu betimleyiciler ile görüntüdeki nesnelerin sınıflandırılması veya var olup olmadığını etiketleme işidir. Doğal olarak bu tanımlama görüntünün yoğunluğuna, gradyantlarına veya yüksek mertebeli operatörlerine dayalı olarak da yapılabilir.

### 1.6.2.1 Görüntünün Yoğunluğuna Bağlı Bölge veya Çerçeve Tanımlanması

(Sirovitch ve Kirby, 1987) ve (Turk ve Pentland, 1991) çalışmalarında önerilmiş görüntünün yoğunluğuna bağlı ‘özyüz’ yaklaşımıdır. Bu yaklaşımda yüz vektörlerinin temel varyasyonuna bağlı öznitelik vektörleri Temel Bileşen Analizi (TBA) metodu ile bulunmaktadır. Görüntünün yoğunluğunu kullanarak yüz detekt sistemi oluşturan diğer çalışmalar (Rowley ve ark. 1998) ve (Bishop, 1995) tarafından önerilmiştir. (Ullman ve ark. 2001), (Vidal-Naquet ve Ullman, 2003) çalışmalarında görüntünün yoğun örüntülerine bağlı olarak görüntüdeki nesnelere çerçeveselendirilmiştir.

### 1.6.2.2 Kenara ve Gradyanta Dayalı Detektörler

Görüntünün kenar ve gradyant filtreleri aynı zamanda nesne tanımada kullanılır. En popüler yaklaşım ise (Gavrila and Philomin 1999) tarafından önerilen pedestrian detekt sistemidir, öyleki bu sistemde görüntünün kenarları çıkartılmış ve chamfer uzaklığına bağlı eğitilmiş örnekler ile eşleştirilmiştir. Bu pedestrian detekt sisteminin gerçek zamanlı uygulaması (Gavrila ve ark. 2004) tarafından önerilmiştir. Gradyant betimleyicilerine dayalı diğer yaklaşımlar ise (Ronfard ve ark. 2002) ve (Mikolajczyk ve ark. 2004), (Felzenszwalb ve Huttenlocher 2000) ve (Ioffe ve Forsyth 2001b), (Mikolajczyk ve ark. 2004) çalışmalarında önerilmiştir. Baskın yönelimlerin histogramına dayalı çoklu-ölçekli betimleyicilerin gradyant görüntülerindeki kullanımı, SIFT (Lowe 1999) ile aynı amaca hizmet etmektedir.

## 1.7 Sınıflandırma

Bilinmeyen bir örüntüyü tanıyabilmek için öznitelik çıkarımı, öznitelik seçimi ve betimleyici oluşturulmasını takiben sınıflandırma işlemi yürütülür. Sınıflandırma için, betimleyiciler ile önceden bulunan belirli sayıdaki öznitelik vektörünün oluşturduğu “veri kümeleri” bir eğitim sürecinden geçirilir ve bir özellik vektörü elde edilir. Bu eğitim sonucunda, bilinmeyen örüntüyü uygun sınıfa atamakta kullanılan bir karar kuralı ya da mekanizması oluşturulur. Bir eğitim kümesi ve birtakım önsel olasılıklar yardımıyla gerçekleştirilen bu sınıflandırma yaklaşımı “güdümlü sınıflandırma” olarak isimlendirilir. Herhangi bir önsel bilgi ve eğitim kümesi kullanılmadan gerçekleştirilen sınıflandırma ise “güdümsüz sınıflandırma”dır (Duda ve ark., 2001; Theodoridis ve Koutroumbas, 2003).

## 1.8 Tez Çalışması

Öncelikli olarak, bu tez çalışması, istatistiksel örüntü tanıma çerçevesinde nicel öznitelikler ve güdümlü sınıflandırma yöntemleri kullanılarak gerçekleştirilmiştir. Çalışmada, temel olarak örüntü tanıma sürecinin yukarıda bahsi geçen üç ana başlığı (öznitelik çıkarımı, öznitelik seçimi, betimleyici çıkarımı ve sınıflandırma) üzerinde durulmuştur. Tez çalışması kapsamında,

- Örüntü tanıma uygulamalarında kullanılacak Temel Bileşen Analizi (TBA) temelli bir detektör ile öznitelik çıkarma yöntemi
- TBA ya dayalı betimleyici oluşturma ve çok sınıflı örüntü tanıma uygulamaları için TBA'ya dayalı öznitelik seçim yöntemi
- Gaussian kernel fonksiyonunu kullanarak Destek Vektör Makineleri (DVM) ile sınıflandırma yapılmıştır.

Çalışmanın düzeni şu şekildedir:

Bölüm 2'de, başlangıç olarak şeklin fonksiyon halinde betimlenmesi hakkında temel bilgiler verilmiş ve bazı betimleme yöntemleri hakkında örnekler sunulmuştur. Daha sonra, şeklin TBA ya dayalı fonksiyon halinde betimlenmesi anlatılmıştır ve örneklendirilmiştir.

Bölüm 3'te, öncelikle şekil betimleyicilerine genel bir şekilde incelenmiştir. Görüntüde baskın nokta analizi ile ilgili bilgiler verilmiştir. TBA'ya dayalı anlamlı nokta analizi kullanılarak detektör oluşturulmuş ve önceki çalışmalarla sonuçları karşılaştırılmıştır. TBA'ya dayalı anlamlı nokta analizi ile aynı zamanda çoklu primitif bölütleme gerçekleştirilmiştir. Şekil veritabanından bir kaç görüntüye önerilen çoklu primitif bölütleme uygulanmış ve örnekleri verilmiştir. Kısacası görüntüden öznitelik seçimi için seyrek ilgi nokta tanımlaması metodu kullanılacak şekilde detektör elde edilmiştir.

Bölüm 4, öznitelik çıkarımından sonra örüntü tanınmanın başka bir aşaması olan betimleyici tanımlanmıştır. Bu bölümde, lokal görüntü betimleyicileri esas alınmıştır. TBA'ya dayalı lokal betimleyici önerilmiştir ve deneysel sonuçlar elde edilmiştir. Deneysel sonuçlar için iki farklı veritabanında ilk olarak DoG ilgi noktalarına göre betimleyiciler elde edilmiş sınıflandırma oranları bulunmuştur. Daha sonra yoğun örneklendirmeye bağlı olarak

betimleyiciler elde edilmiş ve sınıflandırma oranları bulunmuştur. Son deneysel çalışma olarakta, farklı detektörler (DoG, Harris ve önerilen anlamlı nokta detektörleri) kullanarak değişik ilgi noktaları bulunmuş ve önerilen betimleyici ile SIFT betimleyicisi bu noktalar üzerine uygulanarak histogram vektörleri elde edilmiştir. Histogram vektörlerini sınıflandırmak için DVM sınıflandırıcısı kullanılmış ve 5-kez çapraz doğrulama ile sınıflandırma oranları elde edilmiştir.

Bölüm 5, önerilen metodun sonuçları ve gelecekte yapılacak olan çalışmalar irdelenmiştir.

Bölüm 6, önerilen betimleyici ve öznitelik seçim detektörü için gerekli olan ön bilgiler ekler kısmında verilmiştir. Aynı zamanda, deneysel sonuçlarda karşılaştırmak için kullandığımız diğer betimleyici metodları anlatılmaktadır.

## BÖLÜM 2

### 2. ŞEKLİN FONKSİYON HALİNE GETİRİLMESİ

Şeklin sınır koordinatlarından tek değişkenli fonksiyon üretilebilir ve şekil bu fonksiyon ile ifade edilebilir. Bu üretilen fonksiyon genellikle şeklin imzası olarak adlandırılmaktadır (D. Zhang and G. Lu, 2002), (H. Kauppinen ve ark. 1995). Şeklin imzası genel itibariyle şeklin özneliğini kapsamaktadır (A. Soffer, 1997). Kompleks koordinatlar, merkez uzaklığı fonksiyonu, tanjant açısı (A. Soffer, 1997), (D. Zhang and G. Lu, 2002), (H. Kauppinen ve ark. 1995), eğrisellik fonksiyonu (Y. P. Wang ve ark. 1999), (F. Mokhtarian ve ark. 1992) ve (A. C. Jalba ve ark. 2006), alan fonksiyonu, üçgen alan gösterimi (N. Alajlan ve ark. 2006) (N. Alajlan ve ark. 2007), kiriş uzunluğu fonksiyonu şekil imza yöntemlerine örnek olarak sayılabilir.

Örneğin fonksiyon üretimi maksadıyla merkez noktasına olan uzaklık bilgisi kullanıldığında her sınır noktası için bir değer üretilir ve böylece şekil bir fonksiyon halinde ifade edilmiş olur. Şekilden fonksiyon üretimi maksadıyla, örnekte belirtilen merkez uzaklığı bilgisi yerine, yukarıda sayılan yöntemlerden herhangi biri kullanılabilir.

Şekil konturu üzerinden elde edilen tek (1-D) boyutlu fonksiyona önceden de değindiği gibi şeklin imzası denmektedir. Şeklin imzası, ötelemeye göre değişmezlik özelliğine sahip olması için, göreceli değerlere göre tanımlanmalıdır. Ölçeklemeye göre değişmezlik özelliğine sahip olması için, normalizasyon gereklidir. Yönelim değişimlerini gidermek için, ötelenmiş eşleştirmenin iki şekil arasındaki en iyi eşleştirmeyi bulması gerekir. Tanjant açısı, konturun eğrisellik ve üçgen alan gösterimi fonksiyonları örtüşmeye göre değişmezlik özelliklerine sahiptir. Ek olarak şeklin imzasının sayısal ifadesinin basit olması gerekir. Ayrıca, şeklin imzaları gürültüye duyarlıdır, ve şeklin sınırlarında gerçekleşen küçük değişiklikler bile eşleştirmede büyük hatalara sebep olabilir.

Dolayısıyla, şekli direkt olarak şeklin imzası ile göstermek istenmeyen durumlardandır. Bu yüzden, şeklin imzasının gürbüz bir algoritmaya sahip olması ve eşleştirmeyi düzgün yapabilmesi istenir. Örneğin, şeklin imzasının imza histogramına göre nicelenmesi yapılabilir, bu takdirde dönme dönüşümüne göre değişmez olur.

## 2.1 Kompleks Koordinatlar

Sınır noktalarının koordinatlarından üretilen kompleks sayılardan kompleks koordinatlar fonksiyonu elde edilir.  $(g_x, g_y)$  şeklin merkez noktaları olmak üzere ;

$$\begin{cases} g_x = \frac{1}{N} \sum_{i=1}^N x_i \\ g_y = \frac{1}{N} \sum_{i=1}^N y_i \end{cases} \quad (2.1.1)$$

$P_n(x(n), y(n)), n \in [1, N]$  olmak üzere:

$$z(n) = [x(n) - g_x] + i[y(n) - g_y] \quad (2.1.2)$$

kompleks koordinatlar fonksiyonu elde edilir.

## 2.2 Merkez Uzaklığı Fonksiyonu

Sınır noktalarının,  $(g_x, g_y)$  merkez noktalarına olan uzaklıklarından elde edilen fonksiyona merkez uzaklığı fonksiyonu denir ve

$$r(n) = \left[ (x(n) - g_x)^2 + (y(n) - g_y)^2 \right]^{1/2} \quad (2.2.1)$$

ile gösterilir.

Merkez uzaklığı fonksiyonu, sınır koordinatlarından şeklin pozisyonunu tanımlayabilmektedir. Dolayısıyla, merkez uzaklığı ve kompleks koordinatlar fonksiyonları ötelemeye göre değişmez özelliğine sahiptirler.

### 2.3 Tanjant Açısı Fonksiyonu

Kontur üzerindeki her bir  $P_n(x(n), y(n))$  sınır noktasından elde edilen tanjant yönü (D. Zhang and G. Lu, 2002) :

$w$  sınır noktaları etrafında alınan küçük bir pencere olmak üzere;


$$\theta(n) = \theta_n = \arctan \frac{y(n) - y(n-w)}{x(n) - x(n-w)} \quad (2.3.1)$$

elde edilir. Öyleki  $\theta_n$  tanjant açısı fonksiyonu olarak adlandırılır.

Tanjant açı fonksiyonu iki probleme duyarlıdır. Bunlardan birincisi gürültüye karşı duyarlılığıdır. Gürültünün etkisini gidermek için, tanjant açı fonksiyonu bulunmadan önce kontur ilk olarak low-pass ve ona uygun bandwidth filtreden geçirilir, Diğer problem ise fonksiyonun süreksizliğidir, öyle ki tanjant açı fonksiyonunun aldığı değerlerin aralık uzunluğu  $2\pi$  dir, ve genel olarak  $[-\pi, \pi]$  ve  $[0, 2\pi]$  aralıkları kullanılır. Dolayısıyla  $\theta_n$  tanjant açısının  $2\pi$  aralık uzunluklarında süreksizlikleri vardır. Bu süreksizlik problemlerini aşmak için herhangi bir başlangıç noktasından, toplamsal açı fonksiyonu  $\varphi_n$  fonksiyonu tanjant açısı fonksiyonu yerine kullanılır.

$$\varphi(n) = [\theta(n) - \theta(0)] \quad (2.3.2)$$

(F. Mokhtarian ve ark. 1992) de yapılan çalışmada tanjant açısına bağlı bir metod önerilmiştir. Önerilen metodun dijital bir eğriye uygulanması ve eğrinin tanjant uzayında basamak fonksiyonu ile betimlenmesi Şekil 2.1 de resmedilmektedir.



Şekil 2.1. Dijital eğri ve onun tanjant uzayında basamak fonksiyonu ile tanımlanması




## 2.4 Kontura Dayalı Eğrilik Fonksiyonu

Şekiller arasındaki benzerlikleri bulmak için elde edilen eğrilik fonksiyonları sınır öznitelikleri arasında büyük önem taşımaktadır. Eğrilik fonksiyonları şeklin göze çarpan kısımlarını karakterize etmektedir ve dolayısıyla şekil tanımada oldukça kullanışlıdır (A. C. Jalba ve ark. 2006). Eğrilik fonksiyonu

$K(n)$  ile gösterilmek üzere:

$$K(n) = \frac{\dot{x}(n)\ddot{y}(n) - \dot{y}(n)\ddot{x}(n)}{(\dot{x}(n)^2 + \dot{y}(n)^2)^{3/2}} \quad (2.4.1)$$

şeklinde formülize edilir (N. Alajlan ve ark. 2006, 2007). Kontura dayalı eğrilik fonksiyonu ile ilgili örnek Şekil 2.2’de resmedilmektedir.




**Şekil 2.2.** Eğrilik Fonksiyonu (a) Kontur 128 noktaya göre normalize edilmiştir; yıldızla işaretlenen nokta eğrilik fonksiyonlarını hesaplariken seçilen başlangıç noktasıdır, (b) saat yönünde elde edilen eğrilik fonksiyonlarıdır.

## 2.5 Alan Fonksiyonu

Sınır noktaları kontur üzerinde sürekli değişim halinde ise, iki sınır noktası arasından merkez noktasına çizilen üçgenlerden şeklin alanı elde edilir. Bu forma şeklin alan fonksiyonu

ile gösterimi denilmektedir ve Şekil 2.3’de bir örnek resmedilmiştir.  $P_n, P_{n+1}$  sınır noktaları,  $G$  şeklin merkezi ve sınır noktalarından elde edilen üçgenel bölgenin alanı  $S(n)$  ile ifade edilmiştir.



**Şekil 2.3.** Alan fonksiyonu (a) Orjinal Kontur; (b) Şekil (a) nın alan fonksiyonu.

## 2.6 Üçgen – Alan Gösterimi

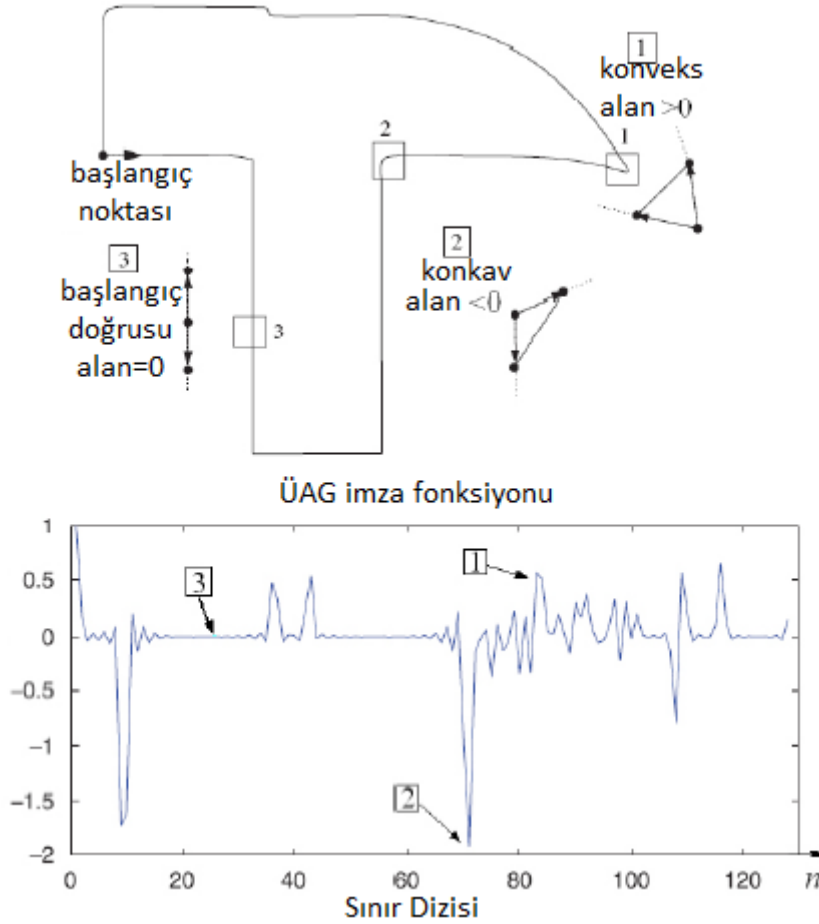
Şeklin sınır noktaları üzerinden elde edilen üçgenlerin alanlarından şeklin üçgen-alan gösterimi elde edilir (S. Han ve S. Yang 2005), (L. J. Latecki and R. Lakamper, 1999).  $(x_n, y_n)$  kontur noktalarından üçgen-alan gösterimi (ÜAG) kullanılarak eğrilik fonksiyonu aşağıdaki şekilde elde edilir:

$N$  çift sayı,  $n \in [1, N]$  ve  $t_s \in \left[1, \frac{N}{2} - 1\right]$  olmak üzere,  $P_{n-t_s}(x_{n-t_s}, y_{n-t_s}), P_n(x_n, y_n)$  ve  $P_{n+t_s}(x_{n+t_s}, y_{n+t_s})$  ard arda üç nokta olsun. Bu noktalardan elde edilen üçgenel bölge ;

$$TAR(n, t_s) = \frac{1}{2} \begin{vmatrix} x_{n-t_s} & y_{n-t_s} & 1 \\ x_n & y_n & 1 \\ x_{n+t_s} & y_{n+t_s} & 1 \end{vmatrix} \quad (2.6.1)$$

şeklinde formülize edilir.

Kontur zik zaklı bir şekilde saat yönünün tersinde ilerliyorsa, yani sınır noktalarından elde edilen üçgenel bölge konveks bir yapıda, konkav yapıda veya düz doğru şeklinde ise ÜAG fonksiyonu sırasıyla pozitif, negatif ve sıfır değerlerini alır. Bu üç tip üçgenel yapı ve çekiç şeklinin ÜAG fonksiyonunu ile betimlenmesi Şekil 2.4' de resmedilmiştir.




**Şekil 2.4.** Üç farklı tip üçgenel alan değerleri ve çekiç şeklinin ÜAG fonksiyonu ile betimlenmesi

## 2.7 Kiriş Uzunluk Fonksiyonu

Şeklin sınır noktalarından herhangi bir referans noktası seçmeden elde edilen fonksiyon kiriş uzunluk fonksiyonudur. Her bir  $p$  sınır noktası için herhangi bir sınır noktası  $p'$  ye minimum uzaklıktaki kiriş çizilir ve  $p$  noktasından geçen ve  $pp'$  ye dik olan tanjant vektörü

kiriş uzunluk fonksiyonu olarak adlandırılır (D. Zhang and G. Lu, 2002). Kiriş uzunluk fonksiyonu ile ilgili örnek Şekil 2.5’de resmedilmektedir.



Şekil 2.5. Kiriş Uzunluk Fonksiyonu

## 2.8 Önerilen Fonksiyon Betimlenmesi

### 2.8.1 Temel bileşen analizi kullanarak şeklin bir fonksiyon halinde betimlenmesi

Önerilen fonksiyon betimlemesi için ilk olarak Canny kenar algılayıcı ile tüm aday baskın noktaları elde edilir. Canny kenar algılayıcı uygulandıktan sonra elde edilen kenar noktaları aday anlamlı nokta olarak adlandırılır ve  $P_i$  aday noktası seçilir. Bu nokta, orjinal çevritteki herhangi bir kenar noktasıdır. Elektronik, anlamsal ve sayısallaştırma/niceleme etkileri gibi çeşitli gürültü kaynaklarından dolayı elde edilen kenar haritasında tırtıklı bir yapı olabilmektedir. Bu duruma örnek Şekil 2.5’de verilmiştir. Bu aday nokta,  $P_i$  nin içinde bulunduğu sol ve sağ destek bölgesi Temel Bileşen Analizi (TBA) metodu kullanılarak belirlenir.  $P_i$  ve  $P_i$  nin komşuluğundaki üç nokta alınarak TBA uygulanır ve bu verinin ana öğeleri olan dağılım matrisinin özdeğer ve özvektörleri bulunur. Bu metodla verinin dağılım yönünün açısında elde edilir. Özvektör verinin dağılım yönüne ait ana bilgiye sahiptir, özdeğerler ise verinin dağılım vektörünün uzunluğuna ait bilgiye sahiptir. Veriye TBA metodu uygulandıktan sonra elde edilen birinci özdeğer diğer özdeğerlere göre büyüktür ve eğer verinin dağılımı düzgün bir doğru ise diğer özdeğerlerin değeri sıfıra yakındır (Yun-Seok Lee ve ark. 2006). Fakat, dağılımın şekli düzgün doğru olsa bile ikinci özdeğer sıfır değildir.

- Dağılım matrisi:

$$S = \begin{pmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{pmatrix}. \quad (2.8.1)$$

- $n$  doğru üzerindeki piksel sayısı ve  $(x_i, y_i)$  noktasıda doğru üzerindeki  $i$ . piksel noktası olmak üzere,

$$x_m = \frac{1}{n} \sum_{i=1}^n x_i, \quad y_m = \frac{1}{n} \sum_{i=1}^n y_i. \quad (2.8.2)$$

verinin  $x$  ve  $y$  yönündeki ortalama vektörleri olacak şekilde

$$S_{11} = \frac{1}{n} \sum_{i=1}^n (x_i - x_m)^2, \quad (2.8.3)$$

$$S_{12} = S_{21} = \frac{1}{n} \sum_{i=1}^n (x_i - x_m)(y_i - y_m), \quad (2.8.4)$$

$$S_{22} = \frac{1}{n} \sum_{i=1}^n (y_i - y_m)^2, \quad (2.8.5)$$

dağılım matrisi bulunur.

- $S$ ,  $A$  lineer dönüşüm matrisi ile tanımlanabilen bir matris olsun. Eğer  $X \in R^n \neq 0$  vektörü verildiğinde aşağıdaki eşitliğin formunda yazılabilir.

$$AX = \lambda X \quad (2.8.6)$$

Eşitlik (2.8.6) daki  $\lambda$  değerleri  $S$  matrisinin özdeğerleri ve  $X$  değerleri ise özvektörleri olarak adlandırılır. Eşitlik (2.8.6) aynı zamanda  $I$  birim matris olmak üzere;

$$(A - \lambda I)X = 0 \quad (2.8.7)$$

kompakt bir şekilde yazılabilir. Cramer kuralına göre eşitlik (2.8.7) deki lineer sistemin aşikar olmayan çözümü olduğu görülür ve eşitlik (2.8.7) in çözümü aşağıdaki formda hesaplanır.

$$\det(S - \lambda I) = 0 \quad (2.8.8)$$

- Örneğin,  $2 \times 2$  boyutlu matrisin özdeğerleri

$$\lambda_{\mp} = \frac{1}{2} \left\{ S_{11} + S_{22} + \sqrt{(S_{11} - S_{22})^2 + 4S_{12}^2} \right\} \quad (2.8.9)$$

şeklinde formülize edilir. Çözümlerinin elde edildiği karakteristik denklem

$$\lambda^2 - \lambda(S_{11} + S_{22}) + (S_{11}S_{22} - S_{12}S_{21}) = 0 \quad (2.8.10)$$

formundadır.

- En büyük özdeğere sahip özvektörün  $X$  eksenini ile yaptığı açı  $\tan^{-1}\left(\frac{x_2}{x_1}\right)$  formülü ile hesaplanır.

- $\lambda_1$  en büyük özdeğer ve bu özdeğere karşılık gelen özvektör X olmak üzere buradan

$$\begin{bmatrix} S_{11} - \lambda_1 & S_{12} \\ S_{21} & S_{11} - \lambda_1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = 0 \quad (2.8.11)$$

$$\frac{x_2}{x_1} = \frac{S_{21}}{\lambda_1 - S_{22}} \quad \text{veya}$$

$$\frac{x_2}{x_1} = \frac{\lambda_1 - S_{11}}{S_{12}} \quad (2.8.12)$$

eşitlikleri elde edilir.

- Buradan açı aşağıdaki şekilde formülize edilir:

$$\theta = \tan^{-1} \frac{(\lambda_1 - S_{11})}{S_{12}} \quad \text{veya} \quad (2.8.13)$$

$$\theta = \tan^{-1} \frac{S_{21}}{(\lambda_1 - S_{22})} \quad (2.8.14)$$

- Dağılım matrisinin büyük özdeğeri  $\lambda_1$  ve küçük özdeğeri  $\lambda_2$  olmak üzere

$$\lambda_1 = \frac{1}{2} \left\{ S_{11} + S_{22} + \sqrt{(S_{11} - S_{22})^2 + 4S_{12}^2} \right\}, \quad (2.8.15)$$

$$\lambda_2 = \frac{1}{2} \left\{ S_{11} + S_{22} - \sqrt{(S_{11} - S_{22})^2 + 4S_{12}^2} \right\}. \quad (2.8.16)$$

- Dolayısıyla, doğrunun dağılım yönünün açısı  $\theta$ ,


$$\theta = \tan^{-1} \frac{(\lambda_1 - S_{11})}{S_{12}} \quad \text{or} \quad \theta = \tan^{-1} \frac{S_{21}}{(\lambda_1 - S_{22})}. \quad (2.8.17)$$

formülü ile belirlenir.

Yukarıdaki algoritmadan görüldüğü üzere, dağılım matrisinin özvektörü ile doğrunun yönü ve pozisyonu belirlenir. Aynı zamanda, bu algoritmanın karmaşıklığı diğer metodlara göre daha iyidir (Yun-Seok Lee ve ark. 2006).

Bu algoritma kullanılarak sağ destek bölgesine ait olan ana öğeler büyük özdeğer  $\lambda_{1r}$  ve küçük özdeğer  $\lambda_{2r}$ , aynı zamanda bölgenin yönünü ifade eden  $\theta_r$  açısı bulunur. Bu adım yinelemeli bir şekilde veriye uygulanarak  $\theta_r$  açısı eşik değerden ( $\theta_{the} = 45$ ) büyük

bulunursa  $w_r$  uzunluk değeri elde edilir. Öyle ki, bu uzunluk değeri büyük özdeğere bağlı olarak değişen sağ destek bölgesinin uzunluğunu ifade etmektedir. Bu prosedür sol destek bölgesini de bulmak içinde yinelenir.  $P_i$  ve  $P_i$  nin sol komşuluğundaki üç nokta alınarak TBA uygulanır ve bu verilerin ana öğeleri olan dağılım matrisinin özdeğer ve özvektörleri bulunur. Bu adım sol destek bölgesinin uzunluğunu ifade eden  $w_l$  uzunluk değeri elde edilene kadar tekrarlı bir şekilde yinelenir.



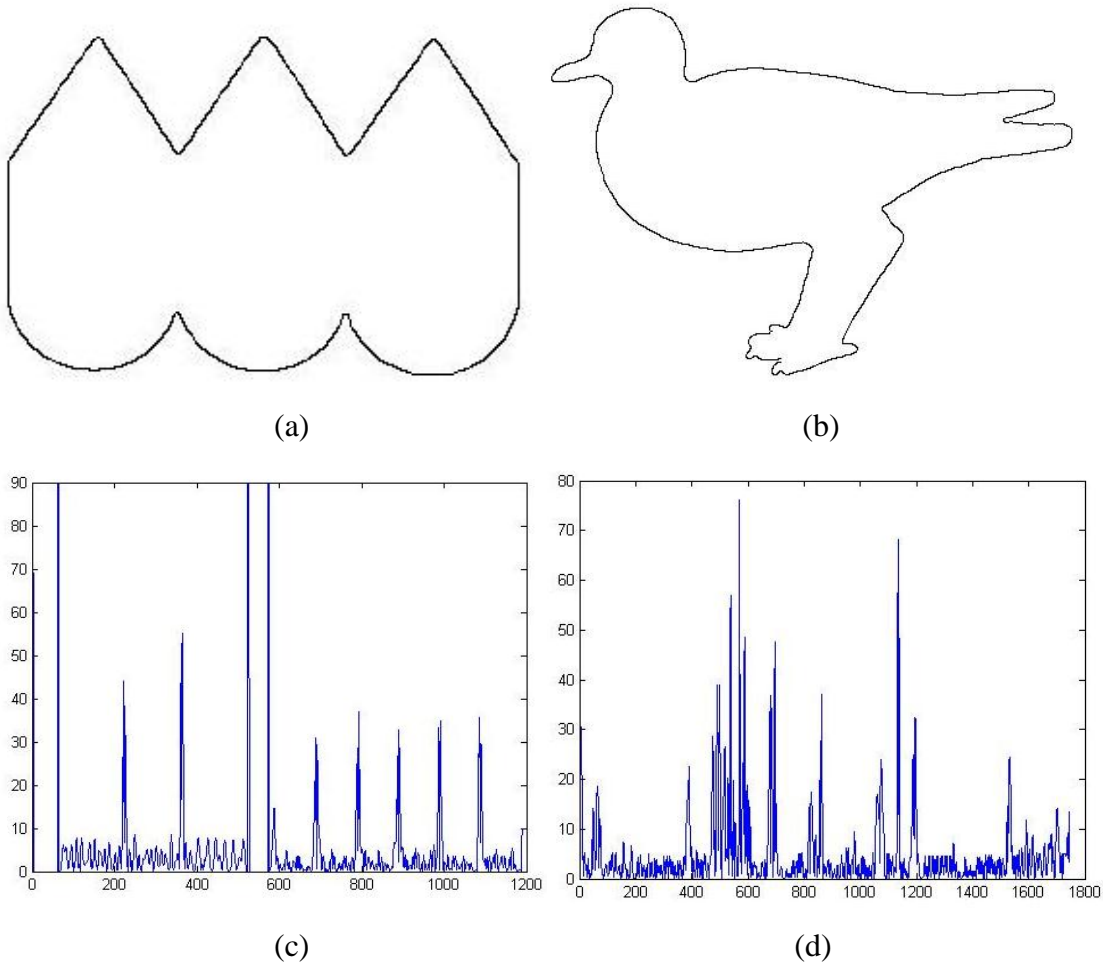
**Şekil 2.6.** Tırtıklı yapıya (a) Verilen veriye Teh ve Chin'in algoritması uygulanırsa, (b) Wen-Yen Wu'nun algoritması uygulanırsa, (c) Önerdiğimiz TBA'ya dayalı metod uygulanırsa

Şekil 2.6'dan da görüldüğü üzere  $P_i$  aday noktasının sol destek bölgesindeki kenar noktaları düzgün dağılmasına (düzgün zincir kodlara sahip) rağmen sağ destek bölgesindeki kenar noktaları düzgün olmayan zincir koduna sahiptir. Bu durum destek bölgesi hesabında hatalara sebep olabilmektedir. Bu hatalı tespit örnekleri Şekil 2.6(a) ve Şekil 2.6(b)'de verilen (Teh ve Chin, 1989) ile (Wen-Yen Wu 2003)'de önerdikleri çalışmalarındaki algoritmalar uygulanarak görülebilir. Komşu pikseller arasındaki ilişkiyi kullanarak destek bölgesini hesaplayabilmek için temel bileşen analizi (TBA) kullanılabilir.

TBA orijinal  $p$  değişkeninin varyans yapısını daha az sayıda ve bu değişkenlerin doğrusal bileşenleri olan yeni değişkenlerle ifade etme yöntemidir. Veri matrisinde yer alan  $p$  değişkenin doğrusal bileşenlerini bulmak için kovaryans matrisinin ya da korelasyon matrisinin özdeğerleri ve özvektörleri kullanılır. Birinci temel bileşen değişkeni verinin varyansını en çok açıklayan (gürültünün etkisinin en az olduğu) en büyük özdeğere karşılık gelen özvektördür. Bu özvektörün koordinat eksenini ile yaptığı açı veri dağılımının koordinat eksenini ile yaptığı açıyı vermektedir. Bu açı bilgisi kullanılarak yinelemeli bir yöntemle destek bölgesinin bulunması aşağıda özetlenmektedir.

Başlangıç olarak üç adet nokta alınır, TBA uygulanır ve en büyük özdeğere karşılık gelen özvektörün koordinat eksenleri ile yapmış olduğu açı hesaplanır. Nokta sayısı artırılarak her seferinde bulunan açı ile önceki seferde bulunan açı karşılaştırılır, açı belli bir eşik değerinden büyük olana kadar bu işleme devam edilir. Aynı adım diğer taraftaki destek bölgesi hesabı içinde uygulanır. Böylece sağ ve sol destek bölgesinin uzunlukları ( $w_r$  ve  $w_l$ ) bulunmuş olmaktadır. Bulunan sağ ve sol destek bölgesi kullanarak sağ ve sol vektörler elde edilir. Şeklin fonksiyon olarak betimlenmesi için bu vektörlerin arasındaki dar açı kullanılabilir.

Örnek resimler ve betimleme fonksiyonları Şekil 2.7'de verilmiştir. Şekli 2.7 (a),(b) konturları çıkarılmış orijinal şekiller verilmiş olup (c),(d) de ise sırasıyla şekillerin önerilen fonksiyon ile betimlenmiş halleri resmedilmektedir. (c) ve (d) de görüldüğü üzere şekiller sağ ve sol destek bölgeleri arasındaki dar açı ile betimlenmiştir.



**Şekil 2.7.** Şeklin TBA'ya dayalı fonksiyon ile betimlenmesi (a),(b) konturları çıkarılmış orijinal şekiller, (c),(d) sırasıyla şekillerin önerilen fonksiyon ile betimlenmiş halleridir.



## BÖLÜM 3

### 3. ŞEKİL BETİMLEYİCİLERİNE GENEL BİR BAKIŞ

Şekil betimleyicileri üzerine son yıllarda bir çok çalışma yapılmıştır ve görsel tanıma alanında en yaygın kullanılan betimleyicilerdir. Genel bir literatür taraması özeti için (Y.Mingqiang ve ark. 2008) ve (K. Mikolajczyk ve C. Schmid, 2005)'deki yayınlar incelenebilir. Şekil betimleme yöntemleri en genel şekliyle; sınır tabanlı yöntemler ve bölge tabanlı yöntemler olmak üzere ikiye ayrılabilir. Sınır tabanlı yöntemlerde şeklin sınır noktalarından elde edilen bilgilerden yararlanılırken, bölge tabanlı yöntemlerde şeklin iç bölgelerindeki bilgilerden yararlanılır. İyi bir şekil betimleyicisinde aşağıdaki özellikler bulunmalıdır:

- Ayırt edebilirlik: Görsel olarak birbirine benzeyen şekiller için benzer özellikler verebilmeli ve böylece şekil diğerlerinden ayırt edilebilir halde betimlenebilmelidir.
- Geometrik dönüşümlere karşı değişmezlik: Çıkarılan özelliklerin geometrik dönüşümlerde de değişmemesi gerekir. Geometrik dönüşümler, öteleme, döndürme, ölçekleme, yatırma ve diğer dönüşümlerin birleşiminden oluşabilir.
- Gürültüye dayanıklılık: Şeklin elde edilmesi sırasında ortaya çıkan gürültüye karşı dayanıklı olmalıdır.
- Örtüşmeye dayanıklılık: Şeklin herhangi bir bölümü örtülü veya eksik olduğunda da çıkarılan özelliklerin mümkün olduğunca değişmemesi gerekir.
- Düşük betimleyici boyutu: Her özelliğin birbirinden farklı olması gerekir. Böylece mümkün olduğu kadar az boyutlu betimleyici ile mümkün olduğu kadar çok bilgi kullanılabilir.

- Gürbüzlük: Bir şekil ne kadar bozulmaya uğramış olursa olsun, ondan çıkarılan özellikler mümkün olduğunca orijinal halinden farklı olmamalıdır.

Şekil betimleyicileri, şekildeki görsel olarak benzerliği yansıtan önemli özellikleri içeren vektörler üretirler. Böylece şekiller, ortak vektörler var olması durumunda bir benzerliğin tespit edilebilmesi maksadıyla karşılaştırılabilir hale getirilmiş olur. Benzerlik, iki şekle ait özellikler arasındaki uzaklığın, ihtiyaca göre seçilen bir yöntemle ölçülmesiyle tespit edilir. Çıkarılan özellikler mümkün olduğunca çok bilgiyi asgari boyutlu olacak şekilde içermelidir. Ayrıca uygulamaların gerçekçi ve uygun sürelerde çalışabilmeleri için, benzerlik veya uzaklık tespit algoritmasının düşük karmaşıklığa sahip olması gerekir. Çalışma prensipleri yönünden bakıldığında, şekil betimleyicileri; şeklin fonksiyon halinde ifade edildiği yöntemler, poligonal yakınsama yöntemleri, uzaysal ilişkilerin kullanıldığı yöntemler, momentler, ölçek uzayı yaklaşımları, dönüşüm uzaylarının kullanıldığı yöntemler olarak sınıflandırılabilir.

Genel olarak, şekil betimleyicileri verilen şekil özniteliklerine bağlı olarak sayılar kümesi (vektörler) oluşturmaktadır. Bir betimleyicinin insanların sezgisel tanımlamalarını içerecek şekilde şekili nicelemesi gerekir. İyi tanımlama oranları elde etmek için bir şekil betimleyicisinin aynı veri tabanındaki benzer şekilleri etkili bir şekilde idrak etmesi gerekir. Betimleyiciler genellikle vektör formundadırlar. Şekil betimleyicilerinin aşağıdaki özellikleri sağlar :

1. betimleyiciler şeklin içerik bilgilerini mümkün olduğunca tanımlayabilmesi gerekir.
2. betimleyicilerin kompakt bir şekilde tanımlanması ve depolanması gerekir. Betimleyici vektörünün boyutunun çok da büyük olmaması gerekir.
3. betimleyiciler arasındaki uzunlukların sayısal olarak hesaplanması basit ve hızlı olması gerekir. Aksi takdirde betimleyici çıkarım hızı uzun sürecektir.

Şeklin tanımlanması ve öznitelik çıkarımı aşağıda verilen kategorilerde ve onların uygulamalarında büyük bir rol oynamaktadır:

- şekli bulma: büyük veri tabanlarında aynı şekli içeren sıralı şekilleri bulma işidir. Genellikle veritabanındaki tüm şekillerin birbirine olan uzaklığına bakılarak sıralı şekiller veya en küçük uzaklığa sahip birkaç şekil belirlenir.

- Őekil tanıma ve sınıflandırma: Őeklin oluşturulmuş bir modelle eşleşip eşleşmediğinin belirlenmesi veya Őekle en benzer tanımlayıcının hangi sınıfa ait olduđu bilgisidir.
- Őekilleri gruplama ve kayıt etme: dönüştürülmüş veya ötelenmiş bir Őeklin diđer bir Őekille bir parçasının veya tümünün eşleştirilmesidir.
- Őekli yakınsama ve sadeleştirme : Őekli birkaç elemanı (noktalar, bölütler, üçgenler, vs.) ile oluřturma işidir, öyleki elde edilen Őeklin orjinaline benzemesi gerekir.

Geçmiş yıllarda Őekil betimleyicileri benzer ölçü tekniklerine bađlı olarak oluřturulmaktaydı. Son yıllarda birçok yeni teknikler önerilmiştir. Geleneksel sınıflandırmaların aksine, Őekil tabanlı öznelilik çıkarma ve tanımlama yaklaşımları sınıflandırılabilir. Őekil 3.1’de Őekil tabanlı öznelilik çıkarım yöntemlerinin hiyerarşik sınıflandırılması verilmiştir.



Őekil 3.1. Őekil betimleme tekniklerine genel bir bakış.

Şekil betimleyicileri tarafından şekillerin betimlenmesi esnasında şeklin geneline ait bazı parametreler de doğrudan veya ilave olarak kullanılabilir. Bu parametrelerden bazıları : ağırlık merkezi, ortalama bükülme kuvveti (S. Loncaric, 1998), (I. Young ve ark. 1974), eksantriklik, dairesellik oranı (D. Zhang ve G. Lu 2004), eliptik varyans, dikdörtgenlik, konvekslik (M. Peura ve J. Iivarinen 1997), Euler numarası, delik-alan oranı (A. Soffer 1997) olarak sayılabilir.

Şekil betimleyicileri tüm görüntü betimleyicilerinde olduğu gibi iki farklı şekilde, kontura dayalı ve bölgeye dayalı olarak, tanımlanabilir. Diğer betimleyici çeşitlerindeki yaklaşım gibi şekil betimleyicileride yapısal(lokal) veya global bir şekilde elde edilir. Şekil 3.2 de şekil betimleyicilerinin hiyerarşik sınıflandırılması verilmiştir.

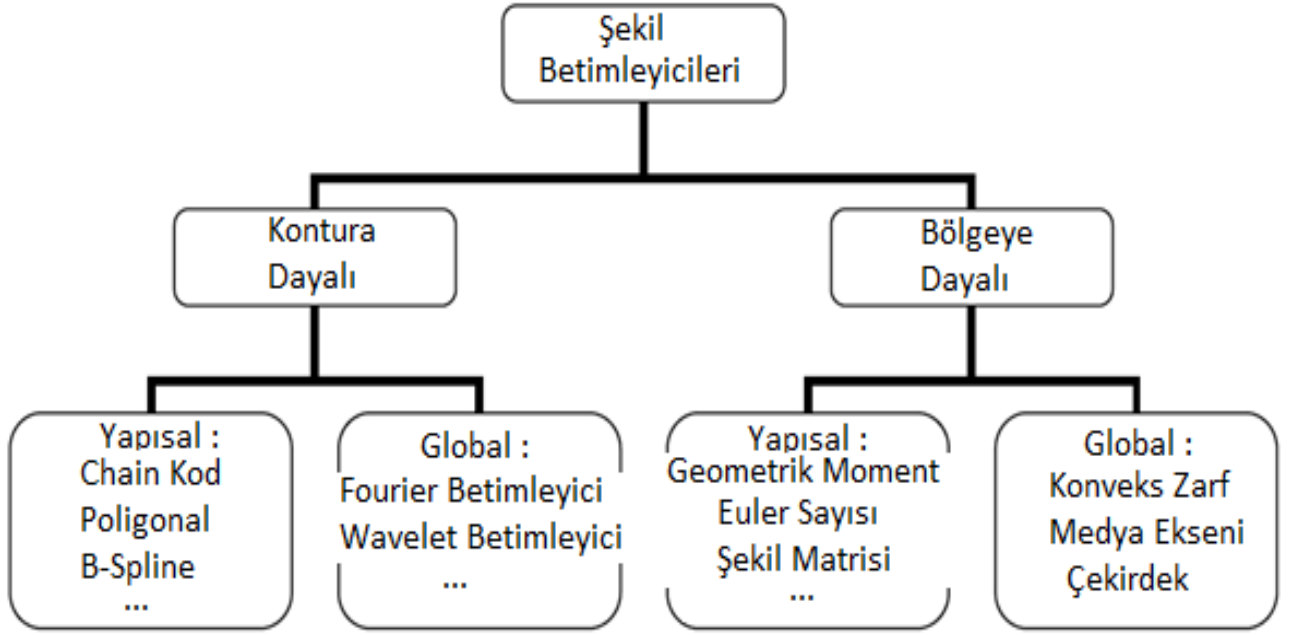
### **3.1 Kontura Dayalı Şekil Betimleyicileri**

#### **3.1.1 Global Şekil Betimleyicileri**

##### **3.1.1.1 Fourier Betimleyicisi**

Fourier betimleyicileri şekil betimleyicileri arasında en yaygın kullanılanıdır (Zhang, D., ve Lu, G. 2003), (Rafiei, D. ve Mendelzon, A. O. 2002) , (Phokharatkul, P. ve Kimpan, C., 2002) ve (Granlund, G., 1972). Fourier betimleyicisinin avantajlarından bazıları şöyledir:

- i. basit bir şekilde hesaplanır,
- ii. her bir betimleyici aynı zamanda özel fiziksel anlama sahiptir,
- iii. normalizasyonu kolaydır, eşleştirme işleminde basit bir algoritmaya sahiptir,
- iv. hem lokal hem de global öznitelikler içerir,
- v. kaba bir algoritmayla iyi bir tanıma kapasitesi vardır.



Şekil 3.2. Şekil Betimleme Tekniklerinin Sınıflandırılması

$u(t)$  şeklin bir boyutlu imza vektörü olmak üzere, şekile fourier dönüşümü uygulanarak elde edilir.  $u(t)$  objenin kapalı sınırlarından elde edilen periyodik fonksiyondur.  $T$  periyot olmak üzere  $u(t) = u(t + nT)$  dir.

$u(t)$  imza vektörünün ayrık Fourier dönüşümü ;

$$a_n = \frac{1}{N} \sum_{t=0}^{N-1} u(t) \exp\left(-\frac{j2\pi nt}{N}\right) \quad n = 0, 1, \dots, N-1 \quad (3.1)$$

$a_n$ , fourier bileşenlerinin kümesi olarak şekli ifade edebilir. Buradan şeklin fourier bileşenleri ile gösterimi geometrik dönüşümlere; dönmeye, ötelemeye ve ölçeklendirmeye göre değişmezdir. Şeklin sınır noktalarından farklı noktalarını başlangıç noktası olarak seçmek şeklin betimleyicisini etkilememektedir.

Fourier teorisinden yararlanarak, dönmeye, ötelemeye, ölçeklemeye ve farklı başlangıç noktalarına bağlı olarak fourier bileşenlerinin formulizasyonu (Granlund, G. 1972) :

$a_n^{(0)}$  orijinal şeklin ve  $a_n$  ise dönüştürülmüş şeklin fourier bileşenleri olmak üzere;

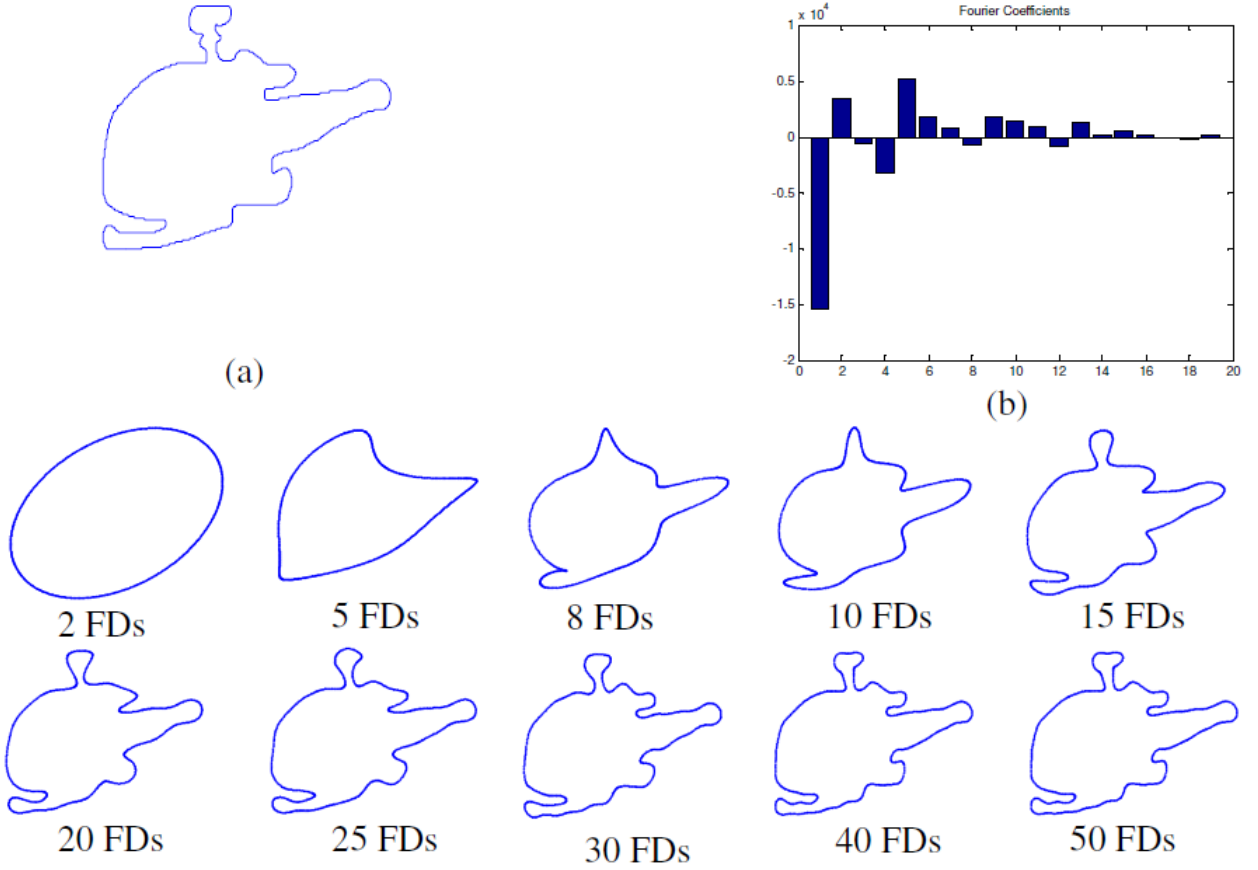
$$a_n = \exp(jn\tau) \times \exp(j\varphi) \times s \times a_n^{(0)} \quad n \neq 0 \quad (3.2)$$

şeklindedir.  $\exp(jn\tau)$ ,  $\exp(j\varphi)$  ve  $s$  sırasıyla başlangıç noktası değişiminin, dönme ve ölçeklemenin parametreleridir.  $a_n^{(0)}$  ayrık bileşeni hariç, diğer bileşenleri ötelemeye etkilenmemektedir. Buradan yola çıkarak;

$$\begin{aligned} b_n &= \frac{a_n}{a_0} = \frac{\exp(jn\tau) \times \exp(j\varphi) \times s \times a_n^{(0)}}{\exp(jn\tau) \times \exp(j\varphi) \times s \times a_0^{(0)}} \\ &= \frac{a_n^{(0)}}{a_0^{(0)}} \exp[j(n-1)\tau] = b_n^{(0)} \exp[j(n-1)\tau] \end{aligned} \quad (3.3)$$

$b_n$  ve  $b_n^{(0)}$  sırasıyla normalize edilmiş türetilmiş ve orijinal şeklin fourier bileşenleridir. (3.3)'den anlaşıldığı üzere  $b_n$  ile  $b_n^{(0)}$  arasındaki tek fark  $\exp[j(n-1)\tau]$  dir. Faz bilgisi gözardı edildiğinde büyüklük (magnitude) bileşenlerinin aynı olduğu görülür. Dolayısıyla,  $b_n$  fourier bileşenlerinin dönmeye, ötelemeye, ölçeklendirmeye ve farklı başlangıç noktalarına göre değişmez olduğu görülür.


Şekil 3.3 (a)'da siyah beyaz helikopter şeklinin fourier dönüşümü ile resmedilişi, (b)'de Fourier betimleyicisi uygulanarak kompleks koordinatlardaki şeklin imzası, (c)'de şeklin sınırındaki farklı noktalara fourier betimleyicisi uygulayarak yeniden elde edilen helikopter şekli verilmektedir. Şeklin sınırlarından seçilmiş 30 nokta veya fazlasına uygulanan fourier dönüşümünün helikopteri tam olarak oluşturduğu görülmüştür. Böylelikle görüntüdeki daha az veri fourier betimleyicisi yardımıyla kullanılarak görüntüdeki şekil betimlenmiştir.



**Şekil 3.3.** Fourier tanımlama ve helikopter şeklinin fourier betimleyicisi ile yeniden oluşturulması.

### 3.1.1.2 Wavelet Betimleyicisi

Wavelet dönüşümü düzlemdeki eğrilere uygulanarak hiyerarşik bir şekilde elde edilen betimleyicidir (Cremers, D. ve ark. 2007). Bu betimleyici eğrinin farklı ölçeklenmiş halinin bileşenlerini içerir. İyi bir ölçeklendirme bileşeni lokal bilgi gerektirirken, kaba ölçeklendirme bileşenleri global yakınsama bilgisine ihtiyaç duyar. Wavelet betimleyicisi ölçeklendirme bileşenlerine göre global ve lokal öznitelikleri içerir. Ayrıca, bu betimleyici değişmezlik, teklik, durağanlık, çoklu-çözünürlük ve uzaysal yerselleştirme özelliklerine sahiptir. Diyadik wavelet dönüşümünün afin dönüşümüne göre değişmez olduğu (Cremers, D. ve ark. 2007) çalışmasında gösterilmiştir. Kutupsal açı eksenine fourier dönüşümü ve radyan eksenine wavelet dönüşümü uygulanarak (Ayed, I.B. ve ark. 2009)' da betimleyici elde edilmiştir. Bu öznitelikler öteleme, dönme ve ölçeklendirmeye göre değişmezdir. Aynı zamanda wavelet betimleyicisi ile eşleştirme işlemide ucuz ve uygundur.



**Şekil 3.4.** Wavelet betimleyicisindeki ölçeklendirme bileşenlerini kullanarak şeklin elde edilmesi

### 3.1.2 Yapısal Şekil Betimleyicileri

Son yıllarda dijital görüntü işleme araçlarındaki gelişme, modern dünyadaki bir çok alanda resim arşivlerinin büyümesine neden olmuştur. Dijital görüntüleme aynı zamanda görüntü uygulamaların maliyetini de oldukça düşürmüştür, bunun sonucunda da resim veri tabanları içerik olarak gittikçe genişlemiştir. Dijital resim arşivlerinin genişlemesi, nesne tanıma çalışmalarına olan ihtiyacı artırmıştır. Görüntünün tanımlayıcı en önemli görsel özelliklerden bir tanesi resimdeki nesnelerin şekillerinin çevritleridir. Şeklin konturları bölütlenerek görüntü tanıma ve şekil analizi gibi daha yüksek seviyedeki görüntü işleme uygulamalarında anlamlı ve kompakt bir biçimde bir nesneyi tanımlamak için kullanılabilir.




Bu sınıflandırmanın yapılabilmesi için şeklin konturları üzerindeki anlamlı noktaların tespit edilmesi gerekmektedir. Literatürde bununla ilgili çok sayıda yayın mevcuttur.

### 3.1.2.1 Baskın Nokta Analizi

Dijital eğrilerden anlamlı öznitelikler çıkarımı şekil analizinde önemli bir adımdır. Baskın nokta (dominant point) terimi; önemli nokta, anlamlı nokta, köşe noktası olarakta bilinmektedir ve düzlemsel objenin sınırında yüksek eğriliğe sahip nokta olarakta adlandırılabilir. Kontur metotlarının önemli bir parçası da baskın nokta analizidir. Bu noktalarda eğrilik ekstremdir ve eğri üzerinde görsel algılama ve tanımaya uygundur (A. Carmona-Poyato ve ark. 2005), (P. Cornic 1997).

E. Atteneave (1954) eğri üzerindeki baskın nokta analizine ilk olarak değinen isim olmak üzere Şekil 3.5' deki kediyi farklı baskın noktalara bağlı parçaları birleştirerek oluşturmuştur.



Şekil 3.5. E. Atteneave' in kedisi (1954).

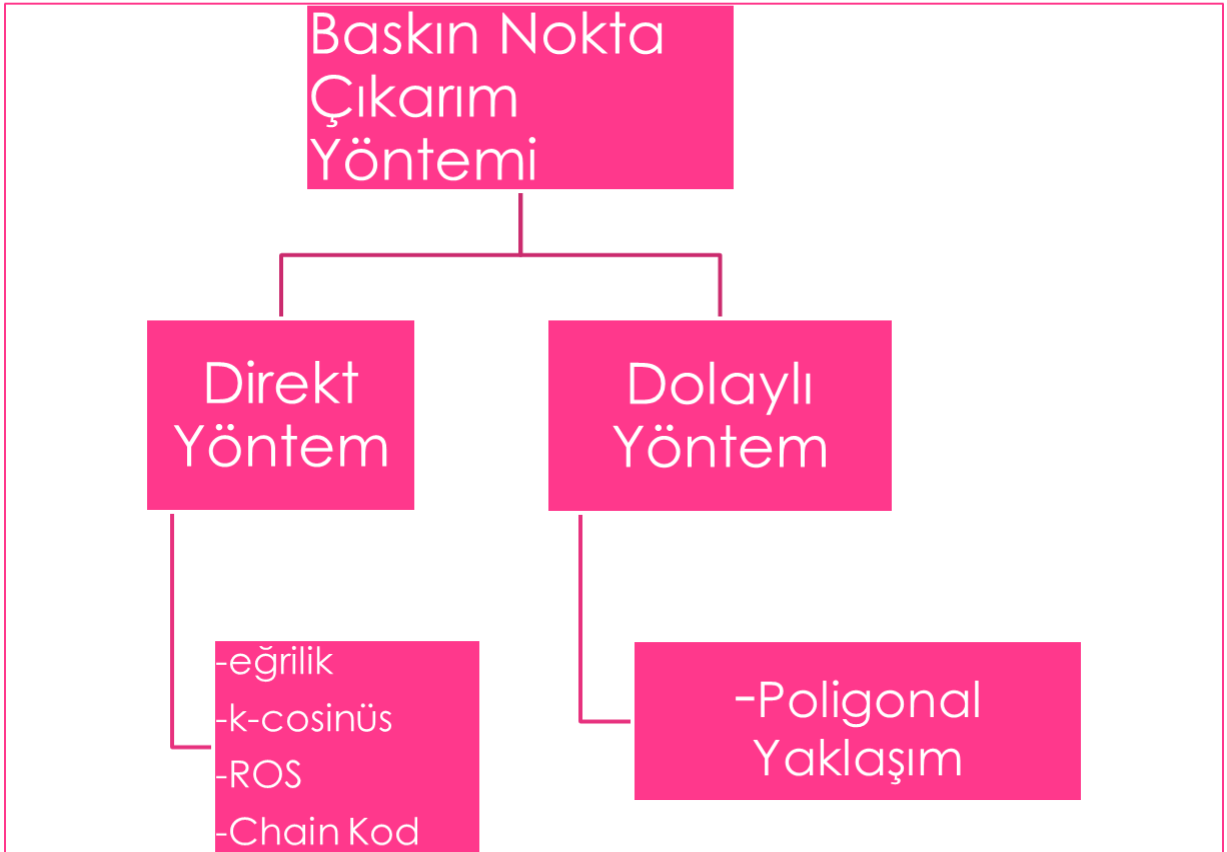
Baskın noktalardan şekil konturunu diğer işlemler için sadeleştirmede de yararlanılabilir. Bu tanımlama, şeklin tüm kontur bilgisini almak yerine öznitelik noktalarının kümesini almayı ifade eder. İki boyutlu şekilleri baskın noktalarla tanımlanmasının en büyük avantajlarından biri yüksek boyutlu verinin boyutunun düşürülmesidir. Böylelikle, verimli bir şekilde öznitelik çıkarımı ve şekil eşleştirme algoritması uygulanabilir. Boyut indirgemenin depolama ve geçiş zamanının az olması gibi yararları vardır.

Boyut indirgemek dışında bu yaklaşımın diğer önemli yanı ise şeklin bilgilerini kaybetmeyecek formda şekile ait ilgi noktalarının bulmasıdır. İnsanların şekilleri ayırt etmede kullandıkları sezgilerinde ilgi noktalarının büyük bir rol oynadığı bilinir. Dolayısıyla,

şekildeki ilgi noktaları orijinal eğriyi elde edebilecek özneliklere sahiptir ve gürültüden az etkilenmektedir. Ayrıca, ilgi noktaları arasındaki bölgede şeklin konturuna yakınsanmış eğri sınıflandırmaya uygundur.

### 3.1.2.2 Baskın Nokta Tespiti Algoritmaları

Baskın nokta tespiti için birçok yaklaşım önerilmiştir. Çoğu algoritma kontur bölgelerindeki (direkt veya dolaylı) eğri üzerindeki her bir noktanın lokal özelliklerini ölçmek için bir veya birden fazla parametre gerektirmektedir. Baskın nokta çıkarım tekniklerinin sınıflandırılması (Nguyen ve Debled-Renneson 2011) Şekil 3.6' da verilmiştir.



Şekil 3.6. Baskın nokta çıkarım tekniklerinin sınıflandırılması

Şekil 3.6'da görüldüğü üzere bu metotlar iki ayrı ana kategoriye ayrılmıştır: köşe tespit metodları (direkt metodlar) ve poligonal yaklaşım metodlarıdır (dolaylı metodlar).


### 3.1.2.3 Direkt Metodlar

Direkt yöntemde de eğri denklemindeki yüksek değerlere sahip olan noktalar baskın nokta olarak belirlenir. Eğri denklemi eğrilik tabanlı ölçme kriteri (B. Kerautret ve ark., 2008) veya buna alternatif olan k-cosine (A. Rosenfeld ve E. Johnston, 1973), destek bölgesi (DB) (C.H. Teh ve R.T. Chin, 1978) gibi yöntemlerle elde edilebilir. (Rosenfeld ve Johnston, 1973), noktanın her iki tarafındaki k uzunluğundaki eğri arasındaki açının kosinüsünü (k-cosine) eğrilik tabanlı ölçme kriteri olarak kullanmışlardır. Destek Bölgesi (DB) hesaplamak için (Ray ve Ray, 1992), Rosenfeld ve Johnston'ın tanımladığı k-cosine ölçümünü kullanmışlardır. (Teh ve Chin, 1978) DB'deki her bir noktanın kirişe olan uzaklığının kirişin uzunluğuna oranına bağlı bir oran geliştirmişlerdir. Kiriş uzaklık oranını,  $p_{i-k}$  ile  $p_{i+k}$  noktaları arasındaki bağlama kirişinin uzunluğu ( $l_{ik}$ ),  $p_i$  noktasının bu kirişe olan dik uzaklığı ( $d_{ik}$ ) olmak üzere  $r_{ik} = \frac{d_{ik}}{l_{ik}}$  olarak formülize etmişlerdir ve bu oran kullanılarak DB'ni tespit etmişlerdir. (Cornic, 1997) , Teh ve Chin'in ve Ray ve Ray'in algoritmalarının gürültülü çevritlere sahip resimlerde iyi sonuç vermediğine değinmiş ve eğriliğe bağlı olmayan uyarlamalı bir algoritma önermişlerdir. Baskın noktalarının Sağ Limit ve Sol Limit vektörlerine bağlı olarak DB'ni belirlemişlerdir. (Wu, 2003), çevritteki her bir nokta için adaptif büküm değer ölçüsünü önermiş ve bu ölçüye bağlı olarak baskın noktalar belirlemiştir. (Marji ve Siy, 2004) kontur üzerinde belirlenen baskın nokta kümesindeki aynı çizgi üzerinde bulunan bitişik noktaları elimine edecek şekilde algoritma geliştirmişlerdir.

### 3.1.2.4 Dolaylı Yöntemler

#### 3.1.2.4.1 Poligonal Yakınsama

Örüntü tanıma alanında birçok araştırmacı tarafından baskın nokta analizi ve poligonal yakınsama metodları kullanılmaktadır. Genellikle optimal, iteratif ve dizisel algoritmalar poligonal yakınsama metodlarında kullanılmaktadır. Şekil 3.7'de poligonal yakınsamaya örnek resmedilmektedir.



**Şekil 3.7.** Dinazor şekli üzerindeki (seçilmiş 10, 20 ve 30 nokta) ile poligonal yakınsama (550 kontur noktaları)

#### 3.1.2.4.2 Poligonal Yakınsama Yöntemleri

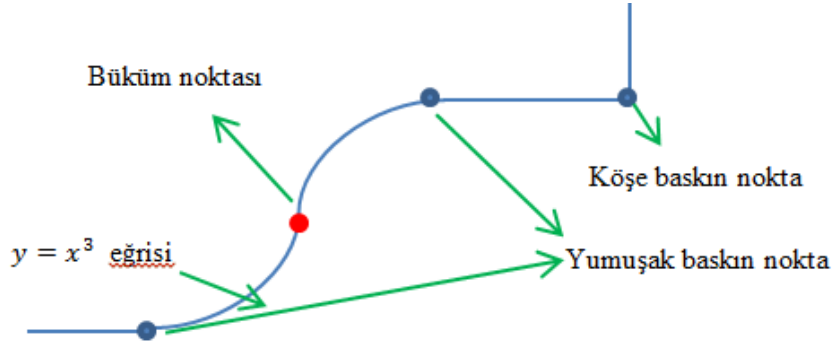
Şeklin konturlarının bölütlenmesindeki amaç minimum bozulma ile çizgi, çember, elips gibi basit eğrilerle poligonal yaklaşım yapmaktır. Bu konuda son yıllarda çok sayıda çalışma yapılmıştır. Bu yöntemlerde şekil sınırı, küçük değişimler yok edilerek eğriler ya da doğrular haline getirilir. Bu işlem sınır noktaları üzerine doğrular ya da eğriler oturtularak yapılır. Böylece hem gürültüden kurtulunur hem de pikselleşme etkisi azaltılır. Poligonal yakınsama yöntemleri, birleştirerek uygulanan yöntemler ve ayrıştırarak uygulanan yöntemler olmak üzere ikiye ayrılır. Birleştirme yöntemlerinde, eğer sınır noktası oturtulan doğrudan veya eğriden fazla sapma yapmıyorsa oturtulan doğru veya eğri grubuna dahil edilir. Böylece şekil doğrulardan veya eğrilerden oluşan bir hale sokulmuş olur. Ayrıştırma yöntemlerinde ise noktalar üzerine oturtulan doğru, daha iyi oturtulabilmesi için bölümlenir.

(P. Cornic, 1997), (M. Marji, P. Siy, 2004) çalışmalarında, poligonal yaklaşımdaki temel fikir şeklin konturları üzerindeki anlamlı noktaları bulup, bu anlamlı noktalar arasına basit eğriler uyarlamak ve bu basit eğrileri şeklin tanımlanması veya analizinde kullanmak

olduđuna deđinilmiřtir. Bu anlamlı noktalar kőře veya baskın noktalar olabilmektedir. Kőře noktaların tespiti iin (J. Sporning ve ark. 2000), (F. Chabat ve ark. 1999), (L. Li ve W. Chen, 1999), (H.T. Sheu ve W.C. Hu, 1996), (D.M. Tsai, 1996) ve (A. Rattarangsi, R.T. Chin, 1992) baskın nokta tespiti iin (Wen-Yen Wu, 2003), (J.H. Horng, 2002), (B. Sarkar ve ark. 2003) ve (C.H. Teh ve R.T. Chin, 1989) numaralı yayınlara bakılabilir. Anlamlı noktaları kullanarak poligonal yaklařım konusundaki ilk yapılan alıřmalar da eđri olarak izgi ve dairesel yaylar kullanılmıřtır (J.H. Horng, 2003), (B. Sarkar ve ark. 2003), (H.T. Sheu ve W.C. Hu, 1999) ve (P.L. Rosin ve G.A.W, 1989). izgi ve dairesel yayların kullanmanın temel sebebi olarak izgilerin dőrt parametre (bařlangı ve bitiř noktalarının x ve y koordinatları), dairesel yayların ise ũ parametre (merkez noktasının x ve y koordinatları ile yarıap) ile basit olarak temsil edilebilmesidir. Ancak dairesel, eliptik, parabolik ve hiperbolik yaylar gibi yũksek mertebeden analitik eđrileri sadece dairesel yayları kullanmaktan daha dođru temsil edebileceđi (Wu-Chih Hu, 2005) numaralı yayında belirtilmiřtir. Őnerilen yőntem kırılma noktası sınıflandırma ve ayarlama yaklařımına dayalı (Wu-Chih Hu, 2005)' deki yayının modifiye edilmiř / geniřletilmiř yőntemdir. (H.T. Sheu ve W.C. Hu, 1999), numaralı yayında ilk Őnce kırılma noktalarını *c* kőře noktalarını, *s* yumuřak geiřleri, *l* izgileri ve *a* eđrileri gőstermek ũzere beř sınıfla katagorize etmiřlerdir. Bunlar *c-ll*, *c-la*, *c-aa*, *s-la* ve *s-aa* dır. Bu sınıfları daha sonraki alıřmalarında 29 tip olarak geniřletmiřlerdir (Wu-Chih Hu, 2005). Bu tipler sırasıyla *c*, *e*, *p* ve *h* dairesel, elips, parabolik ve hiperbolik olmak ũzere řoyledir: *c-ll*, *c-lc*, *c-le*, *c-lp*, *c-lh*, *c-cc*, *c-ce*, *c-cp*, *c-ch*, *c-ee*, *c-ep*, *c-eh*, *c-pp*, *c-ph*, *c-hh*, *s-lc*, *s-le*, *s-lp*, *s-lh*, *c-cc*, *s-ce*, *s-cp*, *s-ch*, *s-ee*, *s-ep*, *s-eh*, *s-pp*, *s-ph*, *s-hh*.

Hu ve ark.'nın yaptıđı bu iki alıřmada da baskın noktalar kőře veya yumuřak olarak sınıflandırılmıřtır (Wu-Chih Hu, 2005), (H.T. Sheu ve W.C. Hu, 1999). Halbuki  $y = x^3$  eđrisini dũřünecek olursak  $x = 0$  bũkũm noktası ne kőře ne de yumuřak geiř noktasıdır. Bu nokta matematiksel olarak bũkũm noktası olarak tanımlanmaktadır. Parametrik eđrinin bũkũm yőnũnũn deđiřtiđi noktadır ve  $P'(t) * P''(t) = 0$  denkleminin özũm noktasıdır. Bũkũlme noktasında eđrinin i ya da dıřbũkeyliđi Őteki yőne geer. Bir bařka deyiřle, bu noktada iki yőn akıřık iken diđer iki yőn ise ters yőnlũdũr. Yani, bu noktada eđrinin ait olduđu fonksiyonun ikinci tũrevi iřaret deđiřtirir ya sıfır ya da sonsuz olur ve benzer řekilde eđrinin birinci tũrevi ise sıfırdır.

Şekil 3.8’ de görüldüğü üzere baskın noktaların sadece köşe ve yumuşak nokta olarak işaretlenmesi yeterli değildir. Bundan dolayı bu çalışmada Hu ve ark. nın (2005)’de önermiş olduğu 29 sınıfa ilaveten büküm noktaları da eklenerek 43 sınıfa çıkartılmıştır. Bu sayede şekil çevritlerine daha hassas olarak poligonal yaklaşım yapılabilir.




Şekil 3.8. Büküm noktası gösterimi

### 3.1.2.5 Anlamlı Noktaların Tespiti

Önerilen metoddaki anlamlı nokta tespit algoritması aşağıda verilmiştir:

**Adım 1:** Destek bölgesi uzunluk değerleri  $w_r$  ve  $w_l$  bulunduktan sonra  $(P_i - w_l, P_i + w_r)$  aralığına ait kenar noktaları seçilir.  $(P_i - w_l, P_i)$  aralığındaki noktalara TBA metodu uygulanır ki  $\lambda_{1l}, \lambda_{2l}$  özdeğerleri ve verinin dağılım yönü olan  $\theta_l$  açısı elde edilir. Benzer şekilde  $(P_i, P_i + w_r)$  aralığındaki noktalara TBA metodu uygulanarak  $\lambda_{1r}, \lambda_{2r}$  özdeğerleri ve verinin dağılım yönü olan  $\theta_r$  açısı elde edilir.




Şekil 3.9.  $m_b > thresh1$  olacak şekilde baskın nokta türleri.

**Adım 2:**  $\theta_l$ ,  $\theta_r$  iki dağılım yönüne ait açı bulunduktan sonra, iki vektör arasındaki açı bulunur ( $m_b = tg^{-1}\left(\frac{\theta_r - \theta_l}{1 + \theta_r \theta_l}\right)$ ). Bu açı ölçüsü,  $m_b$ , (Wen-Yen Wu, 2003) deki eğrilik fonksiyonu yerine önerilmiştir ve Şekil 2.5 de resmedilmektedir.

**Adım 3:** Canny algoritmasında olduğu gibi  $thresh1 > thresh2$  olmak üzere iki tane eşik değeri belirlenir. Eğer  $m_b > thresh1$  ise,  $P_i$  noktası kesin anlamlı nokta olarak adlandırılır (Canny algoritmasındaki yüksek eşik değerinden büyük olan aday köşe noktalarının kesin köşe olarak işaretlenmesi gibi). Kesin anlamlı nokta örnekleri Şekil 3.9'da verilmiştir. Eğer açı değeri iki eşik değeri arasında ise ( $thresh1 > m_b > thresh2$ ),  $P_i$  zayıf anlamlı nokta olarak adlandırılır Zayıf anlamlı nokta örnekleri Şekil 3.10'da görülebilir. Eğer açı değeri  $thresh2$  eşik değerinden küçükse bu nokta anlamlı nokta değildir.


**Adım 4:** Zayıf anlamlı noktalar belirlendikten sonra o noktanın sağ ve sol destek bölgelerine doğru uydurulur. Eğer doğru uydurma hata miktarı küçük ise doğru, değilse eğri olarak kabul edilir.

- Eğer bitişik zayıf anlamlı noktalar arasındaki her iki aralığa da doğru uyarlanmışsa zayıf anlamlı noktalar anlamlı nokta olarak adlandırılır Şekil 3.10 (a).
- Eğer aralığın birine doğru uyarlanmış ve diğer aralığa da eğri uyarlanmışsa zayıf anlamlı noktalar anlamlı nokta olarak adlandırılır Şekil 3.10 (b).
- Eğer her iki aralığa da eğri uyarlanmışsa zayıf anlamlı noktalar aday anlamlı noktalardan silinir Şekil 3.10 (c).
- Eğer her iki aralık eğri olarak belirlenmiş ise eğri üzerinde büküm noktası araştırılır. Şekil 3.8.'de gösterildiği gibi parametrik eğrilerin  $P'(t) * P''(t) = 0$  denklemini çözen büküm noktası bulunur. Büküm noktalarında eğrinin geçiş yönü ters olduğundan anlamlı nokta olarak belirlenir.



**Şekil 3.10.**  $thresh1 > m_b > thresh2$  olmak üzere; (a) Doğru-doğru birleşmesinde zayıf anlamlı nokta anlamlı noktadır. (b) Eğri-doğru veya doğru eğri birleşmesinde zayıf anlamlı nokta anlamlı noktadır. (c) Eğri-eğri birleşmesinde zayıf anlamlı nokta silinir.

Şekil 3.11’de tüm olası sonuçlar gösterilmiştir. Şekil 3.11’ de arda arda gelen anlamlı noktalar arasına doğru ardından doğru uyarlanmışsa anlamlı noktalar (1) ile, eğri ardından doğru uyarlanmışsa (2) ile, eğri ardından eğri uyarlanmış ise (3) ile, silinen zayıf anlamlı noktalar kırmızı noktalar ile işaretlenmiş ve (4) ile gösterilmektedir. Şekil 3.11 (b)’de verilen şekilde büküm noktası da bulunmuştur ve bu nokta (5) ile gösterilmektedir.




**Şekil 3.11.** Baskın nokta elde edildikten sonra : (a)1, doğru ardından doğru gelmişse Şekil 3.9.(a). 2, eğri ardından doğru gelmişse Şekil 3.9 (b). 3, eğri ardından eğri gelmişse Şekil 3.9 (c). 4, silinen zayıf anlamlı noktadır Şekil 3.10.(c). (b) 5, büküm noktasıdır Şekil 3.8.

Anlamlı noktaların önerilen şekil betimleme fonksiyonları üzerindeki bulunduğu kısımlara bakılınca fonksiyonun bu noktalarda yüksek değerler aldığı Şekil 3.12’de görülmektedir. Şekil 3.12 (a) ve (b) de verilen şekillerin anlamlı nokta analizi yapılmış halleri vardır. (a) daki şekilden 15 aday anlamlı nokta ve (b) deki şekilden ise 21 aday anlamlı nokta



bulunmuştur. (a) ve (b) kesin anlamlı noktalar yeşil nokta ile, zayıf anlamlı (silinen) noktalar mavi nokta ile ve son olarak büküm noktaları kırmızı nokta ile işaretlenmiştir. Şekil 3.12 (c) ve (d)' de verilen şekillerin fonksiyon ile betimlenmiş halleri verilmiş ve aday anlamlı noktaların fonksiyon ile aldığı değerler işaretlenmiştir. (c) ve (d) incelendiğinde zayıf anlamlı (silinen) noktaların fonksiyon üzerinde aldığı değerlerin birinci eşik değerinden küçük olduğu, kesin anlamlı noktaların aldığı değerlerin büyük eşik değerinden de büyük olduğu görülür. İki eşik değer arasına düşen noktalarda anlamlı nokta olarak işaretlenmiştir. Şekil 3.12. (c) ve (d) de büküm noktalarının fonksiyon üzerinde aldığı değerlerin birinci eşik değerden küçük olduğu görülür, fakat büküm noktası şartını sağladığından büküm noktaları kesin anlamlı nokta olarak işaretlenir.



**Şekil 3.12.** Şeklin TBA'ya dayalı fonksiyon ile betimlenmesi (a),(b) anlamlı nokta analizi yapılmış orijinal şekiller, (c),(d) sırasıyla şekillerin önerilen tek değişkenli fonksiyon ile betimlenmiş ve anlamlı noktaların eşik değerleri ile sınırlandırılmış halidir.

### 3.2. Konik Eğrilerin Sınıflandırılması

Parametrik eğrilere konik uydururken üç çeşit model kullanılmaktadır : (a) rehber üçgen, (b) giriş ve (c) tepe noktası modelleri olarak adlandırılmaktadır. Önerdiğimiz metod da konik uydururken rehber üçgen modeli ele alınmıştır.

#### 3.2.1 Rehber Üçgen Modeli

Konik eğriler rehber üçgen modeli ile elde edilebilir Şekil 3.13’de resmedilmektedir. Rehber üçgen  $T_c$  ve köşe noktaları  $p_0$ ,  $p_1$  ve  $p_2$  olarak adlandırılmak üzere konik bölümün başlangıç ve bitiş noktaları  $p_0$  ve  $p_2$  olsun.  $C$ , konik bölüm

$$B_0(t) = (1 - t)^2, B_1(t) = 2(1 - t)t \text{ ve } B_2(t) = t^2 \quad (3.4)$$

Bernstein baz fonksiyonları olmak üzere geometrik olarak kuadratik formda:

$$C(t) = \frac{B_0(t)p_0 + B_1(t)wp_1 + B_2(t)p_2}{B_0(t) + B_1(t)w + B_2(t)}, \quad 0 \leq t \leq 1 \quad (3.5)$$


ifade edilebilir (Qiuming Zhu, 2006).  $w$  parametresi konik sınıfları ayırmada ve koniklerin keskinliğini belirlemede kullanılır. Eğer  $w < 1$  ise konik bölge elips,  $w = 1$  ise konik bölge parabol ve  $w > 1$  ise konik bölge hiperbol olarak adlandırılır.  $p_0 - p_1$  ve  $p_1 - p_2$  vektörleri  $p_0$  ve  $p_2$  den geçen konik eğrinin tanjant vektörleridir.  $p_0 - p_2$  de rehber üçgeninin temel doğrusudur.

$p_0 - p_1$  vektörüne bağlı doğrunun denklemi  $a_x x + a_y y + a_0 = 0$ ,  $p_2 - p_1$  vektörüne bağlı doğrunun denklemi  $b_x x + b_y y + b_0 = 0$  ve  $p_0 - p_2$  vektörüne bağlı doğrunun denklemi  $u_x x + u_y y + u_0 = 0$  olmak üzere konik denklem cebirsel olarak :

$$(a_x x + a_y y + a_0)(b_x x + b_y y + b_0) = K(u_x x + u_y y + u_0)^2 \quad (3.6)$$

formunda da yazılabilir.

$K$  parametresi, (3.5) denklemindeki  $w$  parametresi ile aynı role sahiptir. Dolayısıyla, rehber üçgen (3.6) daki denklem ile de ifade edilebilir ve  $K$  parametresine bağlı olarak konik bölge sınıflandırılabilir:



**Şekil 3.13.** Konik bölgeler için rehber üçgen modeli

- 1) Eğer  $K = \frac{a_y b_y}{u_y^2}$  ise parabol,
- 2) Eğer  $K > \frac{a_y b_y}{u_y^2}$  ise elips ve
- 3) Eğer  $K < \frac{a_y b_y}{u_y^2}$  ise hiperbol.

$K$  parametresine bağlı olarak anlamlı noktalar arasına konik uydururken elde edilmiş sonuçlar Şekil 3.18 ve 3.19’da resmedilmiştir.

### 3.3. Ölçü Kriterleri

Poligonal yakınsama algoritmalarında ana amaç yakınsamalar sonucu oluşan bozulmaların etkisini gidermek ve hata paylarını oldukça düşürebilmektir. Bu amaçla birçok ölçü birimi önerilmiştir. Yaygın olarak kullanılan ölçü birimlerinden bazıları :

- $n$  kontur üzerindeki noktaların sayısı ve  $n_d$  poligonal yakınsamanın yapılacağı noktaların sayısını göstermek üzere,

$$CR = n/n_d \quad (3.7)$$

ölçü birimi sıkıştırma oranı olarak adlandırılır. Bu ölçü biriminde yakınsamanın yapılacağı noktaların sayısı az alındığında sıkıştırma oranı büyümektedir. Dolayısıyla, poligonal yakınsama sonucu oluşan hata payını ölçerken sıkıştırma oranı ölçüsünün yetmediği görülür ve diğer ölçü birimlerine ihtiyaç duyulur.

- $e_i$ , yakınsanmış doğrusal bölgenin kontur üzerinde o bölgedeki herhangi bir  $P_i$  noktasına olan uzaklığını göstermek üzere,

$$ISE = \sum_{i=1}^n e_i^2 \quad (3.8)$$

karesel hata toplamı olarak adlandırılır.

- (Sarkar, 2003) de bu iki ölçü birimini oran gibi kullanarak birleştirmiştir

$$FOM = \frac{CR}{ISE} \quad (3.9)$$

ve değer katsayısı olarak adlandırmıştır.

- (Marji ve Syi, 2004) bu iki ölçü biriminin FOM'u tam olarak dengelemediğini göstermiştir ve Sarkar'ın ölçü birimini modifike ederek

$$FOM = \frac{(CR)^x}{ISE} \quad (3.10)$$

ölçü birimini önermişlerdir.  $x$  parametresi bu iki ölçü biriminin dengesizliğini kontrol etmek için eklenmiştir ve (Marji ve Syi 2004)'de  $x = 1, 2, 3$  değerlerini alacak şekilde kullanılmıştır. Ancak,  $x$ 'in aldığı hangi değere göre iyi sonuçlar elde edildiği belirlenememiştir.

- (Carmona, 2005)' de poligonal yakınsamayı optimize edecek üç farklı ölçü birimi önermiştir.  $x = 1, 2, 3$  değerlerini almak üzere

$$F_x = \frac{ISE}{(CR)^x} \quad (3.11)$$


olarak tanımlamıştır.

### 3.4. Deneysel Sonuçlar

Önerilen metod da performansı ölçebilmek için çalışmalarda kullanılan beş adet ölçü kriteri ile deneysel sonuçlar elde edilmiştir. Bu ölçü kriterleri; dominant noktaların sayısı ( $n_{dp}$ ), sıkıştırma oranı (CR), karesel hata toplamı (ISE), değer katsayısıdır (FOM). Sonuçlar yaygın olarak kullanılan üç şekile uygulanılarak elde edilmiştir. Bu şekiller kromozom eğrisi (Şekil 3.14(a)), yaprak eğrisi (Şekil 3.14(b)) ve yarım daire eğrisi (Şekil 3.14(c))'de resmedilmektedir. Sarkar kriterleri kullanılarak elde edilen sonuçlar Tablo 3.1'de verilmiştir. Tablo 3.1'deki sonuçlara bakılırsa FOM değerinin aldığı en büyük değer önerdiğimiz metod ile elde edilmiştir.

Şekil	Algoritma	$n_{dp}$	CR	$L_{\infty}$	ISE	FOM
<b>Kromozom</b>	Önerilen	17	3.53	0.59	4.08	0.865
	Nguyen	18	3.33	0.63	4.06	0.821
	Sarkar	19	3.16	0.55	3.86	0.819
	Shearer	10	6.00	-	6.09	0.744
	Wu	17	3.53	0.64	5.01	0.704
	Ray	18	3.33	0.65	4.81	0.693
	Masood	12	5.00	0.88	7.76	0.650
	Teh	15	4.00	0.74	7.20	0.556
	Marji	11	5.45	0.90	9.96	0.548
<b>Yaprak</b>	Önerilen	28	4.29	0.82	7.02	0.611
	Nguyen	24	5.00	0.73	9.99	0.500
	Masood	23	5.22	0.74	10.61	0.490
	Shearer	22	5.46	-	13.06	0.418
	Marji	22	5.45	0.78	13.21	0.413
	Sarkar	23	5.22	0.78	13.17	0.396
	Teh	29	4.14	0.99	14.96	0.277
	Ray	32	3.75	0.99	14.18	0.264
	Wu	23	5.22	1.00	20.34	0.256
<b>Yarım Daire</b>	Masood	22	4.64	0.72	8.61	0.540
	Önerilen	23	4.44	0.66	5.85	0.759
	Nguyen	22	4.68	0.78	10.31	0.454
	Wu	27	3.78	0.88	9.19	0.411
	Ray	27	3.78	0.88	11.50	0.329
	Sarkar	19	5.37	1.47	17.37	0.309
	Ansari	28	3.64	1.26	17.83	0.240
	Marji	18	5.67	1.00	24.2	0.234
	Teh	22	4.64	1.00	20.61	0.225

**Tablo 3.1.** Sarkar kriterlerine göre karşılaştırma



**Şekil 3.14.** (a) Kromozom eğrisi, (b) Yaprak eğrisi, (c) Yarım Daire eğrisi

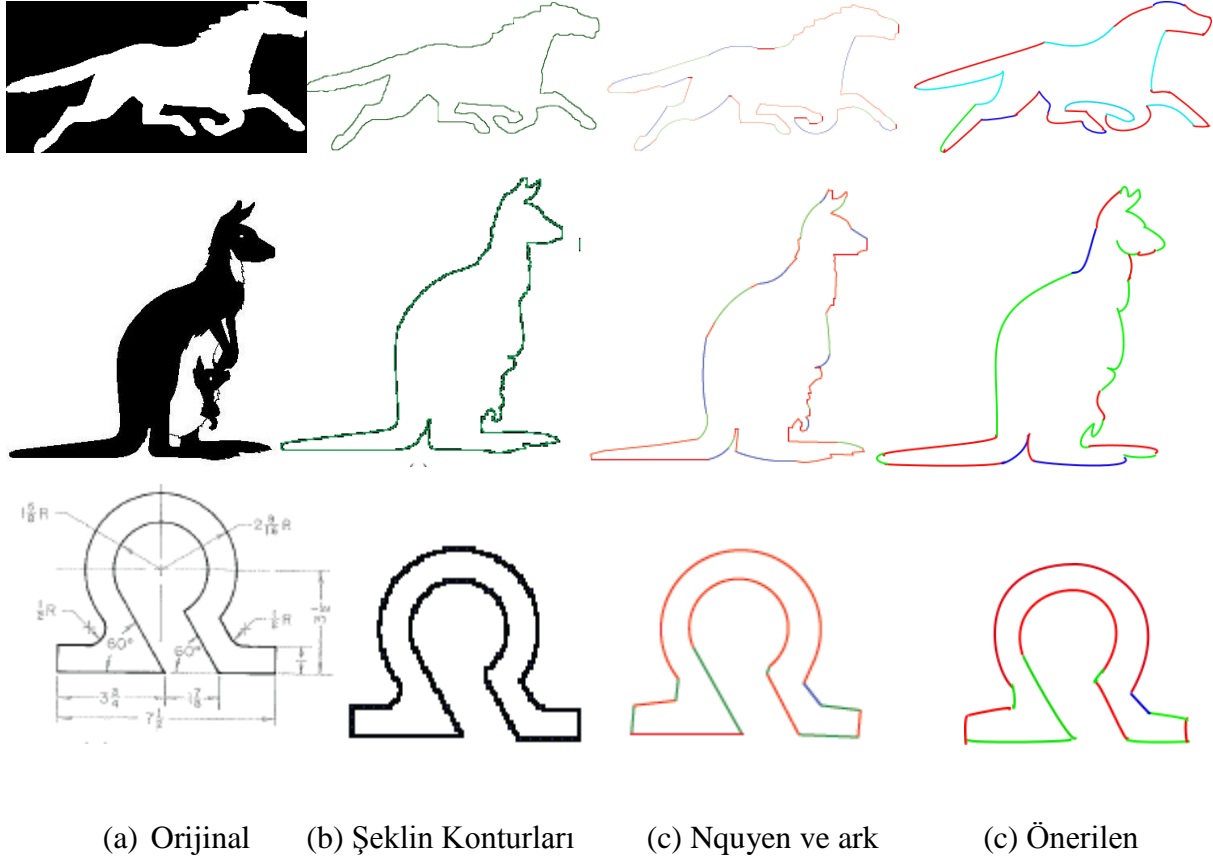
(A. Carmona-Poyato ve ark. 2005)' de  $x=1,2,3$  olmak üzere  $F_x = \frac{ISE}{CR^x}$  olacak şekilde yeni ölçü birimleri tanımlamıştır. Bu ölçülerle elde edilen sonuçlar Tablo 2'de gösterilmektedir. Tablo 3.2'de Carmona'nın önerdiği ölçü birimleri kullanılarak bizim önerdiğimiz metodla karşılaştırılmıştır. İlk sütunda Carmona'nın sonuçları ikinci sütunda ise önerdiğimiz metodla elde edilen sonuçlar gösterilmiştir. Tabloya bakıldığında önerdiğimiz metodla elde edilen sonuçların önceki değerlere göre daha küçük değerler olduğu görülür.

Şekil	N	Primitiflerin Sayısı	F1	F2	F3
Tin openers	580	33   28	10.86   10.77	0.62   0.52	0.04   0.025
Plane 1	1015	39   28	23.25   21.74	0.89   0.77	0.03   0.027
Plane 2	787	31   22	18.30   17.82	0.72   0.50	0.03   0.014
Plane 3	1073	39   39	20.05   18.74	0.73   0.68	0.03   0.025
Plane 4	1126	53   41	28.95   19.84	1.32   0.72	0.05   0.026

**Tablo 3.2.** Carmona ve ark. (2005) ile karşılaştırılan sonuçlar (2. sütundaki rakamlar önerilen yöntem sonuçları)

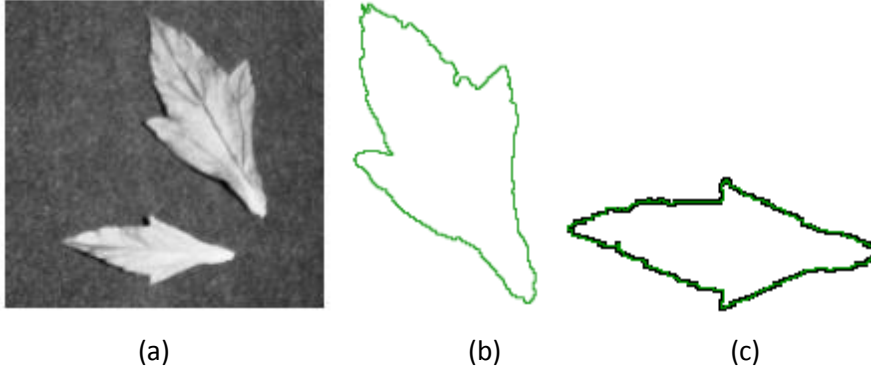
Nguyen ve Rennesson (2011)'de eldeki görüntüden ilk olarak baskın nokta tespiti yapmışlardır ve ard arda gelen baskın noktaların arasına konik eğri veya doğru uydurmuşlardır. Böylece verilen bir şekli konik eğrilerle ve doğrularla bölütlemişlerdir. Elde edilen sonuçlar Şekil 3.15'de resmedilmektedir. Şekil 3.15'in (c) şikkında Nguyen ve

Renesson (2011)'de elde ettiği bölütleme ve (d) şıkında ise önerdiğimiz metodla elde edilen sonuçlar gösterilmektedir.

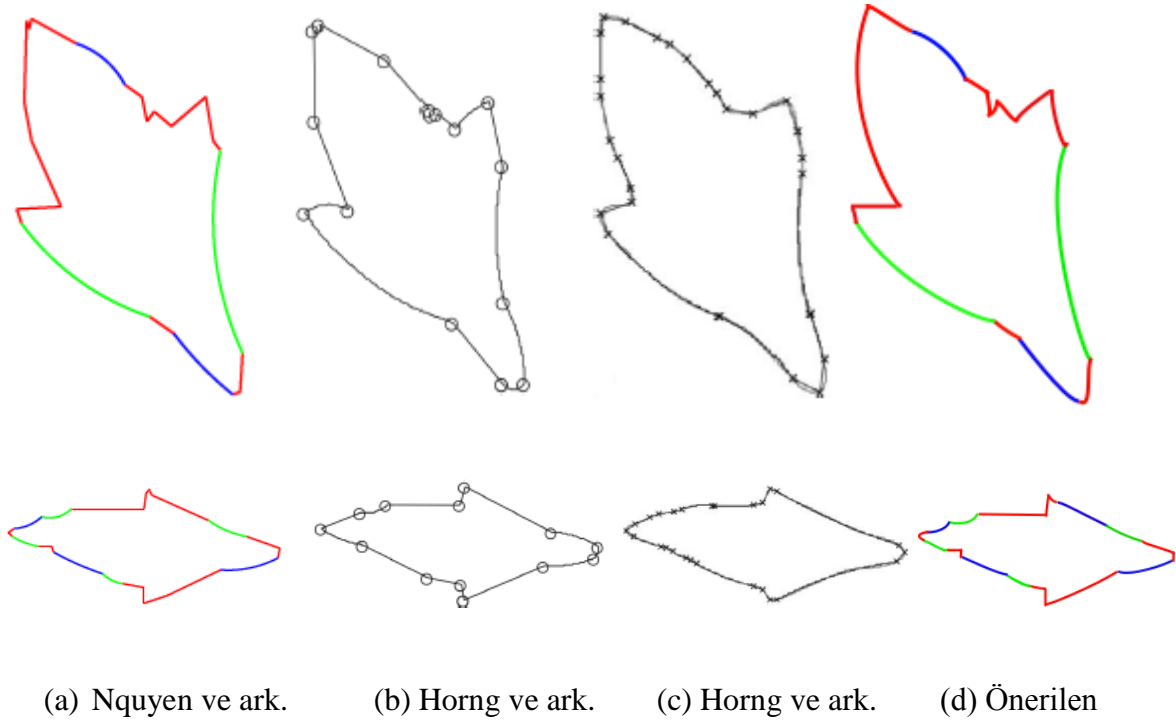


**Şekil 3.15.** Nquyen'in (2005) metodu ile önerilen metodun karşılaştırılması

Önceki çalışmalarda kullanılan yaprak 1 ve yaprak 2 eğrilerinin orjinal imgeleri Şekil 3.16'da resmedilmektedir. Şekil 3.17'de, (a) sütununda Nguyen'in (2011)' de elde ettiği bölütlenmiş imgeler, (b) sütununda Horng ve ark.nın (2003) de, (c) sütununda Horng'un diğer (2002) de elde ettiği sonuçlar ve (d) sütununda da önerdiğimiz metod ile elde edilen bölütlenme resmedilmektedir. Aynı zamanda yaprak 1. ve yaprak 2 eğrileri için ölçü kriterleri ile elde edilen sonuçları Tablo 3.'de gösterilmektedir. Önerdiğimiz metodla orijinal imgeden elde edilen ölçüm değerleri Nguyen (2011) ve Horng (2002, 2003) ile karşılaştırılmıştır. Tablo 3.3'deki FOM değerlerine bakıldığında önerdiğimiz metod ile elde ettiğimiz değerlerin daha yüksek olduğu görülmektedir.



Şekil 3.16. (a) orijinal imge, (b) eğri 1, (c) eğri 2.



Şekil 3.17. Şekil 3.16 da verilen şeklin anlamlı noktaları ve bölütlenmesi


Çoklu-primitif (multiprimitive) bölütlemenin uygulandığı örnek bazı görüntüler aşağıda Şekil 3.18 ve Şekil 3.19 de gösterilmektedir. Wu Chih Hu'nun (2005)'de önerdiği metolla elde edilen bölütleme Şekil 3.18(a)'da resmedilmektedir. Bizim önerdiğimiz metolla elde edilen sonuçlar Şekil 3.18(b)'dedir. Sonuçlar karşılaştırıldığında ise (Wu Chih Hu 2005) de elde edilen sonuçlarla aynı sonuçlar elde edilmiş ve büküm noktası kavramı eklenmiştir.



Şekil 3.19' da ise (Shape database) şekil veritabanındaki bazı görüntülere önerdiğimiz eğri ve doğru uydurma metodu uygulanarak bölütleme yapılmıştır.

Eğri	Nokta Sayısı	Metod	Primitiflerin Sayısı	ISE	CR	FOM
Yaprak1 Şekli	605	Önerilen	30	276.949	20.17	0.073
		Nguyen ve ark.	22	449.828	27.50	0.060
		Hornng ve ark.	15	489.700	40.33	0.082
		Hornng	29	329.9	20.86	0.063
Yaprak 2 Şekil	413	Önerilen	15	145.599	27.53	0.189
		Nguyen ve ark.	22	139.746	18.77	0.129
		Hornng ve ark.	13	175.4	31.77	0.181
		Hornng	26	107.7	15.89	0.148

**Tablo 3.3.** Diğer metodlar ile önerilen metodu ölçü kriterlerini kullanarak karşılaştırma



**Şekil 3.18.** (a) (Hu ve ark. 1999) nin sonuçları (b) Önerilen yöntem sonuçları



## BÖLÜM 4

### 4. BÖLGEYE DAYALI ŞEKİL BETİMLEYİCİLERİ

#### 4.1. Noktalar Arası Uzamsal İlişkiler

Uzamsal ilişkiler özneliği şeklin bölge veya konturunun piksel veya eğriler ile ilişkisidir. Dolayısıyla, bu yöntemlerde şekil, şeklin içinde mevcut öğelerin aralarındaki uzamsal ilişkiler kullanılarak betimlenir. Betimleme işlemi, uzunluk, eğrisellik, nispi yönelim, mevki, alan, mesafe veya açı gibi birimlerle ölçülür.

Bu yöntemlerden Değişken Grid Çözünürlüğü (K. Chakrabarti ve ark. 2000), Kapsayan Kutu (C. Bauckhage ve J. K. Tsotsos, 2005), Konveks Parçalar (E. Davies, 1997), (R. Gonzalez ve R. Woods, 2002) ve (M. Sonka ve ark. 1993), Temel Parçalara Ayırma (S. Berretti ve ark. 2000) gibi yöntemlerde, görüntüdeki nesne, başka geometrik şekiller kullanılarak ifade edilir. Bu sınıfa ayrılacak diğer yöntemler arasında, Zincir Kodu (Y. K. Liu ve ark. 2007), (M.-K. Hu, 1962), Kerteriz Açısı İstatistiği (N. Arica ve F. Vural 2003), Kare veya polar şekil matrisleri (J. Flusser, 1989), (A. Taza ve C. Suen, 1999) ve (G. Lu and A. Sajjanhar, 1999), Şekil Bağlamı (S. Belongie ve ark. 2002), Kordon Dağılımı (S. P. Smith ve A. K. Jain, 1982), Shock Grafları K. (Siddiqi ve B. Kimia, 1996), SIFT (Ölçeklemeyle Değişmeyen Öznitelik Çıkarım Metodu) (D.G. Lowe, 1999), örnek olarak sayılabilir.

Bu bölümde, günümüzde bölgeye dayalı şekil betimleyicilerinden yaygın olarak kullanılan şekil bağlamı ve ölçeklemeyle değişmeyen öznitelik çıkarım metodundan kısaca bahsedilecektir.


### 4.1.1 Şekil Bağlamı

Nesne tanıma alanında şekil bağlamı yöntemi güçlü ve kullanışlı bir yöntemdir (R. J. Prokop ve A. P. Reeves, 1992). Model ve imge arasındaki aynı öznitelikleri bulmak için şekil bağlamı kullanılır.

Şekil bağlamı analizi, şeklin kenar elemanlarından N tane örnek alınmasıyla başlanır. Bu noktalar iç veya dış konturlar üzerinden alınır. Şeklin herhangi bir noktasından diğer tüm örnek noktalara vektörler elde edilir. Bu vektörler referans noktasından şeklin tüm görünümü ile ilgili bilgiler içermektedir. Her nokta üzerine polar bir grid oturtulur ve griddeki her bölme düşen nokta sayısı bulunur. Böylece referans alınan nokta için diğer nokta mevkilerinin polar gride göre histogramı alınmış olur. Bu betimleyici diğer tüm noktaların polar koordinatlardaki histogramıdır:

$$h_i(k) = \{Q \neq P_i : (Q - P_i) \in \text{bin}(k)\}$$

Şekil Bağlamı yöntemine bir örnek Şekil 4.1'de resmedilmektedir. Şekil 4.1(c) de verilen örnekte log-polar histogram elde etmek için, polar yönelim için 5 kutu ve açısal yönelim için 12 polar kutudan oluşan diyagram çizilmiştir.  $P_i$  noktasına bağlı histogram elde edildiğinden, histogram kutu diyagramının merkez noktası olarak  $P_i$  noktası seçilir ve her bir histogram kutusuna düşen noktalar sayılarak histogram oluşturulur. Şekil 4.1'in (a), (b) kısımlarında sırasıyla daire, üçgen ve baklava şeklinde bazı örnek sınır noktaları işaretlenmiştir ve (d),(e) ve (f) kısımlarında ise bu sınır noktalarından elde edilen şekil bağlamı (log-polar histogram) bilgisi vardır. Daire ve baklava dilimi ile işaretlenmiş noktaların alınmış olduğu bölgeler birbirine benzediği için bu noktalardan elde edilen şekil bağlamı bilgileri de benzerdir. Tersine, üçgen ile işaretlenmiş nokta diğer noktalara göre nesnenin farklı bir bölgesinden alındığı için şekil bağlamı bilgisi diğerlerinden farklıdır. Açıkça görülür ki bu betimleyici zengin bir tanımlamaya sahiptir ve şekilden alınan nokta sayısı arttıkça daha iyi bir şekilde şekil yeniden elde edilebilir.



**Şekil 4.1** : Şekil Bağlamı yöntemi örneği. (a) ve (b)'de iki şeklin örneklenmiş sınır noktaları, (c) betimlemede kullanılan log-polar grid, (d) (e) ve (f) sırasıyla daire, baklava ve üçgen olarak işaretlenmiş noktalardan elde edilen şekil bağlamı bilgisi. (Siyah renk=büyük değer). ((S. Belongie, J. Malik ve J. Puzicha, 2002)'den alınmıştır).

#### 4.1.2 Ölçeklemeye Göre Değişmeyen Öznitelik Çıkarımı (SIFT)

SIFT betimleyicisinin orijinal formülü bir imge üzerindeki öznitelikleri elde etmek için uygulanan 4 aşamadan oluşmaktadır: Ölçekleme uzayında (Scale space) lokal maksimal noktaların bulunması, ilgi noktasının hassas olarak mevkilendirilmesi, baskın yönelimin bulunması ve lokal imge betimleyicilerinin oluşturulmasıdır. Bu aşamalardan ilk ikisi ilgi noktasının bulunmasını, uzaysal/ölçekleme düzlemlerinde hassas mevkilendirilmesini, düşük karşıtlık veya yüksek sınır tepkisi veren, dolayısı ile kararlı olmayan ilgi noktalarının elenmesini kapsar. Bu özellikler SIFT algoritmasının ilgi noktası bulucu işlevini tasvir etmektedir. İlgi noktasının tespit edilmesinin ardından, bir sonraki işlem ilgi noktasına ait baskın yönelim açısının tespit edilmesidir. Bu işlem için daha önceden tespit edilen ilgi noktası ölçeğine en yakın ölçekteki Gaussian Fonksiyonu tarafından normalize edilmiş ölçekleme uzayındaki mevcut imge kullanılır. İlgi sahası, merkezi ilgi noktası olan ve uzunluğu piksel sayısı olarak ilgi noktasının ölçeğinin 1.5 katı büyüklüğünde kare bir alandır.

İlgi sahasındaki her bir pikselin yönelim histogramına katkısı, bahse konu pikselin yönelim büyüklüğü ile standart sapması 1.5 ilgi ölçeği olan Gaussian pencere fonksiyonundaki katsayı değerlerinin çarpımına eşittir. İlgi noktası ölçeğine göre normalize edilmiş imgedeki yönelim açısı ve büyüklüğünün hesabı aşağıdaki şekilde hesaplanır:

$$M(x, y) = \sqrt{I_x(x, y)^2 + I_y(x, y)^2}$$

$$\theta(x, y) = \arctan \left( \frac{I_y(x, y)}{I_x(x, y)} \right) \quad (4.1)$$

Formüllerde geçen  $I_x(x, y)$  ve  $I_y(x, y)$  terimleri normalize edilmiş  $I(x, y)$  imgesi üzerinde x ve y eksenleri boyunca icra edilen basit türev işlemlerine karşılık gelir. Türev işlemleri ise  $(x, y)$  piksel noktasının x veya y eksenini boyunca dörtlü yan komşulukları ile arasında değer farkları alınarak şu şekilde hesaplanır:

$$I_x(x, y) = I(x + 1, y) - I(x - 1, y)$$

$$I_y(x, y) = I(x, y + 1) - I(x, y - 1) \quad (4.2)$$

Yönelim histogramı 36 göze nicelenmiştir (her bir göz 10 dereceye karşılık gelir) ve histogramdaki tepe noktası ise ele alınan ilgi noktasının baskın yönelim açısını oluşturmaktadır. Yukarıda bahsedildiği üzere tüm işlemler esnasında ölçeklendirme uzayındaki ilgi noktasının ölçeğine göre normalize edilmiş imge kullanıldığından ve betimleyici hesabında da baskın yöneline göreli işlemler yapıldığından; betimleyici ölçek (scale) ve iki boyutlu eksen dönüşüne (rotation) göre değişmezlik özelliklerine sahiptir. Betimleyici hesabı yine daha önceden baskın yönelim bulunmasında kullanılan ölçek normalize edilmiş imge kullanılarak yapılır. Bu kapsamda ilgi noktası merkez olmak üzere, imge üzerinde birim uzunluğu imge ölçeği kadar piksel uzunluğunda olan bir 4x4 (hem x hem de y eksenini boyunca 4 birimlik gridleme) kartezyen gridleme meydana getirilir. Grid sistemi ilgi noktasının baskın yönelimi boyunca döndürülür. Bu döndürme işleminin iki sonucu vardır. Birincisi, önceki gridlemede ilgi sahası içerisine düşen piksel noktalarının dönme nedeniyle değişmesidir ki lineer enterpolasyon yöntemiyle artık yeni noktalar hesaplamaya dahil edilir. İkinci etkisi ise ilgi sahası içerisindeki piksel noktalarının yönelimlerinin ilgi noktası baskın yönelimine göreli değişimleridir. 4x4 grid düzlemi baskın yöneline göreli

döndürüldükten sonra gridlemedeki her bir hücre için ayrı ayrı yönelim histogramları elde edilir. Bu kapsamda, her bir grid hücresi (toplam 16 adet) içerisinde mevcut bütün piksellerin yönelim açıları 8 göz nicelenmiş bir histograma dağıtılır. Histograma oy verme işlemi esnasında baskın yönelim hesabındaki gibi yönelim büyüklüğü ile Gaussian pencere katsayısının çarpımı göz önünde bulundurulur. Neticede, her bir hücre için elde edilen 8 gözlü yönelim histogramları alt alta birleştirilerek  $4 \times 4 \times 8 = 128$  elementli SIFT imge betimleyicisi elde edilir:

$$SIFT = (h_{r(1.1)}, h_{r(1.2)}, h_{r(1.3)}, h_{r(1.4)}, \dots, h_{r(4.1)}, h_{r(4.2)}, h_{r(4.3)}, h_{r(4.4)}) \quad (4.3)$$

Son aşama olarak elde edilen imge betimleyicisi  $L2$  normuna göre normalize edilir. Bu sayede düzgün aydınlatma değişimlerinin betimleyicisi üzerindeki etkisi azaltılır. SIFT imge betimleyicisi çıkarımı Şekil 4.2'de sunulmuştur.

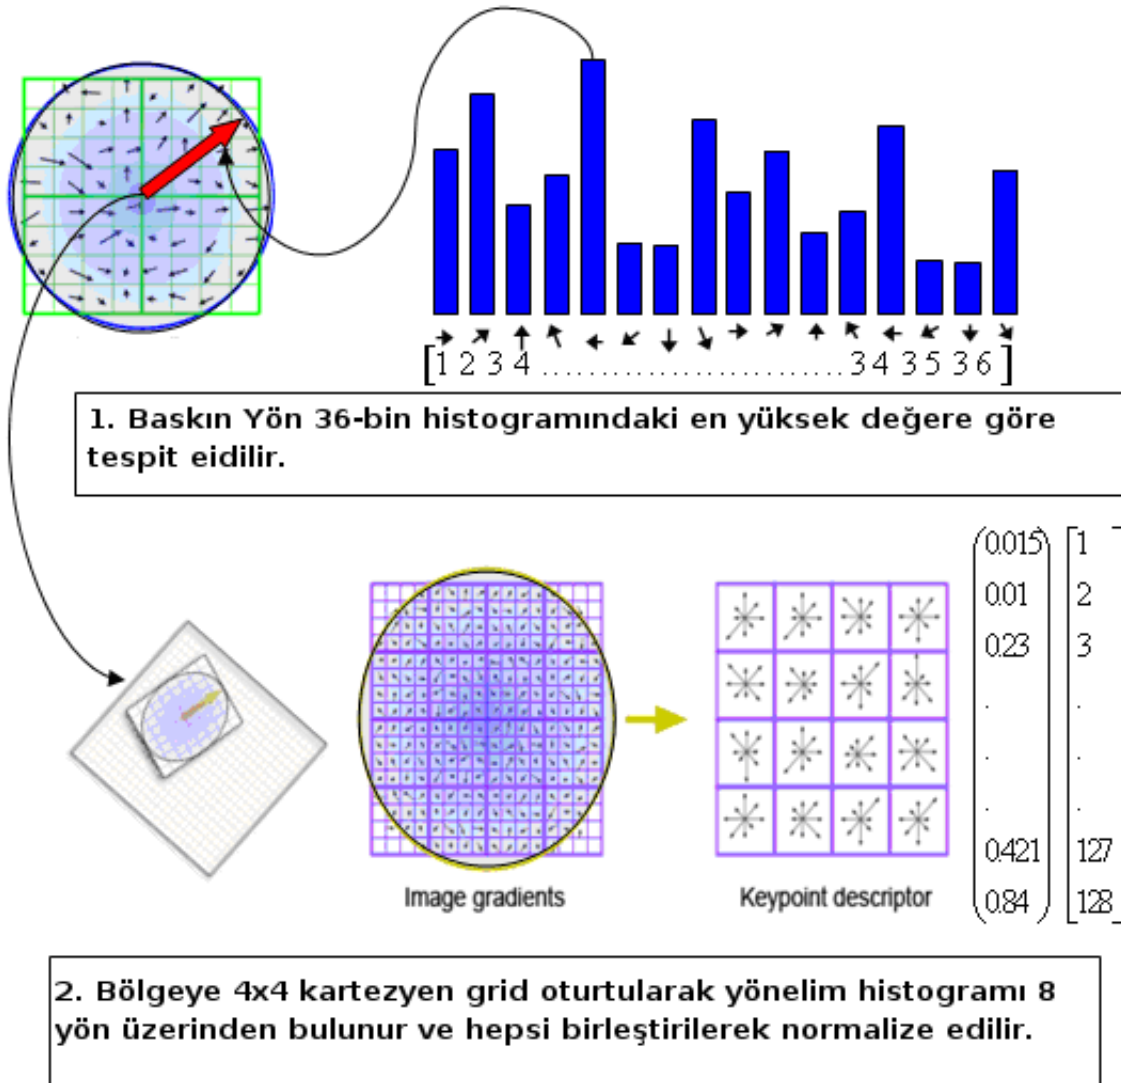
### 4.1.3. Önerilen Bölgeye Dayalı Betimleyici

#### 4.1.3.1 Temel Bileşen Analizi

Temel Bileşen Analizi (TBA), asal bileşen analizi veya Karhunen-Loeve dönüşümü olarak da adlandırılan, örüntü tanıma çalışmalarında geniş kullanım alanı bulunan bir altuzay indirgeme yöntemidir. Yüz tanıma uygulamalarının büyük bir çoğunluğu bu boyut indirgeme yöntemine dayanmaktadır. Bunun nedeni olarak karmaşık hesaplama algoritmaları gerektiren yeni tekniklere temel çözüm modeli oluşturması ve ayrıca vektör, matris, özdeğer, özvektor gibi matematiksel elemanların anlaşılmasındaki kolaylıkla gösterilebilir. Temel bileşenler analizi; değişkenlerden oluşan bir veri kümesinin varyans-kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri yardımıyla açıklayarak, boyut indirgemesi ve yorumlanmasını sağlayan çok değişkenli bir istatistik yöntemidir.

TBA vektör tabanlı bir yaklaşımdır. Bu yöntemde amaç, büyük boyutlu ve birbiriyle ilişkili vektörleri, küçük boyutlu birbiriyle ilişkisiz vektörler biçiminde ifade eden bir boyut indirgemesi gerçekleştirmektir. Görüntü tanıma uygulamalarında kullanımı, sayısal görüntü verisinin vektör biçiminde temsil edilmesiyle gerçekleşir. TBA, şekildeki en gerekli bilgilerin bir grup karakteristik öznelik üzerinden elde edilmesi ve daha sonra diğer şekillerin, bu

betimleyici adı verilen resimlerin birer doğrusal birlesimi olarak ifade edilmesi ilkesine dayanmaktadır. Şekiller üzerinde öznitelik vektörlerinin izdüşümünün alınmasıyla daha küçük boyutta betimleyici vektörleri elde edilir.



Şekil 4.2. SIFT ilgi bölgesi baskın yönelim hesabı ve betimleyicinin oluşturulması.

#### 4.1.3.2 Önerilen TBA betimleyicisi

İlk olarak görüntüden ilgi noktaları tespit edilir. Bu çalışmada DoG, anlamlı nokta veya Harris ile ilgi noktaları bulunmuştur. İlgi noktaları bulunduktan sonra ilgi noktalarının yarıçapına (ölçekleme parametresine) göre sağdan, soldan, yukarıdan ve aşağıdan ölçekleme parametresinin üç katı kadar genişleyecek bir karesel çerçeve çizilir. Bu karesel çerçeve, SIFT



algoritmasında olduğu gibi 4x4 hücelere ayrılır. Herbir hücrenin sütunları alt alta yazılarak çerçevenin sütun matrisi elde edilir.

$$X = [x^1 | x^2 | \dots | x^M] \quad (4.4)$$

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \cdot & x_1^M \\ x_2^1 & x_2^2 & \cdot & x_2^M \\ \cdot & \cdot & \cdot & \cdot \\ x_N^1 & x_N^2 & \cdot & x_N^M \end{bmatrix} \quad (4.5)$$

Bu sütun matrisinin ortalaması bulunarak sütun matrisinden çıkartılır.  $\check{X}$  ortalaması çıkarılmış veri matrisi elde edilir.

$$m = \frac{1}{M} \sum_{i=1}^M X^i = \begin{bmatrix} m_1 \\ m_2 \\ \cdot \\ m_N \end{bmatrix} \quad (4.6)$$

$$\check{x}^i = x^i - m, \quad \forall i \quad (4.7)$$

$$\check{X} = [\check{x}^1 | \check{x}^2 | \dots | \check{x}^M] \quad (N \times M) \quad (4.8)$$

$$\check{X} = \begin{bmatrix} x_1^1 - m_1 & x_1^2 - m_1 & \cdot & x_1^M - m_1 \\ x_2^1 - m_2 & x_2^2 - m_2 & \cdot & x_2^M - m_2 \\ \cdot & \cdot & \cdot & \cdot \\ x_N^1 - m_N & x_N^2 - m_n & \cdot & x_N^M - m_n \end{bmatrix} \quad (4.9)$$

Elde edilen bu  $\check{X}$  matrisinin kovaryans matrisi bulunur. Kovaryans matrisinde özdeğer ve özvektörleri bulunur.

$$C = \check{X}\check{X}^T = \frac{1}{M-1} \sum_{i=1}^M (x^i - m)(x^i - m)^T \quad (4.10)$$

$$\begin{bmatrix} (x_1^1 - m_1)^2 & (x_1^2 - m_1)(x_2^1 - m_2) & \cdot & (x_M^1 - m_1)(x_N^1 - m_N) \\ (x_2^1 - m_2)(x_2^1 - m_2) & (x_2^2 - m_2)^2 & \cdot & (x_M^2 - m_2)(x_N^2 - m_N) \\ \cdot & \cdot & \cdot & \cdot \\ (x_N^1 - m_N)(x_1^M - m_1) & (x_N^2 - m_n)(x_2^M - m_2) & \cdot & (x_N^M - m_n)^2 \end{bmatrix} \quad (4.11)$$

$C$ ,  $N \times N$  boyutlu bir matris,  $\lambda$  herhangi bir skaler ve  $v$  sıfırdan farklı bir sütun vektör olmak üzere,

$$Cv = \lambda v \quad (4.12)$$

Eşitliğini sağlayan  $\lambda$  sayısı  $C$ 'nin öz değeri ve  $v$  de  $\lambda$  ile ilişkili öz vektördür. Sıfır özdeğerlere karşılık gelen özvektörlere göre izdüşüm alınır.


$$G^T = \begin{bmatrix} g_1 \\ g_2 \\ \cdot \\ g_N \end{bmatrix} \quad (4.13)$$

(4.14)'deki gibi öz nitelik vektörü belirlenmek istenen vektörlerin  $G$  matrisi üzerinde izdüşümü alınır. Bu izdüşüm vektörü ortak vektör olarak adlandırılır, ve bu vektör, vektör gruplarının değişmeyen kısımlarını vermektedir.

$$y^i = G^T x^i \quad i = 1, 2, \dots, M \quad (4.14)$$


Ortalaması çıkarılmış veri matrisinden ortak vektör çıkarılır ve böylece tüm çerçeve boyunca satır farkları bulunmuş olur. Bu fark matrisi aslında  $x$  yönündeki değişim oranını verir. Dikey yöndeki değişim oranlarını bulabilmek için ise bu sefer ilgi noktası etrafındaki çerçeve matrisinin satır vektörleri ele alınarak aynı işlem gerçekleştirilir. Dolayısıyla Sift betimleyicisi fark matrisini türev ile bulurken, bu çalışmada fark matrisleri TBA ya dayalı bir yöntemle vektörel boyutlarda bulunmuştur. Ayrıca, satır ve sütunlardan elde edilmiş olan fark matrislerinin yönelim açılarına bağlı olarak 8 farklı kutucukta histogramları bulunur. Dolayısıyla  $(4 \times 4 \times 8)$  128 boyutlu TBA'ya dayalı betimleyiciler elde edilmiş olur. Elde edilen bu 128 boyutlu betimleyicinin çıkarılışı Şekil 4.4' de resmedilmektedir.

Verilen orijinal bir görüntüden TBA'ya dayalı yöntemle elde edilen dikey ve yatay değişim oranları Şekil 4.3' de resmedilmektedir. Şekil 4.3 (b) ve (c) de sırasıyla görüntünün TBA uygulanarak bulunmuş yatay ve dikey yöndeki değişim oranları verilmiştir. Şekil 4.3.(d) ve (e) de sırasıyla görüntüye gradyant uygulanarak bulunmuş x ve y yöndeki değişim oranları verilmiştir. (b),(c) deki görüntüler ile sırasıyla (d) ve (e) deki görüntüler karşılaştırıldığında TBA'ya dayalı yöntemin gradyanta dayalı yöntem ile benzer sonuçları verdiği görülür.



**Şekil 4.3.** a) Orijinal görüntü b) TBA uygulanarak bulunmuş yatay yöndeki değişim oranı c) TBA uygulanarak bulunmuş dikey yöndeki değişim oranı d) Gradyant ile x yöndeki değişim oranı e) Gradyant ile y yöndeki değişim oranı.

Şekil 4.4' de TBA'ya dayalı betimleyiciyi açıklayabilmek için verilen bir görüntünün belli bir bölgesi alınmıştır. Bu bölgedeki hücreleri açık bir şekilde göstermek için bu bölge 4x4 yerine 2x2'ye bölünmüştür. Elde edilen her bir hücreden ilk olarak TBA'ya dayalı değişim oranları bulunmuştur ve bu oranlar yönelim açlarına göre ağırlıklandırılarak histogramları elde edilmiştir. Şekil 4.4' den görüldüğü üzere 8 farklı yönelim açısı dikkate alınmıştır, dolayısıyla histogram 8 farklı kutucuktaki açılarının ağırlıklandırılmasıyla elde edilmektedir. Son olarak her bir hücreden elde edilen 8 boyutlu histogramın birleştirilmesiyle betimleyici vektörü elde edilmiş olur.




**Şekil 4.4.** TBA'ya dayalı betimleyicinin hesaplanması. İlk olarak görüntünün verilen bölgesi 2x2 hücreye bölünmüştür. Her bir hücreden TBA'ya dayalı değişim oranları ve bunlar yönelim açılarına göre ağırlıklandırılarak histogramları elde edilir. Son olarak her bir hücreden elde edilen histogramların birleştirilmesiyle betimleyici elde edilmiş olur.

Böylece eğitim aşaması tamamlanmıştır. Bir sonraki basamak, eğitimde kullanılmayan bir test görüntüsü geldiğinde, eğitim aşamasındaki öznitelikler kullanılarak test vektörüne sınıf ataması yapmayı amaçlayan bir sınıflandırma gerçekleştirmektir.

$G$  izdüşüm matrisi olarak tanımlanan ve öznitelikler tarafından gerilen betimleyicilerin k-means ile sınıflandırılması sonucu öznitelikler kümesi (kelimeler çantası) belirlenir. Eğitim aşamasında belirlenen özniteliklerle yeni test şeklinin betimleyicisi ile karşılaştırılır. Karşılaştırmalar sonucunda görsel sözlüğün boyutu kadar boyutlu bir histogram elde edilir. Bu histogramdaki verileri sınıflandırmak için TBA temeline uyumlu ve yüksek performans veren en yaygın sınıflandırıcı olarak bu çalışmada destek vektör makineleri kullanılmıştır. Çapraz doğrulama metodu uygulanarak sınıflandırma oranı elde edilir.

Kelimeler çantası modeli kullanılarak görsel nesne sınıflandırmaya dair örnek Şekil 4.5'te resmedilmiştir. Şekil 4.5(a)' da eğitim resimleri ve bu resimlerden bulunan ilgi

noktaları üzerine çizilmiş karesel çerçeveler resmedilmiştir. Herbir karesel çerçeveden elde edilmiş betimleyiciler  $w_n$ 'ler ile gösterilen öbeklere eklenmektedir. Şekil 4.5(b)'de  $w_n$  öbeklerinin k-means sınıflandırıcısı ile sınıflandırılması sonucu görsel sözlük elde edilir. Veri tabanındaki test resimlerinin betimleyicileri görsel sözlükteki kelimelere göre ağırlıklandırılması sonucu görsel sözlükteki kelimelerin boyutunda bir histogram elde edilir. Bu histogram Şekil 4.5(c)'de gösterilmektedir. Şekil 4.5(d)'de ise bu histogramın sınıflandırılması sonucunda test resimlerinin hangi sınıfa ait olduğuna dair etiketlenmesi resmedilmiştir.



Şekil 4.5. Kelimeler çantası modeli kullanılarak görsel nesne sınıflandırması

## 4.2. Sınıflandırma

### 4.2.1 Destek vektör makineleri

Son yıllarda en başarılı sınıflandırma yaklaşımlarından biri olan Destek Vektör Makinelerinde (DVM) amaç, genelleştirme başarımını arttırmak için, iki kümeyi ayıracak olan hiperdüzlemler arasındaki marjinin en büyüklenmesidir (C. J. C. Burges 1998). Destek vektör makineleri kullanılarak çeşitli alanlardaki sınıflandırma problemleri için oldukça başarılı uygulamalar yapılmaktadır (P. Zhong ve M. Fukushima 2006).

İzleyen alt bölümlerde doğrusal olarak ayrılabilir olan ve ayrılamayan durumlar için DVM'leri ile ilgili bilgi verilmektedir (E. Alpaydin 2005).

#### 4.2.1.1 Doğrusal ayrılabilir durum

En iyi ayırıcı hiperdüzlem, genelleştirme başarımı eniyi olan hiperdüzlemdir. İzleyen formülasyonlarda sadelik sağlamak için sınıf etiketlerinde 0 yerine 1, +1 yerine ise -1 kullanılmıştır.

Eğer  $x^t \in C_1$  ise  $r^t = +1$  ve  $x^t \in C_2$  ise  $r^t = -1$  olduğu durumda,  $N$  tane örnek  $X = \{x^t, r^t\}, t = 1, \dots, N$  ile gösterilsin. DVM'de iki kümeyi ayıracak hiperdüzlemin parametreleri olan  $w$  ve  $w_0$  değişkenlerinin değerleri izleyen şekilde araştırılır.

$$\begin{aligned} r^t = +1 \text{ için } wx^t + w_0 &\geq +1 \\ r^t = -1 \text{ için } wx^t + w_0 &\leq -1 \end{aligned} \quad (4.15)$$

Yukarıda verilen bu eşitsizlikler, denklem (4.16) biçiminde yeniden yazılabilir.

$$r^t(wx^t + w_0) \geq +1 \quad (4.16)$$

Sınıflandırma problemlerinde örnekleri hiperdüzlemin doğru tarafında sınıflandırmanın yanında, daha iyi genelleştirme için örneklerin hiperdüzlemden belli bir mesafe uzakta olması da istenir. En iyi genelleştirme için en büyüklenmeye çalışılan bu uzaklık, marjin olarak adlandırılmaktadır. En iyi ayırıcı hiperdüzlem, marjini en büyükleen hiperdüzlemdir.

$t$ . örnek  $x^t$ 'nin hiperdüzleme olan uzaklığı;

$$\frac{|wx^t + w_0|}{\|w\|}$$

$r^t \in \{-1, +1\}$  olduğunda şu şekilde yazılabilir:

$$\frac{r^t(wx^t + w_0)}{\|w\|}$$

Bu değer için tüm örnekler için  $\rho$  değerinden büyük olması istenir.

$$\forall t, \text{ için } \frac{r^t(wx^t+w_0)}{\|w\|} \geq \rho \quad (4.17)$$

En büyüklenmek istenen  $\rho$  değeri için  $w$  ölçeklendiğinde sonsuz çözüm vardır. Tek bir çözüm için  $\rho\|w\|$  sabitlenir ve böylece  $\rho$  değerini en büyükleme için  $w$  değeri enküçükleme.

$$\forall t, \text{ için } r^t(wx^t + w_0) \leq +1 \quad \text{kısıtları altında } \text{enk} \frac{1}{2} \|w\|^2 \quad (4.18)$$

Denklem (4.18),  $a^t$  Lagrange çarpanları kullanılarak kısıtsız hale getirilir.

$$\begin{aligned} L_p &= \frac{1}{2} \|w\|^2 - \sum_{t=1}^N a^t [r^t(wx^t + w_0) - 1] \\ &= \frac{1}{2} \|w\|^2 - \sum_{t=1}^N a^t r^t(wx^t + w_0) + \sum_{t=1}^N a^t \end{aligned} \quad (4.19)$$

Denklem (4.19)  $w, w_0$  değişkenlerine göre enküçüklemeli ve  $a^t \geq 0$  değişkenine göre en büyüklenmelidir. Bu durumda, eyer noktası çözümü verir.

Asıl terim dışbükey ve doğrusal kısıtlar da dışbükey olduğundan, bu problem bir dışbükey karesel eniyileme problemidir. Bu nedenle, Karush-Khun Tucker koşulları kullanılarak ikili problem eşdeğer şekilde çözülebilir. İkili problem,  $a^t \geq 0$  ve  $L_p$  ifadesinin  $w, w_0$  değişkenlerine göre türevlerinin sıfır olması kısıtları altında  $a^t$  değişkenine göre enb  $L_p$  biçiminde tanımlanır.

$$\frac{dL_p}{dw} = 0 \rightarrow w = \sum_t a^t r^t x^t \quad (4.20)$$

$$\frac{dL_p}{dw_0} = 0 \rightarrow \sum_t a^t r^t = 0 \quad (4.21)$$

(4.20) ve (4.21) ifadeleri Denklem 4.19' da yerine konduğunda,

$$\forall t, \text{ için } a^t \geq 0 \quad \text{ve} \quad \sum_t a^t r^t = 0$$

kısıtları altında sadece  $a^t$  değişkenine göre en büyüklenmek istenilen ikil problem aşağıdaki gibi elde edilir.

$$\begin{aligned}
L_p &= \frac{1}{2}(ww) - w \sum_t a^t r^t x^t - w_0 \sum_t a^t r^t + \sum_{t=1}^N a^t \\
&= -\frac{1}{2}(ww) + \sum_t a^t \\
&= -\frac{1}{2} \sum_t \sum_s a^t a^s r^t r^s (x^t) x^s + \sum_t a^t
\end{aligned} \tag{4.22}$$

Bu problem karesel eniyileme yöntemleri kullanılarak çözülebilir. Problem,  $a^t$  için çözüldüğünde, bir çoğu için  $a^t = 0$  olduğu, sadece küçük bir kısmı için de  $a^t > 0$  olduğu görülür. Destek vektörleri  $a^t > 0$  durumuna karşı gelen  $x^t$ ' ler kümesidir ve Denklem 4.20 ile gösterildiği gibi  $w$ , destek vektörleri olarak seçilen bu eğitim örneklerinin ağırlıklı toplamı olarak yazılabilir. Bu  $x^t$  değişkenleri, eşitliği sağlar ve marjin üzerinde bulunur. Buradan hareketle, herhangi bir destek vektöründen  $w_0$  değişkeninin değeri hesaplanabilir.

$$dw_0 = r^t - wx^t \tag{4.23}$$

Sayısal olarak bir denge sağlamak için, tüm destek vektörler için hesaplama yapılması ve elde edilen değerlerin ortalamasının alınması önerilir. Böylece bulunan bu ayırma, destek vektör makineleri olarak adlandırılır.

$r^t(wx^t + w_0) > 1$  olan çoğu  $a^t$ ' nin değeri sıfırdır. Bu  $x^t$ ' ler marjin içindedir ve hiperdüzleme etkileri yoktur. Ayırma temelli bir yöntem olduğundan, DVM'leri sadece sınıra yakın noktaları dikkate alır, içerdeki noktalarla ilgilenmez. Bu düşüncüyü kullanarak, DVM'nin eniyileme adımının karmaşıklığını azaltacak basit bir sınıflandırıcı kullanmak mümkündür.

Test aşamasında  $g(x) = wx + w_0$  fonksiyonu hesaplanır ve  $g(x)$ 'in işaretine göre, eğer  $g(x) > 0$  ise  $C_1$  diğer durumda  $C_2$ , seçimi yapılır.



#### 4.2.1.2 Doğrusal olarak ayrılamayan durum

Veriler doğrusal olarak ayrılamıyor ise daha önce sunulan DVM yaklaşımı geçerli olmaz. Böyle bir durumda eğer iki sınıf doğrusal ayrılabilir değil ise onları tam olarak ayıracak bir hiperdüzlem yoktur. Bu sebeple enküçük hatayı veren hiperdüzlem aranır. Marjinden sapmayı ifade eden bir  $\xi^t \geq 0$  aylak değişkeni tariflenir. İki sapma türü vardır. Bir örnek hiperdüzlemin yanlış tarafında yer alabilir ve yanlış sınıflandırılabilir veya örnek hiperdüzlemin doğru tarafında yer alır ancak aralık içinde kalabilir. Bu durumda hiperdüzlemden yeterince uzak değildir. Denklem (4.16) gevşetilerek izleyen Denklem (4.24) elde edilir.

$$r^t(wx^t + w_0) \geq +1 - \xi^t \quad (4.24)$$

Eğer  $\xi^t = 0$  ise  $x^t$  noktası için bir problem yoktur. Eğer  $0 < \xi^t < 1$  ise  $x^t$  doğru sınıflandırılır, ancak marjinin içinde kalır. Eğer  $\xi^t \geq 1$  ise  $x^t$  hatalı sınıflandırılmış bir noktadır. Hatalı sınıflandırılmış noktaların sayısı  $\{\xi^t > 1\}$  ve ayrılabilir olmayan noktaların sayısı  $\{\xi^t > 0\}$  olarak gösterilir. Hata  $\sum_t \xi^t$  olarak tanımlanır ve denklem (4.16)'ya ceza terimi olarak eklenir. Elde edilen denklem, Denklem (4.25) ile verilmektedir.

$$L_p = \frac{1}{2} \|w\|^2 - C \sum_t \xi^t - \sum_t a^t [r^t(wx^t + w_0) - 1 + \xi^t] - \sum_t \mu^t \xi^t \quad (4.25)$$

Burada  $\mu^t$  ler,  $\xi^t$ 'lerin pozitifliğini garanti eden yeni Lagrange parametreleri,  $C$  ise karmaşıklık (destek vektörlerinin sayısı) ile hatalı veriler (ayrılamayan nokta sayısı) arasındaki ödünleşmeyi sağlayan herhangi bir düzgünleştirme şeması olarak ceza faktörüdür. Cezalandırma işlemi sadece hatalı sınıflandırılmış noktalar için değil, aynı zamanda sınav aşamasında doğru sayılacak olmalarına rağmen, daha iyi genelleştirme elde etmek adına, marjinin içinde kalan noktalar için de yapılmaktadır.

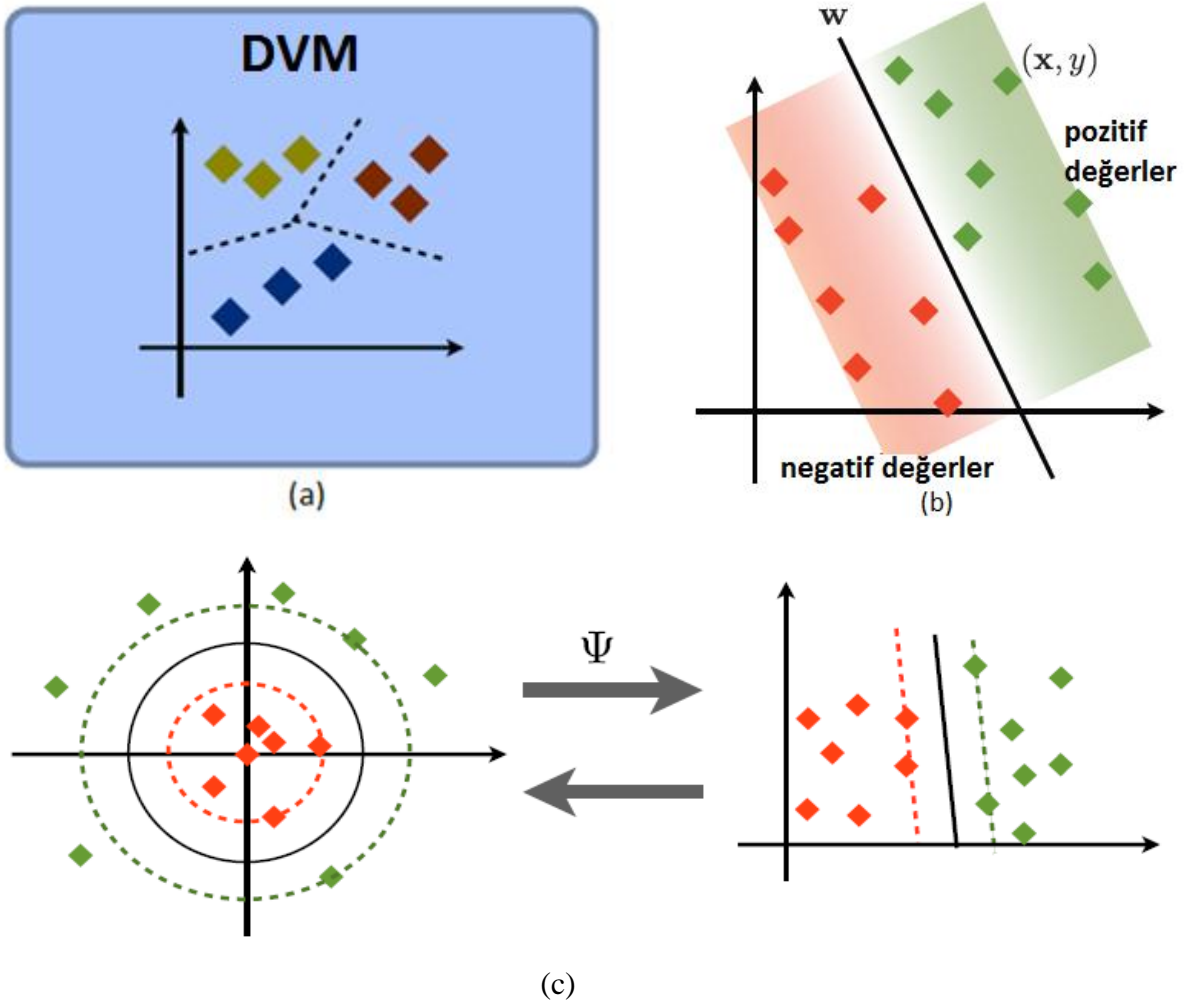
İkil problem Denklem ile izleyen şekilde verilmektedir.

$$\forall t, \text{ için } 0 \leq a^t \leq C \text{ ve } \sum_t a^t r^t = 0$$

kısıtları altında

$$enb L_d = \sum_a^t 1 - \frac{1}{2} \sum_t \sum_s a^t a^s r^t r^s (x^t) x^s \quad (4.26)$$

Ayrılabilir durumda olduğu gibi,  $a^t = 0$  olan noktalar destek vektörleri değildir. Kalan noktalar  $w$  vektörünü tanımlar ve  $w_0$  benzer şekilde elde edilir.



**Şekil 4.6.** DVM ile sınıflandırılmış durumlar (a) Çok sınıflı ayırıcı olarak DVM (b) Doğrusal olarak ayrılabilir durum (c) Doğrusal olarak ayrılamayan durum. ( $\psi$  çekirdek fonksiyonunu temsil eder.)

#### 4.2.1.3 Destek vektör makinelerinin Özellikleri

Destek vektör makineleri genel olarak izleyen özelliklere sahiptir:

- DVM, amaç fonksiyonunun bütünsel en küçüğünü bulabilen etkin algoritmalar içeren bir dışbükey eniyileme problemi olarak formüle edilebilir. Kural temelli sınıflandırıcılar ve yapay sinir ağları gibi diğer sınıflandırma yöntemleri, denence uzayını araştırmak için aç gözlü stratejiler uygularlar. Dolayısıyla, bu gibi yöntemler sadece yerel en iyi çözümleri bulmaya eğilimlidirler.
- DVM kapasite kontrolünü, karar sınırının marjini en büyükleyerek gerçekleştirir. Yine de kullanıcı, çekirdek (kernel) fonksiyonunun tipini belirlemek ve her bir aylak değişkeni azaltmak için  $C$  maliyet fonksiyonu gibi diğer parametreleri sağlamalıdır.
- DVM, verilerde tanımlanan her bir kesikli özellik için kukla değişkenler tanımlayarak kesikli verilere de uygulanabilir.

## 4.2.2 Çok-Sınıflı Problemlerde İkili Sınıflandırma Yöntemlerin Kullanılması

### 4.2.2.1 Bire karşı bir sınıflandırması

Çiftli sınıflandırma olarak da adlandırılan bu yaklaşımda olası her sınıf çiftleri için bir sınıflandırıcı oluşturulur. Sınıf sayısının  $d$  olduğu bir sınıflandırma probleminde,  $d(d - 1)/2$  ikili sınıflandırıcı ortaya çıkar. Sınıflandırıcı sayısı sınıf sayısına bağlı olarak artacağından, sınıf sayısı arttıkça problemlerin bu yaklaşımla ele alınması daha zor hale gelir. Örneğin, dört sınıflı bir problem için altı tane ikili sınıflandırıcı ortaya çıkarken, sınıf sayısı 10 olduğunda ikili sınıflandırıcıların sayısı 45 olacaktır. Dolayısıyla hem eğitim hem de sınav için daha fazla çaba harcamak gerekecektir.  $1e1$  yaklaşımının her bir sınıflandırıcısında sadece iki sınıfa ait örnekler kullanıldığından, sınıflandırıcıyı oluşturmak için ele alınan problemin boyutu  $1eh$  yaklaşımına göre daha küçük olacaktır. Bu durumda daha az üst üste gelen sınıf olacağından ele alınan problemler genellikle daha kolay olmaktadır (B. Schölkopf ve A. J. Smola, 2002). Örneğin, her biri 10 örnekten oluşan 10 sınıflı bir problem düşünelim. Bu problemde oluşturulacak 45 sınıflandırıcının her biri sadece 20 örnek ile oluşturulacaktır.

$1e1$  yaklaşımda ikili sınıflandırıcıların tümü elde edildikten sonra sınav aşamasına geçilir. Herhangi bir sınav noktasının hangi sınıfa ait olduğunu belirlemek üzere farklı yaklaşımlar önerilmiştir. Bu amaçla, genellikle Friedman (J. H. Friedman, 1996) tarafından

önerilen "oylama" ya da diğer bir ismi ile "en çok kazanan" stratejisi kullanılmaktadır (J. C. Platt, 2000), (C.-W. Hsu ve C.-J. Lin, 2002) ve (G. Ou ve ark. 2004).

Yeni bir sınam noktasının oylama yöntemi ile hangi sınıfa ait olacağı belirlenirken, bu nokta tüm sınıflandırıcılarda sınanır. Test noktası, ilgili sınıflandırıcı tarafından hangi sınıfa atandı ise o sınıfın oyu bir artar. Tüm sınıflandırıcılar ile oylama yapıldıktan sonra, sınam noktası en çok oyu alan sınıfa atanır. Bu oylamada en fazla oyu alan birden çok sınıf olması durumunda, atamanın hangi sınıfa yapılacağını belirlemek için farklı öneriler ortaya atılmıştır. Ou ve ark. (2004), bu eşitliğin bozulabilmesi için önsel olasılıkların veya oylar için belirli ağırlıklandırmaların kullanılabileceğini belirtmiştir. Hsu ve Lin, (2002) ise eşit oy alan sınıflardan en küçük sınıf numarasına sahip olana atama yapmıştır. Benzer durumda (B. Schölkopf ve A. J. Smola 2002), ise en yakın sınıfa atama kuralını uygulamıştır.

### 4.2.3 Sonuç Karşılaştırma Yöntemleri

#### 4.2.3.1 *k*-kez Çarpaz Doğrulama

Rassal alt örnelemeye alternatif bir yaklaşım olan çarpaz doğrulamada, her bir kayıt eşit sayıda eğitim kümesinde ve bir defa da sınam kümesinde yer alır. Bu yöntem için şöyle bir örnek ele alalım: Veriler eşit büyüklükte iki alt kümeye ayrılır. Önce bir alt küme eğitim için, diğer alt küme de sınam için seçilir. Ardından, iki kümenin rolü değiştirilir. Bu yaklaşım, iki kere çarpaz doğrulama olarak adlandırılır (P.-N. Tan 2006). Toplam hata, her bir aşamanın hataları toplanarak elde edilir. Bu örnekte her bir kayıt sadece bir defa eğitim ve sadece bir defa sınam için kullanılmıştır. *k*-kere çarpaz doğrulama yöntemi iki kere çarpaz doğrulama yaklaşımını, veri grubunu eşit sayıda örnek içeren *k* parçaya bölerek genelleştirmiştir. Her sınamda *k*-1 parça eğitim kümesini oluştururken kalan parça sınam amaçlı kullanılır. Bu süreç *k* defa tekrarlanır ve böylece her bir bölüm, sınam için kullanılmış olur. Toplam hata yine, tüm *k* aşamadaki hatalarının toplanmasıyla elde edilir. Başarı oranı, toplam doğru sınıflandırılmış nokta sayısının veri kümesindeki örnek sayısına bölünmesi ile bulunur. Genellikle *k* için 5 değeri kullanılır.

### 4.3 Deneysel Sonuçlar

TBA'ya dayalı önerdiğimiz betimleyici yaygın olarak kullanılan görsel nesne sınıflandırma, veri setlerinden Caltech-4 ve Coil-100 veri tabanlarında test edilmiştir. TBA betimleyicisine bağlı olarak Kelimeler Çantası Modeli (BoW) oluşturulmuş ve yaygın olarak bilinen SIFT, LBP, LTP ve Surf betimleyicileri ile karşılaştırmalar yapılmıştır. Sift betimleyicisinde olduğu gibi karesel çerçeveye 4x4 hücreye bölünmüş,  $[0 - 2\pi]$  açı aralığı ise 8 parçaya bölünmüştür. Buradan 128 boyutlu betimleyici elde edilmiştir. Sınıflandırıcı olarak ise doğrusal olmayan DVM kullanılmış ve çoklu sınıf sınıflandırıcısı olarak DVM ye bire-karşı-bir prosedürü uygulanmıştır. Doğrusal olmayan DVM'ye çekirdek fonksiyonu olarak Gaussian çekirdek fonksiyonu  $k(x, y) = \exp(-\frac{\|x-y\|^2}{\sigma})$  kullanılmıştır.




Şekil 4.7. Caltech-4 veritabanı (uçaklar, arabalar, yüzler ve motorsikletler)


#### 4.3.1 Caltech-4 Veri Tabanı Üzerindeki Deneysel Sonuçlar

Caltech-4 veri tabanı (Şekil 4.7) dört farklı görsel kategoriden oluşmaktadır: uçaklar, arabalar, yüzler ve motorsikletler sınıflarıdır. Bu sınıflar sırasıyla 1074,526, 450 ve 826 resimden oluşmaktadır. Her bir sınıftaki tüm resimler karmaşık alt bilgiye sahip, farklı ışıklarda çekilmiş ve nesnelere farklı pozisyonlardadır. Eğitim ve test kümesi oluşturulurken DoG ile bulunmuş ilgi noktalarından (Şekil 4.8) ve yoğun örneklendirilmiş noktalar üzerinden (Şekil 4.9) örnek çerçeveler alınmıştır (D. G. Lowe, 2004). Örnek çerçeveler üzerinden betimleyiciler elde edilmiştir. Bulunan betimleyicilere k-means kümelendirme metodu uygulanarak görsel sözlükler elde edilmiştir. Görsel sözlükteki kelime sayısı (kümelerin merkezi) 1000 tutulmuştur. Herbir sınıftaki resimlerden elde edilen betimleyicilerin görsel sözlüğe göre karşılaştırılması yapılmış ve histogram elde edilmiştir. Sonuç olarak elde edilen histograma L1 normalizasyonu uygulanmıştır.

Betimleyicilere göre elde edilen sınıflandırma oranları Tablo 1’de verilmektedir. Sınıflandırma oranları 5-kez çapraz doğrulama yapılarak hesaplanmıştır. Tablonun ikinci sütununda DoG ilgi noktalarına bağlı olarak ve son sütunda ise yoğun örneklendirmeye bağlı olarak elde edilmiş sınıflandırma oranları verilmiştir. TBA’ya dayalı betimleyicinin ilgi noktalarına bağlı örneklendirmede ve yoğun örneklendirmede de iyi sonuçlar verdiğini göstermektedir. Aynı zamanda yoğun örneklendirmenin detektör tabanlı örneklendirmeye göre daha iyi sonuçlar verdiği görülür.



**Şekil 4.8.** İlgi noktalarına göre örneklendirilmiş görüntü, (a) İlgi nokta analizi yapılmış görüntü, (b) İlgi noktaları üzerine oturtulmuş karesel çerçeve (c) Örnek bir ilgi noktasının ve karesel çerçevenin yakın gösterimi



**Şekil 4.9.** (a)Yoğun bir şekilde örneklendirilmiş görüntü (b) Yoğun örneklendirmenin yakın gösterimi





gibi bu deneylerde de görsel sözlük boyutu (öznitelik vektör boyutu) 1000 tutulmuştur. Sınıflandırıcı olarak DVM kullanılmış ve 5-kez çapraz doğrulma yapılarak sınıflandırma oranları elde edilmiştir.

Veri tabanı kullanılarak elde edilen sınıflandırma oranları Tablo 4.2' de verilmektedir. En iyi tanıma oranının TBA'ya dayalı betimleyiciden elde edildiği görülmektedir ve onu SIFT betimleyicisinden elde edilen sonucun izlediği görülür. Önceki deneylerde de olduğu gibi diğer betimleyicilerden elde edilen sonuçlarla karşılaştırılmıştır.

Betimleyiciler	Yoğun örneklendirme için sınıflandırma oranı
SIFT	89.45 $\pm$ 2.5
SURF	87.88 $\pm$ 1.9
LBP	88.36 $\pm$ 1.3
LTP	89.26 $\pm$ 3.3
TBA	<b>93,54</b> $\pm$ 3,23

**Table 4.2.** Coil 40 veri kümesine uygulanan farklı betimleyicilerinin sınıflandırma (%) oranı

### 4.3.3 Caltech-4 Veri Tabanı Üzerindeki İlgili Noktası Deneysel Sonuçları

Caltech-4 veritabanı üzerinde farklı ilgi noktaları bulan yaygın detektörler uygulanmıştır: harris, DoG ve önerdiğimiz TBA'ya dayalı detektörlerdir. Bu detektörlere bağlı olarak ilgi noktaları bulunmuş ve ilgi noktaları üzerinde örnek çerçeveler elde edilmiştir. Örnek çerçeveler üzerinden betimleyiciler elde edilmiştir ve önceki deneylerde olduğu gibi görsel sözlük boyutu 1000 tutulmuştur.

Sınıflandırma oranları Tablo 4.3' de verilmektedir. En iyi tanıma oranının DoG ilgi noktalarına dayalı örneklerle TBA'ya dayalı betimleyici uygulanarak elde edildiği görülmektedir ve bu sonucu TBA'ya dayalı ilgi noktaları üzerinden elde edilen Sift betimleyicisi kullanılarak oluşturulan histogram vektörünün sınıflandırma sonucunun izlediği görülür. Tablo 4.3'den görüldüğü üzere TBA dayalı ilgi noktaları üzerinden elde edilen TBA'ya dayalı betimleyicisi kullanılarak oluşturulan histogram vektörünün sınıflandırma sonucunun o kadar iyi olmadığı anlaşılır. Bu sonucu geliştirmek için görüntüdeki nesnenin iç



noktalarından da ilgi noktası bulunması gerektiği öngörülür. Önceki deneylerde de olduğu gibi diğer detektörlerden ve betimleyicilerden elde edilen sonuçlar Tablo 4.3’de görülmektedir.

İlgi Noktaları	Betimleyiciler	İlgi noktalarına bağlı Sınıflandırma Oranı
DoG	SIFT	81.36 $\pm$ 5.9
DoG	TBA	<b>91,23</b> $\mp$ 3,38
Harris	SIFT	87,95 $\mp$ 4,16
Harris	TBA	85,99 $\mp$ 4,06
TBA	SIFT	<b>91,024</b> $\mp$ 2,6
TBA	TBA	78,19 $\mp$ 1,05

**Tablo 4.3.** Caltech 4 veri kümesine uygulanan farklı ilgi detektörlerine ve betimleyicilere göre sınıflandırma (%) oranı

## BÖLÜM 5

### 5. SONUÇ VE ÖNERİLER

Yapılan tez çalışmasında ilk olarak verilen görüntünün ilgi noktalarını tespit edecek TBA'ya dayalı bir detektör önerilmiştir. Bu detektör ile bulunmuş noktalara anlamlı nokta denilmiştir. Bu detektörle geçmiş yıllarda çalışılmış görüntüler üzerinde anlamlı noktalar analiz edilmiş ve bu analiz sonuçları diğer çalışmalardaki sonuçlarla karşılaştırılmıştır. Görüntü üzerinden bulunan bu anlamlı noktalar ile çoklu-primitif bölütleme yapılmış ve elde edilen sonuçlar daha önce yapılan çalışmalar ile karşılaştırılmıştır.

Anlamlı nokta analizi ve bu noktalara bağlı bölütleme yapıldıktan sonra bu noktalara bağlı betimleyici geliştirilmesi öngörülmüştür. Görüntüden detekt edilen anlamlı noktalar görüntünün ilgi noktası gibi kabul edilerek bu noktalar üzerinde karesel çerçeveler çizilmiştir. Bulunan karesel çerçeveler hücelere bölünmüştür ve herbir hücreden TBA'ya dayalı betimleyiciler elde edilmiştir. Elde edilen tüm betimleyiciler birleştirilerek, k-means sınıflandırıcısı ile öbeklendirerek, herbir öbekten kelime elde edilmiştir. Test görüntülerinden elde edilen betimleyicilerin bu kelimeler ile ağırlıklandırması sonucu histogram vektörleri bulunmuştur. Bu vektörler DVM ile sınıflandırılarak 5-kez çapraz doğrulaması yapılarak sınıflandırma oranları elde edilmiştir. Sınıflandırma oranlarını elde etmek için kullandığımız kelimeler çantası modeli ve deneysel çalışmalarda sonuçları karşılaştırmak için yaygın olarak kullanılan betimleyiciler hakkındaki önbilgiler Ekler bölümünden incelenebilir.

Yaygın olarak kullanılan iki veritabanı üzerinde deneysel çalışmalar yapılmış ve eğer görüntünün iç noktalarından da anlamlı nokta analizi yapılırsa sonuçların daha iyi olacağı öngörülmüştür. Önerilen TBA'ya dayalı betimleyici ve detektörle daha fazla sınıf içeren veritabanlarında çoklu sınıflandırma yapılacak çalışmalardandır. Bu yapılacak çalışma için ilk olarak karesel çerçeve farklı sayıda hücelere ayrılarak farklı boyutta betimleyiciler elde

edilecek ve bu betimleyiciler oluşturulurken farklı normalizasyonlar kullanılacaktır. Sonraki adım olarak uzaysal bir şekilde histogram elde edilecektir. Histogram vektörünü sınıflandırma işleminde ise DVM'ye farklı çekirdek fonksiyonları uygulanması öngörülmektedir.

## BÖLÜM 6

### 6. EKLER

#### 6.1. Temel Bileşen Analizi (TBA)

1901 yılında Karl Pearson'un başlattığı temel bileşenler analizi çalışmaları, 1933 yılında Hotelling tarafından geliştirilmiştir. TBA çok sayıda birbiri ile ilişkili değişkenler içeren veri setinin boyutlarını veri içerisinde varolan değişimlerin mümkün olduğunca korunarak daha az boyuta indirgenmesini sağlayan bir dönüşüm tekniğidir. Bu analiz eldeki veriyi daha az sayıda değişkenle ifade edebilecek en iyi dönüşümü belirlemeyi amaçlar. Dönüşüm sonrasında elde edilen değişkenler ilk değişkenlerin temel bileşenleri olarak adlandırılır. İlk temel bileşen varyans değeri en büyük olandır ve diğer temel bileşenler varyans değerleri azalacak şekilde sıralanır. Temel bileşenler birbirine diktir. Gürültüye karşı düşük hassasiyet, bellek ve kapasite ihtiyaçlarının azalması, az boyutlu uzaylarda daha etkin çalışması TBA'nın temel avantajları arasında sıralanabilir.

##### 6.1.1 Temel Bileşen Analizi Metodolojisi

Temel Bileşen Analizinin örüntü tanımada bilinen en etkili uygulaması Turk ve Pentland tarafından geliştirilen özyüz (eigenface) yöntemidir (Turk, M. A. ve Pentland A. P., 1991). Eğitim kümesi veri matrisinin ( $X$ ),  $M$  tane  $N \times I$  'lik gözlem vektöründen oluşan bir eğitim matrisi olduğu kabul edilsin. Burada her bir gözlem vektörü, görüntü matrisinin sütun vektörüne dönüştürülmesiyle oluşturulur. TBA yöntemi kısaca aşağıdaki gibi işler:

Eğitim veri matrisi (6.1) ve (6.2)'deki gibi gösterilsin.

$$X = [x^1 | x^2 | \dots | x^M ] \quad (6.1)$$

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \cdot & x_1^M \\ x_2^1 & x_2^2 & \cdot & x_2^M \\ \cdot & \cdot & \cdot & \cdot \\ x_N^1 & x_N^2 & \cdot & x_N^M \end{bmatrix} \quad (6.2)$$

Çok değişkenli analizde, çoğu zaman birimleri farklı olan değişkenlerle ilgilenilir. Ancak, bazı durumlarda verilerin aynı birimde olması daha iyi sonuç verir. Bu amaçla, değişken değerleri merkezileştirilerek aynı birime dönüştürülür. Bu standartlaştırma veri ortalaması 0'a çekilerek yapılır. Eğitim vektörlerinin ortalaması  $m$ , denklem (6.3)'deki gibi hesaplanır. Hesaplanan ortalama vektörü her bir gözlem vektöründen çıkartıldığında değişkenler 0 ortalamalı olur ve ortalaması çıkarılmış veri matrisi  $\check{X}$  ile gösterilir.

$$m = \frac{1}{M} \sum_{i=1}^M X^i = \begin{bmatrix} m_1 \\ m_2 \\ \cdot \\ m_N \end{bmatrix} \quad (6.3)$$

Ortalaması çıkarılmış gözlem vektörleri (5.4) ve (5.5) deki gibi gösterilir.

$$\tilde{x}^i = x^i - m, \quad \forall i \quad (6.4)$$

$$\check{X} = [\check{x}^1 | \check{x}^2 | \dots | \check{x}^M] \quad (N \times M) \quad (6.5)$$

Sıfır ortalamalı eğitim veri matrisi (5.6) ile bulunur.

$$X = \begin{bmatrix} x_1^1 - m_1 & x_1^2 - m_1 & \cdot & x_1^M - m_1 \\ x_2^1 - m_2 & x_2^2 - m_2 & \cdot & x_2^M - m_2 \\ \cdot & \cdot & \cdot & \cdot \\ x_N^1 - m_N & x_N^2 - m_n & \cdot & x_N^M - m_n \end{bmatrix} \quad (6.6)$$

Daha sonra sıfır ortalamalı eğitim vektörünün kovaryans matrisi (6.7) kullanılarak hesaplanır ve (6.8)'deki matris elde edilir.

$$C = \check{X}\check{X}^T = \frac{1}{M-1} \sum_{i=1}^M (x^i - m)(x^i - m)^T \quad (6.7)$$

$$\begin{bmatrix} (x_1^1 - m_1)^2 & (x_1^2 - m_1)(x_2^1 - m_2) & \cdot & (x_M^1 - m_1)(x_N^1 - m_N) \\ (x_2^1 - m_2)(x_2^1 - m_2) & (x_2^2 - m_2)^2 & \cdot & (x_M^2 - m_2)(x_N^2 - m_N) \\ \cdot & \cdot & \cdot & \cdot \\ (x_N^1 - m_N)(x_1^M - m_1) & (x_N^2 - m_n)(x_2^M - m_2) & \cdot & (x_N^M - m_n)^2 \end{bmatrix} \quad (6.8)$$

Burada köşegen üzerinde bulunan katsayılar varyans, diğerleri kovaryans katsayılarıdır. Varyans diğer boyutlardan bağımsız olarak yalnızca bir boyuttaki verinin ortalama değere göre dağılımı hakkında bilgi vermektedir. Kovaryans bir boyutun diğer boyutlara bağlı olarak nasıl bir değişim gösterdiği hakkında bilgi verir. Daima iki boyut arasında hesaplanır. Değişkenlerden birinin değeri artarken diğerinin değeri artıyor ya da biri azalırken diğeri de azalıyorsa iki değişken arasındaki kovaryans değeri pozitif olacaktır. Değişkenlerden birinin değeri artarken diğerinin değeri azalıyor ya da birinin değeri azalırken diğerinin değeri artıyorsa kovaryans değeri negatif çıkacaktır. Eğer değişkenler arasında belirgin bir ilişki yoksa, kovaryans sifıra yakın bir değer olur. Denklem (6.9)'daki eşitlik kullanılarak kovaryans matrisinin öz değer ve öz vektörleri hesaplanır.  $C$ ,  $N \times N$  boyutlu bir matris,  $\lambda$  herhangi bir skaler ve  $v$  sıfırdan farklı bir sütun vektör olmak üzere,

$$Cv = \lambda v \quad (6.9)$$

Eşitliğini sağlayan  $\lambda$  sayısı  $C$ 'nin özdeğeri ve  $v$  de  $\lambda$  ile ilişkili özvektördür. Öz değerler büyükten küçüğe doğru sıralanır. Bu sıralı öz değerlere karşılık gelen sıralı vektörlerden ilk  $P$  tanesi kullanılarak  $G$  izdüşüm matrisi oluşturulur. Seçilen özvektörler matrisin satırlarını oluşturacak şekilde (6.10)'daki gibi en büyük özdeğere başlıyarak sıralanır.

$$G^T = \begin{bmatrix} g_1 \\ g_2 \\ \cdot \\ g_N \end{bmatrix} \quad (6.10)$$

Bulunan  $P$  tane öznitelik  $N$  boyutlu betimleyici vektörünü tanımlar. (6.11)'deki gibi öznitelik vektörü belirlenmek istenen vektörlerin  $G$  matrisi üzerinde izdüşümü alınır.

$$y^i = G^T x^i \quad i = 1, 2, \dots, M \quad (6.11)$$

Böylece eğitim aşaması tamamlanmıştır. Bir sonraki basamak, eğitimde kullanılmayan bir test görüntüsü geldiğinde, eğitim aşamasındaki öznitelikler kullanılarak test vektörüne sınıf ataması yapmayı amaçlayan bir sınıflandırma gerçekleştirmektir.

## 6.2 Kelimeler Çantası Modeli

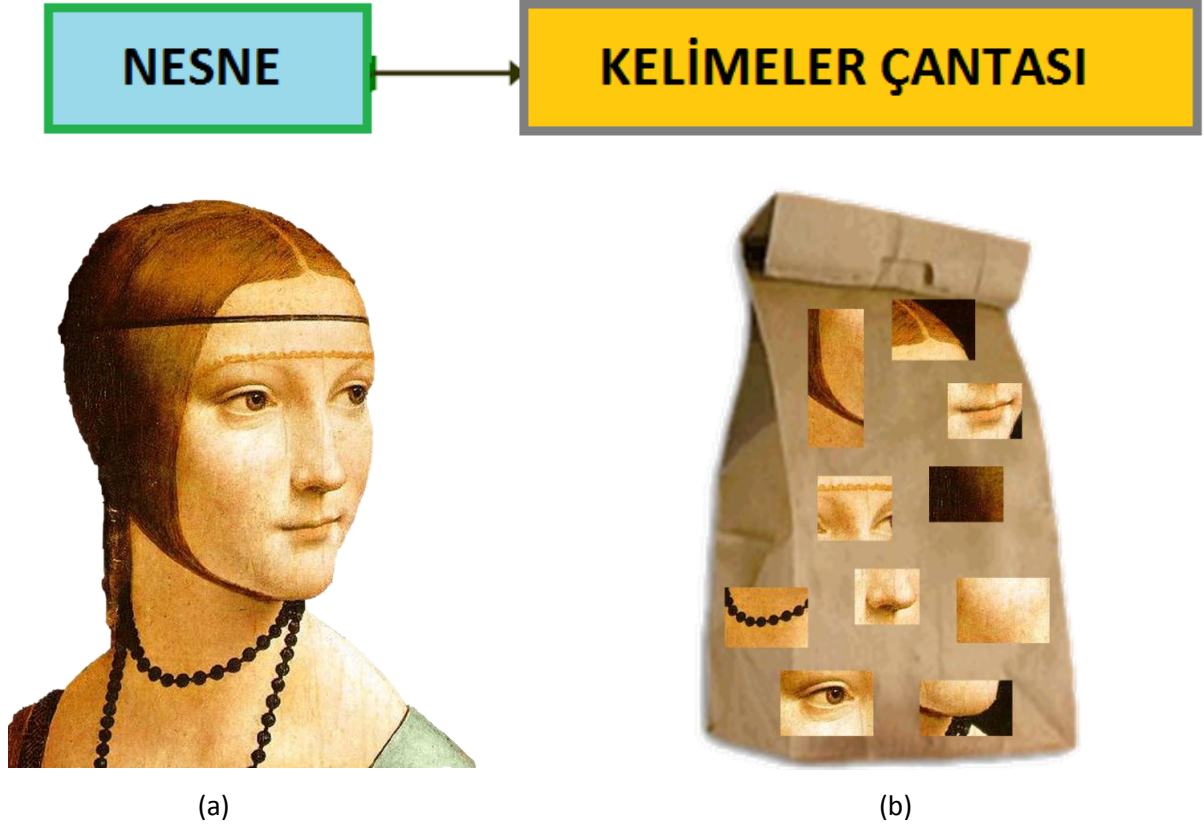
Kelimeler Çantası Modeli (BoW) üç farklı ana adım izlenerek oluşturulur:

- görüntüden hangi bölgelerin örneklendirme için seçileceği
- bu seçilen bölgelerin nasıl betimleneceği (betimleyici seçimi)
- oluşturulan betimleyicilerin nasıl niceleneceğidir.

Bu modele aynı zamanda kod kitabı üretimi de denilmektedir. (Fei-Fei L.ve ark. 2005- 2007), (Grauman K. ve Darrell T., 2005) yayınlarında görsel nesne tanıma alanında bu model ile ilgili çalışmalar yapılmıştır.

BoW modelinden ilk olarak herbir görüntüden, o görüntüyü tanımlayabilecek bölgeler toplanır. Dolayısıyla herbir görüntüden gelen bölgelerden bir küme oluşturulur, kümedeki herbir bölge üzerinde betimleyici vektör elde edilir ve bu betimleyici vektör nicelenir. Nicelenmiş bu betimleyiciler ait olduğu görüntünün özniteliği olarak kabul edilir. Bu öznitelik vektörleri sınıflandırılarak 'görsel sözlük' elde edilir. Görsel sözlükteki herbir kelimenin görüntülerdeki bulunma oranlarına bakılarak herbir görüntü için histogram vektörleri elde edilir. Bu histogram vektörleri görsel sözlüğün nicelenmiş halidir. Sonuç olarak herbir görüntüye ait histogramlara bakılarak bulunma olasılığı yüksek kelimeler bulunarak, bu kelimelerle görüntü tekrar tanımlanır. Bu işleme görüntünün 'görsel kelimelerle' tanımlanması denilmektedir. Şekil 6.2' de kelimeler çantası modeli kullanılarak herbir nesne için oluşturulan histogramlar ve son olarak elde edilen görsel sözlük gösterilmektedir.

Şekil 6.1’de kelimeler çantası modeline ait bir örnek resmedilmektedir. Şekil 6.1(a)’da nesne verilmiş olup Şekil 6.1(b)’de o nesneden çıkarılan öznelik vektörleri ile oluşturulmuş kelime çantası gösterilmektedir.



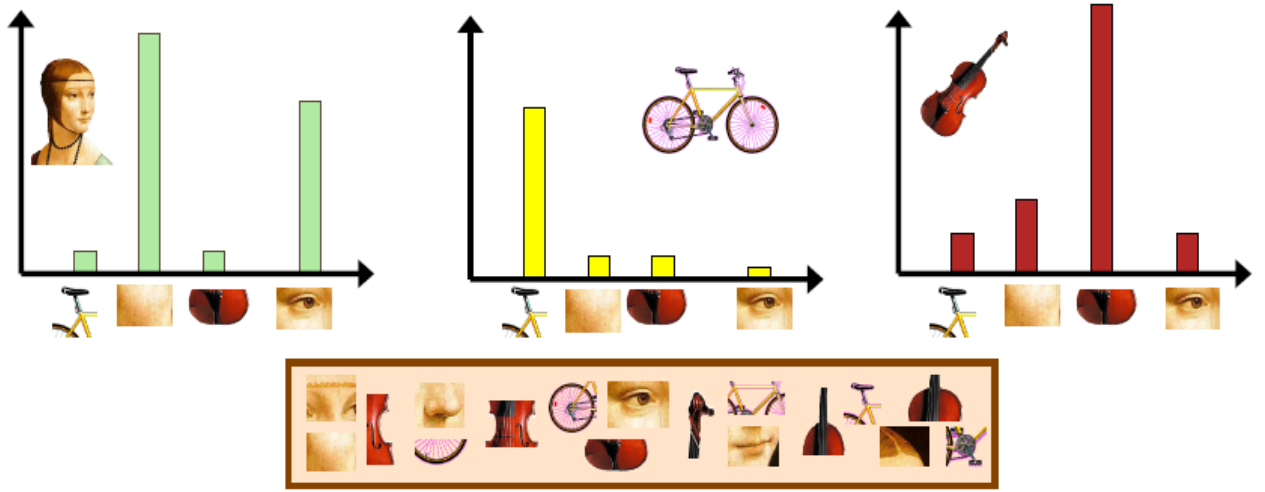
**Şekil 6.1.** Kelimeler çantası modeli (a) Nesne, (b) Verilen nesneden oluşturulmuş kelimeler çantası

Kelimeler Çantası Modelinin avantajları aşağıdaki şekilde sıralanabilir:

- Kelimeler Çantası Modeli öznelikler arasındaki uzaysal ilişkilerini gözardı etmesine rağmen, güçlü ayırıcı kelimelerden dolayı görsel nesne sınıflandırmada iyi sonuçlar vermektedir.
- Bu model örtüşmeye, geometrik deformasyonlara, farklı perspektif açılara ve ışık şiddetindeki çeşitliliklere dayanıklıdır.
- Eğitim ve tanıma süresi diğer modeller ile karşılaştırıldığında daha kısa sürmektedir.



- Bu model kullanılarak eğitim aşamasında elde edilen öznitelikler birbirinden bağımsızdır.



**Şekil 6.2.** Kelimeler çantası modeli kullanılarak her bir nesne için oluşturulan histogramlar ve son olarak elde edilen görsel sözlük.

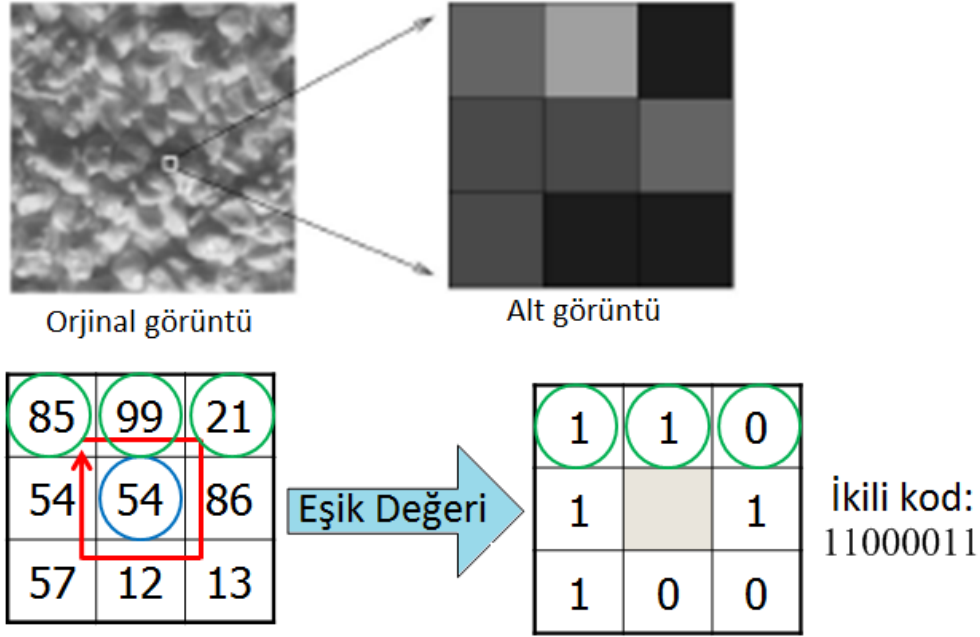
### 6.3 Lokal İkili Örüntü (LBP) ve Lokal Üçlü Örüntü (LTP) Betimleyicileri

Son zamanlarda medikal dijital görüntülerdeki öznitelikleri ayırt etmek için yaygın olarak Lokal İkili Örüntü (LBP) , Lokal Üçlü Örüntü (LTP) betimleyicileri kullanılmaktadır. Bu betimleyiciler genel olarak medikal görüntü analizinde en çok kullanılan desen betimleyicileridir (T. Ojala, M. Pietikäinen ve D. Harwood, 1994-1996), (X. Tan ve B.Triggs, 2007) ve (L. Nanni, A. Lumini ve S. Brahmam, 2010).

Lokal İkili Örüntü betimleyicisinin oluşturulması süreci:

- Görüntünün belli bir bölgesinden merkez piksel değeri eşik değeri olarak seçilir.
- Merkez pikselin etrafındaki piksel değerleri eşik değerine göre ikili sayı sisteminde ifade edilir. Komşu piksellerin değerleri eşik değerinden büyük ise +1, eşik değerine eşit yada küçük ise 0 değerleri bu pikseller yerine yazılır.
- Bu değerlerin lokal desen betimleyicisine göre histogramları elde edilir.

şeklinde işlenir. Bu süreç Şekil 6.3'te resmedilmektedir.



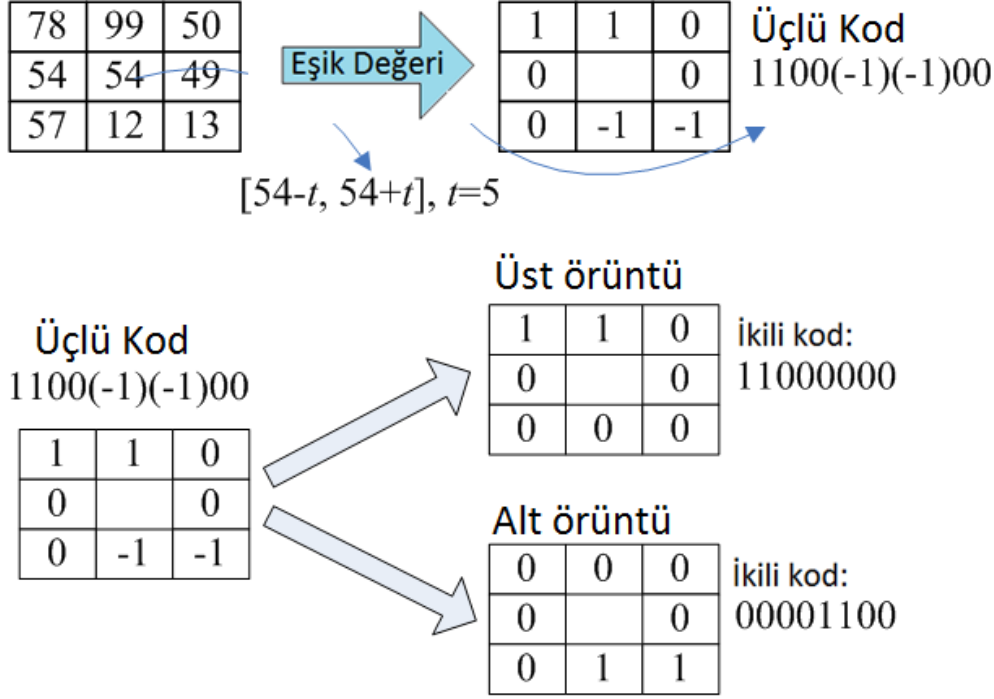
**Şekil 6.3.** Lokal ikili örüntü betimleyicisinin oluşturulması süreci.

Şekil 6.3' de ilk olarak görüntünün belli bir bölgesi alınmıştır. Bu bölgenin piksel değerleri ile gösterimi ifade edilmiştir. Bu bölgenin merkez piksel noktası ve aynı zamanda eşik değeri 54 olarak seçilmiştir. Bu eşik değerine bağlı olarak komşu pikseller ikili sayı sisteminde yazılmıştır. Son olarak bölgenin ikili kodu elde edilmiştir.

Lokal Üçlü Örüntü betimleyicisinin oluşturulması süreci:

- Görüntünün belli bir bölgesinden LBP betimleyicisinde olduğu gibi merkez piksel değeri eşik değeri olarak seçilir.
- Merkez pikselin etrafındaki piksel değerleri eşik değerine göre üçlü sayı sisteminde ifade edilir. Komşu piksellerin değerleri eşik değerinden büyük ise +1, eşik değerine eşit yada küçük ise 0 değerleri bu pikseller yerine yazılır. LBP den farkı eğer komşu piksellerin değerleri eşik değerinden çok düşük ise o komşu pikseller yerine -1 değeri yazılır.
- Bu değerlerin lokal desen betimleyicisine göre histogramları elde edilir.

şeklinde işlenir. Bu süreç Şekil 6.4'te resmedilmektedir.




**Şekil 6.4** Lokal üçlü örüntü betimleyicisinin oluşturulması süreci.

Şekil 6.4' te ilk olarak Şekil 6.3'teki görüntü bölgesinin piksel değerleri alınmıştır. Bu bölgenin merkez piksel noktası ve aynı zamanda eşik değeri 54 olarak seçilmiştir. Bu eşik değerine bağlı olarak komşu pikseller -1, 0, +1 sayı değerlerinde yazılmıştır. Böylece bölgenin üçlü kodu elde edilmiştir. Son olarak bölgenin üst kısmından ve alt kısmından ikili kodlar elde edilmiştir.

#### 6.4 SURF Betimleyicisi

İlk olarak verilen görüntünün ilgi noktaları bulunur. Bu ilgi noktaları üzerine karesel çerçeveler çizilir ve görüntüden alınan karesel çerçeveler 4x4 alt bölgelere bölünür. Bu alt bölgelere Haar Wavelet dönüşümü uygulanarak  $d_x$  ve  $d_y$  bileşenleri elde edilir. Alt bölgelerden elde  $d_x$  ve  $d_y$  Haar Wavelet bileşenlerinin toplamlarında bileşen olarak kabul edilir. Böylece görüntüden alınan alt bölgelerin bu bileşenlere göre histogramları bulunur. Son olarak elde edilen bu histogram vektörleri, Surf betimleyicisi olarak adlandırılır (Herbert Bay ve ark. 2008).

Şekil 6.5' de Surf betimleyicisi oluşturulma süreci ile ilgili bir örnek resmedilmiştir. Şekil 6.5(a)'da ilk olarak verilen görüntünün ilgi noktaları bulunmuş olup bu noktalar üzeri karesel çerçeveler çizilmiştir. Bu çerçeveler 4x4 alt bölgelere bölünmüştür ve bu bölgeler üzerine Haar-Wavelet dönüşümü uygulanmıştır. Dönüşüm uygulandıktan sonra  $\sum d_x$ ,  $\sum |d_x|$ ,  $\sum d_y$ ,  $\sum |d_y|$  bileşenleri elde edilmiştir. Şekil 6.5 (b),(c) ve (d)'de Haar-Wavelet dönüşüm bileşenlerine bağlı olan görüntüler verilmiş ve bu görüntülerin histogram vektörleri elde edilmiştir.



**Şekil 6.5.** (a) Surf betimleyicisi oluşturulma süreci (b),(c) ve (d) ilk olarak görüntüler verilmiş ve bu görüntülerin Haar-Wavelet bileşenlerine göre histogramları elde edilmiştir.

## KAYNAKLAR DİZİNİ

Alajlan N., Kamel M. S., and Freeman G., 2006, Multi-object image retrieval based on shape and topology, *Signal Processing: Image Communication*, vol. 21, pp. 904-918.

Alajlan N., Rube I. E., Kamel M. S., and Freeman G., 2007, Shape retrieval using triangle-area representation and dynamic space warping, *Pattern Recognition*, vol. 40(7), pp. 1911-1920.

Attneave E., 1954, Some informational aspects of visual perception, *Psychol. Rev.*, 61, 183-193.

Ayed I.B., Li S., and Ross I., 2009, A Statistical Overlap Prior for Variational Image Segmentation, *International Journal of Computer Vision*, Vol. 85, no. 1, pp. 115-132.

Arica N. and Vural F., 2003, BAS: a perceptual shape descriptor based on the beam angle statistics, *Pattern Recognition Letters*, vol. 24(9-10).

Alpaydin E., 2005, *Introduction to Machine Learning*. Massachusetts: MIT Press.

Bauckhage C. and Tsotsos J. K., 2005, Bounding box splitting for robust shape classification, in *Proc. IEEE International Conference on Image Processing*, pp. 478-481.

Bay H., Ess A., Tuytelaars T., Luc V. G., 2008, SURF: Speeded Up Robust Features, *Computer Vision and Image Understanding (CVIU)*, Vol. 110, No. 3, pp. 346—359.

Belongie S., Malik J., and Puzicha J., 2002, Shape matching and object recognition using shape context, *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 24(4), pp. 509-522.

**KAYNAKLAR DİZİNİ (devam)**

Berretti S., Bimbo A. D., and Pala P., 2000, Retrieval by shape similarity with perceptual distance and effective indexing, *IEEE Trans. on Multimedia*, vol. 2(4), pp. 225-239.

Burges C. J. C., 1998, A tutorial on support vectormachines for pattern recognition, *Data Mining and Knowledge Discovery*, vol. 2, pp. 121-167.

Carmona-Poyato A., Fern´andez-Garc´ia N.L., Medina-Carnicer R. and Madrid-Cuevas F.J., 2005, Dominant point detection: A new proposal, *Image and Vision Computing*, 23, 1226-1236.

Cevikalp Hakan, Kurt Zuhul, Onarcan Ahmet Okan, 2013, Return of the King: The Fourier Transform Based Descriptor for Visual Object Classification, *SIU 2013 Semposium*, Cyprus – Girne.

Chabat F., Yang G.Z., Hansell D.M., 1999, A corner orientation detector, *Image and Vision Computing* 17, 761–769.

Chakrabarti K., Binderberger M., Porkaew K., and Mehrotra S., 2000, Similar shape retrieval in mars, in *Proc. IEEE International Conference on Multimedia and Expo*.

Cremers D., Rousson M., and Deriche R., 2007, A Review of Statistical Approaches to Level Set Segmentation: Integrating Color, Texture, Motion and Shape, *International Journal of Computer Vision*, Vol. 72, no. 2, pp. 195-215.

Cornic P., 1997, Another look at the dominant point detection of digital curves, *Pattern Recognition Lett.* 18, 13–25.

Davies E., 1997, *Machine Vision: Theory, Algorithms, Practicalities*. Academic Press, New York.

Fei-Fei L. and Perona P., 2005, A Bayesian Hierarchical Model for Learning Natural Scene Categories, *Proc. of IEEE Computer Vision and Pattern Recognition*, pp. 524–531.

**KAYNAKLAR DİZİNİ (devam)**

Fei-Fei L., R. Fergus, and Torralba A., Recognizing and Learning Object Categories, CVPR 2007 short course.

Flusser J., 1992, Invariant shape description and measure of object similarity, in Proc. 4th International Conference on Image Processing and its Applications, pp. 139-142.

Friedman J. H., 1996, Another approach to polychotomous classification, tech. rep.

Gonzalez R. and Woods R., 2002, Digital image processing, Second Edition. Pearson Education North Asia Limited and Publishing House of Electronics Industry.

Granlund G., 1972, Fourier preprocessing for hand print character recognition, IEEE Transactions on Computers, Vol. 21, no. 2, pp. 195-201.

Grauman K. ve Darrell T., 2005, The Pyramid Match Kernel: Discriminative Classification with Sets of Image Features, Proc. of IEEE International Conference on Computer Vision.

Günel Ş. E., 2010, Örüntü tanıma uygulamalarında fraktal boyut yardımıyla öznitelik çıkarımı, Doktora Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, 1-7.

Gürsoy H. O., 2009, Sınır bilgisinden uzaysal piramit oluşturulmasına dayalı şekil betimleyicisi, Yüksek Lisans Tezi, Deniz Harp Okulu Deniz Bilimleri Ve Mühendisliği Enstitüsü, 6-13.

Hornig J.H., 2002, Improving fitting quality of polygonal approximation by using the dynamic programming technique, Pattern Recognition Letters 23, 1657–1673.

Hornig J.H., 2003, An adaptive smoothing approach for fitting digital planar curves with line segments and circular arcs, Pattern Recognition Letters 24, 565–577.

Hsu C.-W. and Lin C.-J., 2002, A comparison of methods for multiclass support vector machines, IEEE Transactions on Neural Networks, vol. 13, no. 2, pp. 415- 425.

**KAYNAKLAR DİZİNİ (devam)**

Hu Wu-Chih, 2005, Multiprimitive segmentation based on meaningful breakpoints for fitting digital planar curves with line segments and conic arcs, *Image and Vision Computing* 23, 783–789.

Hu M.-K., 1962, Visual pattern recognition by moment invariants, *IRE Trans. Information Theory*, vol. IT-8, pp. 179- 187.

Jalba A. C., Wilkinson M. H. F., and Roerdink J. B. T. M., 2006, Shape representation and recognition through morphological curvature scale spaces, *IEEE Trans. Image Processing*, vol. 15(2), pp. 331-341.

Kauppinen H., Seppanen T., and Pietikainen M., 1995, An experimental comparison of autoregressive and fourier-based descriptors in 2-D shape classification, *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 17(2), pp. 201-207.

Kerautret B., Lachaud J.-O., Naegel B., 2008, Comparison of discrete curvature estimators and application to corner detection, in: *ISVC (1)*, Vol. 5358 of LNCS, pp. 710-719.

Kurt Zuhail, Özkan Kemal, 2013, Description of Contour with Meaningful Points, *SIU 2013 Semposium*, Cyprus – Girne.

Lee Yun-Seok, Koo Han-Suh, Jeong Chang-Sung, 2006, A straight line detection using principal component analysis, *Pattern Recognition Letters* 27, 1744–1754.

Li L., Chen W., 1999, Corner detection and interpretation on planar curves using fuzzy reasoning, *IEEE Transactions on Pattern Analysis and Machine Intelligence* 21, 1204–1210.

Liu Y. K., Wei W., Wang P. J., and Zalik B., Compressed vertex chain codes, 2007, *Pattern Recognition*, vol. 40(11), pp. 2908-2913.

Lowe D.G., 1999, Object Recognition from Local Scale-Invariant Features, *Proc. Seventh Int'l Conf. Computer Vision*, pp. 1150-1157.



**KAYNAKLAR DİZİNİ (devam)**

Lu G. and Sajjanhar A., 1999, Region-based shape representation and similarity measure suitable for content based image retrieval, *ACM Multimedia System Journal*, vol. 7(2), pp. 165-174.

Marji M., Siy P., 2004, Polygonal representation of digital planar curves through dominant point detection - a nonparametric algorithm, *Pattern Recognition* 37, 2113–2130.

Mokhtarian F. and Mackworth A. K., 1992, A theory of multiscale, curvature-based shape representation for planar curves, *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 14(8), pp. 789-805.

Nanni L., Lumini A. and Brahmam S., 2010, Local binary patterns variants as texture descriptors for medical image analysis, *Artificial Intelligence in Medicine*, vol. 49, pp. 117-125.

Ojala T., Pietikäinen M., and Harwood D., 1994, Performance evaluation of texture measures with classification based on Kullback discrimination of distributions, *Proceedings of the 12th IAPR International Conference on Pattern Recognition (ICPR 1994)*, vol. 1, pp. 582 - 585.

Ojala T., Pietikäinen M., and Harwood D., 1996, A Comparative Study of Texture Measures with Classification Based on Feature Distributions, *Pattern Recognition*, vol. 29, pp. 51-59.

Ou G., Murphey Y. L., and Feldkamp L., 2004, Multiclass pattern classification using neural networks, in *ICPR '04: Proceedings of the Pattern Recognition, 17th International Conference on (ICPR'04) Volume 4*, (Washington, DC, USA), pp. 585-588, IEEE Computer Society.

Öztürk G., 2007, Sınıflandırma problemleri için yeni bir matematiksel programlama yaklaşımı, *Doktora Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü*, 31-52.

Phokharatkul P., Kimpan C., 2002, Handwritten Thai Character Recognition Using Fourier Descriptors and Genetic Neural Network, *Computational Intelligence*, Vol. 18, no. 3, pp. 270-293.

**KAYNAKLAR DİZİNİ (devam)**

Platt J. C., Cristianini N., and Shawe-Taylor J., 2000, Large margin DAGs for multiclass classification, in Advances in neural information processing systems (S. A. Solla, T. K. Leen, and K.-R. Müller, eds.), (Cambridge, MA: MIT Press), pp. 547-553.

Rafiei D., and Mendelzon A. O., 2002, Efficient retrieval of similar shapes, The International Journal on Very Large Data Bases, Vol. 11, no. 1, pp. 17-27.

Rattarangsi A., Chin R.T., 1992, Scale-based detection of corner of planar curves, IEEE Transactions on Pattern Analysis and Machine Intelligence 14, 430–449.

Ray B.K., Ray K.S., 1992, Detection of significant points and polygonal approximation of digitized curves, Pattern Recognition Letters 22, 443–452.

Rosenfeld A., Johnston E., 1973, Angle detection on digital curves, IEEE Trans. Comput. 22, 940-941.

Rosin P.L., West G.A.W., 1989, Segmentation of edges into lines and arcs, Image and Vision Computing 7, 109–114.

Sarkar B., Roy S., Sarkar D., 2003, Hierarchical representation of digitized curves through dominant point detection, Pattern Recognition Letters 24, 2869–2882.

Sarkar B., Singh L.K., Sarkar D., 2003, Approximation of digital curves with line segments and circular arcs using genetic algorithms, Pattern Recognition Letters 24, 2585–2595.

Schölkopf B. and Smola A. J., 2002, Learning with kernels. Massachusetts: MIT Press.

Sheu H.T., Hu W.C., 1996, A rotationally invariant two-phase scheme for corner detection, Pattern Recognition 29, 819–828.

**KAYNAKLAR DİZİNİ (devam)**

Sheu H.T., Hu W.C., 1999, Multiprimitive segmentation of planar curves— A two-level breakpoint classification and tuning approach, *IEEE Transactions on Pattern Analysis and Machine Intelligence* 21, 791–797.

Siddiqi K. and Kimia B., June 1996, A shock grammar for recognition, in *Proceedings of the IEEE Conference Computer Vision and Pattern Recognition*, pp. 507-513.

Smith S. P. and Jain A. K., 1982, Chord distribution for shape matching, *Computer Graphics and Image Processing*, vol. 20, pp. 259-271.

Soffer A., May 1997, Negative shape features for image databases consisting of geographic symbols, in *Proc. 3rd International Workshop on Visual Form*.

Sonka M., Hlavac V., and Boyle R., 1993, *Image Processing, Analysis and Machine Vision*. Chapman and Hall, London, UK.

Sporring J., Olsen O.F., Nielsen Weickert M., J., 2000, Smoothing images creates corners, *Image and Vision Computing* 18, 261–266.

Taza A. and Suen C., Discrimination of planar shapes using shape matrices, 1989, *IEEE Trans. System, Man, and Cybernetics*, vol. 19(5), pp. 1281-1289.

Tan P.-N., Steinbach M., and Kumar V., 2006, *Introduction to Data Mining*. Boston: Pearson Education.

Tan X. and Triggs B., 2007, Enhanced local texture feature sets for face recognition under difficult lighting conditions, *LNCS 4778*, pp. 168–182.

Teh C.H., Chin R.T., 1989, On the detection of dominant points on digital curves, *IEEE Transactions of Pattern Analysis and Machine Intelligence* 11, 859–872.

**KAYNAKLAR DİZİNİ (devam)**

Tsai D.M., 1996, Boundary-based corner detection using neural networks, *Pattern Recognition* 29, 85–97.

Wang Y. P., Lee K. T., and Toraichi K., 1999, Multiscale curvature-based shape representation using B-spline wavelets, *IEEE Trans. Image Process*, vol. 8(10), pp. 1586-1592.

Wen-Yen Wu, 2003, Dominant point detection using adaptive bending value, *Image and Vision Computing* 21, 517–525.

Yazar I., 2008, Temel Bileşen Analizi ve Bağımsız Bileşen Analizi Yöntemlerini Temel Alan Bazı Görüntü Tanıma Uygulamaları ve Karşılaştırmaları, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, 3-7.

Zhang D. and Lu G., 2002, A comparative study of fourier descriptors for shape representation and retrieval, in *Proc. 5th Asian Conference on Computer Vision*.

Zhang, D., and Lu, G., 2003, A comparative study of curvature scale space and Fourier descriptors for shape-based image retrieval, *Journal of Visual Communication and Image Representation*, Vol. 14, no. 1, pp. 39-57.

Zhang, D., and Lu, G., 2004, Review of shape representation and description techniques, *Pattern Recognition*, Vol. 37, no. 1, pp. 1-19.

Zhong P. and Fukushima M., 2006, A new multiclass support vector algorithm, *Optimization methods and software*, vol. 21, no. 3, pp. 359-372.

Zhu Qiuming, 1999, On the Geometries of Conic Section Representation of Noisy Object Boundaries, *Journal of Visual Communication and Image Representation* 10, 130–154.

Caltech- 4 Database is available at <http://www.vision.caltech.edu/html-files/archive.html>.

Coil-100 Database is available at <http://www.cs.columbia.edu/CAVE/software/softlib/coil-100.php>.

Shape Database is available at <http://www.lems.brown.edu/vision/researchAreas/SIID/>.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

---

- Ad- Soyad : Zühal KURT
- Doğum Yeri : ANKARA
- Doğum Tarihi : 20/09/1987

### İŞ BİLGİLERİ

---

- Niğde Üniversitesinde Araştırma Görevlisi 2009 - 2010
- Eskişehir Osmangazi Üniversitesinde Araştırma Görevlisi 2010 – Devam Ediyor

### EĞİTİM BİLGİLERİ

---

- Lisans : Uludağ Üniversitesi Matematik Bölümü 2005 - 2009
- Yüksek Lisans : Eskişehir Osmangazi Üniversitesi, Matematik ve Bilgisayar Bilimleri 2011 – Devam Ediyor

### ÇALIŞMA ALANI

---

- Image Processing, Computer Vision , Optimization

### YAYINLAR

---

#### Sempozyumlar

- Kemal ÖZKAN, Erol SEKE, Zühal KURT : Choosing L1 and L2 Norm at Super Resolution Algorithms, Elektrik-Elektronik ve Bilgisayar Sempozyumu2011, Cilt 2, 72, Elazığ – Turkey 2011

- Hakan Cevikalp, Zuhall Kurt, Ahmet Okan Onarcan : Return of the King: The Fourier Transform Based Descriptor for Visual Object Classification, SIU 2013 Semposium, Cyprus – Girne, 2013
- Zuhall KURT, Kemal ÖZKAN: Description of Contour with Meaningful Points, SIU 2013 Semposium, Cyprus – Girne, 2013
- Kemal ÖZKAN, Erol SEKE, Zuhall KURT : In Image Super Resolution Problem Using The New Data Fidelity Term, 4<sup>th</sup> International Conference On Mathematical And Computational Applications, Manisa –Turkey 2013

Haberleşme Adresi: ESOGÜ Fen Edebiyat Fakültesi

Matematik ve Bilgisayar Bilimleri Bölümü F1 Blok Oda:199

Dahili:2253 Email:zkurt@ogu.edu.tr