

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İSKELETSEL KRİTİK NOKTALAR İLE ŞEKİL TANIMA

YÜKSEK LİSANS TEZİ
Salih Arda BÖLÜK

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. M. Fatih DEMİRCİ

Mart 2016

Fen Bilimleri Enstitüsü Onayı

.....
Prof.Dr. Osman EROĞUL
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylıyorum.

.....
Prof.Dr. Murat ALANYALI
Anabilimdalı Başkanı

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün numaralı Yüksek Lisans öğrencisi **Salih Arda BÖLÜK**'nın ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "**İSKELETSEL KRİTİK NOKTALAR İLE ŞEKİL TANIMA**" başlıklı tezi tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

Tez Danışmanı: **Doç. Dr. M. Fatih DEMİRCİ**
TOBB Ekonomi ve Teknoloji Üniversitesi

Jüri Üyeleri: **Doç. Dr. Suat ÖZDEMİR (Başkan)**
Gazi Üniversitesi

Yrd. Doç. Dr. Buğra ÇAŞKURLU
TOBB Ekonomi ve Teknoloji Üniversitesi

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Salih Arda BÖLÜK

İMZA

ÖZET

Yüksek Lisans Tezi

İSKELETSEL KRİTİK NOKTALAR İLE ŞEKİL TANIMA

Salih Arda BÖLÜK

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. M. Fatih DEMİRCİ

Tarih: Mart 2016

Son yıllarda görüntü teknolojilerinde meydana gelen gelişmelerle ve internet kullanımının yaygınlaşmasıyla birlikte sanal ortamda çok sayıda resim ve görüntü bulunmaktadır. Sıklıkla büyük veri setleri halinde bulunan bu görüntüler üzerinde arama, indeksleme, gruplama gibi işlemlere ihtiyaç duyulmaktadır. Bilgisayarlı görü teknikleri sayesinde görüntülerdeki nesnelere tanınmakta ve bahsedilen işlemler için görüntüler anlamlandırılabilir. Bu çalışmada, orta eksen çizgeleri kullanılarak şekil tanıma alanında yeni bir yaklaşım sunulmuştur. İskeletleri çıkartılan şekillerin çizgelerinde, her bir iskelet noktasının tüm kritik noktalara olan en kısa yol uzaklığı hesaplanarak her bir şekil için çok boyutlu bir dağılım oluşturulmuştur. Önerilen şekil tanıma platformunda bu dağılımlar üzerinde taşıma tabanlı bir uzaklık fonksiyonu kullanılarak şekiller arasındaki benzerlik oranı bulunmuştur. Alınan sonuçlar daha önceden yapılmış benzer çalışmaların sonuçlarıyla karşılaştırılarak önerilen yaklaşımın başarımı gösterilmiştir. Son olarak önerilen yöntemin performansı ileri beslemeli yapay sinir ağlarıyla desteklenmiş ve sonuçlarda dikkate değer iyileşmeler olduğu görülmüştür.

Anahtar Kelimeler: Şekil Tanıma, Şekil Eşleme, Orta Eksen Çizgesi, Toprak Taşıyıcı Mesafesi

ABSTRACT

Master of Science

SHAPE RECOGNITION USING SKELETAL CRITICAL POINTS

Salih Arda BÖLÜK

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Doç. Dr. M. Fatih DEMİRCİ

Date: March 2016

In recent years, with the advances in imaging technologies and widespread use of the internet, a great number of images and video are present in the digital world. Because the number of images and video is very large, the need for searching, indexing and grouping operations is high. With the help of computer vision techniques, the images can be interpreted and their contents can be recognized for the mentioned operations. In this work, we presented a novel shape recognition framework based on medial axis graph. After extracting medial axis graph of a shape, we constructed a multi-dimensional distribution by calculating shortest path distances between each skeleton point and all of the points in the graph. Then similarity rates between these distributions is found by using a transportationbased distance function. We compared our results with results of similar works conducted in the past. Finally, the performance of the proposed method is increased by using feed forward neural network algorithm which provides a fair amount of improvement on classification results.

Keywords: Shape Retrieval, Shape Matching, Medial Axis Graph, Earth Mover's Distance

TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Doç.Dr. M. Fatih DEMİRCİ, kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Bilgisayar Mühendislięi Bölümü öğretim üyelerine ve destekleriyle her zaman yanımda olan aileme ve arkadaşlarıma çok teşekkür ederim. Bu çalışma TÜBİTAK 113E500 nolu proje tarafından desteklenmiştir.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ	ix
ÇİZELGE LİSTESİ	xii
KISALTMALAR	xiii
RESİM LİSTESİ	xiv
1. GİRİŞ	1
1.1 Tezin Amacı	3
2. LİTERATÜR ARAŞTIRMASI	6
2.1 Dış Kenarları Kullanan Çalışmalar	6
2.2 İskelet Kullanan Çalışmalar	7
2.3 Dış Kenarları ve İskeleti Birlikte Kullanan Çalışmalar	9
2.4 İskeleti Temsilini İyileştiren Çalışmalar	10
2.5 Çizge Eşleme Problemi	10
2.6 Gri Seviyeli Görüntüleri Kullanan Çalışmalar	11
3. İSKELETSEL KRİTİK NOKTALAR İLE ŞEKİL TANIMA	15
3.1 İskelet Çıkarma	15
3.2 Orta Eksen Çizgesi	17
3.3 Kritik Noktaların Bulunması	18
3.4 İskeletin Geometrik Uzayda Temsil Edilmesi	18
3.5 İskeletlerin Eşleştirilmesi	20
3.6 Yöntemin Algoritması ve Zaman Karmaşıklığı	21
4. DENEYSEL ÇALIŞMALAR	25
4.1 Deney Ortamı	25
4.2 Aslan & Tari Veri Seti	26
4.3 ALOI Veri Seti	28
4.4 ETH-80 Veri Seti	29
4.5 Orta Noktaların Kullanımı	31
4.6 Gürültüye Dayanıklılık Testi	32
5. TTM DIŞINDAKİ MESAFE FONKSİYONLARI	34
6. MAKİNE ÖĞRENMESİ ALGORİTMALARININ KULLANIMI	36
7. YALNIZCA KRİTİK NOKTALARIN KULLANIMI	39

7.1 Yöntem	39
7.2 Deneysel Çalışmalar	40
8. YÖNTEMİN GRİ SEVİYELİ GÖRÜNTÜLERDE UYGULANMASI.....	42
8.1 Yöntem	42
8.2 Deneysel Çalışmalar	42
9. SONUÇ VE ÖNERİLER.....	44
KAYNAKLAR	46
ÖZGEÇMİŞ	53



ŞEKİL LİSTESİ

Sayfa

- Şekil 1.1: Önerilen yöntemin özeti. Şekillerin iskeleti orta eksen çizgesi yöntemiyle çıkarılır, kritik noktalar yakın komşuluklarından elde edilen histogramlar kullanılarak sıralanır, iskelet üzerinde her noktanın tüm kritik noktalara olan en kısa yol uzaklıkları hesaplanarak şekillerin iskeleti çok boyutlu uzayda olarak temsil edilir, şekiller arasındaki benzerlik TTM ile hesaplanarak aralarındaki benzerlikler bulunur..... 5
- Şekil 2.1: Şeklin dış kenarlarından noktalar örneklenir. Her bir noktadan diğer noktalara olan uzaklıklar hesaplanır ve Shape Context adı verilen bir histogramla kodlanır. [5] çalışmasından alınmıştır. 6
- Şekil 2.2: İskelet temsili için örnek bir şekil ve iskeleti. Şekillerin iskeleti, simetri ekseni olarak da tanımlanır. Soldaki resim ikili resmin orijinalini, sağdaki resimde beyaz pikseller iskelet noktalarını göstermektedir. Her bir iskelet noktası üzerinde bulunan ve şeklin en az iki dış kenar noktasına teğet olan maksimum diskler kullanılarak şekiller orijinaline çok yakın bir biçimde tekrar elde edilebilir. 8
- Şekil 3.1: Önem fonksiyonu *Bending Potential Ratio*, şeklin dış kenarları üzerinde seçilen iki noktadan ve genel olarak dış kenarların dışında bulunan bir noktadan yararlanır. [51] çalışmasından alınmıştır..... 16
- Şekil 3.2: Minimum Yayılan Ağaç algoritması kullanılarak iskelet noktaları arasındaki komşuluklar bulunmuştur. Şekiller soldan sağa, söz konusu şekli, şeklin iskeleti bulunduktan sonra iskelet noktalarını ve orta eksen çizgesini göstermektedir. 18
- Şekil 3.3: Şekiller, düğümleri iskelet noktalarını ve kenarları iskelet noktalarının komşuluklarını gösteren orta eksen çizgeleri ile temsil edilir. Kritik noktalar şeklin üç veya daha fazla kısmının kesiştiği noktalardan ve bu kısımların bitiş noktalarından oluşur. Şekilde siyah noktalar kritik noktaları göstermektedir. Kritik noktalara verilen sayılar, metinde bahsedildiği gibi bu noktaların yerel histogramlarının kullanılarak hesaplanmış sıralamalarını göstermektedir. 19

Şekil 3.4: Yersel mesafeleri $d(a, b) = \min(2, \text{abs}(a - b))$ olarak tanımlanan akış ağı üzerinde örnek bir dönüşüm. (a)'da $N^2 + N$ kenara sahip orijinal akış ağı. Bu ağda bulunan $N(N - 3)$ tane kenar 2 masrafına sahip. Sol altta bulunan mavi düğüm, histogramların toplam ağırlığı arasındaki farkı alan bitiş düğümü. (b)'de dönüşüme uğramış akış ağı. Çizgili sarı dikdörtgenle gösterilen düğüm aktarma düğümü. Gelen kenar masrafı eşik değeri (burada 2) ve giden kenar masrafı 0'dır. [39] çalışmasından alınmıştır.	22
Şekil 4.1: Aslan & Tari veri seti 14 sınıf ve her sınıfta 4 şekilden oluşan, toplam 56 şekle sahip bir veri setidir. Her satır iki farklı sınıftan oluşan şekilleri göstermektedir.	26
Şekil 4.2: Aslan & Tari veri setinde elde edilen sınıflandırma sonuçlarının bir kısmı. En soldaki sütun sorgu için kullanılan şekilleri göstermektedir. Sonraki üç sütundaki şekiller karşılık gelen sorgu şekline olan benzerliklerine göre sıralanmıştır. Yanlış sınıflandırılan şekiller kutu içine alınmıştır. Farklı sınıflara ait benzer şekiller görüldüğü üzere yanlış sınıflandırılabilir.	27
Şekil 4.3: İlk dört satır kullanılan veri setindeki her sınıftan bir örnek şekil içermektedir. En alt satırda ise bir sınıfın farklı oryantasyonlarından örnek şekiller gösterilmektedir.	28
Şekil 4.4: Sınıflandırma sonuçlarının bir kısmı. İlk on satır doğru sınıflandırmaları gösterirken, en alt satırda üç yanlış sınıflandırma gösterilmektedir. Yanlış sınıflandırmalar çoğunlukla izleme açısına bağlı olarak farklı sınıftan objelerin benzer şekiller sahip olmasından kaynaklanmaktadır.	29
Şekil 4.5: ETH-80 veri seti 8 sınıftan oluşmaktadır. Her sınıfta 10 obje ve her obje için 41 görüntü olmak üzere toplamda 3280 görüntü vardır. Şekildeki her satırda belli bir sınıfa ait objelerden birer tane gösterilmektedir.	30
Şekil 4.6: Orta eksen çizgesi üzerinde kritik noktalar arasında kalan noktaların da kritik noktalar kümesine dahil edilmesi gösterilmiştir.	31
Şekil 4.7: a) Önerilen çalışmada, gittikçe artan gürültü altında elde edilen başarımlar. Çember, yıldız ve üçgen sırayla Aslan & Tari, ALOI ve ETH-80 veri setlerinde alınan başarımları göstermektedir. Gürültü seviyesi arttıkça başarımlar yavaş bir şekilde düşmektedir. b) Gürültü eklenmesi sonucu örnek bir şekilde meydana gelen değişim. Şeklin orijinal hali ve %15 gürültü eklenmiş hali karşılaştırıldığında, orta eksen çizgesinin yapısının az da olsa değiştiğini ve birtakım kritik noktaların kaybolduğu görülmektedir. Buna rağmen kritik noktalar, hala şekillerin benzer bölümlerini temsil edebilmektedir.	33

Şekil 7.1: Kritik olmayan noktaların başarıma olan etkisini test etmek için şekil, kritik noktaların birbirlerine olan en kısa yol uzaklıklarıyla temsil edilmiştir. Şekilde, ortadaki kritik noktanın diğer kritik noktalara olan en kısa yol uzaklığının hesaplandığı gösterilmektedir. Vektörler gösterim amacıyla belirtilmiştir. 40



ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 4.1: Aslan & Tari veri seti üzerinde sonuçların karşılaştırılması.....	27
Çizelge 4.2: ALOI veri setinin kullanılan alt kümesi üzerinde sonuçların karşılaştırılması.	29
Çizelge 4.3: ETH-80 veri seti üzerinde sonuçların karşılaştırılması.	30
Çizelge 7.1: Kritik olmayan noktaların başarıma etkisi verilmiştir. Elde edilen başarımlar, ilk aşamada elde edilen başarımlarla birlikte gösterilmektedir.	40

KISALTMALAR

MYA	: minimum yayılan ağaç
TBA	: temel bileşen analizi
TTM	: toprak taşıyıcı mesafesi
SC	: shape context
IDSC	: inner distance shape context
LBP	: local binary pattern
SSC	: solid shape context
BCF	: bag of contour fragments
BSP	: bag of skeleton paths
BPR	: bending potential ratio
ECDS	: electrical charge distribution on the shape
DVM	: Destek Vektör Makinesi

RESİM LİSTESİ

	<u>Sayfa</u>
Resim 1.1: Dođuşundan bugüne bilgisayarlı görü alanındaki aktif olarak araştırılmış konular. [59] çalışmasından alınmıştır.	2
Resim 1.2: Örnek bir resim ve resme Sobel operatörü uygulanması sonucu elde edilen eğim değerleri.	3
Resim 2.1: Çok boyutlu uzayda Harris köşeleri hesaplanır ve yakın komşuluklar kullanılarak her bir özneliğın baskın yönü belirlenir. Soldan sağa ve yukarıdan aşağı, görüntünün orijinal hali ve her bir boyutta bulunan MOPS öznelikleri gösterilmiştir. [9] çalışmasından alınmıştır.	12
Resim 8.1: İlk iki satırda ALOI veri setinden alınan 10 farklı sınıftan birer görüntü gösterilmektedir. Üçüncü satırda ise bir sınıfın farklı açılardan çekilmiş görüntüleri vardır.	43


1. GİRİŞ

Son yıllarda görüntüleme teknolojilerinde yaşanan gelişmeler ve bilgisayarların işlem gücünde meydana gelen artış, gittikçe daha karmaşık işlemler yapabilen bilgisayarlı görü algoritmaları için gerekli olan temeli hazırlamıştır. Geçmişte yalnızca insan müdahalesiyle yapılabilen, elektronik cihazlara verilmesi dahi düşünülmemeyen çoğu görev, bugünkü bilgisayarlı görü ve makine öğrenmesi teknikleri sayesinde mümkündür. Nesne tespiti, nesne tanıma, nesnelere görüntünün arka planından ve diğer nesnelere ayırma, karakter tanıma, yüz tespit ve tanıma, artırılmış gerçeklik, uzaktan algılama gibi birçok işlem bilgisayarlı görü teknikleri sayesinde otomatik olarak yapılabilmektedir.

Bilgisayarlı görü alanının ortaya çıkışından itibaren bugüne kadar olan süreç kısaca gözden geçirilecek olursa 1960 ve 1970 yılları arasından başlamak gerekir [59]. O yıllarda görüntülerin anlamlandırılması kolay bir problem olarak görülmüştür. Yaygın olarak bilinen bir anlatıma göre, 1966'da Massachusetts Institute of Technology (MIT)'de Marvin Minsky'nin, lisans öğrencisi olan Gerald Jay Sussman'dan yaz dönemi projesi olarak, bilgisayarına bir kamera bağlamasını ve kameranın çektiği görüntüleri anlamlandırmasını istemiştir. Araştırmalar derinleştikçe ve konu çeşitliliği arttıkça bilgisayarların, görüntüleri insanların yapabildiği gibi anlamlandırmasının zor bir problem olduğu anlaşılmıştır. Resim-1.1'de bilgisayarlı görü alanında 1970'den başlayarak son yıllara kadar aktif olarak araştırılmış konular görülmektedir.

Bilgisayarlı görü alanındaki araştırmalar, 1970'lerde, iki boyutlu resimlerden kenar noktalarının bulunarak, nesnelere 3 boyutlu modellerinin hesaplanması, objeleri parça bazında anlamlandırma ve bu parçalar arasındaki ilişkileri modelleme konuları üzerine yoğunlaşmıştır. Ayrıca bu dönemde öznitelik tabanlı stereo eşleme ve optik akış algoritmaları üzerine ilk çalışmalar yapılmıştır. 1980'lerde matematiksel tekniklerin önem artmıştır. Görüntü piramidi, desen ve tondan şekil tespiti konuları üzerine çalışmalar yapılmıştır. Ayrıca daha yüksek performanslı kenar ve köşe tespit teknikleri geliştirilmiştir. Optik akış, stereo, kenar tespit ve birtakım başka teknikler, sonradan daha gelişmiş global arama ve optimizasyon algoritmalarıyla birlikte kullanılacak, ayrık *Markov Random Field* modelleri aracılığıyla bir platformda birleştirilmiştir.

1990'lara gelindiğinde, sözü edilen alanlardaki çalışmalara devam edilirken bazı alan-



Resim 1.1: Doğuştan bugüne bilgisayarlı görü alanındaki aktif olarak araştırılmış konular. [59] çalışmasından alınmıştır.

lar daha aktif bir biçimde araştırılmıştır. Hareketli görüntülerden sahnenin 3 boyutlu modelinin oluşturulması konusu önem kazanmıştır. İlk çalışmalar, kamera kalibrasyonunun yapılmadığı *projective reconstruction* üzerine yoğunlaşmıştır. Sonradan ortografik kamera modeli ve dönemin sonuna doğru perspektif kamera modeli geliştirilmiştir. 1980’lerde geliştirilmeye başlanan ve görüntülerin renk, parlaklık değerlerini fiziksel ışınım taşınımı ve renkli görüntü oluşumu modelleriyle birleştiren teknikler özelleşerek *fizik tabanlı görü* adını almıştır. Optik akış ve stereo eşleme metotları geliştirilmiştir. Dönemin en önemli buluşlarından biri, global optimizasyon için de kullanılan, çizge kesme *graph cut* tekniğidir. Bu çalışmaların yanında izleme (*tracking*), segmentasyon ve istatistiksel öğrenme alanlarında gelişmeler yaşanmıştır. Ayrıca bilgisayar grafiği alanında da birçok çalışma yapılmıştır.

2000’lerde yaşanan gelişmeler bilgisayarlı görü ve bilgisayar grafiği alanları arasında gidip gelmiştir. Görüntü dikişi, (*light field capture*), yüksek dinamik aralık (*high dynamic range*), basamaklı pozlama (*exposure bracketing*) gibi teknikler *bilgisayarlı fotoğrafçılık* adı verilen yeni bir alan altında toplanmıştır. Bu dönemde ayrıca, makine öğrenmesi teknikleriyle birlikte kullanılan, öznitelik tabanlı nesne tanıma yöntemleri ortaya çıkmıştır. Kimi araştırmacılar dış kenarlar üzerine yoğunlaşırken kimileri öznitelik tabanlı yöntemleri tercih etmiştir. Son olarak, son yıllarda gelişmiş makine öğrenmesi teknikleri giderek daha fazla bilgisayarlı görü problemine uygulanmaya başlamıştır. Katlamalı sinir ağları tekniği, büyük veri seti gereksinimine rağmen, diğer bilgisayarlı görü tekniklerine göre nesne tanıma konusunda oldukça yüksek başarımler vermektedir.

Sunulan çalışmada, şekil eşleme problemi üzerine gidilmiştir. İnternet teknolojilerinin gelişmesiyle büyük veri setleri içinde resim arama ihtiyacı oldukça artmıştır. Bu ihtiyacı karşılamaya yönelik yapılan çalışmaların bazılarında benzeri aranan resim veri setindeki tüm resimlerle karşılaştırılırken bazılarında indeksleme yöntemleri kullanıla-

arak aranan resim veri setindeki tüm resimlerin bir alt kümesiyle karşılaştırılır. Resimleri karşılaştırmak için genel olarak segmentasyon yapılır ve her segment ayırt edici öznelikleri temsil edilir. Öznelik olarak şekil, renk, desen, merkezi moment gibi özellikler kullanılabilir [1]. Şekil bilgisi bunların arasında en yaygın kullanılan özelliklerden biridir. Birçok uygulamada objelerin şekilleri kenar ya da iskelet noktalarıyla tanımlanır.

Geçmişte şekillerin dış kenar noktaları birçok çalışmada kullanılmıştır. Verilen bir şeklin dış kenarları Sobel, Prewitt, LoG, DoG gibi operatörlerle veya Canny [11] gibi çok aşamalı kenar tespit algoritmalarıyla bulunabilir. Resim-1.2’de gösterildiği gibi, bu operatörler uygulandığında görüntüdeki yatay ve düşey eğim değerlerinin şiddeti ve yönü bulunur. Önerilen çalışmada kullanılan ikili (binary) görüntülere uygulandığında ise, şeklin sınırları dahilinde kalan bölgedeki piksellerin parlaklık değerlerinde herhangi bir değişim olmadığından dolayı, dış kenar noktaları elde edilir.



Resim 1.2: Örnek bir resim ve resme Sobel operatörü uygulanması sonucu elde edilen eğim değerleri.

1.1 Tezin Amacı


Büyük görüntü veri setlerinde arama, verilen bir resimdeki nesnelere sınıflandırılarak resimlerin anlamlandırılması gibi işlemler günden güne önem kazanmakta ve bu alanda yapılan araştırmalar sayesinde sürekli bir ilerleme sağlanmaktadır. Bu çalışmada orta eksen çizgesi dönüşümü kullanılarak iskeletleri çıkarılan şekiller üzerinde yeni bir temsil yönteminin oluşturulması ve temsilleri elde edilen şekiller arasındaki

benzerliğin taşıma tabanlı bir mesafe fonksiyonuyla hesaplanarak şekil tanıma alanında yeni bir yaklaşım sunulması amaçlanmaktadır.

Önerilen yöntemin performansını artırmak için sonuçlar, ileri beslemeli yapay sinir ağlarıyla desteklenmiş ve sınıflandırma sonuçları üzerinde büyük iyileşme sağlandığı görülmüştür. Yöntemin gürültüye karşı dayanıklılığının ölçülebilmesi için, şekillerin iskeleti çıkarıldıktan sonra, %5 ile %20 aralığında rastgele iskelet noktaları silinmiştir. Bu yöntemle, kullanılan veri setlerine gürültü eklenerek önerilen yöntem test edilmiş ve sonuçlar verilmiştir. Ayrıca, kritik olmayan noktaların başarıma etkisini gösterebilmek için, şekiller yalnızca kritik noktaların birbirlerine olan en kısa yol uzaklıklarıyla temsil edilmiş ve bu yönde deneyler yapılarak sonuçlar verilmiştir. Son olarak, yöntemin gri seviyeli görüntülerde verdiği başarıyı test edebilmek için şekillerin iskeletini çıkarmak yerine yerel öznitelikler bulunmuş ve şekli temsil eden çizge bu öznitelikler üzerinden hesaplanmıştır.

Sunulan çalışmada siyah beyaz görüntüler için şekil tanımlayıcısı olarak iskelet (ya da orta eksen dönüşümü) kullanılmıştır. Dış kenar (contour) noktaları yerine iskelet tabanlı bir şekil tanımlayıcısı kullanma sebebi, önceki çalışmalarda gösterildiği üzere, iskelet tabanlı şekil tanımlayıcılarının kenar tabanlı şekil tanımlayıcılarından kısmi kapanma durumunda bile daha iyi sonuç vermesidir [45, 46]. İskelet çıkarma işlemi sonucunda elde edilen diskler kullanılarak şeklin tam olarak aynı tekrar elde edilebildiğinden, bu yöntem şekillerin geometrik ve topolojik özelliklerini korumakta [7] ve karakter tanıma, içerik tabanlı resim arama, biyomedikal görüntüleme gibi birçok alanda kullanılmaktadır.

Önerilen çalışmada benzer şekillerin benzer iskeletlere sahip olacağı kabulünden yola çıkarak [19] yeni bir şekil eşleme çalışması sunulmuştur. Şekillerin iskeletlerini her düğüm bir iskelet noktası olacak şekilde ve her kenar en yakın iki düğümü bağlayacak şekilde bir çizge olarak temsil ettikten sonra iskeletin parçalarını birbirine bağlayan kritik noktalar bulunmuştur. Her noktanın tüm kritik noktalara olan en kısa yol uzaklığı bulunarak şekiller çok boyutlu uzayda bir dağılım olarak temsil edilmiştir. Bu dağılımlar arasındaki benzerlik taşıma-tabanlı bir uzaklık fonksiyonuyla hesaplanarak şekiller arasındaki benzerlik bulunmuştur. Ayrıca sadece kritik noktaların kullanılması durumunda başarımın nasıl etkileneceğini gözlemlemek için şekillerin iskeleti yalnızca kritik noktaların birbirine olan uzaklıkları kullanılarak temsil edilmiş ve deneyler bu bağlamda tekrarlanmıştır. Ek olarak sunulan yaklaşım yerel öznitelikler yardımıyla gri-seviyeli görüntüler üzerinde uygulanmış ve son olarak elde edilen sonuçlar tartışılmıştır.



Şekil 1.1: Önerilen yöntemin özeti. Şekillerin iskeleti orta eksen çizgesi yöntemiyle çıkarılır, kritik noktalar yakın komşuluklarından elde edilen histogramlar kullanılarak sıralanır, iskelet üzerinde her noktanın tüm kritik noktalara olan en kısa yol uzaklıkları hesaplanarak şekillerin iskeleti çok boyutlu uzayda olarak temsil edilir, şekiller arasındaki benzerlik TTM ile hesaplanarak aralarındaki benzerlikler bulunur.


Şekillerin iskeletini, iskelet noktalarının kritik noktalara olan uzaklıkları hesaplanarak çok boyutlu bir dağılım olarak temsil etme yaklaşımı bulunurken Vleugels ve Veltkamp [63] çalışmasından etkilenilmiştir. Bu çalışmada, iki şekil arasındaki benzerliğin mutlak bir uzaklık fonksiyonuyla bulunabileceği varsayılarak, bu iki şeklin benzerliklerinin üçüncü bir şekle olan benzerliklerinden yola çıkarak bulunabileceği gösterilmiştir. Veri setindeki her şekil, önceden belirlenmiş n temsilci şekle (*vantage objects*) olan uzaklıklarına göre n boyutlu uzayda (*vantage space*) bir nokta ile temsil edilmiştir. Birbirine yakın olan şekillerin bu uzayda temsil edildiği noktalar da birbirine yakındır. Bu yaklaşımdan esinlenerek, bu çalışmada her şeklin iskeleti çok boyutlu uzayda bir dağılım olarak gösterilmiştir. Beklendiği gibi, birbirine benzer şekillerin dağılımları birbirine yakın çıkmaktadır. Önerilen çalışmanın uygulanabilirliğini göstermek adına, üç farklı veri seti üzerinde deneyler yapılmıştır. Sunulan yöntemin çalışma özeti Şekil-1.1’de verilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Bu bölümde, literatürde yapılmış önerilen yöntemle ilişkili çalışmalar incelenmiştir.

2.1 Dış Kenarları Kullanan Çalışmalar

Bu bölümde literatürde geçen birtakım şekil eşleme yöntemleri incelenmiştir. Shape Context [5], şekillerin dış kenar noktalarını kullanan güçlü bir tanımlayıcıdır. Algoritma ilk olarak şeklin dış kenar noktalarından n tane nokta örnekler. Daha sonra her bir nokta p_i için, p_i den diğer $n - 1$ noktaya olan uzaklıklardan oluşan bir $n - 1$ boyutlu bir vektör tanımlanarak şekil p_i noktasına göre temsil edilir. Bu vektör, Şekil-2.1’de gösterildiği gibi, shape context adı verilen bir histogram aracılığıyla kodlanır. Sözü edilen yöntem iyi bir şekil tanımlayıcısı olmasına rağmen birçok eklemleme noktasına sahip şekiller üzerinde iyi sonuç vermemektedir. Bu problemin üstesinden gelmek için Inner Distance Shape Context [32] yöntemi önerilmiştir. Verilen şeklin dış kenar noktaları üzerinde örnekleme yapıldıktan sonra her bir nokta çifti arasında, Euclid uzaklığı yerine, en kısa yol uzaklığı kullanılmaktadır. Bu yöntem şekilde meydana gelen bozulmalara karşı dayanıklılık göstermesine karşın şeklin dış kenarlarını oluşturan nokta sayısına karşı duyarlıdır, bu noktaların sayısı az olduğunda bahsedilen yöntemin performansı düşmektedir.



Şekil 2.1: Şeklin dış kenarlarından noktalar örneklenir. Her bir noktadan diğer noktalara olan uzaklıklar hesaplanır ve Shape Context adı verilen bir histogramla kodlanır. [5] çalışmasından alınmıştır.

SC ve IDSC yöntemlerinde şekillerin yerel özellikleri temsil edilemediğinden, bu yön-


temler şekillerin yerel özelliklerinde meydana gelen küçük bozulmalara karşı hassastır. Bu sorunu gidermek için Shekar ve diğerleri tarafından IDSC ve Local Binary Pattern yöntemleri birleştirilerek şekillerin dış kenar bilgisi yanında yerel özelliklerini de temsil edebilen birleşik bir sistem önerilmiştir [50]. Her iki şekil arasında ayrı ayrı IDSC ve LBP mesafeleri hesaplanarak D_{IDSC} ve D_{LBP} mesafe matrisleri oluşturulur. Hesaplanan D_{IDSC} ve D_{LBP} matrisleri yeni bir D matrisinde $D = \alpha D_{IDSC} + \beta D_{LBP}$ formülüne uygun olarak α ve β katsayıları ile ağırlıklandırılarak birleştirilir ve sınıflandırma için bulunan D matrisi kullanılır.

Yine SC yönteminin bir türevi olan ve şekillerin içsel bilgilerinin kullanıldığı Solid Shape Context yöntemi önerilmiştir [40]. Şekillerin içsel, diğer bir ifadeyle dış kenarlar arasında kalan, özelliklerinin temsil edilmesi için şeklin iç bölgesi eşit aralıklara sahip yoğun bir noktalar kümesiyle örneklenir. Daha sonra seyrek bir noktalar kümesi kullanılarak bir önceki adımda bulunan yoğun noktalar kümesi üzerinde örnekleme yapılır. Son olarak seyrek noktaların her biri üzerinde, yoğun noktalar kümesiyle tanımlanan, SC hesaplanır. İki şekil arasındaki eşleme, seyrek noktaları üzerinde hesaplanmış SC ler aracılığıyla yapılır.

Guocheng ve diğerleri tarafından, şekillerin bölütlerini temsil edebilen ve eklemlenme problemiyle ilgilenen bir yöntem önerilmiştir [24]. İlk olarak şeklin dış kenar noktaları üzerinde eşit aralıklarla örnekleme yapılır. Örneklenen her bir nokta c üzerinde çeşitli yarıçaplarda daireler çizilir ve dairelerin sınırları içinde kalan şekle ait piksellerin sayısının şeklin tüm piksellerinin sayısına oranı bulunarak bir vektör oluşturulur. İki şekil arasındaki mesafe oluşturulan bu vektörler üzerinde χ^2 test istatistiği hesaplanarak bulunur. Yakınlarda, Sirin ve Demirci [55] bu tekniği şekillerin iskeleti üzerinde kullanmışlardır. Ayrıca yöntemin farklı şekillerin aynı sayıda noktaya sahip olması gerektiği şartını esneterek ve eşleme aşamasında noktaların koordinatlarını da dikkate alarak tekniği geliştirmişlerdir.

2.2 İskelet Kullanan Çalışmalar

Dış kenar noktalarını kullanan yöntemlerin yanında şekillerin iskeletini kullanan birçok yöntem mevcuttur. Şekillerin iskeleti, simetri eksenini olarak da tanımlanır. Şekil-2.2'de örnek bir şekil ve iskeleti verilmiştir. Soldaki resim ikili resmin orijinalini, sağdaki resimde beyaz pikseller iskelet noktalarını göstermektedir. Her bir iskelet noktası üzerinde bulunan ve şeklin en az iki dış kenar noktasına teğet olan maksimum diskler kullanılarak şekiller orijinaline çok yakın bir biçimde tekrar elde edilebilir.



Şekil 2.2: İskelet temsili için örnek bir şekil ve iskeleti. Şekillerin iskeleti, simetri eksenini olarak da tanımlanır. Soldaki resim ikili resmin orijinalini, sağdaki resimde beyaz pikseller iskelet noktalarını göstermektedir. Her bir iskelet noktası üzerinde bulunan ve şeklin en az iki dış kenar noktasına teğet olan maksimum diskler kullanılarak şekiller orijinaline çok yakın bir biçimde tekrar elde edilebilir.

[33] çalışmasında, dış kenar noktalarının optimal olarak karşılık geldiği iskelet noktalarının yerel komşulukları kullanılarak oluşturulan şekil eksen ağaçlarının eşleştirilmesiyle şekiller arasındaki benzerlik bulunmuştur. Etkili bir yöntem olmasına karşın, şekle karşılık gelen çizgenin topolojisini değiştiren metotlar kullanıldığından şekillerin bütünlüğü bozulabilmektedir. Sharvit ve diğerleri tarafından şok çizgesi (shock graph) tabanlı bir yaklaşım önerilmiştir [49]. Bu yöntemle umut verici sonuçlar elde edilmesine karşın temel akışlarda meydana gelen hatalar şeklin bölütleri arasındaki hiyerarşiyi bozabilmektedir. Siddiqi ve diğerleri tarafından önerilen çalışmada [54], şekil eşleme için alt-çizge problemi çözülmüştür. Şekli temsil eden şok çizgesi köklü ağaca dönüştürülmüş ve bir ağaç eşleştirme algoritmasıyla şekiller eşlenmiştir. Sebastian vd. yaptığı çalışmada [44] iki şekil arasındaki mesafe, bir şekli diğer şekle benzetmek için uygulanacak en küçük deformasyon hesaplanarak bulunmuştur. Yang ve diğerleri iskeletler üzerinde tanımlanan en kısa yolların kullanılarak şekillerin sınıflandırıldığı bir yöntem önermişlerdir [71]. Orta eksen çizgesi üzerinde uç noktaları bulunduktan sonra her iki uç nokta arasındaki en kısa yol bulunur. Bulunan bu yollar üzerindeki iskelet noktalarına karşılık gelen maksimum disklerin yarıçapı kullanılarak şekillerin iskeleti arasındaki benzerlikler hesaplanır.

2.3 Dış Kenarları ve İskeleti Birlikte Kullanan Çalışmalar

Literatürde şekillerin iskeletleri ve dış kenarları başarılı bir şekilde kullanılmasına karşın bazı çalışmalar bu iki tekniği birden kullanarak her ikisinin de tamamlayıcı özelliklerini birleştirmişlerdir. Bai ve diğerleri yaptıkları çalışmada [3] şeklin dış kenarlar bölütlerini ve iskelet yollarını kullanmışlardır. Şeklin dış kenar bölütleri ve iskelet yolları bulunduktan sonra, yöntemin düzlemsel benzerlik dönüşümlerine olan hassaslığını azaltmak için bulunan öznelilikler normalize edilir. Daha sonra dış kenar bölütlerinin temsilleri hesaplanır ve iskelet yollarıyla birlikte bir veri setinde tutulur. Test aşamasında, hedef resmin de iskelet yolları ve dış kenar bölütlerinin temsilleri hesaplanır ve en yakın komşu sınıflandırıcısı kullanılarak önceden hesaplanmış veri setindeki özneliliklerle karşılaştırılır. Yang ve diğerlerinin yaptığı çalışmada [69] şeklin dış kenarları, orta eksen çizgesindeki uç noktalar kullanılarak bölütlere ayrılır. Her bir bölütün özelliklerini temsil edebilmek için 12 boyutlu özellik vektörleri tanımlanır. Bu vektörlerle bölütü ayıran uç noktaların arasındaki Euclid uzaklığı, bölütteki toplam piksel sayısı, bölüt ile bölütü ayıran uç noktalar arasındaki doğru arasında kalan alan ve bölütü oluşturan alt-bölütleri kapsayan sınırlayıcı kutuların özellikleri temsil edilir. Şekillerin eşlenmesi, şekillerin iskeleti arasındaki uzaklığın dış kenar bölütlerini eşleştiren minimum fonksiyonun masrafının birleştirilmesiyle gerçekleştirilir.

Sözü edilen bu yöntemlerde şekillerin dış kenarları ve iskeletleri birlikte kullanılmaktadır. Fakat bu birleştirme işlemi bütünleşik bir temsilden çok ayrı ayrı oluşturulan modellerden elde edilen sonuçların ağırlıklı toplamıdır. Buna rağmen literatürde bütünleşik temsil yöntemleri sunan çalışmalar da vardır. Shen ve diğerlerinin yaptığı çalışmada [52] Bag of Contour Fragments (BCF) [66] ve Bag of Skeleton Paths (BSP) algoritmalarından elde edilen öznelilik vektörleri bütünleşik bir temsilde birleştirilerek çok sınıflı doğrusal destek vektör makinesine girdir olarak verilmiştir. Kod çizelgesinin oluşturulmasından sonra, iskelet yolları veri setindeki tüm şekillerden elde edilen iskelet yollarının küme merkezleri kullanılarak oluşturulmuş LLC şemasıyla [65] kodlanmıştır. Bai ve diğerleri [4] bir Tree-Union yapısı kullanarak şeklin iskelet ve dış kenar bilgisini birleştirdikleri bütünleşik bir yöntem sunmuşlardır. Belirli bir kategoriye ait örnek resimler kullanılarak, şekillerin dış kenarları iskelet dallarına göre bölütlenmiş ve bu bölütler kullanılarak bir Tree-Union yapısı oluşturulmuştur. Ağacın her bir düğümü şekillerin ortak iskeletinin bir kritik noktasını ya da uç noktasını ve her bir kenarı iskeletin karşılık gelen dalını temsil etmektedir. Şekil eşleme ağacının kökünden başlanarak, mevcut düğüme bağlanan her bir dala karşılık gelen dış kenar bölütlerinin hedef şekilden elde edilen ağacın kenarlarıyla olasılıksal bir biçimde karşılaştırılmasıyla gerçekleştirilmektedir.

2.4 İskeleti Temsilini İyileştiren Çalışmalar

Benzer iki şekil karşılaştırılırken, dış kenarlarda meydana gelen küçük bozulmalar ve eklemlemeler, şekiller benzer olmasına karşın, iskeletlerinin birbirinden oldukça farklı olmasına yol açmaktadır. Bu tür bir durumda, benzer şekiller arasında büyük mesafeler verdiğinden, şekil eşleme algoritmalarının etkinliği azalmaktadır. Bu sorunun üstesinden gelebilmek için iskelet budama teknikleri geliştirilmiştir. Bu çalışmalardan bazıları, şekillerin iskeleti çıkarılmadan önce dış kenarları üzerinde yumuşatma yapmaktadır [17, 54]. Bu yöntemin sakıncası, bazı dış kenar noktalarının yerini değiştireceğinden iskelet noktalarının da yerlerini değiştirmesidir. Bazı çalışmalarda ise [37, 47, 51] her bir iskelet noktası için bir önem fonksiyonu hesaplanmakta ve bu fonksiyonun çıktısı önceden belirlenmiş bir eşik değerinin altında kalan iskelet noktaları silinmektedir.

2.5 Çizge Eşleme Problemi

Çizgeler, resimler, metin belgeleri, videolar, biyolojik ve biyomedikal veriler gibi karmaşık veri türlerinin modellenmesinde kullanılan güçlü yapılardır. Çizge tabanlı şekil eşleme tekniklerinde, şekilleri temsil etmek için çizge topolojisi kullanılır ve çizgeler arasındaki benzerliği hesaplamak için çizge eşleme algoritmalarından yararlanır [15, 53, 58, 61]. Çizgeler birçok çalışmada aktif olarak kullanılmasına karşın etkili ve verimli çizge eşleme konusu hala aktif bir araştırma alanıdır.

Macrini ve diğerleri izleme noktasındaki değişimlere ve eklemlemeye karşı dayanıklı, çizge tabanlı bir çalışma önermişlerdir [35]. Bu dayanıklılık, şeklin silüetini benzer izleme noktalarında kararlı olan bölümlere ve bu bölümler arasındaki ilişkilere ayırmakla sağlanmaktadır. Bunun için ilk olarak şeklin iskeleti üzerindeki bağlayan (*ligature*) ve bağlamayan (*non – ligature*) dallar bulunmaktadır. Makalede bağlayan dallar, iskeletin yapısına diğer kısımlardan daha az katkı sağlayan bölümler olarak tanımlanmıştır, bağlamayan dallar ise iskeletin bağlayan dalları dışındaki dallardır. Bu dalların bulunmasından sonra kemik çizgesi (*bonegraph*) tanımlanmıştır. Bu çizgenin her bir düğümü şeklin bir bölümünü temsil etmektedir, kenarları ise şekilde birbirine komşu olan bölümlerin karşılık geldiği düğümleri bağlamaktadır. Feldman ve diğerleri tarafından yapılan çalışmada [20] ise olasılıksal bir iskelet modeli önerilmiştir. Yöntemin temel çıkış noktası gerçek dünyadaki bir şeklin altta yatan bir iskelet ve rastlantısal bir büyüme fonksiyonunun sonucu olduğudur. Şekiller bir *apriori* ve bir olasılık fonksiyonunun Bayes kuralıyla birleştirilmesiyle tanımlanmaktadır. *apriori* fonksiyonu şekillerin basit iskeletlere sahip olduğunu varsayarken olasılık fonksiyonu

büyüme iskeletin büyümesi işleminde rastgele değişiklikler olacağını kabul eder.


2.6 Gri Seviyeli Görüntüleri Kullanan Çalışmalar

Geçmişte gri seviyeli görüntü öznitelikleri üzerine birçok çalışma yapılmıştır ve bu konu halen oldukça aktif bir araştırma alanıdır. Genel olarak verilen bir görüntüden öznitelikleri çıkarma işlemi, yerel özniteliklerin bulunması ve öznitelik tanımlayıcılarının hesaplanması olmak üzere iki aşamadan oluşur. *Histogram of Oriented Gradients* (HOG) [14], parça temelli modeller (*Pictorial Structures* [22], *Discriminatively Trained Part Based Models* [21]), görsel kelimeler [70, 72] ve *Haar-benzeri öznitelikler* [31, 62] gibi bu yöntemi takip etmeyerek kayan pencere metoduyla yalnızca tanımlayıcı hesaplayan ve bu tanımlayıcılar üzerinden çeşitli işlemler yapan metodlar da mevcuttur. Sunulan çalışmanın yapısı gereği orta eksen çizgesi çıkarılabilmesi için görüntüler üzerinde belli sayıda öznitelige ihtiyaç vardır. Bundan dolayı burada incelenen çalışmalar kayan pencere temelli yöntemlerden çok görüntü üzerinde belirgin bölgelerin tespitini yapan ve bu bölgelerin yakın komşuluğu üzerinde tanımlayıcı hesaplayan çalışmalardır.

Öznitelik tespiti basitçe görüntü üzerindeki belirgin bölgelerin çıkarılması olarak düşünülebilir. Belirgin nokta tespiti genel olarak görüntüdeki eğim değerlerinin *Gauss'lar Farkı* (Difference of Gaussians ya da DoG), *Laplacian of Gaussian*, Sobel operatörü gibi filtreler kullanılarak bulunmasından sonra bu eğim değerleri üzerinden yapılır. *Harris & Stephens* [25] köşe tespit algoritması görüntülerdeki belirgin noktaları tespit etmek için literatürde en yaygın olarak kullanılan yöntemlerden birisidir. Temelde, verilen görüntünün yatay ve düşey eksenindeki eğim değerlerinin değişimine bakarak her iki eksen de kuvvetli değişim gösteren bölgeleri köşe olarak kabul eder. Eğim değerlerindeki değişimin matematiksel olarak hesaplanmasında, Eşitlik-2.1'de gösterildiği gibi, ikincil moment matrisi kullanılır. Köşe cevabının bulunabilmesi için ikincil moment matrisinin özdeğerlerinin hesaplanması gerekmektedir. Özdeğer hesaplanması pahalı bir işlem olduğundan, gerçek zamanlı birçok uygulamada yöntemin kullanılabilmesi için matrisin determinanı ve izi kullanılarak köşe cevabı hesaplanır.

$$A = \sum_u \sum_v w(u, v) \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} = \begin{bmatrix} \sum I_x^2 & \sum I_x I_y \\ \sum I_x I_y & \sum I_y^2 \end{bmatrix} \quad (2.1)$$

Öznitelik tespiti işlemi sonrası bulunan özniteliklerin yerel komşulukları etrafındaki parlaklık değerleri ve eğim değerleri kullanılarak her öznitelik için bir tanımlayıcı he-



Resim 2.1: Çok boyutlu uzayda Harris köşeleri hesaplanır ve yakın komşuluklar kullanılarak her bir özneliğin baskın yönü belirlenir. Soldan sağa ve yukarıdan aşağı, görüntünün orijinal hali ve her bir boyutta bulunan MOPS öznelikleri gösterilmiştir. [9] çalışmasından alınmıştır.

saplanır. Literatürde birçok tanımlayıcı mevcuttur. Bunların içinde en yaygın kullanılanlardan biri *Multi-Scale Oriented Patches* (MOPS) [9] yöntemidir. Tanımlayıcı hesaplanmasında genel olarak SIFT'in alternatifi olarak kullanılan bu yöntemde, belirgin nokta tespiti için verilen görüntü çeşitli boyutlarda küçültülerek ve görüntüye Gauss filtresi uygulanarak Gauss piramidi oluşturulur. Bu piramit üzerinde Harris köşeleri tespit edilir ve çok boyutlu uzayda belirgin noktalar bulunmuş olur. Daha sonra maksimum köşe cevabına sahip olmayan öznelikler, kalanların görüntü üzerinde düzgün bir biçimde dağılması sağlanarak, bastırılır (*adaptive non-maximal suppression*) ve yerel komşuluklar kullanılarak her özneliğin baskın yönü belirlenir. Resim-2.1'de örnek bir görüntü için bulunmuş MOPS öznelikleri gösterilmiştir. Son olarak yine yerel komşuluklar kullanılarak her bir öznelik için tanımlayıcılar hesaplanır. Tanımlayıcı hesaplanırken ilk olarak özneliğin 8x8 komşuluğu 5 piksel aralıklı olacak biçimde örneklenir ve komşuluk içinde kalan pikseller normalleştirilir. Daha sonra Haar-benzeri öznelikler kullanılarak 64 boyutlu bir vektör oluşturulur. Her bir tanımlayıcı için ayrı ayrı oluşturulan bu vektörler kullanılarak en yakın komşu algoritmasıyla Euclid uzayında farklı görüntülerin öznelikleri arasında eşleme yapılır görüntüler arasındaki benzerlik bulunur.

Gerçek zamanlı uygulamalarda, öznelik tespiti ve tanımlayıcı hesaplanması için kullanılan algoritmaların performansı oldukça önemlidir. *Oriented FAST and Rotated BRIEF* (ORB) metodu [42] bu anlamda özellikle hız gereksinimi göz önüne alınarak tasarlanmıştır. Öznelik tespiti için *Features from Accelerated Segment Test* (FAST) [41] ve tanımlayıcı hesaplamak için *Binary Robust Independent Elementary Features* (BRIEF) [10] yöntemleri temel alınarak düşük işlemci gücüne sahip cihazlarda bile hesaplanabilecek bir yöntem sunulmuştur.

Öznitelik tespiti için kullanılan FAST metodunda, verilen görüntüdeki her bir piksel etrafında, çevresi toplam 16 piksel olan bir daire tanımlanır ve bu dairenin sınırlarında bulunan 16 piksel merkezdeki pikselle karşılaştırılır. Yalnızca bu yapıldığında yöntemin başarımı oldukça düşük çıkmaktadır. Yöntemi makine öğrenmesi ile desteklemek için kullanılan veri setindeki her bir görüntüye ilk olarak FAST uygulanır ve belirgin noktalar bulunur. Daha sonra her görüntüdeki her bir öznitelik etrafında sözü edilen 16 piksel ile makine öğrenmesi algoritması için eğitim seti oluşturulur. Eğitim kümesindeki her bir girdi, veri setindeki bir görüntünün bir özneliğinin etrafındaki 16 pikselin parlaklık değerleridir. Girdinin sınıfları ise merkezdeki pikselin bu 16 pikselle karşılaştırılmasıyla bulunan, pikselin köşe olup olmadığıdır. Öğrenme algoritması olarak karar ağacı kullanılır ve bu eğitim kümesi üzerinde eğitilir. Test aşaması sırasında verilen görüntü üzerindeki belirgin noktalar bulunur ve karar ağacı kullanılarak aranan öznitelik olup olmadığına karar verilir. FAST öznitelikleri için baskın yön bulunmadığından ORB yönteminde bu ayrıca yapılmıştır.

Öznitelik tespitinden sonra tanımlayıcılar hesaplanır. Literatürde birçok yöntemde hesaplanan tanımlayıcılar, sayıları da göz önüne alındığında, bellekte büyük yer tutmakta ve eşleme aşamasında fazlaca işlemci zamanı tüketmektedir. Tanımlayıcı hesaplandıktan sonra oluşturulan vektörlerin boyutlarının azaltılması için TBA [36] veya *Doğrusal Diskriminant Analizi* [27] gibi boyut azaltma teknikleri kullanılmaktadır. BRIEF yönteminde ise ayrıca bir boyut azaltma yapılmadan, doğrudan düşük maliyetli bir tanımlayıcı hesaplanabilmektedir. Öznitelikler tespit edildikten sonra her bir özneliğin yerel komşuluğunda örnekleme yapılarak belli sayıda piksel çifti seçilir. Seçilen bu piksellerin parlaklık değerleri arasında büyüklük-küçüklük ilişkisine göre her bir vektör için, 1 ve 0 değerlerinden oluşan (ikili), tanımlayıcı vektör oluşturulur. Eşleme aşamasında farklı görüntülerden çıkarılan öznitelikler Hamming mesafe fonksiyonu kullanılarak karşılaştırılır.

Önerilen yöntemin gri seviyeli görüntüler üzerinde test edilmesi için SIFT [34] öznitelikleri kullanılmıştır. Bu yöntemde öznitelik tespiti için Gaussian'lar Farkı (DoG) tekniği kullanılır. Verilen görüntü çeşitli oranlarda küçültüldükten sonra Gaussian operatörü kullanılarak yumuşatılır ve Gaussian piramidi oluşturulur. Piramidin her bir basamağında yine çeşitli seviyelerde Gaussian operatörü uygulanır ve seviyelerin farkı alınarak piramidin mevcut seviyesinde görüntü üzerinde belirgin bölgeler, diğer adıyla öznitelikler, çıkarılır. Bu aşamada özniteliklerin sayısı oldukça fazla olduğundan maksimum cevaba sahip olmayanların bastırılması, eğim değeri önceden belirlenmiş bir eşik değerinin altında kalanların ve köşe cevabı düşük olanların silinmesi gibi işlemlerle bu sayı azaltılır. Daha sonra yakın komşulukları kullanılarak her bir özneliğe baskın yönü atanır. Son olarak yine yakın komşulukları kullanılarak her bir öznitelik

için 128 boyutlu tanımlayıcı vektör oluşturulur. Eşleme aşamasında farklı görüntülerin öznitelikleri en yakın komşu yöntemiyle 128 boyutlu vektör uzayında karşılaştırılır. Önerilen yöntemde SIFT özniteliklerinin, diğer özniteliklere tercih edilmesinin özel bir nedeni yoktur, deneyler için kullanılan platform gereği SIFT öznitelikleri daha uygun bulunmuştur.



3. İSKELETSEL KRİTİK NOKTALAR İLE ŞEKİL TANIMA

Bu bölümde önerilen yöntem detaylı bir biçimde anlatılmıştır. Şekillerin iskeleti çıkarılmış, her bir iskelet geometrik uzaya alınmış ve iskeletler arasında eşleştirme yapılarak şekiller sınıflandırılmıştır. Yapılan işlemler Algoritma-2 ve Şekil-1.1'de gösterilmiştir.


3.1 İskelet Çıkarma

Verilen bir şekiller, iskelet isimli, diğer adıyla orta eksen, bir yöntemle temsil edilebilir. İskelet üzerindeki her bir nokta, şeklin sınırları üzerinde birden fazla noktaya en yakın mesafede bulunur. Böylece bu noktaların oluşturduğu küme, şeklin simetri eksenini üzerinde bulunur. Geçmişte şekillerin simetri eksenini hesaplamak için çeşitli yaklaşımlar yapılmış olsa da, en çok bilinen ve kullanılan yöntem [6] çalışmasında verilen *grassfire* dönüşümüdür. Bu yaklaşımda, şeklin yüzeyinin aşağıdaki özelliklere sahip bir malzemedен yapıldığı varsayılmıştır:

1. Uyarma (*Excitation*) - her nokta 0 ya da 1 değerine sahip olabilir
2. Yayılma (*Propagation*) - uyarılmış her bir nokta, aradaki mesafeyle orantılı bir gecikmeyle, komşu bir noktayı uyarır
3. Durgunluk Süresi (*Refractory Time*) - bir nokta uyarıldığında, belli bir zaman dilimi içinde, bir daha uyarılamaz

Bu özelliklere sahip bir şekil sınır noktalarından uyarıldığında, iki sinyal birbiri içinden geçmeyecek şekilde sinyaller yayılır ve simetri ekseninde buluşarak orta eksenini oluşturur. Dönüşüm, sürekli bir örnek uzayı için iyi bir tanım olsa da, sanal ortamda görüntülerin ifade edildiği piksellerden oluşan ayrık düzlemde birtakım bozulmalar kaçınılmaz olmaktadır.

Literatür araştırması kısmında da bahsedildiği üzere, iskelet temsilini çeşitli yollarla iyileştiren çalışmalar yapılmıştır. Önerilen çalışmada şekillerin iskeletinin çıkarılması için kullanılan yöntemde [51], iskelet büyümesi (*growth*) ve budanması için iskeletin



Şekil 3.1: Önem fonksiyonu *Bending Potential Ratio*, şeklin dış kenarları üzerinde seçilen iki noktadan ve genel olarak dış kenarların dışında bulunan bir noktadan yararlanır. [51] çalışmasından alınmıştır.

dalları üzerinde *Bending Potential Ratio (BPR)* adı verilen bir önem fonksiyonu tanımlanmıştır. Şekil-3.1'de gösterildiği üzere, şeklin dış kenarları içerisinde kalan noktalardan verilen bir noktanın iskelet noktası olup olmadığına karar verilirken, şeklin dış kenarları üzerinde seçilen iki noktadan ve genel olarak dış kenarların dışında bulunan bir noktadan yararlanır. Verilen nokta p ile gösterilirse, $R(p)$ şeklin dış kenarları üzerinde p 'ye ve p 'nin 8 komşuluğunda bulunan noktalara en yakın noktaların kümesini gösterir. p bir iskelet noktası olduğunda, $R(p)$ 'nin eleman sayısı 2 veya daha fazla olacaktır. $R(p)$ 'den seçilen q_1 ve q_2 noktaları arasındaki mesafe $d(q_1, q_2)$ ile gösterilir. q_1 ve q_2 noktaları arasında kalan doğruyu taban kabul eden ve $d(g, q_1) = d(g, q_2) = \frac{1}{2}l(q_1, q_2)$ şartını sağlayan bir g noktası kullanılarak ikizkenar bir üçgen tanımlanır. q_1gq_2 üçgeninin yüksekliği h_g ve bu üçgenle aynı tabanı paylaşan q_1pq_2 üçgeninin yüksekliği h_p 'dir. Bu noktada BPR $\varepsilon(p, q_1, q_2) = \frac{h_g}{h_p}$ olarak tanımlanır. Bu tanıma göre, h_g , ilgili dış kenar bölütü üzerinden şeklin yerel özelliklerini temsil ederken $\angle q_1pq_2$ açısı da yine ilgili bölütün genişliği üzerinden şeklin genel özelliklerini temsil eder. Böylece bir noktanın iskelet noktası olup olmadığına karar verilirken ilgili dış kenar bölütünün dışbükeyliğinin yanında, bu dışbükeyliğin şeklin geneline göre ne kadar anlam taşıdığına da bakılır.

Aynı çalışmada, iskelet budama için tanımlanan bu önem fonksiyonu kullanılarak iskelet oluşturma için de bir yöntem tanımlanmıştır. Yine, q_1 ve q_2 , $R(p)$ kümesine ait iki nokta olmak üzere, p noktasının budanmış iskelete ait bir nokta olması için kriter tanımlanmıştır. Buna göre,

Algorithm 1: BPR yöntemiyle şekillerin iskeletinin çıkarılması için kullanılan algoritma. [51] çalışmasından alınmıştır.

Data: F

Result: Sk

$\kappa(p_m)$ 'i minimum yapacak şekilde $p_m \in F$ noktası seç;

if p_m kriteri tatmin ederse **then**

 | $(p_m, \kappa(p_m))$ 'i Sk'ya ekle ve p_m 'i S yığıtına it;

end

while S boş olmadığı sürece **do**

 | $p \leftarrow \text{çek}(S)$;

for Kriteri sağlayan p 'nin 8 komşuluğunda bulunan x noktası **do**

 | $(x, \kappa(x))$ 'i Sk'ya ekle ve x 'i S yığıtına it;

end

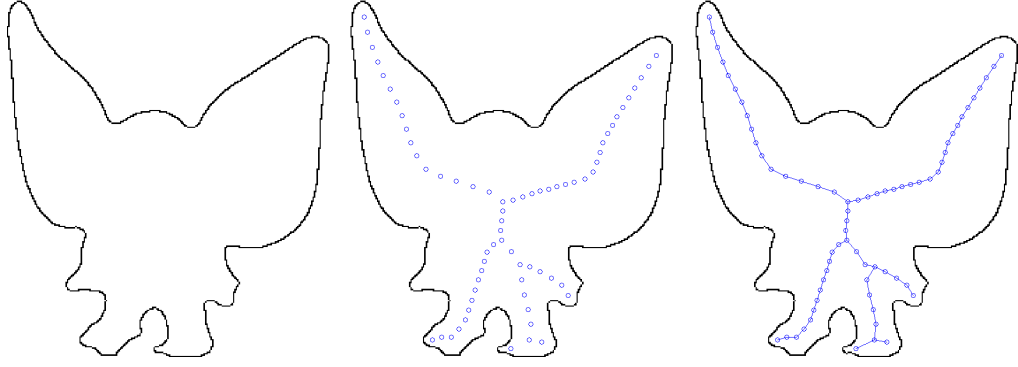
end

$$d^2(p, q_1) - d^2(p, q_2) \leq \max(\text{abs}(x_1 - x_2), \text{abs}(y_1 - y_2)),$$
$$\varepsilon(p, q_1, q_2) > t$$

kriterini tatmin eden p noktası bir iskelet noktasıdır. Burada t , BPR için dışarıdan sağlanan bir eşik değeridir. Verilen bir şeklin iskeleti, Algoritma-1'deki yöntemle bulunur. Burada F verilen şeklin sınırları içinde kalan noktalar kümesini temsil eder ve $\kappa(p)$ fonksiyonu, p noktası F'in bir elemanıysa $\min_{v \in C} d(p, v)$; değilse 0 olarak tanımlanır.

3.2 Orta Eksen Çizgesi

Bir şeklin bölümleri orta eksen çizgesi ile temsil edilebilir. Bu temsilde, her düğüm şeklin iskeletine ait bir noktayı gösterir ve her kenar birbirine komşu olan iki düğümü bağlar. Metnin devamında iskelet noktası ile orta eksen çizgesine ait düğüm kavramları birbirinin yerine kullanılmıştır. Sunulan çalışmada, şekillerin iskeletleri elde edildikten sonra, iskelet noktalarının komşuluklarının bulunabilmesi için Minimum Yayılan Ağaç algoritması kullanılmıştır. Sonlu sayıda nokta içeren bir noktalar kümesi verildiğinde, MYA algoritması, ağırlığı diğer yayılan ağaçlardan büyük olmayan bir yayılan ağaç verir. İskelet noktalarından ve her bir nokta çiftini birbirine bağlayan kenarlardan oluşan bir *tam çizge* oluşturulduktan sonra MYA algoritması kullanılarak orta eksen çizgesi elde edilmiştir. Orta eksen çizgesi oluşturma işlemi Şekil-3.2'de gösterilmiştir.



Şekil 3.2: Minimum Yayılan Ağaç algoritması kullanılarak iskelet noktaları arasındaki komşuluklar bulunmuştur. Şekiller soldan sağa, söz konusu şekli, şeklin iskeleti bulunduktan sonra iskelet noktalarını ve orta eksen çizgesini göstermektedir.

3.3 Kritik Noktaların Bulunması

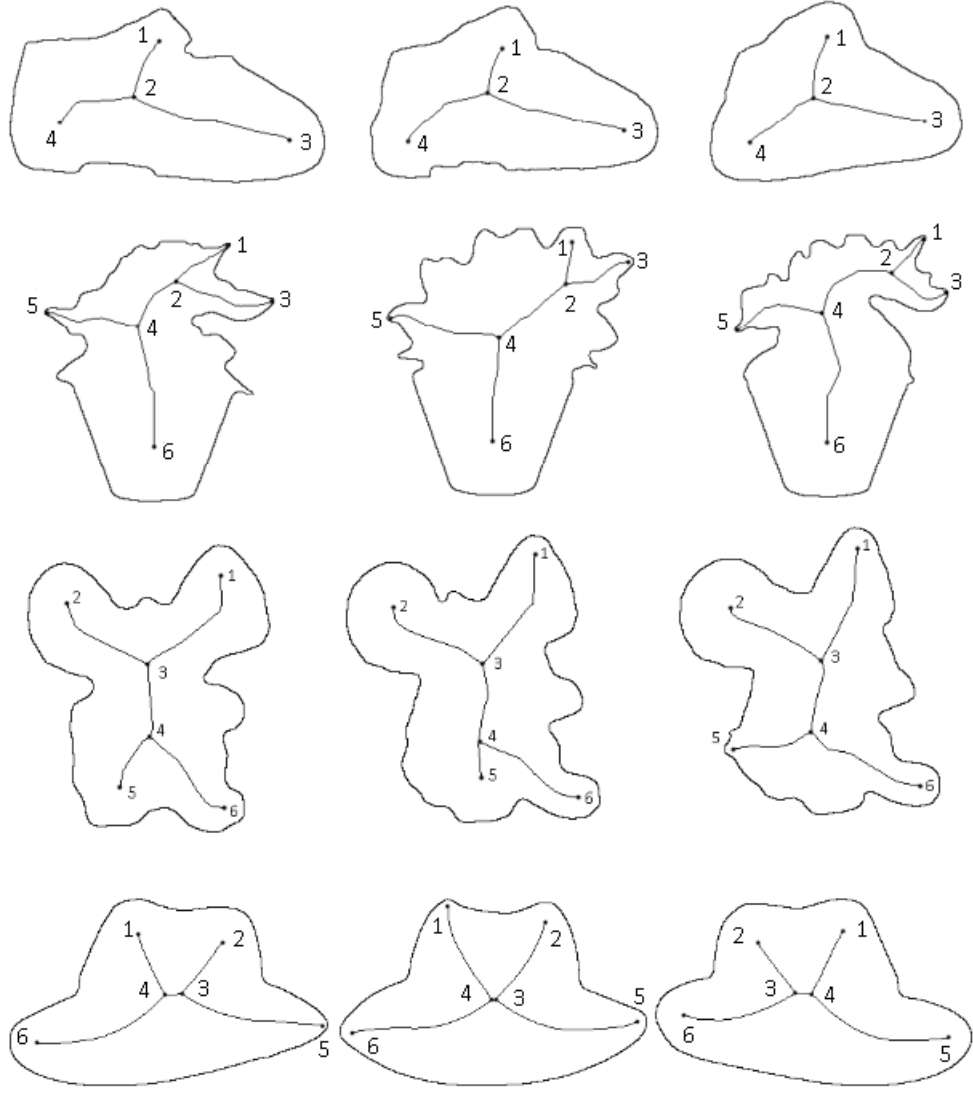
Orta eksen, şeklin birbirinden farklı bölgelerinin simetrik yapılarını gösterir [6] ve çizgenin dallarının bu bölgeleri temsil ettiği düşünülebilir. Bundan dolayı çizgedeki bir kritik nokta en az üç farklı bölgenin kesişim noktasıdır. Şeklin kısımlarının daha belirleyici olarak temsil edilebilmesi için derecesi 3 olan noktalar yanında derecesi 1 olan noktalar da kritik nokta olarak alınmıştır. Şekil-3.3, iskeleti çıkarılmış bir şekildeki kritik noktaları göstermektedir. Buradaki şekiller farklı açılardan görüntülenmiş olmalarına karşın kritik noktaları şeklin benzer kısımlarını temsil etmektedir.

3.4 İskeletin Geometrik Uzayda Temsil Edilmesi

Kritik noktalar bulunduktan sonra, her noktanın çizge üzerinde tüm kritik noktalara olan en kısa yol uzaklıkları hesaplanarak şeklin iskeleti, eksenleri kritik noktalar olan çok boyutlu uzayda temsil edilir. Kritik noktalar $B = \{b_1, b_2, \dots, b_k\}$ ile gösterilmiş olsun. Bu durumda iskelet noktası s_i , k -boyutlu uzayda bir noktadır öyleki j . koordinat, s_i ve b_j arasındaki en kısa yolun ağırlığıdır. İki nokta arasındaki mesafeyi ölçek uzayında bulan Eberly'nin çalışmasından [18] yararlanılarak, iskelet noktaları s_i ve s_j arasındaki uzaklık $d(s_i, s_j)$ şu şekilde bulunur:

$$d(s_i, s_j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (r_i - r_j)^2} \quad (3.1)$$

Burada r_i (r_j) çizge üzerindeki söz konusu noktanın ait olduğu maksimum diskin yarıçapıdır. Çizge üzerindeki herhangi bir noktayla bir kritik nokta arasındaki en kısa yol uzaklığı $p = \{s_1, \dots, s_m\}$ ile gösterilirse bu yolun ağırlığı aşağıdaki eşitlikle ifade



Şekil 3.3: Şekiller, düğümleri iskelet noktalarını ve kenarları iskelet noktalarının komşuluklarını gösteren orta eksen çizgeleri ile temsil edilir. Kritik noktalar şeklin üç veya daha kısmının kesiştiği noktalardan ve bu kısımların bitiş noktalarından oluşur. Şekilde siyah noktalar kritik noktaları göstermektedir. Kritik noktalara verilen sayılar, metinde bahsedildiği gibi bu noktaların yerel histogramlarının kullanılarak hesaplanmış sıralamalarını göstermektedir.

edilir:

$$w(p) = \sum_{i=1}^{m-1} d(s_i, s_{i+1}). \quad (3.2)$$

İskeletin temsil edildiği uzayın boyut sayısını şeklin iskeletindeki kritik nokta sayısı belirlediğinden farklı şekiller farklı boyutta uzaylarda temsil edilecektir. Düşük sayıda ayırım düğümüne sahip iskeletlerin koordinatları sıfır ile doldurularak ve yüksek sayıda ayırım düğümüne sahip iskeletlerin koordinatları Temel Bileşen Analizi gibi bir boyut azaltma tekniği ile düşük boyutta temsil edilerek farklı sayıda kritik noktaya sahip iskeletler, sayısı önceden deneysel olarak belirlenmiş boyuta sahip bir uzayda temsil edilmiştir.

Çok boyutlu uzayda temsil edilen iskeletin oryantasyonu kritik noktaların sıralamasına bağlıdır; kritik noktalar farklı sıralamada alınarak aynı iskeletin farklı oryantasyonları elde edilebilir. İskeletler arasındaki benzerliğin tutarlı bir şekilde bulunabilmesi için kritik noktalar, belli komşuluktaki noktalarının yarıçaplarına göre oluşturulan yerel histogramlar gözetilerek sıralanmıştır. Bir kritik noktanın yerel komşuluğundaki noktalar, yarıçaplarına göre n aralıklı $H=(h_1, h_2, \dots, h_n)$ histogramı ile gösterilir. Burada h_i iskelette ilgili yarıçapa sahip komşu noktaların sayısını belirtmektedir. Stricker ve Orengo tarafından gösterildiği gibi histogram aralıklarının küçük bir miktar yer değiştirmesi, benzer resimlerin histogramlarının oldukça farklı çıkmasına neden olmaktadır [56]. Bu problemin sıralama işlemine olan etkisini azaltmak için kümülatif histogram kullanılmıştır. Her kritik nokta için hesaplanan kümülatif histogram $H = (h_1, h_2, \dots, h_n)$ ile gösterilirse her histogram için $\alpha_1 \times h_1 + \alpha_2 \times h_2 + \dots + \alpha_n \times h_n$ değeri hesaplanır ve kritik noktalar bu değerlere göre sıralanır. Burada her α , $0 < \alpha < 1$, $\alpha_1 \leq \alpha_2 \leq \dots \leq \alpha_n$ ve $\sum_{i=1}^n \alpha_i = 1$ olmak üzere bir sabittir. Şekil-3.3'de ayırım düğümleri sıralaması verilen şekiller gösterilmektedir.

3.5 İskeletlerin Eşleştirilmesi

Son adım, çok boyutlu uzayda birer dağılım olarak temsil edilen iskeletlerin Toprak Taşıyıcı Mesafesi kullanılarak eşleştirilmesidir [43]. TTM metodu birçok çalışmada başarılı bir şekilde kullanılmıştır [29, 53, 64, 67]. P_1 ve P_2 sırasıyla n ve m sayıda nokta içeren nokta kümelerini, $D = [d_{ij}]$ yersel mesafe matrisini temsil eder. Burada d_{ij} , $s_i \in P_1$ ve $s_j \in P_2$ arasındaki yersel mesafeyi gösterir ve Eşitlik-3.1 ile hesaplanır. Amaç, $F = [f_{ij}]$ akış matrisini hesaplamaktır, f_{ij} p_i ve p_j arasındaki akışı temsil eder ve yapılan işi minimize eder:

$$\text{Work}(P_1, P_2, F) = \sum_{i=1}^m \sum_{j=1}^n f_{ij} d_{ij} \quad (3.3)$$

Yapılan iş minimize edilirken aşağıdaki kısıtlar sağlanır:

$$\begin{aligned} f_{ij} &\geq 0, \quad 1 \leq i \leq m, \quad 1 \leq j \leq n \\ \sum_{j=1}^n f_{ij} &\leq w_{s_i}, \quad 1 \leq i \leq m \\ \sum_{i=1}^m f_{ij} &\leq w_{s_j}, \quad 1 \leq j \leq n \\ \sum_{i=1}^m \sum_{j=1}^n f_{ij} &= \min \left(\sum_{i=1}^m w_{p_i}, \sum_{j=1}^n w_{q_j} \right), \end{aligned}$$


Burada $w_{s_i}(w_{s_j})$, $s_i(s_j)$ iskelet noktasına ait maksimum diskin yarıçapını temsil etmektedir.

Önerilen çalışmanın performansını artırmak için FastEMD [39] algoritması kullanılmıştır. Bu yöntemde, histogramlar arasındaki yersel mesafeler, önceden belirlenmiş bir eşik değerine yaklaştırılır, çalışmadaki ifadeyle doyurulur. Orijinal TTM fonksiyonunda kullanılan yersel mesafelerde olduğu gibi, burada da eşik değerine doyurulmuş mesafelerin metrik olma özelliğine sahip olduğu gösterilmiştir. Çalışmanın esas katkısı, eşik değerine doyurulmuş yersel mesafeleri oldukça hızlı bir biçimde hesaplayabilen bir algoritma sunmasıdır.

Aralarındaki mesafe hesaplanacak histogramlardan biri N aralığa sahip olsun. Bu durumda orijinal TTM yönteminde akış ağı $N^2 + N$ kenara sahip olur. N^2 tane kenar başlangıç düğümlerini bitiş düğümlerine bağlar. Kalan N kenar, başlangıç düğümlerini histogramların arasındaki farkı alan bitiş düğümlerine bağlar. Yapılan dönüşümde ilk olarak masrafı eşik değeri t 'ye eşit olan tüm kenarlar silinir. Daha sonra aktarma düğümü eklenir ve tüm başlangıç düğümleri bu düğüme bağlanır. Son olarak aktarma düğümü, masrafı 0 olan kenarlarla bitiş düğümlerine bağlanır. Böylece, yeni akış ağı $N(K + 3)$ kenara sahip olur. K , her bir aralıktan çıkan ve masrafı t 'den farklı olan ortalama kenar sayısını göstermektedir. Çalışmada, orijinal ve dönüşüme uğratılmış akış ağları üzerinde tanımlı en düşük maliyetli akış probleminin (*min-cost-flow*) aynı en düşük maliyetli akışa sahip olduğu gösterilmiştir.

3.6 Yöntemin Algoritması ve Zaman Karmaşıklığı

Bu bölümde, yöntemin algoritması verilmiş ve zaman karmaşıklığı analizi yapılmıştır.



Şekil 3.4: Yersel mesafeleri $d(a, b) = \min(2, \text{abs}(a - b))$ olarak tanımlanan akış ağı üzerinde örnek bir dönüşüm. (a)'da $N^2 + N$ kenara sahip orijinal akış ağı. Bu ağda bulunan $N(N - 3)$ tane kenar 2 masrafına sahip. Sol altta bulunan mavi düğüm, histogramların toplam ağırlığı arasındaki farkı alan bitiş düğümü. (b)'de dönüşüme uğramış akış ağı. Çizgili sarı dikdörtgenle gösterilen düğüm aktarma düğümü. Gelen kenar masrafı eşik değeri (burada 2) ve giden kenar masrafı 0'dır. [39] çalışmasından alınmıştır.

Algorithm 2: İskelet noktalarının geometrik uzayda temsili.

Data: Şekil Veri Seti S_D
Result: Şekillerin L_D Geometrik Uzayında Temsili
 $L_D \leftarrow$ şekillerin geometrik uzayda temsili;
foreach Şekil S in S_D **do**
 $K \leftarrow$ iskeletÇıkar(S); $C \leftarrow$ herhangiİkiDüğümüBağla(K); $T \leftarrow$ MYA(C);
 $B \leftarrow$ kritikNoktalar(T); $B \leftarrow$ Bölüm-3.4'e göre B 'yi sırala;
 $L \leftarrow L_D$ 'de S 'in temsili; $d_D \leftarrow L_D$ 'nin boyut sayısı;
 $s \leftarrow S_D$ 'de S 'in indeksi;
 foreach Nokta p_T in T **do**
 foreach Nokta p_B in B **do**
 $t \leftarrow p_T$ 'nin T 'deki indeksi;
 $b \leftarrow p_B$ 'nin B 'deki indeksi;
 $L(t, b) \leftarrow$ enKısaYol(p_T, p_B);
 end
 end
 if boyut(B) $\leq d_D$ **then**
 $L \leftarrow$ sıfırDoldur($L, d_D -$ boyut(B));
 else
 $L \leftarrow$ TBA(L, d_D);
 end
 $L_D(s) \leftarrow L$;
end

Algorithm 3: Uzaklık matrisinin hesaplanarak iskeletlerin eşleştirilmesi.

Data: Şekillerin L_D Geometrik Uzayında Temsili

Result: Uzaklık Matrisi M_D

```
for  $i \leftarrow 1$  to  $\text{boyut}(L_D)$  do
  for  $j \leftarrow 1$  to  $\text{boyut}(L_D)$  do
     $M_D(i,j) \leftarrow \text{FastEMD}(L_D(i), L_D(j))$ ;
  end
end
```

Algoritma-2’de şekillerin geometrik uzaya alınma işlemleri verilmiştir. Algoritma-3’de ise elemanları geometrik uzaya alınan şekiller arasındaki TTM uzaklıklarından oluşan uzaklık matrisinin hesaplanması gösterilmiştir. Algoritma-2’deki işlemler gerçek zamanlı olmayıp, verilen bir şeklin tanınması işleminden önce veri setindeki görüntüler üzerinde çalıştırılmaktadır. Algoritma-3’deki işlemler ise tanıma işlemi sırasında çalıştırılmaktadır. Şekil tanıma işlemi sırasında uzaklık matrisinin yalnızca verilen şekle karşılık gelen satırındaki uzaklıkların hesaplanması, o şeklin tanınması için yeterlidir.

Yöntemin zaman karmaşıklığının bulunabilmesi için verilen algoritmalar üzerinde karmaşıklık analizi yapılmıştır. Şekillerin iskeletlerinin çıkarılması için kullanılan yöntemin [51] çalışma zamanı $O(rP + b)$ ’dir. Burada b , iskeleti çıkarılan şeklin kenar noktaları sayısını, r hakim nokta sayısını ve P şeklin sınırları içinde kalan nokta sayısını göstermektedir. Hakim nokta sayısı genellikle 3 veya 4 olduğundan kullanılan iskelet çıkarma yönteminin çalışma zamanı $O(P + b)$ ’dir.

Yöntemin kalan kısmının analizinde, verilen bir şekil S için n şeklin iskelet noktaları sayısını, c iskeletteki kritik nokta sayısını, k Bölüm-3.4’de gösterildiği üzere kritik noktaların sıralanması için kullanılan komşu sayısını ve t veri setindeki görüntü sayısını göstermektedir. Prim’in MYA algoritması Bölüm-3.2’de söz edilen tam çizge üzerinde kullanıldığında, şeklin iskeletinden orta eksen çizgesi bulunması $O(n^2 \log n)$ zaman almaktadır. Kritik noktaların sıralanması $O(c \log c)$ zaman almaktadır. Fakat kritik noktaların sıralanması kısmında baskın gelen işlem her kritik noktanın k komşuluğundaki noktaların bulunması olduğundan sıralama işlemi için harcanan zaman $O(n^2 + cn \log n)$ ’dir. Şekilleri geometrik uzaya alma işlemi iki alt kısımdan oluşmaktadır. Dijkstra’nın en kısa yol algoritması kullanılarak kritik noktalar ile diğer iskelet noktaları arasındaki uzaklıkları bulmak $O(cn \log n)$ ve şekiller geometrik uzaya alındıktan sonra TBA yöntemiyle boyut azaltılması $O(nc)$ zaman almaktadır [8]. Kullanılan veri setlerindeki resimlerde gözlemlendiği kadarıyla kritik nokta sayısı 40’ın üzerine çıkmadığından c bir sabit kabul edilip yok sayılabilir. Söz edilen bu işlemler arasında baskın olan işlem $O(n^2 \log n)$ çalışma zamanına sahip MYA’dır.

Şekillerin geometrik uzayda temsil edilmesinden sonra TTM kullanılarak her iki şekil arasındaki uzaklık hesaplanmıştır. TTM hesaplamasını hızlandırmak için kullanılan yöntemin [28] zaman karmaşıklığı $O(n^2 \log n)$ 'dir. Tanıma işlemi sırasında verilen şekil ile veri setinde bulunan tüm şekiller arasındaki uzaklıklar bulunduğundan eşleme işleminin zaman karmaşıklığı $O(tn^2 \log n)$ olmaktadır. Eşleme kısmı yöntemde baskın gelen kısım olduğundan yöntemin zaman karmaşıklığının $O(tn^2 \log n)$ olduğu sonucuna varılır.



4. DENEYSEL ÇALIŞMALAR


Önerilen yöntem, Aslan-Tari, ALOI (Amsterdam Library of Object Images) ve ETH-80 olmak üzere üç şekil veri seti üzerinde test edilmiştir. İlk olarak deney ortamı anlaşılmıştır, daha sonra veri setlerinden bahsedilmiş ve son olarak deneylerde elde edilen sonuçlar, önceki birtakım çalışmaların sonuçlarıyla karşılaştırılarak verilmiştir.

4.1 Deney Ortamı

İskeletin Çıkarılması: Şekillerin iskeletinin dış kenarlardaki küçük değişimlere karşı hassas olduğu bilinmesine karşın bu hassaslık, dış kenar noktalarının iskeletin çıkarılmasından önce işlenmesiyle veya çıkarılan iskeletler üzerinde yapılan çeşitli işlemlerle azaltılabilmektedir. Önerilen çalışmada iskeletlerin şekillerin dış kenarlarında meydana gelen bozulmalara olan hassaslığını en aza indirgeyebilmek için *Bending Potential Ratio (BPR)* [51] kullanılmıştır. BPR, iskeletin dalları üzerinde bir önem fonksiyonu tanımlayarak, budanacak dalları iskelete en az katkı sağlayan dallar arasından seçmektedir. Çalışmada, yöntemin *bprthreshold* ve *chordthreshold* parametreleri için çeşitli değerler denenmiş ve alınan başarımlar kontrol edilmiştir. Fakat sonuç olarak bu parametrelerin varsayılan değerleri olan, sırasıyla, 0.8 ve 9 değerleri kullanılmıştır.

Toprak Taşıyıcı Mesafesi: Önceden de bahsedildiği üzere, önerilen çalışmada toprak taşıyıcı mesafesini bulunurken, büyük veri setlerinde fazla zaman kaybetmemek adına, FastEMD [39] metodu kullanılmıştır. Bunu gerçekleştirmek için FastEMD metodunda yersel mesafeler üzerinde tanımlanmış bir eşik değeri kullanılarak akış ağındaki kenar sayısını azaltılır. Eşik değeri hatalı bir şekilde seçildiği takdirde eşleme doğruluğu düşmektedir. Ayrıca farklı veri setleri farklı sayıda ve şekilde objelere sahip görüntüler içerdiğinden her bir veri seti için eşik değeri ayrıca belirlenmelidir. Önerilen çalışmada kullanılan veri setleri için eşik değerleri eğitim kümeleri üzerinde deneysel olarak belirlenmiştir. Aslan & Tari, ALOI ve ETH-80 veri setleri için eşik değerleri sırayla 10.0, 130.0 ve 50.0 olarak belirlenmiştir.

Değerlendirme: Sonuçların elde edilmesi için *birini çıkar* yöntemi kullanılmıştır. Bu yöntemde ilk şekil veri setinden çıkarılmış ve geri kalan şekiller üzerinde sorgu objesi olarak kullanılmıştır. Sorgu için kullanılan şekil tekrar veri setine koyulduktan sonra



Şekil 4.1: Aslan & Tari veri seti 14 sınıf ve her sınıfta 4 şekilden oluşan, toplam 56 şekle sahip bir veri setidir. Her satır iki farklı sınıftan oluşan şekilleri göstermektedir.

























yöntem bir sonraki şekilden devam etmiş ve böylece veri setindeki tüm şekiller sorgu için kullanılmıştır. Doğru bir sınıflandırmada, şekil eşleme algoritması sorgu için kullanılan şeklin en yakın komşusu olarak bu şekille aynı sınıftan bir şekil vermelidir. Bu durumda eşleme doğru kabul edilmektedir.

4.2 Aslan & Tari Veri Seti

Aslan & Tari veri seti [2] Şekil-4.1’de gösterildiği gibi 14 sınıf ve her sınıfta 4 şekilden oluşan, toplam 56 şekle sahip bir veri setidir. Bu veri setinin seçilme nedeni sınıflar arasında gösterdiği yüksek değişkenliktir. Önerilen yöntem, bu veri setini kullanan iki çalışma ile karşılaştırılmıştır. İlk yöntemde [57] parça tabanlı bir yaklaşım kullanılarak şekillerin dış kenar bölütleri düzlemsel dönüşümlere dayanıklı bölüt uzayında eşlenmektedir. İkinci yöntemde de benzer bir metot kullanılmıştır [71]. Fakat burada dış kenar bölütleri yerine iskelet yolları kullanılmıştır. Bir iskelet yolu, iskeletin iki uç noktası arasındaki en kısa yol olarak tanımlanır. Şekil S_i ile sınıf C_j arasındaki mesafe, Bayesian tabanlı bir yöntemle, S_i deki her bir iskelet yolunun C_j deki tüm şekillerin iskelet yollarıyla arasındaki fark olarak bulunur.

Çizelge 4.1: Aslan & Tari veri seti üzerinde sonuçların karşılaştırılması

	Önerilen Yöntem	Sun&Super ^[57]	Yang et al. ^[71]
Aslan&Tari	%96.4	%92.8	%98.2

Sorgu	1	2	3
			
			
			
			
			
			

Şekil 4.2: Aslan & Tari veri setinde elde edilen sınıflandırma sonuçlarının bir kısmı. En soldaki sütun sorgu için kullanılan şekilleri göstermektedir. Sonraki üç sütundaki şekiller karşılık gelen sorgu şekline olan benzerliklerine göre sıralanmıştır. Yanlış sınıflandırılan şekiller kutu içine alınmıştır. Farklı sınıflara ait benzer şekiller görüldüğü üzere yanlış sınıflandırılabilir.

En yakın komşu sınıflandırıcısından elde edilen sonuçlara göre, [57] ve [71] çalışmalarında sunulan yöntemler sırayla 4 ve 1 yanlış sonuç vermiştir, önerilen çalışmada ise 2 yanlış sonuç alınmıştır. Buna göre sınıflandırma başarımları yüzdeleri önerilen yöntem için %96.4, [57] çalışmasında %92.8 ve [71] çalışmasında %98.2 olarak hesaplanmıştır. Başarımları yüzdeleri Çizelge-4.1’de gösterilmiştir. Yanlış sınıflandırmalar çoğunlukla iskeletleri benzer olan farklı şekillerden kaynaklanmaktadır, örneğin fil ve kedi, yıldız ve palmye ağacının üst kısmı, çiçek ve timsah şekillerinin iskeletleri birbirine benzer çıkmaktadır. Şekil-4.2’de eşleştirme sonuçlarının bir kısmı gösterilmektedir. İskeletler benzer olduğunda, iskeletlerin kritik noktaları ve bu kritik noktalar kullanılarak oluşturulmuş geometrik uzaydaki pozisyonları da benzer olmaktadır. Daha güçlü bir iskelet çıkarma algoritması kullanıldığında eşleme sonuçlarının iyileşmesi beklenmektedir.



Şekil 4.3: İlk dört satır kullanılan veri setindeki her sınıftan bir örnek şekil içermektedir. En alt satırda ise bir sınıfın farklı oryantasyonlarından örnek şekiller gösterilmektedir.













































4.3 ALOI Veri Seti

Deneyleerde kullanılan ikinci yöntem Amsterdam Library of Object Images (ALOI) veri setidir [23]. ALOI veri seti farklı oryantasyonlar ve ışıklandırma koşulları altında çekilmiş 1000 obje resminden oluşmaktadır. Önerilen çalışmada ALOI veri setinin 20 objeden oluşan bir alt kümesi kullanılmıştır. Kullanılan veri setinde 20 obje ve her obje için 72 şekil olmak üzere toplam 1440 şekil bulunmaktadır. Komşu iki şekil arasında 5 derecelik dönüş açısı farkı vardır. Şekil-4.3 ilk 4 satırda her sınıftan bir örnek şekli göstermektedir, en alt satırda ise bir sınıfın farklı oryantasyonlarından örnek şekiller gösterilmektedir.

Önerilen yöntemin sonuçlarını test etmek için SC ve IDSC metodları bu veri seti üzerinde denemiş ve sonuçları verilmiştir. Çizelge-4.2’de de gösterildiği gibi önerilen yöntemin başarıımı %95.35 iken SC ve IDSC metodları sırayla %96.64 ve %100 sonuçlar vermiştir. SC ve IDSC yöntemleri daha yüksek başarıma sahip olmakla beraber önerilen yöntemin başarıımı da oldukça yüksektir. Şekil-4.4’de örnek sorgu objeleri ve önerilen yöntemin verdiği sonuçlar gösterilmiştir. Yanlış sınıflandırmalar kutu içine alınmıştır. Aslan & Tari veri setinde olduğu gibi yanlış sınıflandırmalar çoğunlukla izleme açısına bağlı olarak farklı sınıftan objelerin benzer şekiller sahip olmasından kaynaklanmaktadır. Bundan dolayı, "big smurf" ve "windmill", "mouse" ve "big pink eared animal", "toy keys" ve "eland", "water sprayer" ve "tea pot" objelerinin iskeletlerinin yüksek benzerliğe sahip olması sınıflandırma sonuçlarını olumsuz yönde etki-

Çizelge 4.2: ALOI veri setinin kullanılan alt kümesi üzerinde sonuçların karşılaştırılması.

	Önerilen Yöntem	SC [5]	IDSC [32]
ALOI	%95.35	%96.64	%100

Sorgu	Sonuç	Sorgu	Sonuç	Sorgu	Sonuç	Sorgu	Sonuç
	B.P. Eared Animal		B.P. Eared Animal		Big Smurf		Big Smurf
	Windmill		Windmill		Bonsai Tree		Bonsai Tree
	Eland5		Eland		Feather Ring		Feather Ring
	Halter Toy		Halter Toy		Head		Head
	Mouse		Mouse		Plant In Pot		Plant In Pot
	Shell7		Shell7		Shoe		Shoe
	Smiling Duck		Smiling Duck		Toy Keys		Toy Keys
	Water Sprayer		Water Sprayer		Cup		Cup
	Shoe		Shoe		Wooden Massage		Wooden Massage
	Princess		Princess		Tea Pot		Tea Pot
	Windmill		B.P. Eared Animal		Eland		Tea Pot

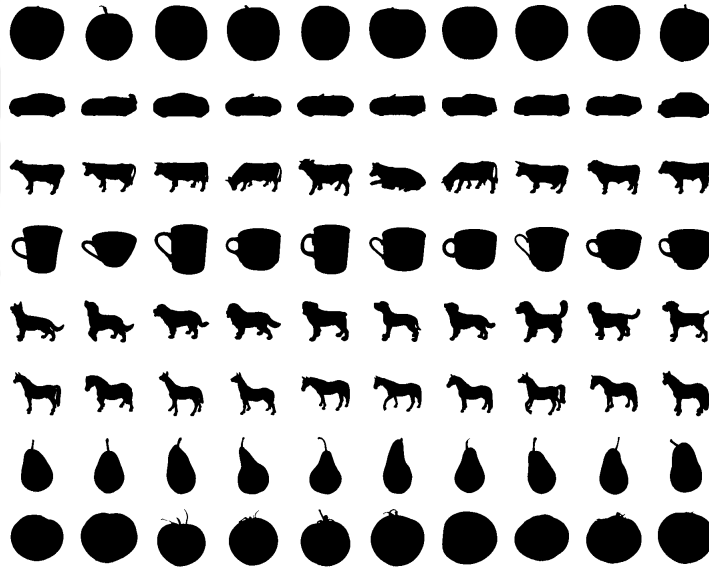
Şekil 4.4: Sınıflandırma sonuçlarının bir kısmı. İlk on satır doğru sınıflandırmaları gösterirken, en alt satırda üç yanlış sınıflandırma gösterilmektedir. Yanlış sınıflandırmalar çoğunlukla izleme açısına bağlı olarak farklı sınıftan objelerin benzer şekiller sahip olmasından kaynaklanmaktadır.

lemektedir.

4.4 ETH-80 Veri Seti

Önerilen yöntem ayrıca 8 sınıftan oluşan 80 obje içeren ETH-80 veri seti üzerinde de test edilmiştir. Her objenin değişik izleme açılarından çekilmiş 41 şekli olmak üzere veri setinde toplam 3280 şekil bulunmaktadır. Veri setinde renkli resimler ve her resim

için verilmiş siyah beyaz maskeler mevcuttur. Önerilen yöntemde siyah beyaz maskeler kullanılmıştır. Şekil-4.5’de her satırda belli bir sınıfa ait objelerden birer tane gösterilmiştir. Önerilen yöntemin başarımını test etmek için sonuçlar SC, IDSC ve ECDS (Electrical Charge Distribution on the Shape) [30] olmak üzere üç farklı yöntemin sonuçlarıyla karşılaştırılmıştır. Bilindiği kadarıyla, mevcut çalışmaların içinde, literatürde ETH-80 veri setinin siyah beyaz görüntüleri üzerinde en iyi başarıyı veren yöntem ECDS’dir. ECDS, iki boyutlu geometrik uzayda şeklin yerel eğrilik özelliklerini ve bölümlerini temsil edebilen bir şekil tanımlayıcıdır. Tekniğin temelinde iki boyutlu bir şeklin yüklü bir iletken olduğu varsayılır ve yükler elektrostatik denge noktasına ulaştığında benzer şekiller benzer yük dağılımına sahipken farklı şekillerin yük dağılımı farklı olur. Çizelge-4.3’de de gösterildiği üzere, önerilen yöntemin başarımı SC, IDSC ve ECDS yöntemlerinin verdikleri başarıyla karşılaştırıldığında önerilen yöntem %87.47 başarıma sahipken sözü edilen yöntemler sırayla %86.40, %88.11 ve %89.27 başarımlar vermektedir.

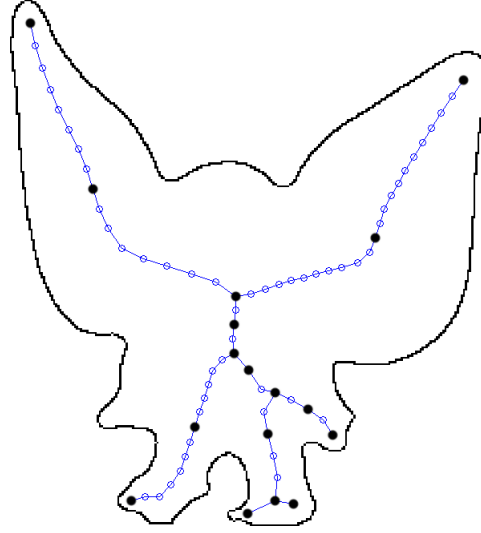


Şekil 4.5: ETH-80 veri seti 8 sınıftan oluşmaktadır. Her sınıfta 10 obje ve her obje için 41 görüntü olmak üzere toplamda 3280 görüntü vardır. Şekildeki her satırda belli bir sınıfa ait objelerden birer tane gösterilmektedir.

Çizelge 4.3: ETH-80 veri seti üzerinde sonuçların karşılaştırılması.

	Önerilen Yöntem	SC [5]	IDSC [32]	ECDS [30]
ETH-80	%87.47	%86.40	%88.11	%89.27

Kullanılan veri setleri üzerinde verilen başarımlar göz önüne alındığında, önerilen yöntemin başarımının literatürde en iyi sonuç veren metodların başarımlarına yakın olduğu



Şekil 4.6: Orta eksen çizgesi üzerinde kritik noktalar arasında kalan noktaların da kritik noktalar kümesine dahil edilmesi gösterilmiştir.

görülmemektedir. Bu da şekil eşleme alanında önerilen yöntemin potansiyelini göstermektedir. Bunun yanında, metodun performansını daha da artırabilmek için sözü edilen özneliliklerle beraber gözetimli makine öğrenmesi algoritmaları da kullanılmıştır. Geçmişte yapılan birçok çalışmada şekil tanıma yöntemlerinin performansını geliştirmek amacıyla makine öğrenmesi algoritmaları kullanılmıştır [16, 38, 41, 62]. Önerilen çalışmada da benzer bir yöntem izlenmiş ve bir gözetimli makine öğrenmesi algoritması kullanılarak sorgu şekli veri setinde var olan sınıflardan biriyle eşleştirilmiştir. Bölüm-6'de bahsedildiği üzere, şekillerin sınıflandırılması için ileri beslemeli yapay sinir ağları, destek vektör makineleri, karar ağaçları ve rastgele orman algoritmaları kullanılmış ve yapılan deneyler sonucu her üç veri seti üzerinde ileri beslemeli yapay sinir ağlarının en yüksek başarıyı verdiği gözlemlenmiştir.

4.5 Orta Noktaların Kullanımı

Kritik noktaların kullanılması, aynı sınıflar arasında, iskelet üzerindeki kararlı noktaların kullanılarak şekillerin temsil edilmesi olarak yorumlanabilir. Farklı bir bakış açısından bakıldığında ise kritik noktaların kullanımı, iskelet üzerinde örnekleme yapmak ve örneklenen bu noktaların iskeletin temsili için kullanılmasıdır. Bu yaklaşımdan esinlenerek önerilen çalışmada, iskeletin her bir dalı üzerinde iki kritik nokta arasında kalan noktalardan ortadaki bir nokta da kritik noktalar kümesinde dahil edilmiştir. Şekil-4.6'de verilen bir şeklin orta eksen çizgesi çıkarılmış ve orta noktaların da dahil edilmesiyle bulunan yeni kritik noktalar kümesi gösterilmiştir.

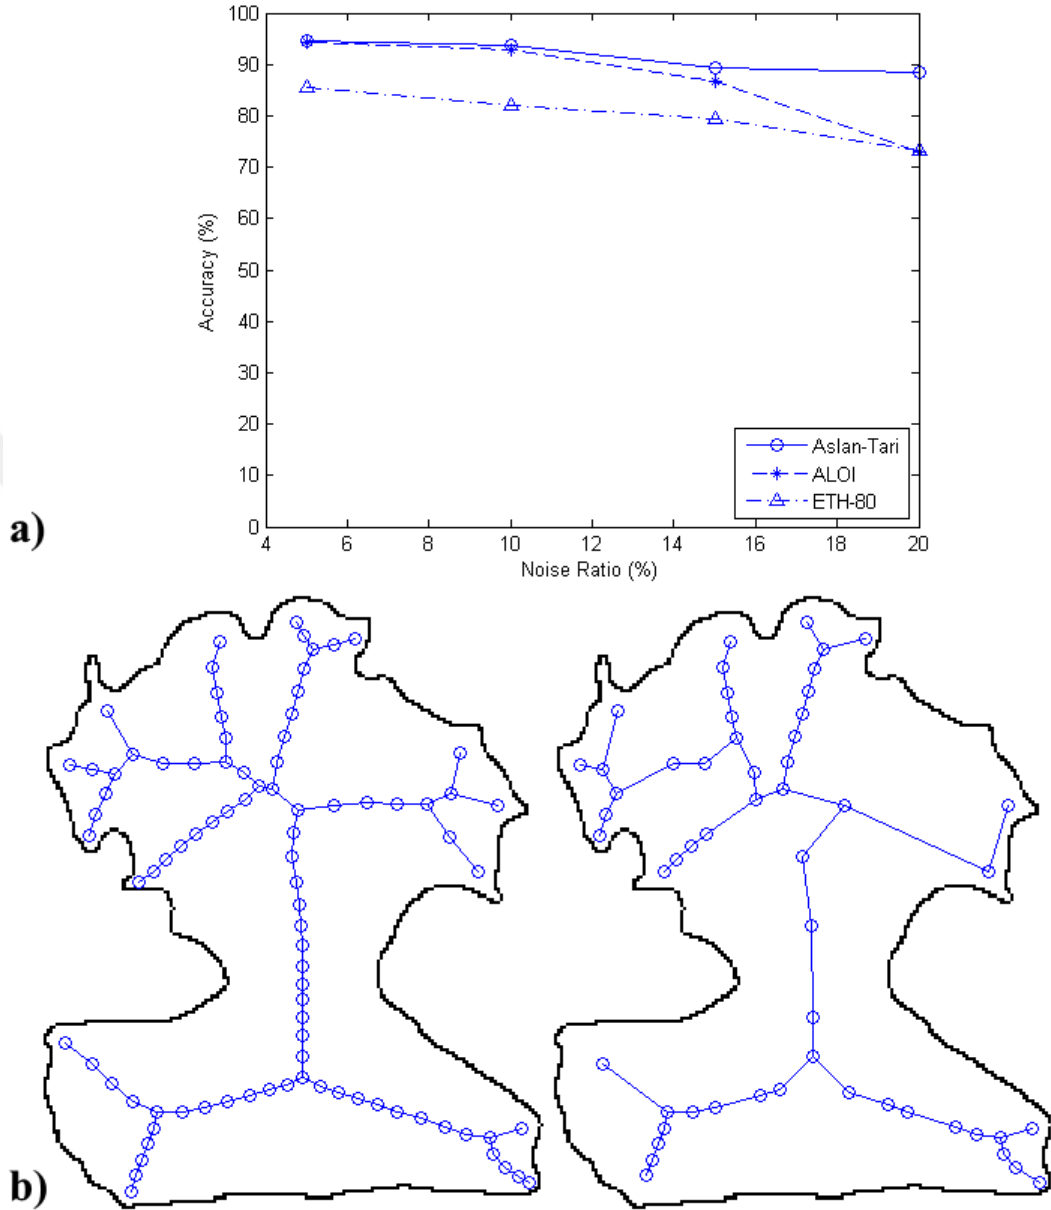
Bu yöntem ETH-80 veri seti üzerinde uygulandığında en yakın komşu sınıflandırıcı-

sından alınan başarımların %85'e düşmüştür. Bu durumun nedeni olarak orta noktaların, derecesi ≥ 3 veya 1 olan noktalara göre daha az kararlı olması gösterilebilir. Örnek olarak verilen Şekil-4.6'de de görülebileceği üzere bu yöntem, iskeletin görece daha kısa olan dallarını daha yoğun bir biçimde örneklemeye eğilimlidir ve izleme açısı, oryantasyon gibi faktörler değiştirildiğinde şekillerin yanlış sınıflandırılmasına yol açmaktadır.

4.6 Gürültüye Dayanıklılık Testi

Yöntemin gürültüye karşı dayanıklılığının test edilmesi için her bir veri setindeki şekillerin iskeletleri çıkarıldıktan sonra, şekildeki toplam iskelet noktası sayısının %5 ile %20 aralığında bir oranda, iskelet noktaları rastgele silinmiştir. Daha sonra tekrar birini çıkar ve 5 katlı çapraz doğrulama yöntemleri kullanılarak deneyler tekrarlanmıştır. Alınan sonuçlara göre, %10 gürültü altında, her bir veri setinde en yakın komşu sınıflandırıcısı kullanılarak elde edilen başarımlar %2.7 ile %6 arası bir oranda düşüş yaşanmıştır. Gürültü altında elde edilen başarımlar Şekil-4.7 a) da verilmiştir. Gürültü oranı arttıkça Aslan & Tari veri setinde elde edilen başarımların diğer iki veri setinde elde edilen başarımlara göre daha yavaş bir şekilde düştüğü gözlemlenmiştir. Ayrıca, gürültü seviyesi %15'den %20'ye çıktığında ETH-80 veri setinde elde edilen başarımların ALOI veri setinde elde edilen başarımlardan daha az düştüğü görülmektedir. ALOI veri seti, izleme açısındaki 5 derecelik farklarla, her bir sınıf için 72 şekil içermektedir. Diğer yandan Aslan & Tari ve ETH-80 veri setlerinde sınıflar kendi içlerinde daha fazla varyasyona sahiptir. En yakın komşu sınıflandırıcısı birbirine daha çok benzeyen şekilleri aynı sınıfta kabul etmeye yatkın olduğundan, sınıfları içinde daha çok varyasyona sahip olan veri setleri gürültü arttıkça daha kararlı duruma gelmektedir. Böylece gürültü artışının Aslan & Tari ve ETH-80 veri setleri üzerindeki olumsuz etkisi, ALOI veri seti üzerindeki olumsuz etkisinden daha az olmaktadır.

Yine de gürültü arttıkça üç veri setinde elde edilen başarımlardaki düşüş yavaştır. Bu durum, kapanma problemi karşısında yöntemden alınacak başarımların umut verici bir nitelikte olabileceğini düşündürmektedir. Önerilen yöntemin gürültüye karşı gösterdiği dayanıklılık, şekillerin geometrik uzayda iskelet kritik noktaları kullanılarak elde edilen temsillerinin kararlılığına ve TTM fonksiyonunun kısmi eşlemedeki performansına bağlanabilir. Şekil-4.7 b) de örnek bir şekle %15 gürültü eklenmiştir. Şeklin gürültü eklenmiş haliyle orijinal hali karşılaştırıldığında, orta eksen çizgesinin yapısının az da olsa değiştiğini ve birtakım kritik noktaların kaybolduğu görülmektedir. Buna rağmen kritik noktalar, hala şekillerin benzer bölümlerini temsil edebilmektedir.



Şekil 4.7: a) Önerilen çalışmada, gittikçe artan gürültü altında elde edilen başarımlar. Çember, yıldız ve üçgen sırayla Aslan & Tari, ALOI ve ETH-80 veri setlerinde alınan başarımları göstermektedir. Gürültü seviyesi arttıkça başarımlar yavaş bir şekilde düşmektedir. b) Gürültü eklenmesi sonucu örnek bir şekilde meydana gelen değişim. Şeklin orijinal hali ve %15 gürültü eklenmiş hali karşılaştırıldığında, orta eksen çizgesinin yapısının az da olsa değiştiğini ve birtakım kritik noktaların kaybolduğu görülmektedir. Buna rağmen kritik noktalar, hala şekillerin benzer bölümlerini temsil edebilmektedir.

5. TTM DIŐINDAKİ MESAFE FONKSİYONLARI

Yöntemin TTM dışındaki mesafe fonksiyonlarıyla vereceđi başarımı ölçmek için, şekiller arasındaki mesafe χ^2 ve Hausdorff fonksiyonları kullanılarak hesaplanmıştır.

TTM mesafesi histogramlar üzerinde tanımlı bir mesafe fonksiyonudur. Yine histogramlar üzerinde tanımlı bir diđer mesafe fonksiyonu olan χ^2 mesafe fonksiyonu kullanılmıştır. Aralıkları x_1, x_2, \dots ve y_1, y_2, \dots frekanslarına sahip iki histogram arasındaki mesafe, χ^2 fonksiyonu kullanılarak řu şekilde hesaplanabilir:

$$d(x, y) = \frac{1}{2} \sum_i \frac{(x_i^2 - y_i^2)}{x_i + y_i}$$

Önerilen çalışmada iskeletleri çıkarılan şekiller, iskelet noktalarını merkez alan maksimum disklerin yarı çapları üzerinde oluşturulmuş histogramlar kullanılarak karşılaştırılmıştır.

Hausdorff, verilen iki nokta kümesi üzerinde tanımlanmış bir mesafe fonksiyonudur. Genel olarak bilinen şekliyle Hausdorff mesafesi, bir kümedeki noktalardan diđer kümedeki noktalara olan en küçük uzaklıkların en büyüđü olarak tanımlanır:

$$H(A, B) = \max(h(A, B), h(B, A)) \quad \text{öyleki}$$

$$h(A, B) = \max_{a \in A} \min_{b \in B} \|a - b\|$$

Literatürde Hausdorff mesafe fonksiyonunun birçok versiyonu bulunmaktadır. Önerilen çalışmada, standart Hausdorff mesafesi yerine diđerlerinden daha yüksek performansa sahip olan *minimumların ortalaması* fonksiyonu kullanılmıştır [48].

χ^2 kullanıldığı durumda, şekillerin iskelet noktalarının yarıçaplarına göre histogramlar oluşturulmuştur. Bu histogramlar üzerinde hesaplanan standart χ^2 mesafesi kullanılarak şekiller arasındaki uzaklık bulunmuştur. ALOI veri seti üzerinde yapılan deneyde elde edilen başarımlar, TTM mesafesi kullanılarak elde edilen başarımlara göre oldukça

düşüktür. En yakın komşu sınıflandırıcısından alınan sonuçlara göre TTM kullanıldığında başarıım %95.35 iken χ^2 kullanıldığında başarıım %61'e düşmüştür.

Hausdorff mesafesi kullanıldığı durumda şekiller, iskelet çıkarma işleminden sonra, ilk aşamada anlatıldığı gibi, geometrik uzayda temsil edilmiştir. ETH-80 veri seti üzerinde yapılan deneyde, TTM fonksiyonu kullanılarak %87.47 başarıım elde edilmişken burada %83 başarıım elde edilmiştir.

Hausdorff ve χ^2 fonksiyonlarının TTM fonksiyonuna göre daha düşük başarıım vermesinin nedeni olarak, TTM fonksiyonunda histogramların yalnızca karşılık gelen aralıklarının değil, mümkün olan tüm aralık çiftleri arasındaki mesafenin göz önüne alınması görülmektedir. TTM fonksiyonu histogramlar arasındaki benzerliği, bir histogramı diğerine dönüştürmek için yapılması gereken en küçük masrafı hesaplayarak bulmaktadır. Bu masraf hesaplanırken global bir eşleştirme masrafı minimize edilmektedir. Hausdorff ise, nokta kümeleri arasındaki mesafeyi hesaplarken, yalnızca belli nokta çiftleri arasındaki mesafeyi kullanmaktadır. χ^2 fonksiyonu da, karşılaştırılan histogramların yalnızca karşılık gelen aralıkları arasındaki mesafeyi hesapladığından yine global bir eşleştirme sunamamaktadır.

Sonuç olarak, gerek χ^2 fonksiyonu kullanılarak alınan başarıım, gerekse Hausdorff fonksiyonu kullanılarak alınan başarıım TTM fonksiyonu kullanılması durumunda elde edilen başarıımdan oldukça düşüktür. Bundan dolayı her iki mesafe fonksiyonunun da diğer veri setleri üzerinde uygulanmasına gerek görülmemiş ve çalışmada uzaklık fonksiyonu olarak TTM kullanılmaya devam edilmiştir.

6. MAKİNE ÖĞRENMESİ ALGORİTMALARININ KULLANIMI

Önerilen çalışmada sunulan yöntemin performansını daha da artırabilmek için mesafe matrisi üzerinde birtakım gözetimli makine öğrenmesi algoritmaları kullanılmış ve veri setlerinde elde edilen başarımda meydana gelen artış gözlemlenmiştir. Alınan sonuçlara göre, ileri beslemeli yapay sinir ağları kullanıldığında her üç veri seti üzerinde alınan başarımlar %100'e çok yakın olmaktadır.

Her biri ait olduğu sınıfa göre işaretlenmiş görüntülerden oluşan bir eğitim kümesi üzerinde ileri beslemeli yapay sinir ağları kullanılarak sorgu şekilleri sınıflandırılmıştır. İleri beslemeli yapay sinir ağları literatürde birçok çalışmada başarılı bir şekilde kullanılmıştır [13, 60]. Bir ileri beslemeli yapay sinir ağı, verilerin sadece ileri yönde aktığı belli sayıda katmandan oluşmaktadır. İlk katman giriş katmanıdır, son katman çıkış katmanıdır, ortadaki katmanlar ise gizli katmanlardır. Gizli katmanlardaki ve çıkış katmanındaki sinir hücreleri, önceki katmanların ağırlıklandırılmış çıktısını alır. Bu ağırlıklar, yapay sinir ağının beklenen çıktısı ve gerçek çıktısı arasındaki farkı minimum yapacak şekilde hesaplanmaktadır. Her veri seti için çıktı katmanındaki sinir hücresi sayısı veri setindeki sınıf sayısına eşittir.

Makine öğrenmesi için kullanılacak deney ortamında Aslan & Tari, ALOI ve ETH-80 veri setlerinin her birinden, sınıf dağılımına uygun olarak seçilen, %80 oranında görüntü eğitim kümesi için ve %20 oranında görüntü test kümesi için seçilmiştir. Toprak taşıyıcı mesafe fonksiyonu kullanılarak oluşturulan mesafe matrisi, satırları örnek (instance) ve sütunları özellik (feature) olarak kullanılmak üzere ileri beslemeli yapay sinir ağı algoritmasına verilmiştir. Bu çalışmada kullanılan ileri beslemeli yapay sinir ağı, bir giriş katmanı, bir gizli katman ve bir çıkış katmanı olmak üzere 3 katmandan oluşmaktadır. ALOI ve ETH-80 veri setlerinin sınıflandırılması için kullanılan ileri beslemeli yapay sinir ağının gizli katmanında 20 sinir hücresi vardır, Aslan & Tari veri seti için kullanıldığında ise, bu veri setindeki görüntü sayısı diğer veri setlerindeki görüntü sayısına göre oldukça az olduğundan, 5 sinir hücresi kullanılmıştır.

Bu aşamada yapılan deneyler sonunda sonuçların düşük olduğu görülmüştür. Bunun nedeni olarak ise mesafe matrisinin köşegeninin 0 olmasıdır. Mesafe matrisinde her bir satır, matrisin sütun sayısı kadar boyuta sahip olan bir uzayda bir nokta olarak düşünülebilir. Matrisin köşegeninin 0 olması ise her bir noktanın uzayın (hiper) yüzeylerine

dağılmış ve hiçbirinin uzayın yüzeyleri arasında kalan bölümünde bulunmamasına neden olmaktadır. Bu durumda, ileri beslemeli yapay sinir ağları da dahil, test edilen çeşitli makine öğrenmesi algoritmaları içinde en iyi sonucu veren yöntem karar ağacı ve rastgele orman (*random forest*) olmuştur. Bunun nedeni teorik olarak gösterilmese de, içgüdüsel olarak karar ağaçlarının yapısının böyle bir sınıflandırma için elverişli olduğu bilinmektedir. Bu uzayda oluşturulan bir karar ağacında, karar kurallarının (decision rules), kural hiyerarşisinin başından itibaren, yüzeyleri kolayca ayırabileceği düşünülmektedir. Bahsedilen bu problemin önüne geçebilmek için, mesafe matrisi oluşturulduktan sonra, makine öğrenmesi algoritmalarına verilmeden önce, satırların ve sütunların farklı nesnelere alınması sağlanmıştır. Böylece mesafe matrisinde hiçbir nesnenin kendisiyle arasındaki, değeri 0 olan, mesafe bulunmamaktadır. Bu yöntem eğitim kümesi için kullanılan mesafe matrisine uygulandığı gibi, test kümesi için oluşturulan mesafe matrisine de uygulanmıştır. Uygulanan bu değişiklik sonucu kullanılan makine öğrenmesi algoritmalarının test kümesi üzerinde verdiği başarı artmıştır.

Her bir veri seti için eğitim ve test kümeleri rastgele seçilerek deneyler 5 kez tekrarlanmıştır (5 katlı çapraz doğrulama). Önceden de bahsedildiği üzere, ileri beslemeli yapay sinir ağları dışında birtakım makine öğrenmesi algoritmaları denenmiştir. Bunlar Destek Vektör Makinesi (DVM) [12], Karar Ağaçları ve Rastgele Orman [26] algoritmalarıdır. En yakın komşu sınıflandırıcısı sonuçları önceden verildiğinden burada söz edilmemiştir. DVM, Karar Ağacı ve Rastgele Orman algoritmalarının ETH-80 veri seti için verdikleri başarımlar sırasıyla %64, %83 ve %90'dır. ALOI veri setinde ise başarımlar %67, %65 ve %82 şeklindedir. Aslan & Tari veri seti için DVM ve Karar Ağacı algoritmalarının verdikleri başarımlar dikkate alınmayacak kadar düşük iken Rastgele Orman algoritmasından alınan başarımlar %75 olmuştur. Farklı makine öğrenmesi algoritmalarının aynı veri seti için farklı sonuçlar vermesi, kullanılan veri setinin büyüklüğü, sınıfları arasındaki varyasyon ve örneklerinin vektör uzayındaki dağılımı dikkate alındığında, doğal bir durum olduğu görülebilir.

Önceden de söz edildiği gibi, bu algoritmaların içinden her üç veri seti için de en iyi sonucu ileri beslemeli yapay sinir ağları vermiştir. Alınan sonuçlara göre, önerilen yöntemin başarımları Aslan & Tari veri setinde %100, ALOI veri setinde %99.24 ve ETH-80 veri setinde %99.51'e ulaşmıştır. Bu sonuçlar, önerilen yöntem kuvvetli bir sınıflandırıcıyla desteklendiğinde %100'e oldukça yakın bir başarımla alındığını göstermektedir. Öznitelik temsili ve sınıflandırılması şekil tanıma platformlarının iki önemli parçasıdır. Bu sebepten ötürü, önerilen çalışmada aynı sınıftaki şekillerin iskeletleri arasındaki benzerlik artırılıp farklı sınıftaki şekillerin iskeletleri arasındaki benzerlik azaltıldığında en yakın komşu sınıflandırıcısından alınan sonuçların iyileşmesi öngörülmektedir. Sonuç bölümünde de tartışıldığı üzere, önerilen çalışma için gelecekte

yapılması planlanan iyileřtirmelerden biri de iskelet temsili için daha gelişmiş yöntemlerin kullanılmasıdır.




7. YALNIZCA KRİTİK NOKTALARIN KULLANIMI

Bu bölümde, orta eksen çizgesi çıkarılan şekiller üzerinde kritik olmayan noktaların başarıma etkisinin araştırılması amaçlanmaktadır. Önceki bölümde anlatılan işlemin aksine şekillerin iskeleti geometrik uzayda temsil edilirken her bir iskelet noktasının kritik noktalara olan uzaklığı yerine kritik noktaların birbiri arasındaki uzaklık kullanılmıştır.

7.1 Yöntem

Şekillerin iskeletlerinin çıkarılması ve iskelet noktalarından orta eksen çizgesi bulunması yöntemi ilk aşamayla aynıdır. Diğer bir ifadeyle, şekillerin iskeletleri her düğüm bir iskelet noktası olacak ve her kenar en yakın iki düğümü bağlayacak şekilde bir çizge (orta eksen çizgesi) olarak temsil edilerek iskeletin parçalarını birbirine bağlayan kritik noktalar bulunmuştur ve kritik noktalar yakın komşuluklarından elde edilen histogramlar kullanılarak sıralanmıştır. İlk aşamadan farklı olarak şekillerin iskeleti geometrik uzayda temsil edilirken yalnızca kritik noktalar arasındaki en kısa yol uzaklıkları kullanılmıştır. Eşleme aşamasında da bir değişikliğe gidilmemiş ve şekillerin iskeleti arasındaki benzerlik, aynı boyutlu geometrik uzayda TTM kullanılarak hesaplanmıştır. Şekil-7.1’de ortadaki kritik noktanın diğer kritik noktalara olan uzaklığı hesaplanmaktadır. Vektörler gösterim amacıyla belirtilmiştir.

Literatürde benzer çalışmalar olmasına karşın, burada uygulanan yöntemin aynısına rastlanmamıştır. Xu ve diğerlerinin yaptığı çalışmada [68], iskelet üzerinde ilk olarak sadece kesişim noktaları arasındaki, daha sonra sadece uç noktalar arasındaki en kısa yolların benzerliğinden yararlanılarak bu noktalar arasında bire bir eşleştirme yapılmıştır. Önerilen çalışmada, Xu ve diğerlerinin yaklaşımından farklı olarak aşamalı bir eşleştirme yapılmamış ve tüm kritik noktalar arasındaki en kısa yol uzaklıkları bulunarak şekiller geometrik uzayda doğrudan eşleştirilmiştir.



Şekil 7.1: Kritik olmayan noktaların başarımına olan etkisini test etmek için şekil, kritik noktaların birbirlerine olan en kısa yol uzaklıklarıyla temsil edilmiştir. Şekilde, ortadaki kritik noktanın diğer kritik noktalara olan en kısa yol uzaklığının hesaplandığı gösterilmektedir. Vektörler gösterim amacıyla belirtilmiştir.

Çizelge 7.1: Kritik olmayan noktaların başarımına etkisi verilmiştir. Elde edilen başarımlar, ilk aşamada elde edilen başarımlarla birlikte gösterilmektedir.

	Aslan & Tari	ALOI	ETH-80
Yeni Sonuçlar	%95.54	%92.5	%81.65
Önceki Sonuçlar	%96.4	%95.35	%87.47

7.2 Deneysel Çalışmalar

Çalışmanın ilk aşamasında olduğu gibi burada da deneyler Aslan & Tari, ALOI ve ETH-80 veri setleri üzerinde yapılmış ve değerlendirme için birini çıkar yöntemiyle en yakın komşu sınıflandırıcısı kullanılmıştır. En yakın komşu sınıflandırıcısından alınan sonuçlara göre Aslan & Tari, ALOI ve ETH-80 veri setleri üzerinde sırayla %95.54, %92.5 ve %81.65 başarımlar elde edilmiştir. Üç veri seti üzerinde elde edilen başarımlar, çalışmanın ilk aşamasında elde edilen başarımlarla birlikte Çizelge-7.1’de verilmiştir.

Sonuçlar ilk aşamada elde edilen sonuçlarla karşılaştırıldığında, belli oranda düşüş gözlemlenmektedir. İlk aşamada, Intel(R) Xeon(R) E5-1650 v2 (3.5 GHz) işlemciye sahip bir bilgisayarda, Aslan-Tari, ALOI ve ETH-80 veri setleri için sırayla %96.4 ve %95.35 ve %87.47 başarımlar elde edilmişken kritik olmayan noktaların dikkate alınmamasıyla, aynı bilgisayar üzerinde, başarımlarımızda sırayla %0.89, %2.99 ve %6.65 düşüş

gözlemlenmiştir. Başarımdaki bu düşüşe karşın çalışma zamanında büyük ölçüde iyileşme görülmüştür. Önceki çalışmada çalışma zamanı sırayla 0.5 saat, 6 saat ve 13 saat iken önerilen çalışmada bu zaman 0.54 saniye, 64 saniye ve 142 saniye olarak gözlemlenmiştir. Başarımdaki bu kısmi düşüşe karşın çalışma zamanında meydana büyük iyileşmenin nedeni, ilk aşamanın tersine şekilleri temsil etmek için tüm iskelet noktalarının değil, yalnızca kritik noktaların kullanılmasıdır. Şekillerin iskeletlerinde genel olarak kritik noktaların sayısı tüm iskelet noktalarının sayısının birkaç yüzde biridir. Bu durum, çalışma zamanındaki iyileşmeyi açıklarken şekillerin eşleştirilmesinde tüm iskelet noktaları yerine sadece kritik noktaların kullanılması başarımdaki düşüşün nedeni olarak görülmektedir. Bu düşüşün çalışma zamanındaki iyileşmeye göre oldukça az olmasının nedeni olarak kritik noktaların iskeletin topolojik yapısını temsil etmekteki başarısı gösterilebilir.



8. YÖNTEMİN GRİ SEVİYELİ GÖRÜNTÜLERDE UYGULANMASI

Bu bölümde, sunulan çalışmada önerilen yöntemin gri seviyeli görüntüler üzerindeki performansının test edilmesi amaçlanmaktadır. Burada da, çalışmanın ilk aşamasında olduğu gibi öznetelik çıkarılması, özneteliklerden çizge hesaplanması, çizgedeki kritik noktaların kullanılarak şekillerin geometrik uzayda temsili ve TTM ile şekiller arasındaki benzerliğin hesaplanması işlemleri yapılmıştır.

8.1 Yöntem

Gri seviyeli görüntüler kullanıldığından, çalışmanın ilk aşamasında yapılan işlemlerden farklı olarak şekillerin iskeleti çıkarılmamış bunun yerine SIFT öznetelikleri [34] kullanılmıştır. Şeklin temsili için çizge hesaplanması için ilk aşamada yapıldığı gibi, her bir özneteliğin bir düğümü temsil ettiği bir tam çizge oluşturulmuş ve MYA algoritmasıyla öznetelikler arasındaki komşuluklar hesaplanmıştır. Daha sonra, derecesi ≥ 3 ve 1 olan düğümler kritik noktalar olarak kabul edilmiştir. Sonradan şekillerin temsil edileceği geometrik uzayın her bir şekil için farklı oryantasyonda olmaması için kritik noktalar sıralanmıştır. Kritik noktalara uygulanan sıralama işlemi için SIFT özneteliklerine ait 128 boyutlu tanımlayıcı vektör kullanılmıştır. Aslında SIFT özneteliklerine ait tanımlayıcıların kullanılması, tanımlayıcılar özneteliklerin yakın komşuluğu kullanılarak hesaplandığından dolayı, özneteliklerin sıralama işleminin ilk aşamada yapılmış benzer olduğunu göstermektedir. Sıralama işleminden sonra çizge üzerinde her bir noktanın kritik noktalara olan uzaklığı hesaplanarak şekiller geometrik uzayda temsil edilmiştir. Yine, geometrik uzayın boyutunun veri setindeki her şekil için aynı olmasını sağlamak için TBA uygulanmıştır. Son olarak, TTM fonksiyonuyla geometrik uzayda temsil edilen şekiller arasındaki uzaklık bulunmuştur.

8.2 Deneysel Çalışmalar

Önerilen yöntemin test edilebilmesi için ALOI veri setinden seçilen 10 farklı sınıfa ait toplam 720 gri seviyeli görüntü kullanılmıştır. Kullanılan görüntüler Resim-8.1’de gösterilmektedir. İlk iki satırda ALOI veri setinden alınan 10 farklı sınıftan birer görüntü, üçüncü satırda ise bir sınıfın farklı açılardan çekilmiş görüntüleri verilmiştir.



Resim 8.1: İlk iki satırda ALOI veri setinden alınan 10 farklı sınıftan birer görüntü gösterilmektedir. Üçüncü satırda ise bir sınıfın farklı açılardan çekilmiş görüntüleri vardır.

İlk iki aşamada olduğu gibi, burada da "birini çıkar" yöntemi ve en yakın komşu sınıflandırıcısı kullanılmıştır. En yakın komşu sınıflandırıcısından elde edilen sonuçlara göre %90 başarı elde edilmiştir. Yöntemin gri seviyeli görüntülere uygulanması, üzerinde yeni çalışmalar yapılabilecek bir konudur. Kullanılacak öznitelik türünün seçimi, çizge oluşturulurken öznitelik komşuluğunu belirleyen uzaklık fonksiyonu, şekiller arasındaki benzerlik hesaplanırken tanımlayıcılardan yararlanma yolları gibi konular ayrı bir araştırmanın konusu olabilir.

9. SONUÇ VE ÖNERİLER

Yapılan çalışmada, şekillerin iskeletleri üzerinden yeni bir şekil eşleme çalışması sunulmuştur. Algoritma ilk olarak, düğümleri iskelet noktalarını ve kenarları iskelet noktalarının komşuluklarını temsil eden, orta eksen çizgesini çıkarır. Daha sonra çizge üzerinde kesişim ve uç noktalarının birleşimi olan kritik, diğer bir deyişle derecesi ≥ 3 veya 1 olan, noktalar bulunur ve her bir iskelet noktasının kritik noktalara olan uzaklığı hesaplanarak şekiller geometrik uzayda temsil edilir. Geometrik uzayın boyut sayısı iskelet üzerindeki kritik noktaların sayısına bağlı olduğundan bu işlem sonucunda şekillerin temsil edildiği uzaylar farklı boyutta olacaktır. Bu sorunun önüne geçmek için TBA (teme bileşen analizi) kullanılarak farklı boyuttaki nokta dağılımları aynı boyuta indirgenmiştir. Geometrik uzaya alınan iskeletler arasındaki mesafe FastEMD algoritması kullanılarak TTM (toprak taşıyıcı mesafesi) fonksiyonuyla bulunmuştur. Önerilen yöntemin performansını değerlendirmek için üç farklı veri seti üzerinde deneyler yapılmış ve yöntemin başarımı literatürdeki çeşitli yöntemlerin başarımıyla karşılaştırılmıştır. Önerilen yöntemin performansını daha da iyileştirebilmek adına sonuçlar ileri beslemeli yapay sinir ağlarıyla desteklenmiş ve her üç veri seti üzerinde de %100'e yakın başarımla alındığı görülmüştür.

Çalışma boyunca anlatılan adımların bazılarında, alternatif yöntemler denenmiş ve sonuçlar tercih edilen yöntemler uygulandığında alınan sonuçlarla karşılaştırılmıştır. Bu adımlardan biri, orta eksen çizgesi üzerinde hesaplanan kritik noktalar kümesine, iskeletin her bir dalında kritik noktaların arasında kalan birer noktanın dahil edilmesidir. Orta noktalar, derecesi ≥ 3 veya 1 olan noktalara göre daha az kararlı olduğundan ve bu yöntemle iskeletin kısa dalları üzerinde daha yoğun örnekleme eğilimi olduğundan başarımlar bir miktar düşmüştür. Alternatifi test edilen bir diğer yöntem, kullanılan mesafe fonksiyonudur. Geometrik uzayda temsil edilen şekiller arasındaki uzaklığı bulmak için TTM fonksiyonu dışında Hausdorff ve χ^2 mesafe fonksiyonları denenmiş fakat alınan sonuçlardan, TTM fonksiyonunun önerilen yöntem için daha uygun olduğuna karar verilmiştir.

Gürültülü veri setleri üzerinde yapılan deneyler önerilen yöntemin bozuk iskeletlerin kullanımına karşı dayanıklılığını göstermiştir. Bunun yanında, gürültülü veri seti oluşturulması için kullanılan yöntem görüntülerin genelinde değişiklik yaptığından, yöntemin kısmi kapanma problemine karşı test edilmesi amacıyla görüntüler üzerinde ya-

pılacak yerel deęişikliklerin, gürültülü veri setleri için verilen performansı daha aşıęı çekeceęi öngörülmektedir. Gelecekte, yöntemin kısmi kapanma problemine karşı test edilip dayanıklı hale getirilmesi yapılması planlananlar arasındadır.

Başta da belirtildięi üzere önerilen yöntemde, şekillerin önceden belirlenmiş temsilci şekiller kullanılarak indekslenmesi yaklaşımı temel alınmıştır [63]. Bu yöntemde, bulunmak istenen şekil veri setindeki tüm şekillerle karşılaştırılmadan, yalnızca temsilci şekillerle arasındaki benzerlik hesaplanarak, etkili bir biçimde bulunabilmektedir. Önerilen yaklaşımın bir indeksleme sistemiyle desteklenmesi, ileride gerçekleştirilmesi planlanan dikkate değer bir araştırma konusudur.

Sunulan yöntemin gri seviyeli görüntüler üzerindeki kullanımının test edilmesi için, ALOI veri setinden seçilen 10 sınıfa ait renkli görüntüler üzerinde deneyler yapılmıştır. Veri setindeki görüntüler üzerinde SIFT öznelikleri bulunmuştur. Daha sonra şeklin temsili için çizge oluşturulmuş ve derecesi ≥ 3 veya 1 olan kritik noktalar bulunmuştur. Çizge üzerinde her bir noktanın kritik noktalara olan en kısa yol uzaklığı bulunarak şekiller geometrik uzayda temsil edilmiştir. Geometrik uzaya alınan şekiller arasındaki mesafe FastEMD algoritması kullanılarak TTM fonksiyonuyla bulunmuştur. Birini çıkar yöntemiyle yapılan deneyde, en yakın komşu sınıflandırıcısı %90 başarımlıdır.

Ayrıca, kritik olmayan noktaların başarıma etkisini ölçmek için, iskelet noktaları kullanılarak orta eksen çizgesi çıkarıldıktan ve kritik noktalar bulunduktan sonra, kritik olmayan noktalar dikkate alınmamış ve şekiller yalnızca kritik noktaların birbirine olan en kısa yol uzaklıklarıyla temsil edilmiştir. Bunun sonucunda, elde edilen başarımda az bir miktar düşüş olurken, çalışma zamanında oldukça yüksek oranda bir azalma meydana gelmiştir. Başarımdaki düşüşün çalışma zamanındaki iyileşmeye göre oldukça az olmasının nedeni olarak kritik noktaların iskeletin topolojik yapısını temsil etmekteki başarısı gösterilebilir.

Önerilen yöntemin, iskelet çıkarımı, orta eksen çizgesi bulunması, şekillerin geometrik uzayda temsili gibi birçok aşamasındaki teknik, doğrudan uygulanmak yerine çeşitli iyileştirmeler yapılarak kullanılmıştır. Buna karşın, metinde de belirtildięi üzere, hala birçok iyileştirmeye yer vardır. Yöntemde ikili görüntülerde kullanım için ileride yapılabilecek geliştirmeler şu şekilde sıralanabilir: yöntem için daha iyi sonuç verebilecek iskelet yöntemlerinin araştırılması, iskelet noktalarından orta eksen çizgesinin hesaplanması aşamasında düğümler arasında farklı mesafe fonksiyonları denenmesi, kritik noktaları bulmak için derecesi sadece ≥ 3 veya 1 olan noktaları almak yerine, global optimizasyon ve makine öğrenmesi teknikleri kullanılarak bu noktaların her bir şekle

özel olarak seçilmesi gibi çeşitli stratejilerin uygulanması ve farklı noktaların denemesi, eşleştirme aşamasında TTM yerine kullanılacak başka mesafe fonksiyonları bulunması, gürültü ve kısmi kapanma problemleri için konvolüsyon ve interpolasyon metotlarının kullanılması.

Gri seviyeli görüntülerde uygulanan kısım üzerinde ise: SIFT yerine başka özniteliklerin denemesi, özniteliklerden çizge oluşturulurken öznitelikler arasında farklı mesafe fonksiyonları uygulanması, hem ikili görüntüler hem gri seviyeli görüntüler için özniteliklerin gruplanması gibi konuların araştırılması gerekli görülmektedir. Ayrıca çalışma zamanını daha da iyileştirebilmek adına kritik olmayan noktalar üzerinde bir önem fonksiyonu tanımlanması ve FastEMD algoritmasına uygulanan eşik değeri üzerinde, kullanılan veri setine özgü olarak, optimizasyon uygulanması da araştırmaya değer konulardır.



KAYNAKLAR

- [1] ARDIZZONE, E., CASCIA, M. L., GESU, V. D., AND VALENTI, C. Content-based indexing of image and video databases by global and shape features. In *Proceedings of the International Conference on Pattern Recognition (ICPR '96) Volume III-Volume 7276 - Volume 7276* (Washington, DC, USA, 1996), ICPR '96, IEEE Computer Society, pp. 140–.
- [2] ASLAN, C., AND TARI, S. An axis-based representation for recognition. In *ICCV (2005)*, IEEE Computer Society, pp. 1339–1346.
- [3] BAI, X., LIU, W., AND TU, Z. Integrating contour and skeleton for shape classification. In *IEEE Workshop on NORDIA (2009)*.
- [4] BAI, X., WANG, X., LATECKI, L. J., LIU, W., AND TU, Z. Active skeleton for non-rigid object detection. In *Computer Vision, 2009 IEEE 12th International Conference on (2009)*, IEEE, pp. 575–582.
- [5] BELONGIE, S., MALIK, J., AND PUZICHA, J. Shape matching and object recognition using shape contexts. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 24, 4 (2002), 509–522.
- [6] BLUM, H. A Transformation for Extracting New Descriptors of Shape. In *Models for the Perception of Speech and Visual Form*, W. Wathen-Dunn, Ed. MIT Press, Cambridge, 1967, pp. 362–380.
- [7] BLUM, H., AND NAGEL, R. Shape description using weighted symmetric axis features. *Pattern Recognition* 10, 3 (1978), 167–180.
- [8] BRAND, M. Incremental singular value decomposition of uncertain data with missing values. In *Computer Vision-ECCV 2002*. Springer, 2002, pp. 707–720.
- [9] BROWN, M., SZELISKI, R., AND WINDER, S. Multi-image matching using multi-scale oriented patches. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on (2005)*, vol. 1, IEEE, pp. 510–517.
- [10] CALONDER, M., LEPETIT, V., STRECHA, C., AND FUA, P. Brief: Binary robust independent elementary features. *Computer Vision-ECCV 2010 (2010)*, 778–792.
- [11] CANNY, J. A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 6 (1986), 679–698.

- [12] CORTES, C., AND VAPNIK, V. Support-vector networks. *Machine learning* 20, 3 (1995), 273–297.
- [13] COTTRELL, G. Metcalfe. 1991. empath: Face, emotion, and gender recognition using holons. *Advances in Neural Information Processing, Morgan Kaufmann Publishers*.
- [14] DALAL, N., AND TRIGGS, B. Histograms of oriented gradients for human detection. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on* (2005), vol. 1, IEEE, pp. 886–893.
- [15] DEMIRCI, M. F., PLATEL, B., SHOKOUFANDEH, A., FLORACK, L. L., AND DICKINSON, S. J. The representation and matching of images using top points. *Journal of Mathematical Imaging and Vision* 35, 2 (2009), 103–116.
- [16] DIAS, P., KASSIM, A., AND SRINIVASAN, V. A neural network based corner detection method. In *Neural Networks, 1995. Proceedings., IEEE International Conference on* (1995), vol. 4, IEEE, pp. 2116–2120.
- [17] DIMITROV, P., PHILLIPS, C., AND SIDDIQI, K. Robust and efficient skeletal graphs. In *Computer Vision and Pattern Recognition, 2000. Proceedings. IEEE Conference on* (2000), vol. 1, IEEE, pp. 417–423.
- [18] EBERLY, D. A differential geometric approach to anisotropic diffusion. In *Geometry-Driven Diffusion in Computer Vision*, B. Haar Romeny, Ed., vol. 1 of *Computational Imaging and Vision*. Springer Netherlands, 1994, pp. 371–392.
- [19] F. DEMIRCI, A. B. Shape classification based on skeleton branch distances. In *International Conference on Computer Vision Theory and Applications* (2015), INSTICC.
- [20] FELDMAN, J., AND SINGH, M. Bayesian estimation of the shape skeleton. *Proceedings of the National Academy of Sciences* 103, 47 (2006), 18014–18019.
- [21] FELZENSZWALB, P. F., GIRSHICK, R. B., MCALLESTER, D., AND RAMANAN, D. Object detection with discriminatively trained part-based models. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 32, 9 (2010), 1627–1645.
- [22] FELZENSZWALB, P. F., AND HUTTENLOCHER, D. P. Pictorial structures for object recognition. *International Journal of Computer Vision* 61, 1 (2005), 55–79.
- [23] GEUSEBROEK, J., BURGHOUTS, G., AND SMEULDERS, A. The amsterdam library of object images. *International Journal of Computer Vision* 61, 1 (2005), 103–112.
- [24] GUOCHENG, A., FENGJUN, Z., HONG’AN, W., AND GUOZHONG, D. Shape filling rate for silhouette representation and recognition. In *Pattern Recognition (ICPR), 2010 20th International Conference on* (2010), pp. 507–510.

- [25] HARRIS, C., AND STEPHENS, M. A combined corner and edge detector. In *Alvey vision conference* (1988), vol. 15, Citeseer, p. 50.
- [26] HO, T. K. Random decision forests. In *Document Analysis and Recognition, 1995., Proceedings of the Third International Conference on* (1995), vol. 1, IEEE, pp. 278–282.
- [27] HUA, G., BROWN, M., AND WINDER, S. Discriminant embedding for local image descriptors. In *Computer Vision, 2007. ICCV 2007. IEEE 11th International Conference on* (2007), IEEE, pp. 1–8.
- [28] LI, L., MA, M., LEI, P., WANG, X., AND CHEN, X. A linear approximate algorithm for earth mover’s distance with thresholded ground distance. *Mathematical Problems in Engineering* 2014 (2014).
- [29] LI, P., WANG, Q., AND ZHANG, L. A novel earth mover’s distance methodology for image matching with gaussian mixture models. *ICCV*.
- [30] LI, Z., QU, W., CAO, J., QI, H., AND STOJIMENOVIC, M. Ecds: An effective shape signature using electrical charge distribution on the shape. *Pattern Recognition* 48, 2 (2015), 402–410.
- [31] LIENHART, R., AND MAYDT, J. An extended set of haar-like features for rapid object detection. In *Image Processing, 2002. Proceedings. 2002 International Conference on* (2002), vol. 1, IEEE, pp. I–900.
- [32] LING, H., AND JACOBS, D. Shape classification using the inner-distance. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 29, 2 (2007), 286–299.
- [33] LIU, T., AND GEIGER, D. Approximate tree matching and shape similarity. In *Computer Vision, 1999. The Proceedings of the Seventh IEEE International Conference on* (1999), vol. 1, IEEE, pp. 456–462.
- [34] LOWE, D. Object recognition from local scale-invariant features. *ICCV*.
- [35] MACRINI, D., SIDDIQI, K., AND DICKINSON, S. From skeletons to bone graphs: Medial abstraction for object recognition. In *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on* (2008), IEEE, pp. 1–8.
- [36] MIKOLAJCZYK, K., AND SCHMID, C. A performance evaluation of local descriptors. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 27, 10 (2005), 1615–1630.
- [37] OGNIEWICZ, R., AND KÜBLER, O. Hierarchic voronoi skeletons. *Pattern recognition* 28, 3 (1995), 343–359.
- [38] OLIVER, N. M., ROSARIO, B., AND PENTLAND, A. P. A bayesian computer vision system for modeling human interactions. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 22, 8 (2000), 831–843.

- [39] PELE, O., AND WERMAN, M. Fast and robust earth mover’s distances. In *Computer vision, 2009 IEEE 12th international conference on* (2009), IEEE, pp. 460–467.
- [40] PREMACHANDRAN, V., AND KAKARALA, R. Perceptually motivated shape context which uses shape interiors. *Pattern recognition* 46, 8 (2013), 2092–2102.
- [41] ROSTEN, E., AND DRUMMOND, T. Machine learning for high-speed corner detection. In *Computer Vision–ECCV 2006*. Springer, 2006, pp. 430–443.
- [42] RUBLEE, E., RABAUD, V., KONOLIGE, K., AND BRADSKI, G. Orb: an efficient alternative to sift or surf. In *Computer Vision (ICCV), 2011 IEEE International Conference on* (2011), IEEE, pp. 2564–2571.
- [43] RUBNER, Y., TOMASI, C., AND GUIBAS, L. J. The earth mover’s distance as a metric for image retrieval. *International Journal of Computer Vision* 40, 2 (2000), 99–121.
- [44] SEBASTIAN, T., KLEIN, P., AND KIMIA, B. Recognition of shapes by editing their shock graphs. *IEEE Trans. Pattern Anal. Mach. Intell.* 26, 5 (2004), 550–571.
- [45] SEBASTIAN, T. B., AND KIMIA, B. B. Curves vs. skeletons in object recognition. *Signal Processing* 85, 2 (Feb. 2005), 247–263.
- [46] SEBASTIAN, T. B., KLEIN, P. N., AND KIMIA, B. B. Recognition of shapes by editing their shock graphs. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 26, 5 (2004), 550–571.
- [47] SHAKED, D., AND BRUCKSTEIN, A. Pruning medial axes. *Computer vision and image understanding* 69, 2 (1998), 156–169.
- [48] SHAPIRO, M. D., AND BLASCHKO, M. B. On hausdorff distance measures. *Computer Vision Laboratory University of Massachusetts Amherst, MA 1003* (2004).
- [49] SHARVIT, D., CHAN, J., TEK, H., AND KIMIA, B. Symmetry-based indexing of image databases. In *Content-Based Access of Image and Video Libraries, 1998. Proceedings. IEEE Workshop on* (1998), IEEE, pp. 56–62.
- [50] SHEKAR, B., PILAR, B., AND KITTLER, J. An unification of inner distance shape context and local binary pattern for shape representation and classification. In *Proceedings of the 2nd International Conference on Perception and Machine Intelligence* (2015), ACM, pp. 46–55.
- [51] SHEN, W., BAI, X., HU, R., WANG, H., AND JAN LATECKI, L. Skeleton growing and pruning with bending potential ratio. *Pattern Recognition* 44, 2 (2011), 196–209.
- [52] SHEN, W., WANG, X., YAO, C., AND BAI, X. Shape recognition by combining contour and skeleton into a mid-level representation. In *Pattern Recognition*. Springer, 2014, pp. 391–400.

- [53] SHOKOUFANDEH, A., KESELMAN, Y., DEMIRCI, M., MACRINI, D., AND DICKINSON, S. Many-to-many feature matching in object recognition a review of three approaches. *Computer Vision, IET* 6, 6 (2012), 500–513.
- [54] SIDDIQI, K., BOUIX, S., TANNENBAUM, A., AND ZUCKER, S. Hamilton-jacobi skeletons. *International Journal of Computer Vision* 48, 3 (2002), 215–231.
- [55] SIRIN, Y., AND DEMIRCI, F. Skeleton filling rate for shape recognition. In *2014 22nd International Conference on Pattern Recognition (ICPR)* (2014).
- [56] STRICKER, M. A., AND ORENGO, M. Similarity of Color Images. In *Storage and Retrieval for Image and Video Databases (SPIE)* (1995), pp. 381–392.
- [57] SUN, K., AND SUPER, B. Classification of contour shapes using class segment sets. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2005), 20-26 June 2005, San Diego, CA, USA* (2005), IEEE Computer Society, pp. 727–733.
- [58] SUNDAR, H., SILVER, D., GAGVANI, N., AND DICKINSON, S. Skeleton based shape matching and retrieval. In *Shape Modeling International, 2003* (2003), IEEE, pp. 130–139.
- [59] SZELISKI, R. *Computer vision: algorithms and applications*. Springer Science & Business Media, 2010.
- [60] TAMURA, S., KAWAI, H., AND MITSUMOTO, H. Male/female identification from 8×6 very low resolution face images by neural network. *Pattern Recognition* 29, 2 (1996), 331–335.
- [61] TORRESANI, L., KOLMOGOROV, V., AND ROTHER, C. Feature correspondence via graph matching: Models and global optimization. In *Computer Vision—ECCV 2008*. Springer, 2008, pp. 596–609.
- [62] VIOLA, P., AND JONES, M. Rapid object detection using a boosted cascade of simple features. In *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on* (2001), vol. 1, IEEE, pp. I–511.
- [63] VLEUGELS, J., AND VELTKAMP, R. Efficient image retrieval through vantage objects. *Pattern Recognition* 35, 1 (2002), 69–80.
- [64] WANG, F., AND GUIBAS, L. Supervised earth mover’s distance learning and its computer vision applications. In *Computer Vision—ECCV 2012*. Springer, 2012, pp. 442–455.
- [65] WANG, J., YANG, J., YU, K., LV, F., HUANG, T., AND GONG, Y. Locality-constrained linear coding for image classification. In *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on* (2010), IEEE, pp. 3360–3367.

- [66] WANG, X., FENG, B., BAI, X., LIU, W., AND LATECKI, L. J. Bag of contour fragments for robust shape classification. *Pattern Recognition* 47, 6 (2014), 2116–2125.
- [67] XU, J., ZHANG, Z., TUNG, A., AND YU, G. Efficient and effective similarity search over probabilistic data based on earth mover’s distance. *The VLDB Journal-The International Journal on Very Large Data Bases* 21, 4 (2012), 535–559.
- [68] XU, Y., WANG, B., LIU, W., AND BAI, X. Skeleton graph matching based on critical points using path similarity. In *Computer Vision-ACCV 2009*. Springer, 2009, pp. 456–465.
- [69] YANG, C., TIEBE, O., PIETSCH, P., FEINEN, C., KELTER, U., AND GRZEGORZEK, M. Shape-based object retrieval by contour segment matching. In *Image Processing (ICIP), 2014 IEEE International Conference on* (2014), IEEE, pp. 2202–2206.
- [70] YANG, J., JIANG, Y.-G., HAUPTMANN, A. G., AND NGO, C.-W. Evaluating bag-of-visual-words representations in scene classification. In *Proceedings of the international workshop on Workshop on multimedia information retrieval* (2007), ACM, pp. 197–206.
- [71] YANG, X., BAI, X., YU, D., AND LATECKI, L. Shape classification based on skeleton path similarity. In *Energy Minimization Methods in Computer Vision and Pattern Recognition, 6th International Conference, EMMCVPR 2007, Ezhou, China, August 27-29, 2007, Proceedings* (2007), pp. 375–386.
- [72] YANG, Y., AND NEWSAM, S. Bag-of-visual-words and spatial extensions for land-use classification. In *Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems* (2010), ACM, pp. 270–279.

ÖZGEÇMİŞ

Ad-Soyad : Salih Arda BÖLÜK
Uyruğu : T.C.
Doğum Tarihi ve Yeri : 05.01.1991 Ankara
E-posta : ardaboluk2@gmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2014, TOBB ETU, Mühendislik Fakültesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2011-2012	Talya Bilişim	Stajyer Yazılım Mühendisi
2012-2013	Koza İpek Holding	Stajyer Yazılım Mühendisi
2013-2014	Turkish Aerospace Industries	Stajyer Test Mühendisi

YABANCI DİL: İngilizce, Almanca

TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- S. A. **Boluk**, M. F. Demirci, Shape classification based on skeleton-branch distances, in: VISAPP 2015 - Proceedings of the 10th International Conference on Computer Vision Theory and Applications, Volume 2, Berlin, Germany, 11-14 March, 2015., 2015, pp. 353-359.
- S. A. **Boluk**, M. F. Demirci, Skeleton branch distances for shape recognition, in: Signal Processing and Communications Applications Conference (SIU), 2015 23th, IEEE, 2015, pp. 552-555.
- S. A. **Boluk**, M. F. Demirci, Skeleton Critical Points for Shape Matching, in: Signal Processing and Communications Applications Conference (SIU), 2016 24th

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

- Betül Cerit, S. A. **Boluk**, M. F. Demirci, Analysis of the Effect of Image Resolution on Automatic Face Gender and Age Classification, in: Signal Processing and Communications Applications Conference (SIU), 2016 24th

