



Semi-automatic heuristic segmentation of fetal skull images

Umut Konur*

Department of Computer Engineering, Faculty of Engineering, Zonguldak Bülent Ecevit University, 67100, Zonguldak, Türkiye

Highlights:

- Constructing an average shape model reference
- Locating boundary points based on intensity value weights
- Comparable performance on diagnosis of spina bifida neural tube defect

Keywords:

- Image segmentation
- Average shape model
- Intensity-based computation of average positions
- Ultrasound
- Transcerebellar

Article Info:

Research Article
Received: 06.04.2021
Accepted: 20.03.2022

DOI:

10.17341/gazimmfd.910514

Acknowledgement:

The author would like to thank İbrahim Kalelioğlu from the Istanbul University Faculty of Medicine and Füsün Varol from the Trakya University Faculty of Medicine for their assistance in providing the US images. Moreover; We would like to thank Trakya University Faculty of Medicine Scientific Research Ethics Committee, which provided ethical approval with the protocol code of TÜTF-GOKAEK 2014/85 and decision number 09/07 dated 30/04/2014 so that the data can be used in studies.

Correspondence:

Author: Umut Konur
e-mail: konur@beun.edu.tr
phone: +90 372 291 2618

Graphical/Tabular Abstract

The study presents a semi-automatic heuristic segmentation scheme that aims to extract skull contours from transcerebellar fetal head images of ultrasound modality, where the system relies on an average shape model learned from training images and an intensity-based averaging procedure which searches for subjectively optimal points in neighborhoods of model points. Semi-automaticity arises from manually marking few points on input images. Figure A is a flowchart of the overall system.

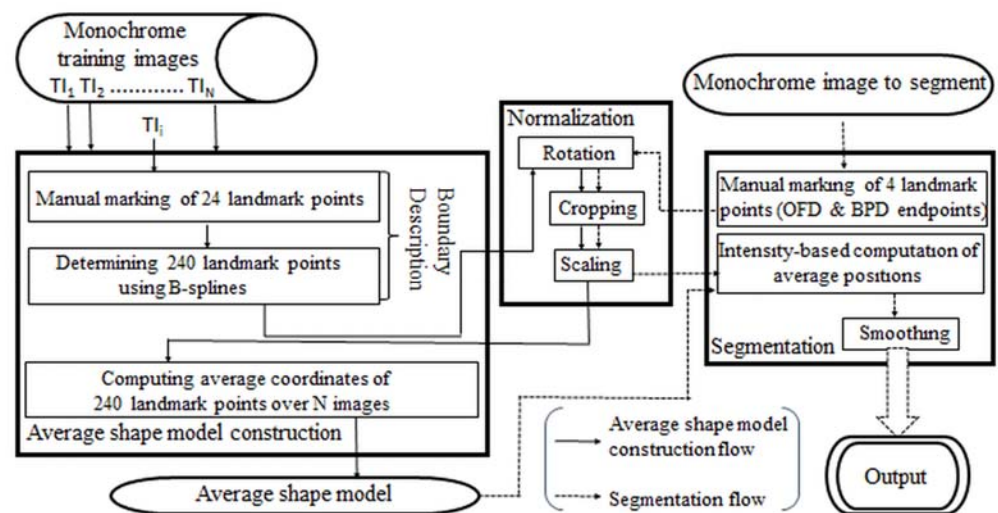


Figure A. Flowchart of the proposed segmentation scheme

Purpose:

This work proposes a heuristic approach attempting to segment fetal skull structures in ultrasound images. The objective of obtaining skull boundaries is to exploit them in automated prenatal diagnosis.

Theory and Methods:

An average shape model describing the coordinates of skull boundary points in a normalized frame is used to find true coordinates of sought points. The search process is based on a simple heuristic that uses linear neighborhoods around specific average shape model points and locates the output points based on the computation of a weighted average of coordinates depending on intensity distributions along neighborhoods. The process requires marking four landmark points manually on the ultrasound image to segment.

Results:

The results are presented on samples selected from a dataset containing 358 fetal skull images. Since the success of segmentation is evident from analysis processes that follow, the outputs are used in two distinct classifiers aiming to detect the presence of the spina bifida pathology in fetuses. The performances are convincing and are comparable to ground truth segmentations. Moreover, comparing segmentation outputs to ground truth images in terms of Dice coefficient values, indicates high visual similarity.

Conclusion:

A fully-automatic segmentation engine for fetal skulls in US images is an ultimate goal for automatic prenatal diagnosis. However, the proposed semi-automatic scheme requires a minimal effort and provides satisfactory results, both when the outputs are visually evaluated and when used as input to classifiers.



Fetal kafatası imgelerinin yarı-otomatik buluşsal bölütlenmesi

Umut Konur*

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 67100, Zonguldak, Türkiye

Ö N E Ç I K A N L A R

- Başvurulan bir ortalama şekil modelinin oluşturulması
- Yoğunluk değeri ağırlıklarına göre çevrit noktalarının konumlarını belirleme
- Spina bifida sinir tüpü kusurunun tanısında karşılaştırılabilir başarımlar

Makale Bilgileri

Araştırma Makalesi

Geliş: 06.04.2021

Kabul: 20.03.2022

DOI:

10.17341/gazimmfd.910514

Anahtar Kelimeler:

İmge bölütleme,
ortalama şekil modeli,
yoğunluğa-dayalı ortalama
konum bulma,
ultrason,
enine-kesit

ÖZ

Amaçları iyi-tanımlı görevlerle belirlenen ve genellikle otomatik uygulamalar için anlamlı olan imge bölütleme, ilgilenilen piksellerin çevrelerinden yalıtılmasını ele alır. Fazlalık ve hamlik nedenleriyle artık, yararsız ve hatta görev-zorlaştırıcı olabilen verinin basitleştirilip, derli toplu gösterimlerinin elde edilmesi ve yararlı özneliklerin çıkarılması gerekir. Bu çalışmada, enine-kesit fetal kafataslarını gösteren monokrom ultrason imgelerindeki kafatası çevritlerinin bulunması için buluşsal bir yaklaşım sunulmaktadır. Sürecin başında, kullanıcının girdi imgedeki kafatası çevriti üstünde az sayıda noktayı elle işaretlemesi beklenmektedir. Çevritlerin parlak piksellerden oluşması ve görüntüleme-kaynaklı bölütler arasında kopukluklar olmasından hareketle, buluşsal yöntem, ortalama şekil modeli ve yoğunluğa-dayalı ortalama konum bulma kavramlarından yararlanmaktadır. Örnek imgelerdeki sonuçlar temel doğru bölütlemeler ile karşılaştırıldığında, ortalama %96,5 benzerlik gözlemlenmektedir. Doyurucu olan görsel sonuçlar spina bifida tanısında girdi olduğunda da F-ölçüsü ve GMRP türünden daha iyi veya karşılaştırılabilir niteliktedir. Önerilen yöntem, belirli otomatik tanı sistemlerinde kolaylaştırıcı bir etken olabilecektir.

Semi-automatic heuristic segmentation of fetal skull images

H I G H L I G H T S

- Constructing an average shape model reference
- Locating boundary points based on intensity value weights
- Comparable performance on diagnosis of spina bifida neural tube defect

Article Info

Research Article

Received: 06.04.2021

Accepted: 20.03.2022

DOI:

10.17341/gazimmfd.910514

Keywords:

Image segmentation,
average shape model,
intensity-based computation
of average positions,
ultrasound,
transcerebellar

ABSTRACT

Image segmentation, whose objectives are set by well-defined tasks and which is generally significant for automatic applications, deals with isolating image pixels of interest. Data; which might be redundant, useless or even task-complicating due to amount and rawness, must be reduced, compact representations must be obtained and useful features must be extracted. In this work, a heuristic approach for detecting skull contours in monochrome ultrasound images displaying transcerebellar fetal skulls is described. At the start of the process, the user is expected to mark few points manually along the skull boundary on the input image. Due to the bright-pixels composition of skull contours and discontinuities between edge segments arising from imaging modality, the heuristic method utilizes the concepts of average shape model and intensity-based computation of average positions. The results on sample images, when compared to ground-truth segmentations, indicate a 96,5% similarity on average. When the visually-satisfactory outputs are used as inputs in diagnosis systems for spina bifida detection, either better or comparable results are obtained in terms of F-measure and GMRP. The proposed method is supposed to be a facilitative factor in certain automatic diagnosis systems.

1. Giriş (Introduction)

Sayısal bir imgeyi birden çok bölgeye ayırmak anlamına gelen imge bölütlemenin amacı, imge gösterimini basitleştirerek çözümlemesi daha anlamlı bir biçime dönüştürmektir. Bölütleme, yaygın olarak imgelerdeki nesnelerin, bölgelerin ve sınırların konumunu belirlemek için kullanılır [1]. Başka bir deyişle; imge bölütleme, aynı etikete sahip pikseller belirli ortak özellikler barındırırken, her piksele bir etiket atamadır. İmge bölütlemenin yararlı olduğu uygulamalara bir örnek, girdileri imgeler olan *sınıflandırma* [2] sistemleridir. İmgelerdeki ilgilenilen nesnelere bulmak, sonra iş görecektir öznel özellik çıkarımı ve sınıflandırma, program birimleri için bir gerekliliktir. Yapıların iyi modellenemediği basit durumlar dışında; imge bölütleme görüntü işleme ve bilgisayarla görme alanlarında henüz kesin çözümü bulunmayan en zor görevlerdendir. Genellikle öznel bir nitelik taşıyan bölütleme yöntemlerinin başarımı, izleyen aşamalarda çözümü görevlerinin başarımıyla ilişkilendirilir.


İmge bölütleme amacıyla kullanılan yöntemleri genel çerçevelere oturtmak zordur. Bununla beraber, yararlanılan temel özellikler piksel yoğunluklarının benzerlikleri ve komşu piksellerdeki yoğunluk süreksizlikleridir. Yoğunluk benzerliğine dayalı yöntemler, imgeyi önceden belirlenmiş ölçütlere göre kendi içinde *benzer* bölgelere ayırmayı hedefler. Eşikleme (thresholding) [3], arka plan çıkarma (background subtraction) [4], bölge büyüme (region growing) [5], bölge ayırma ve birleştirme (region splitting and merging) [6] yoğunluk benzerliklerinden yararlanan yaklaşımlardandır. Yoğunluk bilgisinin uzamsal düzende nasıl yer aldığından yararlanan dokuya dayalı (texture-based) yöntemler [7, 8] de bu grupta incelenebilir. Dokuya dayalı benzerlikler, pikseller arasındaki birebir yoğunluk benzerlikleri değil, birbirine yakın piksellerin oluşturduğu piksel gruplarının (bölgelerin) matematiksel olarak modellenen ortak özellikleri çerçevesindeki benzerliklerdir. Bu ortak özellikler de yoğunluk ve birbirine göre konum verisini kullanır. Süreksizliğe dayalı yöntemler, imgeyi komşu pikseller arasındaki beklenmedik yoğunluk değişimleri temelinde bölgelere ayırır. Kenar bulma (edge detection) [9] bu türden bölütlemenin odağındadır. Çoğu zaman, birden fazla ve olasılıkla farklı kategorilerden yöntemin beraber kullanılmasını bölütleme başarımı artırıldığı da görülmektedir. İki kategoriden hangisine ait olduğunu vurgulama kaygısı olmadan, ikisinden de yararlanabilen, yapay zekâ [10] ve yapay öğrenme [2] disiplinlerinden ayrı tutulamayacak birçok bölütleme yaklaşımından söz edilebilir. Piksel gruplarını bulma (clustering) [11, 12], renk ve yoğunluk gibi benzer özelliklere sahip piksellerin gruplara ayrılması işiyle çalışır. Çizge biçiminde örgütlenen pikselleri kullanıp, çizge kesme (graph cut) [13] yöntemleriyle bölgeleri belirlemek olasıdır. Bölütlemenin temel özellikleri birleştirilip biçimbilimsel (morphological) [14] yöntemlerden yararlanılabilir. Frekans alanı yöntemleri [15], derin öğrenme [16], önsel bilgiye güvenen model uydurma [17, 18], değişkenlik veya saçılım bulunan durumlarda biçimi bozulabilen görünüm modelleri (active appearance models) [19, 20] gibi yaklaşımlar bulunmaktadır. Model uydurmada eksik veri varsa, beklenti en büyüme (expectation maximization) [21] algoritmasıyla, yinelemeli adımlarda eksik verinin olasılığını en büyük duruma getiren parametre değerlerinin kestirilmesinde, eksik veri ve eldeki parametre değerleri kullanılarak eksiksiz veri için bir beklenti değerinin hesaplanması ve bu sürecin yakınsamaya kadar yinelenmesi yoluna gidilebilir. Son parametre değerleri, model uydurmada kullanılan eksiksiz verinin en iyi kestirimini hesaplamak için kullanılır.

Genel çerçevede ele alınan bölütleme yanında, tıbbi imgelerin bölütlenmesine ayrıca değinmek gerekir. Problemin ne olduğuna bağlı olarak değerlendirilen bölütleme görevleri, tıbbi imgeler açısından hedeflenen uygulamanın başarımı beklenenler ışığında


değerlendirilmelidir. Bölütlenen yapıların ne olduğu ve görüntüleme tekniklerinin çeşitliliği de bilindiğinde, her bir belirli yöntem veya uygulama ayrı ele alınmalıdır. Böyle bakıldığında, sunulmuş olan yöntemler çok sayıdadır. Yapay öğrenmeye [2] dayalı yöntemlerde, yalnızca imgeye ait yapının kullanıldığı *öğreticisiz* ve öğrenme örneklerinden yararlanarak imge işleme görevine eldeki veriyi katan *öğreticili* yöntemlerden söz edilebilir. İmge bölütlemenin de içinde yer aldığı tıbbi imge çözümleme görevlerine, son yıllarda, *derin öğrenme* (*deep learning*) yöntemlerinin uygulanması [16, 22] eğilimi gözlenmektedir. Yineleyen sinir ağlarının (*recurrent neural networks (RNN)*) prostat bölütleme için uygulanması [23] ve evrimsel sinir ağlarının (*convolutional neural network (CNN)*) göğüs imgelerinin bölütlenmesinde kullanımı [24], ultrason (US) görüntüleme ile edinilen tıbbi imgelerin bölütlenmesine ilişkin örneklerdir. Kafatasları özelinde bakıldığında, üç boyutlu US ile edinilen fetal kafatası imgelerinin bölütlenmesinde bağlamsal ve yapısal bilgiyi de sürece koyan iki-aşamalı CNN ile çalışan yöntem [25] derin öğrenme yaklaşımlarından bir diğeridir. Kolonoskopi video çerçevelerinde görüntülen poliplerin bölütlenmesi için sunulan yöntemde [26], poliplerin sıradüzensel özellikleri tam evrimsel sinir ağı ile öğrenilmekte ve polip sınırlarına ilişkin içerik bilgisi dokuya dayalı gösterimle modellenmektedir. Derin öğrenme yöntemlerinin yanı sıra, tıbbi imgelerin bölütlenmesi için önerilen ve daha alışlageldik kavramlardan yararlanıp diğer farklı yaklaşımlarla iş birliği içinde çalışan yöntemler de bulunmaktadır. US göğüs imgelerinin bölütlenmesi üzerine bir tarama sunan çalışma [27]; ele alınan yöntemleri eşikleme, gruplama, su havzası (watershed) [14, 28], çizge, aktif çevrit [29], Markov rassal alan [30] ve sinir ağları [31] tabanlı olarak sınıflandırmaktadır. Morfolojik işlemler, piksel çıkarma, eşiklemeye dayalı bölütleme ve imge süzme araçlarından yararlanarak beyin ur yapılarının çevre dokulardan ayrılması [32], otomatik bir başlangıç noktası seçiminin sonra temelde bölge büyütmeye güvenerek akciğer lezyonlarının çıkarılması [33], tıbbi imge çözümlemesinde kenarlara dayalı aktif çevrit modellerinin kullanılması [34], karaciğerde bulunan kötücül urların bilgisayarlı tomografi (CT) imgelerinden bulanık bir ölçek-kernel (scale-kernel) gruplama çerçevesinde belirlenmesi [35], karın bölgesinin karşıtlığı (contrast) iyileştirilmiş CT taramalarında böbrek ve korteks dokusunun belirlenmesi amacıyla geliştirilen model-tabanlı yaklaşım [36] anılabilecek sistemlerin örnekleridir. Kısaca, tıbbi imgeleri bölütleme yöntemlerinin; hangi doku veya organı çıkarmayı hedeflediği, kullanılan görüntüleme tekniği, yetecek başarımlı düzeyi gibi farklı yönlerden çeşitlenmeleri çok sayıdadır.

Bu çalışmadaki fetal kafataslarını bölütleme probleminin bağlamı da dikkate alınarak, bölütleme yaklaşımları, süreçte insan katkısı olup olmamasına bağlı olarak *yarı-otomatik* ve *tam-otomatik* olarak sınıflandırılabilir. Tam-otomatik bölütleme gerçekleştiren yöntemlerin, girdi imgeyi hiçbir aşamada insan girişimine gereksinim duymadan bölütleyip çıktıyı üretmesi beklenir. Ne yazık ki, birçok durum için bu kolay değildir, çünkü girdi imgeler boyut, konum, yönelim, poz gibi özellikler bakımından farklı koşullarda alınmakta ve nirengi noktalarının otomatik biçimde edinilememesi nedeniyle hizalanmaları da otomatik olarak yapılamamaktadır. İmgelerde bulunduğu varsayılan nirengi noktalarına ait modellenen ortak bir özelliğin bulunması, her imgede en az bir tane böyle noktanın seziminin yapılarak sonraki bölütleme girişimlerinin de otomatik yollara güvenmesini sağlayabilirdi. Ele alınan enine-kesit fetal kafatası imgelerini bölütleme probleminde, deneyimlerin gösterdiği kadarıyla, bu türden ortak bir özellik bulunmamaktadır. Şekil 1 ve Şekil 2, biçim ve görünüm yönlerinden farklılıklar içeren enine-kesit fetal kafatası imgelerini ikili gruplar olarak göstermektedir.

Tam-otomatik bölütlemenin zor olduğu durumlarda, en az insan etkileşimi gerektirmesi hedefiyle yarı-otomatik bölütleme de bir




Şekil 1. Konumları farklı olup denk düşen nirengi noktaları (Corresponding landmarks with different positions)



Şekil 2. Yoğunlukları farklı olup denk düşen nirengi noktaları (Corresponding landmarks with different intensities)

çözüm olarak dikkate alınabilir. US görüntüleme ile edinilen monokrom enine-kesit imgelerden yarı-otomatik bölütleme ile fetal kafataslarının çevritlerini çıkarma probleminin çözümünü içeren buluşsal süreç şöyle ortaya konmaktadır: Girdi bir imge verildiğinde, kullanıcı kafatası çevriti üstünde dört nokta işaretler. Bu noktaların ikisi oksipitofrontal çapın (OFD) iki ucu ve diğer ikisi biparyetal çapın (BPD) iki ucudur Şekil 3, enine-kesit bir fetal kafatası imgesinde bu boyutları göstermektedir.



Şekil 3. Oksipitofrontal çap ve biparyetal çap (Occipitofrontal diameter and biparietal diameter)

Dört nokta işaretlendikten sonra, bölütleme yapan sistem, kafatası çevriti üstünde her komşu noktalar çiftinin eşit aralıklı olduğu sabit sayıda nokta belirlemek üzere koşar. Noktaların belirlenmesi sürecinde; başvuru bir ortalama şekil modeli kullanılmakta ve bölütlemenin çıktısı olan her nokta, ortalama şekil modeline ait noktaların yakın komşuluklarındaki noktalar arasında yoğunluğa-

dayalı ortalama konum bulma ilkesiyle aranmaktadır. Ortalama şekil modelini elde ederken; imgelerden oluşan bir veri kümesi kullanılıp, bütün imgelerdeki ilgililenen noktalar işaretlenmekte ve işaretlenmiş bütün imgeler önışleme gerçekleştirilip düzgelenmiş bir çerçeveye dönüştürüldükten sonra ortalama nokta koordinatları bulunmaktadır. Düzgelenmiş imgeler; geçerli parametre değerleri kullanılarak imgelerin ötelenmesi (veya kırılması), döndürülmesi, ölçeklenmesi ve sonuçta ortak bir çerçevede kayıtlanması ile elde edilir.

Bölütleme aracını koşturmadan önce dört noktanın işaretlenmesi, işaretlenen hangi noktanın hangi nirengi noktasına karşılık geldiğinin bilinmesini gerektirmemekte ve bu çıkarım bölütleme aracına bırakılmaktadır. İşaretlemenin herhangi bir sırada yapılabilmesine karşın, başarılı çıktılar elde etmenin olmazsa-olmaz koşulu, kullanıcının hangi sırada olursa olsun bu dört noktanın konumunu el ile olabildiğince doğru işaretlemesidir.

Makalenin sonraki bölümünde, önerilen buluşsal bölütleme yönteminin aşamaları farklı başlıklar altında açıklanmaktadır. Takip eden bölümlerde, örnek imgeler için bölütlemeler gösterilmekte, bölütleme çıktılarının temel doğru (ground truth) bölütlemeler ile benzerliği nicel olarak ortaya konmakta, aynı çıktılarının doğum öncesi dönemde spina bifida patolojisini saptamak için tasarlanan otomatik tanı sistemlerinde [37, 38] kullanılmasının başarımı yine temel doğru bölütlemeler ile karşılaştırılmakta ve sonuçlara varılmaktadır. Önerilen buluşsal yöntemin anılan türden otomatik tanı sistemlerinde kolaylaştırıcı bir etken olması beklenmektedir.


2. Önerilen Yöntem (The Proposed Method)

İlgilenilen bölütleme problemi, enine-kesit kafataslarını görüntüleyen US imgelerindeki kafataslarının çevritlerinin belirlenmesi olarak tanımlanabilir. Hedeflenen, her birinde yalnız bir kafatası görüntülenen imgelerde kafatası çevritinin, görüntüleme hangi

ölçekte ve söz konusu çevrit hangi yönelimde olursa olsun, sabit sayıda, sıralı, çevritin bütünü gösteren ve eşit aralıklı ardışık pikseller olarak belirlenmesidir. Geliştirilen yöntemde başarılması gereken görevlerin düzgelenmiş çerçevelerde yapılması tasarlanmıştır. Düzgelenmiş çerçevelerde, her imgedeki söz konusu kafatası çevriti aynı ölçüğe ve aynı yönelime dönüştürülmüş olmalıdır. Önerilen yöntemde iki ana görev bulunmaktadır: 1) Örnek imgeler ile bir ortalama şekil modeli elde etme, 2) Ortalama şekil modelinden ve girdi bir imgede el ile işaretlenen dört noktadan yararlanarak, yoğunluğa-dayalı ortalama konum bulma ilkesini kullanıp bölütleme çıktısı olan 240 noktanın konumlarını bulma. Noktaların sayısının 240 sabit değeri örnekleme sıklığı olarak uygun bulunan bir tasarım tercihidir. İlk görev, bir kere çevrim dışı yapılmakta ve koşma zamanı karmaşıklığına yol açmamaktadır. Betimleyici bir modelin yapımında, 240 noktası işaretlenerek açıklanmış olan imgelerden oluşan bir veri kümesi kullanılmaktadır, ancak bu zorunlu değildir. Tasarımcılar kendilerinden emin olduklarında, ortalama şekil modeli dışarıdan verilen hazır bir model de olabilir.

2.1. Ortalama Şekil Modelinin Oluşturulması (Construction of the Average Shape Model)

Her örnek imge için, kafatası çevriti üstünde bulunan 240 nokta belirlenir. Bu 240 noktayı elle belirlemek elverişsiz olduğundan; kafatasının ön ucundan başlayarak, saat yönünde ilerleyerek ve eşit aralıklar takip ederek, ön uç noktadan saatin tersi yönünde bir aralık geride olan noktaya varana kadar, 24 nokta işaretlenir. Kafatasının ön ucu, OFD'nin iki ucundan kafatasının önünde olanıdır. Eşit aralıkların "eşitliğini" işaretlemeyi yapmanın algısı belirler. Ardışık işaretlenen her iki nokta arasında yaklaşık olarak eşit aralık olmasına ve kafatasının tanımlayıcı noktalarının çevritlerin izinin sürülmesindeki doğru adımlarda işaretlenmesine dikkat edilir. Tanımlayıcı olan 4 nokta OFD ve BFD'nin uç noktalarıdır. İşaretleme süreci belirtik olarak örneklenirse; kafatasının ön ucu ilk, sağ ucu yedinci, arka ucu on üçüncü ve sol ucu on dokuzuncu adımlarda işaretlenir. 24 noktanın işaretlenmesinden sonra, işaretlenme sırası bakımından birbirine komşu olan her iki nokta arasında, dokuz nokta daha kübik B-egirileri (cubic B-splines) [39] ile belirlenir. Böylece, çevrit $24 + 24 \times 9 = 240$ nokta ile tanımlanır. Şekil 4, çevritindeki noktaların 24'ü elle işaretlenen ve 240 noktayla tanımlanan bir fetal kafatası imgesini göstermektedir.



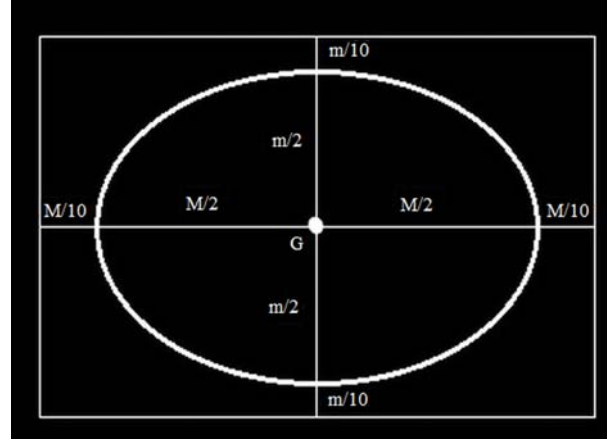
Şekil 4. 240 noktayla tanımlanan kafatası çevriti
(Skull contour described by 240 points)

2.1.1. Düzgeleme (Normalization)

Bir imge 240 noktası işaretlenerek açıklandıktan sonra, kafatasını düzgelenmiş bir çerçevede göstermek için gereken adımlar sırasıyla

uygulanır. Düzgeleme için gerçekleştirilen eylemlerin sıralı listesi şöyledir:


- Açıklanan imge I , OFD'nin iki uç noktasını birleştiren çizginin imge düzleminin yatay eksenine paralel olması için döndürülür. Sonuç imge I_r 'dir.
- İmgenin gereksiz bölümlerini atmak için, I_r kırpılır. I_r 'deki OFD'nin uç noktalarını birleştiren doğru parçasının uzunluğu M ile ve BPD'nin uç noktalarını birleştiren doğru parçasının uzunluğu m ile gösterilirse, kırpma ile yatay uzunluğu $1,2 \times M$ ve dikey uzunluğu $1,2 \times m$ olan bir I_{rc} imgesi elde edilir. M ve m sırasıyla bir elipsin ana eksen ve küçük eksen uzunlukları olarak algılanabilir. I_{rc} kafatasının bütün çevritini içerir, sola ve sağa M 'nin %10'u kadar, yukarı ve aşağı m 'nin %10'u kadar uzar. Şekil 5'te, varsayımsal bir çevrit için kırpma gösterilmektedir.
- Ortalama bir model, büyüklüğü aynı olan imgelerle oluşturulur. Bu yüzden, I_{rc} 'nin büyüklüğü standart bir büyüklüğe ayarlanır (imgenin yatay ve dikey boylarında ölçekleme yapılır). Gerçeklemede, I_{rc} 'nin yatay uzunluğu 228, dikey uzunluğu 200 piksel olarak seçilmiştir. Bu sayılar, ortalama bir durumda, ana eksen uzunluğu M 'nin küçük eksen uzunluğu m 'ye oranını iyi yaklaşılmamaktadır. Sonuç imge I_{rcs} 'dir.



Şekil 5. Kırpma: döndürülmüş bütün imge I_r ve beyaz dikdörtgenle çevrelenen kırpılmış imge I_{rc}
(Cropping: rotated whole image I_r and cropped image I_{rc} surrounded by the white rectangle)

Gerçek durumlarda, I_{rcs} 'nin 180 derecelik açıyla saat yönünde veya saatin tersi yönde döndürülmüş biçimi ve I_{rcs} ile döndürülmüş biçiminin simetrik biçimleri ile karşılaştırılabilir. Biyolojik süreçteki kafatası oluşumunda ve görüntü ediniminde, sol ve sağ ile ön ve arka arasında yanlılık/öncelik/fark bulunmadığı için, sözü edilen çeşitlemeler olanaklıdır. Ortalama model oluşumunda kullanılmak üzere, I_{rcs} 'nin bütün bu çeşitlemeleri elde edilir. Bu adımdaki çıktılar, düzgelenmiş imgenin kendisi olan $I_{rcs}^1 = I_{rcs}$, I_{rcs}^1 'nin 180 derece döndürülmüş biçimi olan I_{rcs}^2 , I_{rcs}^1 'nin simetriği veya ayna görüntüsü olan I_{rcs}^3 ve I_{rcs}^2 'nin ayna görüntüsü olan I_{rcs}^4 'dir. Şekil 6, Şekil 4'teki imgenin düzgelenmiş biçiminin I_{rcs}^1 , I_{rcs}^2 , I_{rcs}^3 ve I_{rcs}^4 çeşitlemelerini göstermektedir.

Veri kümesindeki bir imge için düzgeleme adımlarını koşarken, açıklanan noktaların x ve y koordinatları, düzgeleme eylemlerinin sonuçlarını yansıtması için ayarlanmaktadır. Bu ayarlamalar, nokta koordinatlarını veya nokta indislerini güncellemek biçimindedir. Örnek olarak, I_{rcs}^1 'nin indisi 1 olan noktası I_{rcs}^2 'nin indisi 121 olan noktası olur. Bunun gibi, I_{rcs}^1 'nin indisi 61 olan noktası I_{rcs}^2 'nin indisi 181 olan noktası olur. Başka bir örnek, I_{rcs}^1 'nin indisi 10 olan noktasının I_{rcs}^2 'nin indisi 112 olan noktası olmasıdır.



Şekil 6. Şekil 4'teki imgenin dört çeşitlemesi: I^1_{res} (a) I^2_{res} (b) I^3_{res} (c) I^4_{res} (d)
(The four variations of the image in Figure 4: I^1_{res} (a) I^2_{res} (b) I^3_{res} (c) I^4_{res} (d))

Düzgeleme işlemi N tane imge üzerinde uygulandıktan sonra, ortalama şekil modeli I_{avg} düzgelemenin $4N$ tane çıktısı kullanılarak oluşturulabilir. Yapım, basit olarak, 240 model noktasının her birinin x_i ve y_i koordinatlarını bulmak için $4N$ tane nokta kullanılarak ortalamaların hesaplanmasıyla gerçekleştirilir. $1 \leq i \leq 240$ ve $1 \leq j \leq 4N$ olmak üzere ve x_{ij} ile y_{ij} i . noktanın j . imgedeki x ve y koordinatlarını gösterirken, ortalama model Eş. 1'deki gibi oluşturulabilir:

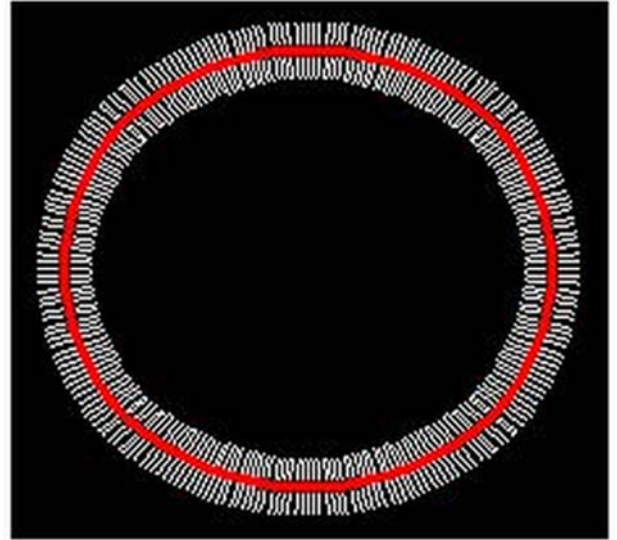
$$x_i = \sum_{j=1}^{4N} x_{ij} / 4N \quad \text{ve} \quad y_i = \sum_{j=1}^{4N} y_{ij} / 4N. \quad (1)$$

Ortalama şekil modeli oluşturulduktan sonra ve piksel sayısı, yatay ve dikey imge uzunlukları bağlamalarında aynı boyutlara sahip bir imgeyi bölütleme için kullanılmadan önce, oluşturulan modelin ağırlık merkezi ve her bir model noktasından geçen doğrular dikkate alınır. 240 model noktasının her biri için, bölütleme sonucu olarak çıkarılacak uygun piksel, merkezi model noktasının kendisi olan ve iki uç noktasının konumları arasındaki Öklid uzaklığı [1] 20 olan doğru parçası üstünde aranacaktır. Doğru parçaları üstündeki noktaların konumları, karşılık gelen piksel koordinatlarının en iyi tamsayı yaklaşımları olarak alınır. Bölütlemeye, doğru parçalarının üstündeki piksellerin yoğunluk dağılımları kullanılır. Şekil 7, eldeki $N = 358$ imgenin $4 \times 358 = 1432$ çeşitlemesi ile hesaplanan ortalama şekil modeli I_{avg} 'yi ve model noktalarından geçen doğru parçalarını göstermektedir.

2.2. Bölütleme (Segmentation)

Bölütleme görevi, bir kafatası çevritini belirlemek üzere bir I imgesi girdi olduğunda, I daki kafatası çevritini belirleyen 240 sıralı ve eşit aralıklı noktayı bulup kapalı bir eğri veya bu eğrinin çevrelediği bölge olarak çıktılacaktır. Bölütlemeye, ana başlıklar olarak görüntü önışleme, yoğunluğa dayalı ortalama konum bulma ve düzeltirmeden yararlanılmaktadır. Yapılanlar, özellikle girdi I imgesinin düzgelemiş çerçeveye dönüştürülmesi sürecinde, ortalama şekil modelinin oluşturulmasında uygulanan işlemlere benzemektedir.


Düzgeleme sırasında uygulanan görüntü önışleme, az sayıda noktanın elle işaretlenmesi ve ilgilenilen bölgenin (region of interest) belirlenmesi, standart büyüklüğe ayarlama (ölçekleme) ve kafatası yöneliminin sabitleştirilmesinden (döndürme) oluşmaktadır. Önışleme sonucunda ortama şekil modeliyle kayıtlanmış (hızalanmış) girdi elde edilir.



Şekil 7. 240 noktalı ortalama şekil modeli ve piksel yaklaşımlarıyla denk düşen doğru parçaları
(Average shape model with 240 points and corresponding line segments with pixel approximations)

Üst veri (meta data) olarak elde bir ortalama şekil modeli bulunması gereken bölütlemeye, kullanıcının girdi I imgesi üzerinde, konumları yaklaşık olarak I daki fetal kafatasına ait OFD'nin iki uç noktası ve

BPD'nin iki uç noktası olan dört noktayı işaretlemesi beklenir. Noktaların işaretlenme sırası önemli değildir, çünkü bölütleme öncesi uygulanan önişleme, işaretlenen noktalara doğru rollerin atanmasını da sağlar. Şekil 8'de, dört noktanın işaretlenmesine bir örnek gösterilmektedir. Doyurucu bölütleme için, noktalar en az hata ile işaretlenmelidir.



Şekil 8. Yarı-otomatik bölütlemde 4 noktayı işaretleme (Marking 4 points in semi-automatic segmentation)


Önişleme ile düzgelemenin gerçekleştirilmesi, sonrasında bu imgeye ait noktalardan ortalama şekil modelindeki 240 noktanın konumlarının komşuluğundaki uygun noktaların yoğunluğa dayalı ortalama konum bulma ilkesiyle belirlenmesi, en sonunda da bulunan 240 nokta üzerinde düzleştirme uygulanmasıyla bölütleme çıktısı noktaların konumları bulunur. Bölgeler kapalı ve sürekli eğrilerle gösterildiğinden, 240 sıralı noktadaki ardışık noktalardan oluşan nokta çiftleri doğru parçalarıyla birleştirilir ve aranan kafatası bölgesi elde edilir.

2.2.1. Önişleme (Preprocessing)

I imgesini ortalama şekil modeli I_{avg} ile aynı boya getirmek ve I_{avg} 'nin çerçevesiyle hizalamak için, model oluşturma sırasında noktaları işaretlenerek açıklanmış imgelerden oluşan veri kümesindeki her imgeye uygulanan işlemlerin aynısı I' ya da uygulanır. Düzgeleme işlemi; döndürme, kırma ve ölçeklemeden oluşmaktadır. Dönme açısını belirlemek, işaretlenen dört noktadan hangi ikisinin I' 'daki kafatası bölgesine karşılık gelen kaba elipsin ana ekseninin, bir başka deyişle OFD'nin, uç noktaları olduğunu belirlemeyi gerekli kılar. Bu belirlemeyi yaparak doğru dönme açısını bulmak için sırasıyla yapılması gerekenler şunlardır:


- İşaretlenen dört P_1, P_2, P_3, P_4 noktasının; iki noktayı bir gruba, kalan iki noktayı da başka bir gruba koyan bütün olası gruplamaları için, iki gruptaki noktalar $\{P_A, P_B\}$ ve $\{P_C, P_D\}$ ile tanımlanan iki doğru olan L_1 ve L_2 bulunur. L_1 ve L_2 'nin kesişim noktası Q bulunur. $d_{AQ}, d_{BQ}, d_{CQ}, d_{DQ}, d_{AB}$ ve d_{CD} alt indislerin ifade ettiği noktalar arasındaki doğrusal uzaklıkları gösterebilir.
- a. $d_{AQ} + d_{BQ} = d_{AB}$ ve $d_{CQ} + d_{DQ} = d_{CD}$ ise Q 'nun doğru merkez olduğuna karar verilir ve (ii)'ye geçilir.
- b. Aksi durumda, (i) adımı başka bir gruplama ile yinelenir.
- $d_{AB} > d_{CD}$ ise, $[P_A P_B]$ 'nin ana eksen ve $[P_C P_D]$ 'nin küçük eksen olduğuna karar verilir.
- Aksi durumda, $[P_C P_D]$ 'nin ana eksen ve $[P_A P_B]$ 'nin küçük eksen olduğuna karar verilir.
- Ana eksenin yönelimi kullanılarak, dönme açısı θ hesaplanır.

Şekil 9, L_1 ve L_2 doğrularını, kafatası merkezi olarak değerlendirilen kesişme noktası Q 'yu ve dönme açısı θ 'yu göstermektedir. I, θ açısı kullanılarak döndürülür ve kafatasının ana eksenini, imge düzleminin yatay eksenine hizalanır. Döndürme, kafatasının ön ucunun sola ve arka ucunun sağa ya da tam tersi konumlanması sonucunu doğurabilir. Bunun bir önemi yoktur, çünkü ortalama şekil modelinin oluşturulmasında izlenen adımlar döndürme ve ayna görüntüsü durumlarından ortaya çıkabilecek iki olasılığı da ele almaktadır.



Şekil 9. Şekil 8'deki imgenin dönme açısı θ (The rotation angle θ of the image of Figure 8)

Döndürmeden sonra, kırma ve ölçekleme de ortalama şekil modelinin üretilmesinde benzer olarak uygulanır. Elde edilen imge I_{imp} , 200 x 228 büyüklüğündedir. Şekil 10, Şekil 8'deki imgenin düzgelmesiyle elde edilen I_{imp} imgesini göstermektedir.



Şekil 10. Şekil 8'deki imge için bölütleme girdisi I_{imp} (The segmentation input I_{imp} for the image of Figure 8)

2.2.2. Yoğunluğa-dayalı ortalama konum bulma (Intensity-based computation of average positions)

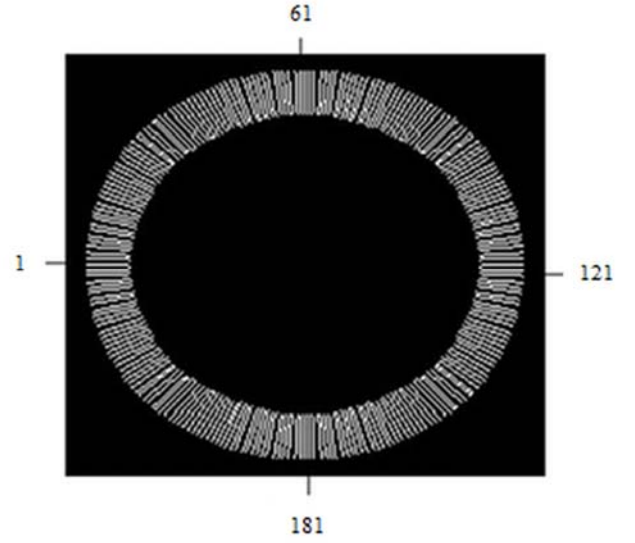
Bölütlemde yapılması gereken, her biri ortalama şekil modelinin oluşturulması sürecinde belirlenen 240 farklı doğru parçası üstündeki 240 farklı noktayı bulmaktır. Doğru parçaları ve aranan noktalar arasında birebir bir eşleşme bulunmaktadır. Kısaca, her doğru

parçasına ait bir ve yalnız bir nokta vardır. Buluşsal bölütleme yöntemi, bir doğru parçası üstündeki noktayı belirlemek için doğru parçası boyunca var olan piksellerin yoğunluk dağılımını ele alır ve ilgili doğru parçasının bütün piksellerindeki yoğunluk değerleri temelinde yapılan bir ağırlıklandırma ile aranan pikselin konumunu bulur. Tümü yapılan deneylerle görsel olarak doğrulanmış olan bölütleme süreci boyunca geçerli olan olgular, kararlar ve varsayımların listesi şöyledir:

- Doğru parçalarının orta noktalarına denk düşen pikseller model noktalarına denk düşen piksellerdir.
- Model noktalarına denk düşen doğru parçalarının uzunlukları 20'dir. Bu sayı, doğru parçası boyunca var olan piksellerin sayısı değil, doğru parçasının iki uç noktası arasındaki Öklid uzaklığıdır. Bir doğru parçasının üstündeki piksel sayısı, imge eksenlerine dik veya yatay olunan durumlarda, en çok 21'dir.
- Doğru parçalarının altındaki doğrular, ortalama şekil modelinin merkezi ve bir model noktasından geçer.
- Bölütleme sırasında belirleyici etkenler olarak, doğru parçalarının üstündeki piksellerin bütün yoğunlukları kullanılmaz. Herhangi bir pikselin yoğunluğu bir eşik değeri τ 'dan küçükse, değeri 0 yapılır ve pratikte bölütlemenin çıktılacağı nokta konumlarını belirlemede etkiye sahip değildir.
- Eşik değeri τ , Otsu [40] tarafından önerilen ve gri-düzyer imgelerin histogramlarını kullanan yöntemle belirlenir. τ 'nın hesaplanmasında, I_{inp} imgesine ait olan ve konumları söz konusu 240 doğru parçasının tümünün üstündeki piksellerle örtüşen piksellerin yoğunluk değerlerinin tümü beraber kullanılır. τ , bir imgenin değerlendirilecek bütün doğru parçaları için sabit bir değerdir.

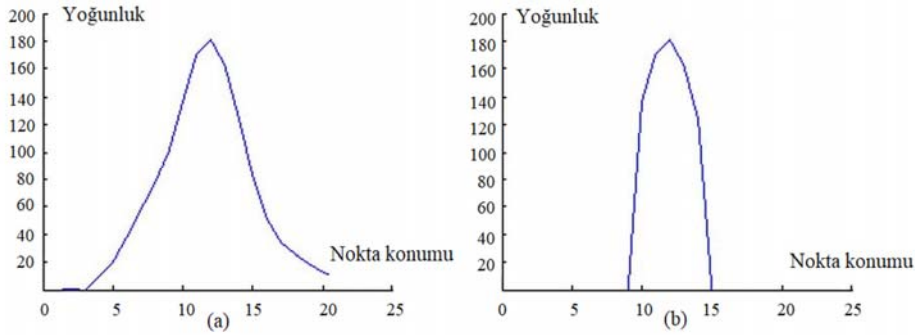
Şekil 11, ortalama şekil modelinin doğru parçalarını gösteren ikili imgedir. OFD'nin ön uç ve arka uç noktaları ile BPD'nin üst uç ve alt

uç noktalarının indisleri de belirtilmektedir. Numaralama, saat yönünde artan bir sıra izlemektedir.

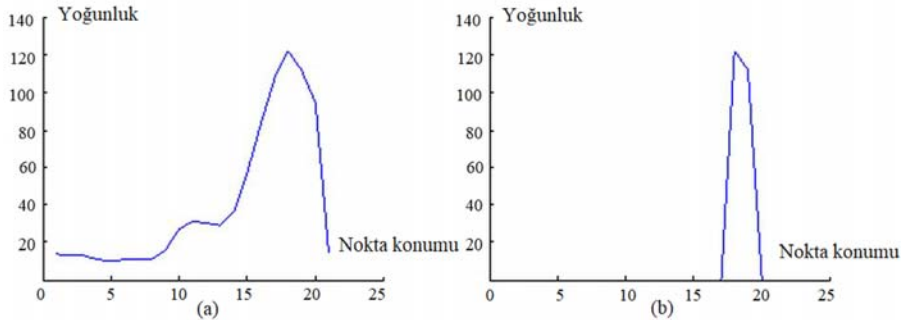


Şekil 11. Doğru parçalarının ikili imgesi ve indisleme (Binary image of line segments and indexing)

Şekil 12 ve Şekil 13'te, sırasıyla, Şekil 10'daki imgenin iki farklı doğru parçası üstündeki ilk ve bazı değerler eşiklemeden sonra çıkarılmasıyla elde edilen eşik-basitleştirilmiş yoğunlukları gösterilmektedir. Şekil 14'te, düzgelennmiş bir imge ve eşik değerini geçen piksel olmayan 1. doğru parçası üstündeki yoğunluklar görülmektedir.



Şekil 12. Şekil 10'daki imgenin 1. doğru parçasının ilk (a) ve eşik-basitleştirilmiş (b) yoğunlukları, $\tau = 111$ (Original (a) and threshold-simplified (b) intensities of line segment 1 of the image of Figure 10, $\tau = 111$)



Şekil 13. Şekil 10'daki imgenin 50. doğru parçasının ilk (a) ve eşik-basitleştirilmiş (b) yoğunlukları, $\tau = 111$ (Initial (a) and threshold-simplified (b) intensities of 50th line segment of the image in Figure 10, $\tau = 111$)

Bir doğru parçası üstündeki gerçeğe olabildiğince yakın bir bölütleme noktasını belirlemede kullanılan sezgisel yaklaşımda, ağırlıklar doğru parçası boyunca yer alan piksellerin yoğunlukları olmak üzere, bu piksellerin konumlarının ağırlıklı ortalaması hesaplanır. Eşik değeri τ 'nın altındaki yoğunluklar sıfır alınır. Burada *konum* kavramıyla ifade edilen gerçek piksel koordinatları değil, dikkate alınan doğru parçası üstündeki piksellerin indisi olan tamsayılardır. Örneğin, bir doğru parçasında 21 piksel varsa, piksel indisleri i , $1 \leq i \leq 21$ koşulunu sağlar. Bütün konumlar, her doğru parçası için gerçek piksel koordinatlarıyla eşlenmiştir. Gerçekleme, hangi konum indisinin hangi piksel koordinat çiftine (x, y) eşlendiğinin izini sürebilmektedir.

Bir noktanın *kesin* konumu; L olası konumların sayısını, i konum indisini, i_{seg} bölütlemenin çıktısı olan konum indisini ve $f(i)$ de i konumundaki pikselin gerçek yoğunluk değeri $I(i)$ 'nin Otsu'nun yöntemi [40] ile belirlenen τ eşik değerine göre Eş. 2'deki gibi tanımlı eşik-basitleştirilmiş yoğunluğunu gösterirken, Eş. 3'teki gibi hesaplanır:

$$f(i) = \begin{cases} I(i) & I(i) \geq \tau \text{ ise} \\ 0 & I(i) < \tau \text{ ise} \end{cases} \quad (2)$$

$$i_{seg} = \frac{\sum_{i=1}^L i \cdot f(i)}{\sum_{i=1}^L f(i)} \quad (3)$$

i_{seg} tamsayı olmazsa; $1 \leq i_{seg} \leq 21$, $i_{seg} \in Z$ koşullarını sağlayan doğru erimdeki bir değere yuvarlanır. Ayrıca, Şekil 14'teki örnekteki gibi bütün $f(i)$ değerleri sıfır olursa, ilgili doğru parçasının orta noktası, başka bir deyişle ortalama şekil modelinin denk düşen noktası, i_{seg} konumu olarak seçilir. Son olarak, i_{seg} konumundaki piksel, bölütlemenin çıktılacağı nokta olarak işaretlenir. Söz konusu işlem, 240 doğru parçasının tümü için yinelenir.

2.2.3. Düzleştirme (Smoothing)

Buluşsal yöntem, her bir nokta için çalışmakla birlikte, bütün komşu nokta çiftlerini düz çizgilerle bağlayarak son bölütleme sonucu olan

kafatası çevritine veya çevrelenen bölgeye ulaşmadan önce, yapılması gereken bir iş daha bulunmaktadır. Çıkarılan noktalar hem görsel olarak hem de makine uygulamaları için uygun olan, yeterince düzgün bir çevrite karşılık gelmemektedir. Bulunan 240 noktanın piksel koordinatlarını ayarlayan bir *düzleştirme* işlemi uygulanır ve sınır düzleştirilmiş noktalarla oluşturulur. Amaç doğrultusunda, bütün noktaların x ve y koordinatlarında 11 boyunda bir yürüyen ortalama penceresi (moving average window) koşut olarak çıktılar yuvarlanır. Şekil 15'te, düzleştirme yapmadan önce ve yaptıktan sonra, Şekil 10'daki imge için çıktılanan noktalar görülmektedir. Şekil 16'da bulunan çevritle çıkarılan bölge, Şekil 10'daki girdinin üstüne yerleştirilmiştir.

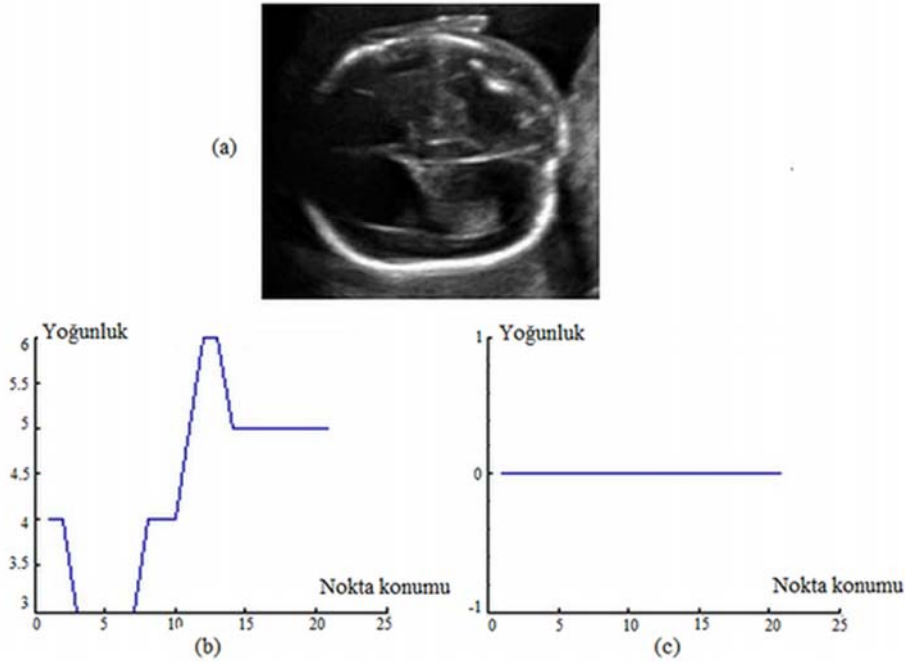
3. Deneysel Sonuçlar (Experimental Results)

Ana hatlarıyla bir ortalama şekil modelinin kullanımı ve yoğunluğaya dayalı ortalama konum bulma ile çalışan, alışlageldik imge işleme yöntemlerinden yararlanan buluşsal bölütleme yönteminin düzleşenmiş örnek girdi imgelerden elde ettiği sonuçlar Şekil 17'de görülmektedir. Ortalama şekil modelinin oluşturulması için İstanbul Üniversitesi İstanbul Tıp Fakültesi Kadın Doğum ve Jinekoloji Kliniği'nin ve Trakya Üniversitesi Tıp Fakültesi Kadın Doğum ve Jinekoloji Kliniği'nin sağladığı 358 enine-kesit US fetal kafatası imgesi kullanılmıştır. Sonuçlar, bu imgelerden seçilen örneklerde gösterilmektedir.


Görsel olarak doyurucu olan sonuçların başarımını nicel olarak ortaya koymanın bir yolu Sorensen-Dice [41, 42] indeksi veya Dice benzerlik indeksi veya kısaca Dice katsayısı olarak bilinen bir ölçüyle iki veri kümesi arasındaki benzerliği ölçmektir. Bu ölçüde iki veri kümesindeki eleman sayısı ve ortak bulunan elemanların sayısı dikkate alınmaktadır. X ve Y aralarındaki benzerlik ölçülmek istenen iki kümeyi göstermek üzere, Dice katsayısı D Eş. 4'teki gibi hesaplanır:

$$D = 2 \cdot |X \cap Y| / (|X| + |Y|) \quad (4)$$

Bölütleme probleminde X bir girdi imgesi için temel doğru bölütleme imgesindeki bölge piksellerini, Y de buluşsal bölütleme ile elde edilen




Şekil 14. Girdi imgenin (a) 1. doğru parçasının ilk (b) ve eşik-basitleştirilmiş (c) yoğunlukları, $\tau = 103$ (Original (b) and threshold-simplified (c) intensities of line segment 1 of the input image (a), $\tau = 103$)



Şekil 15. Şekil 10'daki imge için düzleştirme öncesi (a) ve sonrası (b) çıktılanan noktalar (Output points of the image in Figure 10 before (a) and after (b) smoothing)

sonuçtaki bölge piksellerini ifade etmektedir. Eldeki 358 imge için yapılan ölçümlerde D değeri en az 0,913 ve en çok 0,9874 olarak gözlenmiştir. Ortalama değer 0,9646 ve standart sapma 0,0112'dir.



Şekil 16. Şekil 10'daki imgenin gri zeminde gösterilen bölütleme sonucu


(Segmentation result of the image in Figure 10 displayed on gray background)

Bölütleme problemlerindeki başarımı ortaya koymanın yollarından başka biri ve belki de yararlılığı nesnel ölçütlerle bildirmek açısından en kullanışlı olanı, çıktıları sonraki analiz süreçlerine girdi olarak vererek bu süreçlerin başarımını gözlemlemek ve karşılaştırmalı sonuçları çözümlenektir. Bu amaçla, uzmanlarca elle yapılan temel doğru bölütlemelerdeki ve önerilen yarı-otomatik buluşsal yaklaşımın çıktıları olan enine-kesit fetal kafatası imgeleri spina bifida nöral tüp bozukluğunu doğum öncesi dönemde tespit etmek amacıyla tasarlanan iki otomatik tanı sisteminde [37, 38] girdi olarak kullanılarak, gözlemlenen başarımlar karşılaştırılmıştır [43].

İlk yöntem [37], imgelerden kafataslarına ait eğrilik ölçek uzayı (curvature scale space (CSS)) [44, 45] özniteliklerini çıkarmakta ve bu özniteliklerle en yakın komşu (kNN) sınıflandırması gerçekleştirmektedir. Diğer yöntem [38], fetal kafatası bölgelerinden hesaplanan Zernike momentlerinden [46, 47] edinilen öznitelikleri destek vektör makineleri (DVM) [48, 49] kullanarak sınıflandırma

yapmaya dayanmaktadır. İki yöntemde de, problemin doğası gereği karşılaşılan sınıf dengesizliği ve seyrek sınıflar sorununu ele almak, sınıflandırma başarımını eniyilemek için kaçınılmazdır. Kullanılan yöntemlerdeki başarımlar; seyrekliliği ele alma tercihinine, farklı işleyiş noktalarına ve algoritmik farklılıklara bağlı olarak çeşitlenmektedir. Dengesiz veri dağılımını hafifletmek için, tekrarlamalı üstörnekleme, altörnekleme, yapay seyrek sınıf üstörnekleme (synthetic minority oversampling technique (SMOTE)) [50] gibi yöntemlerden yararlanılmaktadır. Sunulan karşılaştırmalı sonuçlar, sözü edilen otomatik tanı sistemlerinin aynı veri üzerinde hem temel doğru bölütlemelerin hem de yarı-otomatik buluşsal bölütlemelerin; sınıflandırıcıya ilişkin ayarlar, işleyiş noktası seçimi, vs. gibi unsurlarla belirlenen aynı çerçeve içinde kullanılmasıyla elde edilmektedir. Her çerçeve için, sınıflandırıcıların öğrenmesi temel doğru bölütlemelerden oluşan öğrenme kümeleri üzerinde gerçekleştirilmekte, karşılaştırmaların yansızlığı açısından test kümeleri olarak aynı imgelerden edinilmiş temel doğru bölütlemeler ve buluşsal bölütleme çıktıları kullanılmaktadır. Bütün deneylerdeki veri kümelerinde uygulanan çapraz geçerlemeler de karşılaştırmalarda çerçevelerin eşitliğini bozmayacak biçimdedir.

Tablo 1'deki sonuçlarda, altörnekleme uygulayarak hastalıklı (pozitif) ve sağlıklı (negatif) sınıf örneklerinin 1:1 dengeli dağılıma getirildiği 24 pozitif ve 24 negatif öğrenme örneği ile 5 pozitif ve 5 negatif test örneğinden oluşan veri kümeleri kullanılmaktadır. Sınıflandırma başarımı F -ölçüsü (F -measure) ve geri çağırma ve kesinliğin geometrik ortası (geometric mean of recall and precision (GMRP)) ölçüleri [51] aracılığıyla gösterilmektedir. Kullanılan CSS-tabanlı sınıflandırıcılarda kafatası çevritlerinin birbirine uzaklıkları temelinde çalışan k en yakın komşu (kNN) sınıflandırıcılar [37, 43] kullanılmaktadır. Sınıflandırma çerçevesini belirleyen etkenler hangi özniteliklerin kullanıldığı, çevritlerin birbirine uzaklığının nasıl ölçüldüğü ve çevritlerin hangi çeşitlemelerinin kullanıldığıdır. CSS eğrilik ölçek uzayı özniteliklerini gösterirken, C_1 çevritler arası uzaklığı ölçme yöntemlerinden ilkinde, C_2 de ikincisine işaret etmektedir. DMLM, eğrilik ölçek uzayı özniteliklerinin hesaplanmasında uzaklık matrisine-benzer matris (distance matrix-like matrix (DMLM)) [52] kullanıldığını ve çevritler arasındaki uzaklığın bu matrisler arası uzaklıkla bulunduğunu göstermektedir. Asıl çevritler kafatası çevritlerinin kendisi, yansıma çevritler [53] ise merkezi asıl çevritin ağırlık merkezinde olan ve kafatasını içinde bulunduran bir çembersel ayna kullanılarak elde edilmiş çevritlerdir. Eğrilik ölçek uzayı özniteliklerini daha iyileştirilmiş biçimde elde etmenin bir yolu olarak yansıma çevritleri de kullanmak [53] önerilmektedir. Tablo 1'de görülen eşik değerleri, en yakın komşu sınıflandırıcıların karar verirken kullandığı karar eşikleridir. Bu eşik



Şekil 17. Buluşsal yöntemle bölütleme örnekleri: düzgelennmiş girdiler (a), çıktılar (b)
(Segmentation examples of the heuristic method: normalized inputs (a), outputs (b))

değerlerinin değiştirilmesi ile sınıfların farklı işleyiş noktalarındaki başarımını gösteren *alıcı işleyiş özellikleri (receiver operating characteristics (ROC))* [54] eğrileri elde edilebilmektedir. Farklı sınıflandırma çerçeveleri için gösterilen sonuçlar, hem temel doğru hem de buluşsal bölütlemeyle elde edilen girdilerin ROC eğrileri üzerindeki en başarılı sonuçlardır. Kimi ölçümlerin buluşsal bölütleme yöntemi için üstün olduğu görülse de, genel bir çıkarımla, buluşsal ve temel doğru bölütlemeler CSS-tabanlı sınıflandırıcılarda karşılaştırılabilir başarıma sahiptir.

Tablo 2 ve Tablo 3'te, sırasıyla, öğrenmede 274 negatif ve 24 pozitif örnekten oluşan 298 örneğin ve teste 55 negatif ve 5 pozitif örnekten oluşan 60 örneğin kullanıldığı deneylerde doğrusal çekirdekli DVM sınıflandırıcıyla ve radyal taban fonksiyonu (RBF) çekirdekli DVM sınıflandırıcıyla elde edilen sonuçlar gösterilmektedir. Sınıflandırıcılar [55], öznel olarak, çevritlerle sınırlanan

düzgelennmiş bölgelerden hesaplanan Zernike momentlerinin büyüklüklerini kullanmaktadır. Öğrenme kümelerindeki seyreklik sorununu gidermek için, tablolarda b-SMOTE olarak gösterilen borderline-SMOTE [56] ve altörnekleme çeşitli derecelerde (rate) uygulanmaktadır. Sonuçlar, üstörnekleme derecesinin değiştirildiği senaryolar için en iyi ölçümlerin alındığı altörnekleme dereceleri seçilerek gösterilmiştir. Dikkati çeken, doğrusal DVM'lerin en iyi sonuçları hiç altörnekleme olmadan üretmiş olmasıdır. RBF-DVM'lerde ise durumun farklı olduğu gözlenmektedir. Doğrusal-DVM sınıflandırıcılar bazı üstörnekleme dereceleri için buluşsal bölütlemelerle daha iyi sonuçlar üretmekte ama başarımların iki kategorideki bölütlemeler için genelde karşılaştırılabilir olduğu görülmektedir. RBF-sınıflandırıcılarda buluşsal bölütlemelerle elde edilen sonuçlar hiçbir çerçeve için temel bölütlemelerden daha iyi olmamasına rağmen, başarımın genel olarak karşılaştırılabilir olduğu söylenebilir.

Tablo 1. CSS-tabanlı sınıflandırmada sınıflandırma başarımı açısından karşılaştırma
(Comparison in CSS-based classification with respect to classification performance)

| CSS-tabanlı sınıflandırma çerçevesi | Temel doğru bölütlemeler | | | Buluşsal bölütlemeler | | |
|-------------------------------------|--------------------------|----------|--------|------------------------|----------|--------|
| | Eşik değeri (τ) | F-ölçüsü | GMRP | Eşik değeri (τ) | F-ölçüsü | GMRP |
| CSS, C_1 , asıl | 0,30 | 0,6931 | 0,7194 | 0,25 | 0,6936 | 0,7284 |
| CSS, C_1 , asıl & yansıma | 0,45 | 0,7401 | 0,7435 | 0,30 | 0,7248 | 0,7457 |
| CSS, C_2 , asıl | 0,30 | 0,7009 | 0,7259 | 0,25 | 0,6934 | 0,7283 |
| CSS, C_2 , asıl & yansıma | 0,45 | 0,7564 | 0,7590 | 0,30 | 0,7245 | 0,7454 |
| DMLM, asıl | 0,45 | 0,7203 | 0,7421 | 0,45 | 0,7043 | 0,7184 |
| DMLM, asıl & yansıma | 0,60 | 0,7354 | 0,7365 | 0,50 | 0,7098 | 0,7181 |

Tablo 2. Doğrusal-DVM sınıflandırmada sınıflandırma başarımı açısından karşılaştırma
(Comparison in linear-SVM classification with respect to classification performance)

| Doğrusal-DVM sınıflandırmadaki üstörnekleme derecesi | Temel doğru bölütlemeler | | | Buluşsal bölütlemeler | | |
|--|--------------------------|----------|--------|-----------------------|----------|--------|
| | Altörnekleme derecesi | F-ölçüsü | GMRP | Altörnekleme derecesi | F-ölçüsü | GMRP |
| %0 b-SMOTE | %0 | 0,7071 | 0,7088 | %0 | 0,7223 | 0,7391 |
| %100 b-SMOTE | %0 | 0,6829 | 0,6830 | %0 | 0,6903 | 0,6948 |
| %200 b-SMOTE | %0 | 0,6322 | 0,6324 | %0 | 0,6190 | 0,6198 |
| %300 b-SMOTE | %0 | 0,6416 | 0,6421 | %0 | 0,6404 | 0,6410 |
| %400 b-SMOTE | %0 | 0,5953 | 0,5969 | %0 | 0,6147 | 0,6147 |
| %500 b-SMOTE | %0 | 0,5899 | 0,5912 | %0 | 0,6045 | 0,6045 |

Tablo 3. RBF-DVM sınıflandırmada sınıflandırma başarımı açısından karşılaştırma
(Comparison in RBF-SVM classification with respect to classification performance)

| RTF-DVM sınıflandırmadaki üstörnekleme derecesi | Temel doğru bölütlemeler | | | Buluşsal bölütlemeler | | |
|---|--------------------------|----------|--------|-----------------------|----------|--------|
| | Altörnekleme derecesi | F-ölçüsü | GMRP | Altörnekleme derecesi | F-ölçüsü | GMRP |
| %0 b-SMOTE | %100 | 0,6314 | 0,6320 | %100 | 0,4463 | 0,4472 |
| %100 b-SMOTE | %75 | 0,6091 | 0,6091 | %100 | 0,5542 | 0,5687 |
| %200 b-SMOTE | %75 | 0,5782 | 0,5794 | %100 | 0,4988 | 0,5373 |
| %300 b-SMOTE | %60 | 0,6265 | 0,6304 | %100 | 0,5001 | 0,5383 |
| %400 b-SMOTE | %50 | 0,6276 | 0,6306 | %75 | 0,5511 | 0,5585 |
| %500 b-SMOTE | %50 | 0,6125 | 0,6128 | %60 | 0,5681 | 0,5793 |

4. Sonuçlar ve Tartışmalar (Results and Discussions)

Enine-kesit fetal kafatası görüntüleri özelinde; doğum öncesi dönemde gözlemlenen kafatası çevritlerinin ve çevrelenen bölgenin yapısı, doğumdan sonra bireyin yaşamını olumsuz etkileyebilecek nörolojik kusurların erken tanısında önem taşımaktadır. Uzmanlar, başka testlerden de yararlanmakla beraber, genellikle US görüntülemeye edinilen imgeleri inceleyip tanıya gitme yolunu seçmektedirler. Bu bağlamda, hekim, görüntülerdeki kafatasını seçebilmede kendi gözlerine güvenip tanıya çoğunlukla başarılı olmaktadır. Buna rağmen, hataya katlanılamayan tıp alanında otomatik sistemlerin sağlayacağı destek tercih edilmektedir. Günümüzde, bilgisayar destekli tanı sistemleri (computer aided diagnosis (CAD)) [57] aktif bir alandır. Böyle sistemlerin birçoğunda tıbbi görüntülerden edinilen öznelilikler [37, 38, 58, 59, 60] kullanılmakta ve bazılarında imge bölütleme [37, 38, 61] de işin içinde bulunmaktadır. Tanı sürecini destekleyen bu sistemlerin idealde tam-otomatik bölütleme gerçekleştirmesi istenmekle beraber, fetal kafatası imgeleri için sunulan buluşsal yaklaşıma benzeyen ve pratikte çok insan çabası gerektirmeyen yarı-otomatik bölütleme yöntemleri de kullanışlı çözüm adaylarıdır.

Bu çalışmadaki yarı-otomatik buluşsal yöntem, US görüntüleme ile anne karnındaki fetuslardan alınan enine-kesit monokrom kafatası imgeleri üzerinde çalışmakta ve bir ortalama şekil modelinden yararlanarak bölütleme noktalarının yerel komşuluklarındaki piksel yoğunluklarının ağırlıklı ortalamasına dayanan bir nokta koordinatı bulma ilkesiyle iş görmektedir. Örnek imgelerdeki çıktılar görsel olarak incelendiğinde ve nicel benzerlikler ölçüldüğünde, doyurucu

sonuçlara ulaşıldığı söylenebilir. Değerlendirmenin daha da kabul edilir olması için, bölütleme çıktıları otomatik tanı sistemlerine [37, 38] girdi olarak verildiğinde, sınıflandırma başarımlarının temel doğru bölütlemelerinkilerle karşılaştırılması yoluna gidilmiş ve karşılaştırılabilir başarımlar gözlenmiştir.

Sunulan çözüm az insan çabası gerektiren yarı-otomatik bölütleme bağlamında yeterince iyi olsa da asıl hedefin kafatası çevritlerinin kullanıcıların araya girmesine gerek duyulmadan bölütlenebildiği tam-otomatik yöntemler olduğu açıktır. Tam-otomatik bölütleme girişimleri, eldeki problem için imgelerdeki yoğunluk düzensizliklerini belirleme çabalarıyla başlamaktadır. Buna karşın, US imgelerindeki kenar yapıları çoğu zaman berrak olarak seçilememektedir. Kenarlar, önemli miktarda gürültü barındırabilmekte, tek ve bağlı yapılar olarak görünmeyebilmekte ve yapay olarak tamamlanması gereken kopuk sınırların parçaları olabilmektedir. Bu durumda, model uydurma ve kenar sezme yaklaşımlarının başarılı olmadığı görülmektedir. Bu aşamada tam-otomatik bölütlemeyi başarmak için öngörülen aday bir yöntemde, herhangi bir sinyali artık bir fonksiyonlar kümesinden seçilen dalga biçimlerinin doğrusal bir açılımı olarak ayrıştıran *eşleştirme araması* (matching pursuit) [62] yaklaşımı kullanılabilir. Öğrenmeye dayalı bu yöntemin uygulanmasıyla [63, 64], ilgilenilen yapıları göstermek, atomlar adı verilen bir temel öğeler kümesi ile yapıları ayrıştırmak ve imgeler üzerindeki benzer yapıları tanımak olanaklıdır. Buna karşın, seyrek ve artık gösterimlere [65, 66] dayalı olan bu tür yaklaşımlarda başarılı sonuçların elde edilmesi gösterimin temel öğelerini bulunduracak sözlüğün tasarlanması veya öğrenilmesi (dictionary design/learning) [67, 68] süreciyle ilişkilidir. Çok sayıda örnek

bulunan öğrenme kümelerinin sağlayacağı katkı kuşkusuzdur. Genellikle karmaşık ve modellenmesi pratikte olası olmayan enine-kesit fetal kafatası imgelerini bölütleme için umut veren çözüm adayları ve bölütleme probleminin kendine özgü ayırıcı özellikleri ortaya konabildiğinde bulunacak başka yollar, değerlendirilmesi gereken seçeneklerdir.

Teşekkür (Acknowledgement)

İstanbul Üniversitesi Tıp Fakültesi'nden İbrahim Kalelioğlu ve Trakya Üniversitesi Tıp Fakültesi'nden Füsün Varol'a, US görüntülerini sağlama yardımları için teşekkür ederim. Ayrıca; verilerin çalışmalarda kullanılabilmesi için 30/04/2014 tarihli, TÜTF-GOKAEK 2014/85 protokol kodlu ve 09/07 karar numaralı etik onay sağlayan Trakya Üniversitesi Tıp Fakültesi Bilimsel Araştırma Etik Kurulu'na da çalışmadaki katkıları için teşekkür ederim.

Kaynaklar (References)

- Gonzalez R.C. ve Woods R.E., *Digital Image Processing*, Pearson Education, New Jersey, 2018.
- Alpaydın E., *Introduction to Machine Learning*, MIT Press, Cambridge, 2014.
- Sezgin M. ve Sankur B., Survey over image thresholding techniques and quantitative performance evaluation, *Journal of Electronic Imaging*, 13 (1), 146-165, 2004.
- Piccardi M., Background subtraction techniques: a review, *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, 3099-3104, 2004.
- Adams R. ve Bischof L., Seeded region growing, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16 (6), 641-647, 1994.
- Cheevasuvit F., Maitre H., Vidal-Madjar D., A robust method for picture segmentation based on a split-and-merge procedure, *Computer Vision, Graphics, and Image Processing*, 34 (3), 268-281, 1986.
- Haralick R.M., Shanmugam K., Dinstein I., Textural features for image classification, *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3 (6), 610-621, 1973.
- Humeau-Heurtier A., Texture feature extraction methods: a survey, *IEEE Access*, 7, 8975-9000, 2019.
- Canny J., A computational approach for edge detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8 (6), 679-698, 1986.
- Russell S. ve Norvig F., *Artificial Intelligence: A Modern Approach*, Prentice-Hall, New Jersey, 2010.
- Lloyd S.P., Least square quantization in PCM, *IEEE Transactions on Information Theory*, 28 (2), 129-137, 1982.
- Achanta R., Shaji A., Smith K., Lucchi A., Fua P., Süsstrunk S., SLIC superpixels compared to state-of-the-art superpixel methods, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34 (11), 2274-2281, 2012.
- Shi J. ve Malik J., Normalized cuts and image segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22 (8), 888-905, 2000.
- Serra J., *Image Analysis and Mathematical Morphology*, Academic Press, New York, 1988.
- Rajala S.A., Riddle A.N., Snyder W.E., Application of the one-dimensional Fourier transform for tracking moving objects in noisy environments, *Computer Vision, Graphics, and Image Processing*, 21 (2), 280-293, 1983.
- Schmidhuber J., Deep learning in neural networks: an overview, 61, 85-117, 2015.
- Forsyth D. ve Ponce J., *Computer Vision: A Modern Approach*, Pearson, New Jersey, 2012.
- Hough P.V.C., Methods and means for recognizing complex patterns, U.S. Patent 3069654, 1962.
- Cootes T.F., Edwards G.J., Taylor C., *Active appearance models*, Lecture Notes in Computer Science, Cilt 1407, Editör: Burkhardt H. ve Neumann B., Springer, Berlin, 1998.
- Stegmann M.B., *Active appearance models: Theory, extensions and cases*, Master Tezi, Technical University of Denmark, 2000.
- Dempster A.P., Laird N.M., Rubin D.B., Maximum likelihood from incomplete data via the EM algorithm, *Journal of Royal Statistical Society*, 39 (1), 1-38, 1977.
- Litjens G., Kooi T., Bejnordi B.E., Setio A.A.A., Ciompi F., Ghafoorian M., van der Laak J.A.W.M., van Ginneken B., Sanchez C.I., A survey on deep learning in medical image analysis, *Medical Image Analysis*, 42, 60-88, 2017.
- Yang X., Yu L., Wu L., Wang Y., Ni D., Qin J., Heng P-A., Fine grained recurrent neural networks for automatic prostate segmentation in ultrasound images, *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, 2017.
- Xu Y., Wang Y., Yuan J., Cheng Q., Wang X., Carson P.L., Medical breast ultrasound image segmentation by machine learning, *Ultrasonics*, 91, 1-9, 2019.
- Cerrolaza J.J., Sinclair M., Li Y., Gomez A., Ferrante E., Matthew J., Gupta C., Knight C.L., Rueckert D., Deep learning with ultrasound physics for fetal skull segmentation, *Proceedings of the IEEE International Symposium on Biomedical Imaging*, 564-567, 2018.
- Zhang L., Dolwani S., Ye X., Automated polyp segmentation in colonoscopy frames using fully convolutional neural network and textons, *Medical Image Understanding and Analysis*, 723, 707-717, Editör: Valdés Hernandez M. ve González-Castro V., Springer, Cham., 2017.
- Huang Q., Luo Y., Zhang Q., Breast ultrasound image segmentation: a survey, *International Journal of Computer Assisted Radiology and Surgery*, 12 (3), 493-507, 2017.
- Beucher S. ve Meyer F., The morphological approach to segmentation: the watershed transformation, *Mathematical Morphology in Image Processing*, Editör: Dougherty E.R., 1993.
- Kass M., Witkin A., Terzopoulos D., Snakes: active contour models, *International Journal of Computer Vision*, 321-331, 1988.
- Li S.Z., *Markov Random Field Modeling in Image Analysis*, Springer, 2009.
- Hopfield J.J., Neural networks and physical systems with emergent collective computational abilities, *Proceedings of the National Academy of Sciences of the U.S.*, 79 (8), 5554-2558, 1982.
- İlhan Ü. ve İlhan A., Brain tumor segmentation based on a new threshold approach, *Procedia Computer Science*, 120, 580-587, 2017.
- Song J., Yang C., Fan L., Wang K., Yang F., Liu S., Tian J., Lung lesion extraction using a toboggan based growing automatic segmentation approach, *IEEE Transactions on Medical Imaging*, 35 (1), 337-353, 2016.
- Saisri A., Meenakshi S., Prema V., The edge based active contour models for medical images analysis in edge stop functions, *International Journal of Engineering Development and Research*, 7 (2), 64-68, 2019.
- Cai J., Segmentation and diagnosis of liver carcinoma based on adaptive scale-kernel fuzzy clustering model for CT images, *Journal of Medical Systems*, 43, 322, 2019.
- Xiang D., Bağcı U., Jin C., Shi F., Zhu W., Yao J., Sonka M., Chen X., A model-based method for automatic renal cortex segmentation, *Medical Image Analysis*, 42, 257-273, 2017.
- Konur U., Gürgen F.S., Varol F., Akarun L., Computer aided detection of spina bifida using nearest neighbor classification with curvature scale space features of fetal skulls extracted from ultrasound images, *Knowledge-Based Systems*, 85, 80-95, 2015.
- Konur U., Computerized detection of spina bifida using SVM with Zernike moments of fetal skulls in ultrasound screening, *Biomedical Signal Processing and Control*, 43, 18-30, 2018.
- Watt A.H., *Advanced Animation and Rendering Techniques: Theory and Practice*, ACM Press, 1992.
- Otsu N., A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9 (1), 62-66, 1979.
- Dice L.R., Measures of the amount of ecologic association between species, *Ecology*, 26 (3), 297-302, 1945.
- Sørensen T., A method of establishing groups of equal amplitude in plant sociology based on similarity of species and its application to analyses of the vegetation on Danish commons, *Kongelige Danske Videnskabernes Selskab*, 5 (4), 1-34, 1948.
- Konur U., Computer aided detection of spina bifida using features derived from curvature scale space and Zernike moments, *Doktora Tezi, Boğaziçi Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul*, 2015.
- Mokhtarian F. ve Mackworth A.K., A theory of multiscale curvature-based shape representation for planar curves, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14 (18), 789-805, 1992.
- Abbasi S., Mokhtarian F., Kittler J., Curvature scale space image in shape similarity retrieval, *Multimedia Systems*, 7 (6), 467-476, 1999.

46. Teague M.R., Image analysis via the general theory of moments, *Journal of Optical Society of America*, 70 (8), 920-930, 1980.
47. Teh C.H. ve Chin R.T., On image analysis by the method of moments, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10 (4), 496-513, 1988.
48. Boser B., Guyon I., Vapnik V.N., A training algorithm for optimal margin classifiers, *Annual Workshop on Computational Learning Theory*, 1992.
49. Cortes C. ve Vapnik V., Support vector networks, *Machine Learning*, 20 (3), 373-397, 1995.
50. Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P., SMOTE: synthetic minority over-sampling technique, *Journal of Artificial Intelligence Research*, 16 (1), 321-357, 2002.
51. Joshi M.V., On evaluating performance of classifiers for rare classes, *Proceedings of the IEEE International Conference on Data Mining*, 2002.
52. Kpalma K., Yang M., Ronsin J., Planar shapes descriptors based on the turning angle scalogram, *Proceedings of the International Conference on Image Analysis and Recognition*, 2008.
53. Kopf S., Haenselmann T., Effelsberg W., Enhancing curvature scale space features for robust shape classification, *Proceedings of the International Conference on Multimedia and Expo*, 2005.
54. Fawcett T., An introduction to ROC analysis, *Pattern Recognition Letters – Special Issue: ROC Analysis in Pattern Recognition*, 27 (8), 861-874, 2006.
55. Chang C.C. ve Lin C.J., LIBSVM: a library for support vector machines, *ACM Transactions on Intelligent Systems and Technology*, 2 (3), 1-27, 2011.
56. Han H., Wang W.Y., Mao B.H., Borderline-SMOTE: a new over-sampling method in imbalanced data sets learning, *Proceedings of the International Conference on Advances in Intelligent Computing*, 2005.
57. Yanase J. ve Triantaphyllou E., A systematic survey of computer-aided diagnosis in medicine: past and present developments, *Expert Systems with Applications*, 138, 2019.
58. Kaya A., Keçeli A.S., Can A.B., Examination of various classification strategies in classification of lung nodule characteristics, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (2), 709-725, 2019.
59. Yıldız O., Melanoma detection from dermoscopy images with deep learning methods: a comprehensive study, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 2241-2260, 2019.
60. Gürkahraman K. ve Karakış R., Brain tumors classification with deep learning using data augmentation, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (2), 997-1011, 2021.
61. Kaya H., Çavuşoğlu A., Çakmak H.B., Şen B., Delen D., Supporting the diagnosis process and processes after treatment by using image segmentation and image simulation techniques: Keratoconus example, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 31 (3), 737-747, 2016.
62. Mallat S.G. ve Zhang Z., Matching pursuits with time-frequency dictionaries, *IEEE Transactions on Signal Processing*, 41 (12), 3397-3415, 1993.
63. Bergeaud F. ve Mallat S.G., Matching pursuit of images, *Proceedings of the International Conference on Image Processing*, 53-56, 1995.
64. Mendels F., Vanderghyest P., Thiran, J.P., Matching pursuit-based shape representation and recognition using scale-space, *Wiley Periodicals*, 16 (5), 162-180, 2007.
65. Mallat S., *A Wavelet Tour of Signal Processing: The Sparse Way*, Academic Press, Massachusetts, 2009.
66. Elad M., *Sparse and Redundant Representations: From Theory to Applications in Signal and Image Processing*, Springer, New York, 2010.
67. Engan K., Aase S.O., Hakon Husoy J., Method of optimal directions for frame design, *Proceedings (5) of the IEEE International Conference on Acoustics, Speech and Signal Processing*, 2443-2446, 1999.
68. Aharon M., Elad M., Bruckstein A., K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation, *IEEE Transactions on Signal Processing*, 54 (11), 4311-4322, 2006.