

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**HİSTOPATOLOJİK İMGELERİN
DEĞERLENDİRİLMESİNDE ÖRÜNTÜ TANIMA
TEMELLİ KARAR DESTEK SİSTEMLERİ**

Suat TORAMAN

Tez Yöneticisi:
Yrd. Doç.Dr. İbrahim TÜRKOĞLU

YÜKSEK LİSANS TEZİ
ELEKTRONİK VE BİLGİSAYAR EĞİTİMİ ANABİLİM DALI

ELAZIĞ, 2006

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**HİSTOPATOLOJİK İMGELERİN
DEĞERLENDİRİLMESİNDE ÖRÜNTÜ TANIMA
TEMELLİ KARAR DESTEK SİSTEMLERİ**

Suat TORAMAN

Yüksek Lisans Tezi
Elektronik ve Bilgisayar Eğitimi Anabilim Dalı

Bu tez, tarihinde aşağıda belirtilen jüri tarafından oybirliği /oyçokluğu ile başarılı / başarısız olarak değerlendirilmiştir.

Danışman: Yrd.Doç.Dr. İbrahim TÜRKOĞLU

Üye: Prof.Dr. Asaf VAROL

Üye: Yrd.Doç.Dr. Ali KARCI

Bu tezin kabulü, Fen Bilimleri Enstitüsü Yönetim Kurulu'nun/...../..... tarih ve sayılı kararıyla onaylanmıştır.

TEŞEKKÜR

Bu tez çalışmam boyunca, ilgi ve yardımlarını esirgemeyen danışmanım sayın Yrd. Doç. Dr. İbrahim TÜRKOĞLU'na, bugünlere gelmemizde emeği geçen tüm hocalarıma, tezin gelişiminde zaman zaman bilgilerinden faydalandığım Yrd. Doç. Dr. Engin AVCI, Arş. Gör. Abdulkadir ŞENGÜR'e, histopatolojik imgelerin sağlanmasında ve yorumlanmasındaki desteğinden dolayı Doç. Dr. İbrahim Hanifi ÖZERCAN'a, teze destek veren Fırat Üniversitesi Bilimsel Araştırma Projeleri Birimine (FÜBAP-985) ve çalışmam boyunca beni sabır ve özveri ile destekleyen aileme, arkadaşım Ömer Osman DURSUN'a teşekkürlerimi ve şükranlarımı sunarım.

Suat TORAMAN

İÇİNDEKİLER

Sayfa

TEŞEKKÜR	
İÇİNDEKİLER	I
ŞEKİLLER LİSTESİ.....	III
TABLolar LİSTESİ.....	V
EKLER LİSTESİ	VI
SİMGELER LİSTESİ.....	VII
KISALTMALAR LİSTESİ	VIII
ÖZET	IX
ABSTRACT	X
1. GİRİŞ	1
2. GÖRÜNTÜ İŞLEMENİN TEMELLERİ	5
2.1. Sayısal Görüntü İşlemenin Elemanları.....	5
2.2. İmge İşlemedeki Temel Operatörler	6
2.2.1. İmge toplama ve çıkarma	6
2.2.2. İmge döndürme	7
2.2.3. İmgenin negatifini üretme	7
2.3. İmge Dönüşümleri.....	7
2.3.1. Mesafe dönüşümü	8
2.4. Filtreleme	8
2.4.1. Doğrusal filtreleme	8
2.4.2. Düzgünleştirme frekans alan filtreleri.....	11
2.4.3. Keskinleştirme frekans alan filtreleri	15
2.5. Kenar Çıkarma	18
2.5.1. Süreksizliğin tanımlanması	19
3. ÖRÜNTÜ TANIMA.....	21
3.1. Örüntü Tanıma Probleminin Formülasyonu	22
3.2. Örüntü Tanıma Sistemi	23
3.2.1. Özellik çıkarma	24
3.2.2. Sınıflandırma.....	25
4. GELİŞTİRİLEN KARAR DESTEK SİSTEMLERİ	26
4.1. Histopatolojik İmge.....	27
4.2. Histopatolojik İmgelerin Bölütlenmesi	27
4.2.1. Histogram temelli görüntü bölütleme tekniği	27
4.2.2. Histogram ile bölütleme uygulaması	29

4.2.3. Klasik c-ortalama görüntü bölütleme tekniği.....	30
4.2.4. Klasik c-ortalama ile bölütleme uygulaması.....	31
4.2.5. Bulanık c-ortalama görüntü bölütleme tekniği.....	32
4.2.6. Bulanık c-ortalama görüntü bölütleme uygulaması	34
4.2.7. Shannon entropi ile bölütleme tekniği	36
4.2.8. Shannon entropi ile bölütleme uygulaması	37
4.2.9. Kohonen ağları imge bölütleme tekniği.....	38
4.2.10. Kohonen ağları ile bölütleme uygulaması.....	42
4.3. Histopatolojik İmgelerde Alan Bulma	43
4.3.1. Histopatolojik imgelerde alan bulma uygulaması.....	46
4.4. Histopatolojik İmgelerde Hücre Sayma	47
4.4.1. Histopatolojik imgelerde hücre sayma uygulaması	48
4.5. Histopatolojik İmgelerde Sınıflandırma.....	49
4.5.1. Fractal analiz.....	49
4.5.2. Karar ağaçları.....	51
5. SONUÇ VE DEĞERLENDİRME	54
KAYNAKLAR	56
EK-1	58

ŞEKİLLER LİSTESİ

Şekil 1.1. Görüntü işlemede temel basamaklar	3
Şekil 2.1. Fiziksel bir görüntünün sayısal karşılığı	5
Şekil 2.2. Bir görüntüyü sayısallaştırma	6
Şekil 2.3. İmgelerin birleştirilmesi işlemi	7
Şekil 2.4. Ağırlıklar matrisi (Katlama)	9
Şekil 2.5. Ağırlıklar matrisi (İlişki)	10
Şekil 2.6. (a) Orijinal imge (b) Filtrelenmiş imge	11
Şekil 2.7. (a) Düşük geçiren filtrenin transfer fonksiyonunun perspektif çizimi (b) İmge olarak görüntülenen filtre (c) Filtrenin radyan kesiti	13
Şekil 2.8. (a) 1 dizili (b) 2 dizili (c) 5 dizili (d) 20 dizili BLPF'nin uzaysal gösterimi	14
Şekil 2.9. (a) GLPF transfer fonksiyonunun perspektif çizimi (b) Resim gibi görüntülenen filtre	15
(c) D_0 değişik değerleri için filtre radyal kesitleri	15
Şekil 2.10. (a) Orijinal İmge (b) GLPF uygulanmış resim	15
Şekil 2.11. (a) Perspektif çizim (b) İmge temsili (c) Filtre kesiti (Üst: İdeal Yüksek Geçiren Filtre, Orta: Butterworth Yüksek Geçiren Filtre, Alt: Gaussian Yüksek Geçiren Filtre)	16
Şekil 2.12. Genel 3x3 boyutundaki maskeleme	19
Şekil 2.13. Arka plandan farklı olan bir noktayı yakalamak için kullanılan maske	19
Şekil 2.14. Çizgi yakalamak için kullanılan maskeler	20
Şekil 3.1. Örüntü tanıma kavramı	22
Şekil 3.2. Karar yüzeyinin özellik uzayının haritası olarak gösterimi	23
Şekil 3.3. Örüntü tanıma sistemi	23
Şekil 3.4. Akıllı sınıflama yapısı	25
Şekil 4.1. Gri seviyesi histogramı (a) Tek eşik değer (b) Çok seviyeli eşik değer	28
Şekil 4.2. (a) [0-256] gri seviyeli imge (b) Siyah beyaz imge	29
Şekil 4.3. (a) Histopatolojik kanserli imge (b) Bölütlenmiş histopatolojik kanserli imge	30
(c) Histopatolojik hepatitli imge (d) Bölütlenmiş histopatolojik hepatitli imge	30
Şekil 4.4. (a) Orijinal imgeler (b) Klasik c-ortalama ile bölütlenmiş imgeler	32
Şekil 4.5. Bulanık c-ortalama uygulaması	35
Şekil 4.6. (a,c) Kanserli histopatolojik imgeleri (b,d) Bulanık c-ortalama ile bölütlenmiş imgeler	36
Şekil 4.7. Shannon entropi kullanılarak histopatolojik imgede gerçekleştirilen bölütleme uygulaması	38

Şekil 4.8. Kohonen 'in kendi kendini düzenleme haritasının ağ birimleri	39
Şekil 4.9. Kohonen sistem modeli	40
Şekil 4.10. Meksika şapkası fonksiyonu	40
Şekil 4.11. Bir işlem elamanının yapısal komşuluğu ($t_1 < t_2 < t_3$)	41
Şekil 4.12. Kohonen Ağları ile histopatolojik imgelerin bölütlenmesi.....	43
Şekil 4.13. (a) A'nın iç sınırları boyunca dönen B şekillendirme elemanı (b) Açma işleminin sonucu	44
(c) Tamamlanmış açma işlemi	44
Şekil 4.14. (a) A kümesinin dış sınırları boyunca yuvarlanan şekillendirme elemanı B (b) Kapama işleminin gerçekleştirileceği alan (c) Tamamlanmış kapama işlemi	45
Şekil 4.15. Açma-Kapama işleminin yapılışı	46
Şekil 4.16. Alan bulma uygulaması	47
Şekil 4.17. Geliştirilen yöntemin kıyaslaması	48
Şekil 4.18. Histopatolojik imgeler	50
Şekil 4.19. Karar ağacı yapısı	52

TABLÖLAR LİSTESİ

	<u>Sayfa</u>
Tablo 2.1. Mesafe ölçüleri.....	8
Tablo 4.1. Eşik değeri.....	51
Tablo 4.2. İmgelerin kenar uzunluğu-kutu sayıları ve fractal boyutları	51
Tablo 4.3. Karar ağaçları ile sınıflandırma.....	53

EKLER LİSTESİ

EK-1 : Olympus C 4000 sayısal kameranın teknik özellikleri

SİMGELER LİSTESİ

$f(x,y)$	: Nesnenin herhangi bir noktası (birim)
$D(u,v)$	: Mesafe ölçüsü
$H(u, v)$	: Filtre transfer fonksiyonu
D_0	: Yarıçap (radyan)
σ	: Gaussian eğrisi yayılma ölçüsü
$\emptyset$	: Boş küme
λ	: Yoğunluk değeri (lümen)
X	: i) Durağan olmayan işaret, : ii) Gerçek giriş uzayındaki gözlemler veya ölçümler
μ_x	: İşaretin ortalama değeri
P_x	: İşaretin gücü
Y	: i) Çıkış sınıfları, ii) Karar uzayı
$w^{(k)}$	: Karar uzayındaki her bir sınıf
D	: Sınıflandırıcı
F	: Giriş ve karar uzayı arasındaki özellik uzayı
$\mathfrak{S}$	: Eğitim kümesi
N	: Pencere fonksiyonunun nokta sayısı
M	: Veri örnek sayısı
ε	: Hata oranı
T	: Eşik değeri
P	: Olasılık
H	: Entropi tanımı
Log	: Logaritma
R	: Ölçeklendirme elemanı

KISALTMALAR LİSTESİ

EKG	: ElektroKardiyoGrafı
DCT	: Ayrık Cosinüs Dönüşümü (Discrete Cosine Transform)
JPEG	: Ortak Fotograf Uzmanlar Grubu (Joint Photographic Experts Group)
IHPF	: İdeal Yüksek Geçiren Filtre (Ideal High Pass Filter)
ILPF	: İdeal Düşük Geçiren Filtre (Ideal Low Pass Filter)
BLPF	: Butterworth Düşük Geçiren Filtre (Butterworth Low Pass Filter)
BHPF	: Butterworth Yüksek Geçiren Filtre (Butterworth High Pass Filter)
GLPF	: Gaussian Düşük Geçiren Filtre (Gaussian Low Pass Filter)
GHPF	: Gaussian Yüksek Geçiren Filtre (Gaussian High Pass Filter)
T	: Eşik Değeri
3B	: 3 Boyutlu
2B	: 2 Boyutlu
CAT	: Bilgisayarlaştırılmış Aksial Tomografi (Computerized Axial Tomograph)
YSA	: Yapay Sinir Ağları
FCM	: Bulanık C-Ortalama (Fuzzy C-Mean)
EEG	: Elektroensefalografi
DTMF	: Çift Tonlu Çoklu Frekans (Dual Tone Multi Frequency)

ÖZET

YÜKSEK LİSANS TEZİ

HİSTOPATOLOJİK İMGELERİN DEĞERLENDİRİLMESİNDE ÖRÜNTÜ TANIMA TEMELLİ KARAR DESTEK SİSTEMLERİ

Suat TORAMAN

Fırat Üniversitesi

Fen Bilimleri Enstitüsü

Elektronik ve Bilgisayar Eğitimi Anabilim Dalı

2006, Sayfa: 58

Bilgisayar teknolojisi oldukça hızlı gelişim göstermektedir. Bu gelişim, tıp, endüstri ve iletişim gibi alanları da yakından ilgilendirmektedir. Özellikle tıp alanı, bu gelişimden oldukça iyi faydalanmaktadır. Yapılan birçok çalışmadan bilgisayarın hızlı işlem yapabilme özelliği ve birçok veriyi karşılaştırmalı olarak irdeleyebilmesi, uzmanlara teşhis koymada kolaylık sağlamaktadır.

Bu tez çalışmasında, tıbbi karar sürecinin hızlandırılarak, daha doğru teşhis konulmasına yardımcı olacak karar destek sistemleri sunulmuştur. Bu karar destek sistemleri; histopatolojik imgelerde istenen bir örüntünün çıkarılması, alanının bulunması, istenen hücre örüntüsünün sayısının belirlenmesi ve hücrelerin sınıflandırılması işlemlerini içermektedir. Bu işlemlerin gerçekleştirilmesi için Bulanık c-ortalama, Kohonen ağları, Shannon entropi, Fractal analiz gibi yöntemler kullanılmıştır. Kullanılan bu yöntemler ile önce imgeler bölütlenerek, imgeden istenmeyen kısımlar ayrıştırılmıştır. Sonra bölütlenmiş imgelere, alan bulma, hücre sayılarını belirleme, sınıflandırma işlemleri için değişik yöntemler uygulanmıştır. Doktor kontrollü yapılan histopatolojik imge değerlendirme uygulamalarında alan bulma, hücre sayısını belirleme ve sınıflandırma işlemlerinde başarılı sonuçlar elde edilmiştir.

Anahtar kelimeler: Örüntü tanıma, Bulanık c-ortalama, Shannon entropi, Kohonen ağları, Fractal analiz, Karar ağaçları, Karar destek sistemleri, Histopatoloji.

ABSTRACT
MASTER THESIS

DECISION SUPPORT SYSTEMS BASED ON PATTERN RECOGNITION FOR
EVALUATING OF HISTOPATHOLOGIC IMAGES

Suat TORAMAN

Firat University

Graduate School of Natural and Applied Science

Department of Computer and Electronics Education

2006, Page: 58

Computer technology is developed very rapidly. This development is related to the area of medicine, industry and communication, too. Especially, medicine area profits so much from these kinds of developments. From many previous work, it is seen that the computer based decision support systems are used by the physicians because of its fast computation ability and its ability of researching enormous data comparatively.

In this thesis, decision support systems that accelerate the medical decision process are represented to help the physicians for more accurate diagnosis. These decision support systems have the ability of segmenting the histopathology images, computing the area of the region of interest and counting the number of cells in a given region. For fulfilling these operations, fuzzy c-means clustering, Kohonen self organizing maps, Shannon entropy and fractal analysis methods are used. All these methods are used for segmenting the region of interest in a given histopathologic image. Then various methods are applied for cell number counting and cell classification. Physician controlled experiments on histopathologic images have shown that the proposed decision support systems perform successful results.

Key words: Pattern recognition, Fuzzy c-means, Shannon entropy, Kohonen networks, Fractal analysis, Decision trees, Decision support systems, Histopathology.

BÖLÜM 1

1.GİRİŞ

Günümüz teknolojisinin ulaşmak istediği nokta, canlıların istemli veya istem dışı bir şekilde çok kolay yaptıkları işleri bilgisayar ortamında yapabilmektir. Fakat canlıların hala birçok özelliği keşfedilemediği için istenilen noktaya ulaşılmasında bazı sorunlar yaşanmaktadır. Sorunların çözülmesi için bir taraftan canlılardaki yapılar incelenirken, diğer taraftan ise bulunan yeni özellikler bilgisayar ortamına aktarılmaya çalışılmaktadır. Bu açıdan bakıldığında insan görme sistemi, görüntü işleme açısından incelendiğinde bilinen en karmaşık sistemlerden birisidir [1]. Yaşamın devam ettirilmesi noktasında düşünüldüğünde görme-görüntü ilişkisinin önemi daha iyi olarak ortaya çıkmaktadır.

Görüntünün meydana gelmesinde bir ışık kaynağına ihtiyaç duyulur. Bu ışık kaynağı sayesinde sürekli zamanlı bir görüntünün her hangi bir (x,y) noktasındaki (pikselindeki) parlaklık yoğunluğu (değeri) λ olarak ifade edilir. Parlaklık yoğunluğu ve ışık fonksiyonu gerçek ve pozitif niceliklerdir. Tüm görüntü işleme uygulamalarında azda olsa arka planda bir ışık kaynağı mevcuttur. Görüntüyü seviye olarak üçe ayırabiliriz. Bunlar sadece siyah ve beyaz renkleri içeren ikili görüntü, gri seviyeli görüntü ve renkli görüntüdür. Her üç seviyedeki görüntünün sunumu da matris formundadır. Matrisin her hangi bir değeri, görüntünün o koordinatlardaki noktasının parlaklık, ışık veya buna benzer farklı niteliklerdeki değeri olabilir [1, 2].


Görüntü işleme ise, bir görüntüden başka bir görüntünün elde edilmesi için kullanılan tekniklerin bütünüdür. Görüntü işleme teknikleri, görüntünün insan veya bilgisayar tarafından anlaşılabilmesi yada yorumlanabilmesini sağlamayı hedeflemektedir.

İlk gerçekleştirilen görüntü işleme uygulamalarından biri gazete endüstrisi alanında olmuştur. 1920’de Londra ile New York arasında, deniz altından çekilen bir kablo ile görüntü transferi gerçekleştirilmiştir. Bu kablolu görüntü transfer sistemi sayesinde Atlantik üzerinden daha önceleri en az bir haftada yapılabilen görüntü transferi işlemi 3 saatten daha az bir sürede gerçekleştirilmiştir [3]. 1960’ların başında sayısal görüntü işleme uygulamalarını gerçekleştirebilecek bilgisayarların geliştirilmesi ile görüntü işleme uygulamalarında da büyük atılımlar görülmüştür. Bu döneme denk gelen ve Amerika Birleşik Devletlerinin uzay programında olan ay yüzeyinin incelenmesi çalışmalarında, gönderilen uzay aracı tarafından çekilen ay yüzeyi görüntülerindeki bozuklukların giderilmesi ve görüntü kalitesinin artırılması işlemleri, sayısal görüntü işlemenin önemini bir kez daha göstermiştir. Uzay uygulamalarına

paralel, 1970'lerin başında, tıp alanında, ücra yeryüzü kaynaklarının tespitinde ve astronomi alanlarında da görüntü işleme uygulanmaya başlanmıştır. Yine, 1970'lerin başında bilgisayarlı tomografinin (Computerized Axial Tomograph, CAT) keşfiyle, görüntü işleme en önemli uygulama alanı olan tıbbi tanıda ortaya çıkmıştır [3].

Görüntü işleme teknikleri, günümüzde bir çok alanda kullanılmaktadır. Tıp, astronomi, endüstriyel vb. alanlarda görüntü işleme tekniklerinden oldukça çok faydalanılmaktadır. Tıp alanında, gamma ve X ışınları yardımıyla hastalarda damar izleme, işlemleri yapılarak damar tıkanıklıkları, sertleşmeleri ve çatlaklıklar kolayca bulunabilmekte ve daha hızlı bir tedavi süreci ortaya konulabilmektedir [4]. Gözdeki damar hastalıkları veya vücudun herhangi bir bölgesindeki zedelenme, tümör gibi doku bozuklukları tespit edilebilmektedir. Patolojide hastadan alınan doku parçası içerisinde otomatik hücre sayma işlemi yapılarak, hastalıklı hücrelerin, sağlıklı hücrelere oranı tespit edilerek hastalığın derecesi ölçülebilmektedir [5-10]. Endüstriyel alanda eksik eleman, devre çizgileri arasında kopukluk olup olmadığı tespit edilebilmektedir [1]. Meteoroloji de uzaydan çekilen uydu fotoğrafları yorumlanarak, hava tahmini yapılmakta veya özel renklendirme işlemleri yapılarak ozon tabakasının delinmesinden meydana gelen aşırı ısınma olayı izlenebilmektedir. Özel programlar kullanılarak coğrafi bölgelerin bitki yapısı, toprak yapısı, yer altı ve yer üstü kaynakları saptanarak gerekli stratejiler belirlenebilmektedir [1]. Jeolojide, maden-petrol arama işlemlerinde ilk önce uydu fotoğrafları bilgisayar ortamında yorumlanmakta ve bu bilgiler ışığında gerekli çalışmalar yapılmaktadır [11].

Görüntü işlemedeki temel basamaklar Şekil 1.1'de gösterilmiştir. Buradaki her bir blokta, amaca uygun özel bir dizi işlem gerçekleştirilmektedir. Uygulanacak işlemler sonrasında sistemin çıkışı, yeni bir görüntü, giriş görüntüsünün bir kısmı veya giriş görüntüsündeki nesneler olabilir. Her bir bloğun kullanım amacı şöyledir;



Şekil 1.1. Görüntü işlemede temel basamaklar

Görüntü Elde Etme: Görüntünün elde edilmesi ve sayısallaştırılması, görüntü işlemenin ilk adımındır. Bilgisayar sayısal (doğrudan resimle ilgili olmaktan çok) veri ile çalıştığı sürece, bilgisayar ile işlem yapmaya başlamadan önce görüntü sayısal biçime getirilmelidir. Fiziksel görüntü resim elemanları piksel (nokta, dot) adı verilen küçük bölgelere ayrılırlar. En genel anlamda, alt bölümlere ayırma şeması şeklinde verilen iki boyutlu bir dizi şeklinde yapılıdır. Görüntü birbirinden bağımsız piksellerden oluşacak şekilde yatay çizgiler halinde bölünür. Sayısal görüntüye, her piksel bölgesinde girilen rakam, o resimde ilgili noktaya ait parlaklığı göstermektedir.

Görüntü Zenginleştirme: Görüntü zenginleştirme, görüntü işleme bölümleri içinde hem en kolay hem de en çok ilgi çeken bölümü olmuştur. Görüntü zenginleştirmenin temel amacı, görüntüde gözle ayırt edilemeyecek kısımların incelenebilir bir duruma getirilmesidir. Örneğin bir görüntünün parlaklığının artırılması, görüntünün daha iyi sunulmasını sağlar.

Görüntü iyileştirme: Görüntü iyileştirme de, görüntü zenginleştirme gibi görüntünün daha iyi sunulması içindir. Görüntü zenginleştirmeden farkı, matematiksel ve olasılık teorisine dayanmasıdır. Görüntü zenginleştirme daha çok kullanıcının bakış açısına göre düzenlenirken, görüntü iyileştirme daha çok nesneldir.

Renkli Görüntü İşleme: Bu blok, internet üzerinde sıkça sayısal görüntü kullanılmaya başlandıktan bu yana bir hayli önem kazanmıştır.

Görüntü Sıkıştırma: Adından anlaşılacağı gibi, görüntülerin saklanması sırasında gerekli olan hafıza miktarının azaltılması için kullanılan teknikler bu alanda kullanılmaktadır. Örneğin; bilgisayarlarda kullanılan JPEG (Joint Photographic Experts Group) biçimi aslında görüntülerin daha az yer kaplamaları için kullanılan bir sıkıştırma tekniğidir.

Morfolojik İşlemler: Herhangi bir görüntü içindeki şekillerin tanımlanması ve sunulması için morfolojik işlemler kullanılır. Bu bölümde sistemin girişi bir görüntü, çıkışı ise bir görüntü davranışı olarak ifade edilir.

Bölütleme: Görüntü bölütleme, bir görüntüyü bileşenlerine veya görüntüyü oluşturan nesnelere ayırma işlemi olarak tanımlanabilir. Genel olarak, görüntü bölütleme işlemi oldukça zor bir işlemdir. Dayanıklı bölütleme işlemleri, ayrıştırılmak istenen nesneyi, görüntüden başarılı bir şekilde ayrıştırırken, zaman yönünden dezavantaj getirebilir. Diğer taraftan sıradan bölütleme tekniklerinde her zaman belirli bir hata oluşmaktadır.

Sunma ve Tanımlama: Genellikle bölütleme işlemleri sonrasında elde edilen kenarlar veya görüntünün belli bir bölümü ile temsil edilen görüntüdür. Diğer bir deyişle, elde edilen verilerin bilgisayarın anlayabileceği bir biçime dönüştürülmesidir. Örüntü tanıma sistemlerindeki anahtar özellik çıkarma bileşeni ile benzerlik sergiler [15].

Nesne Tanıma: Nesne tanıma, bir nesnenin, tanımlayıcısına bağlı olarak bir sınıfa atanması olarak tanımlanabilir. Görüntü işlemede nesne tanıma, görüntü içinde bulunan nesnelerin belirli özellikleri göz önüne alınarak etiketlenmesidir [27].

Bu tez, değişik bölütleme tekniklerini kullanarak imgede istenilen herhangi bir kısmı veya bileşeni imgeden ayırarak tanınmasını ve sınıflandırılmasını hedeflemektedir. Bu amaçla hazırlanan tez aşağıdaki bölümlerden oluşmuştur:

İkinci bölümde, görüntü işlemenin temelleri olan görüntünün sayısallaştırılması, görüntü dönüşümleri, filtreleme, kenar çıkarma gibi temel kavramlar incelenmiştir.

Üçüncü bölümde, örüntü tanıma yapısı ele alınarak, alt bileşenlerinin işlevleri açıklanmıştır.

Dördüncü bölümde, geliştirilen karar destek sistemleri ile, çeşitli görüntü bölütleme yöntemlerinin histopatolojik imgelere uygulanması, imgeden istenilen bir alanın bulunması, bir hücrenin sayılması ve histopatolojik imgelerin sınıflandırılması yapılmıştır.

Son bölümde ise, elde edilen sonuçlar irdelenerek katkılar vurgulanmıştır. Ayrıca ileride yapılabilecek benzeri çalışmalar ve uygulama alanları için öneriler tartışılmıştır.

Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından FÜBAP-985 nolu proje ile desteklenmiştir.


BÖLÜM 2

2. GÖRÜNTÜ İŞLEMENİN TEMELLERİ

2.1. Sayısal Görüntü İşlemenin Elemanları

En basit anlamda, görüntü (imge, resim) işleme iki parçadan oluşan özel giriş/çıkış cihazı gerektirmektedir. Bunlardan birisi görüntü sayısallaştırıcı ve diğeri ise sayısal görüntüleme cihazıdır.


Doğal oluşma biçiminde, görüntüler bilgisayar analizi için doğrudan uyumlu değildir. Bilgisayarlar, sayısal veri ile çalıştığı sürece, bilgisayarlar ile işlem yapmaya başlamadan önce, görüntü sayısal biçime dönüştürülmelidir. Şekil 2.1’de iki boyutlu bir dizinin, fiziksel bir görüntünün yerini nasıl alabileceği gösterilmiştir. Fiziksel görüntü, resim elemanları piksel adı verilen küçük bölgelere ayrılırlar. Bu işlem en genel anlamda, alt bölümlere ayırma şeması şeklinde verilen iki boyutlu bir dizi şeklinde yapılır. Görüntü birbirinden bağımsız piksellerden oluşacak şekilde, yatay çizgiler halinde bölünür. Sayısal görüntüye, her piksel bölgesinde girilen rakam, o resimde ilgili noktaya ait parlaklığı göstermektedir [13].



Şekil 2.1. Fiziksel bir görüntünün sayısal karşılığı

Bu dönüştürme işlemine, sayısallaştırma işlemi adı verilir ve genel biçimi Şekil 2.2’de görülmektedir. Her piksel bölgesi için görüntü örneklenmiş ve kuantalanmıştır. Bu adım, her piksel için görüntünün o noktadaki parlaklığını ya da koyuluğunu simgeleyen bir tamsayı oluşturarak gerçekleştirilmektedir. Bu tüm pikseller için yapıldığında, görüntü tamsayılardan oluşan iki boyutlu bir dizi şeklinde ifade edilebilir. Her pikselin bir tamsayı bölgesi veya adresi

(çizgi / satır numarası ve örnekleme sütun numarası) ile gri seviyesi adı verilen bir tamsayıdır. Bu sayısal veri dizisi artık bilgisayarda işlenmek üzere kullanılabilir [13].



Şekil 2.2. Bir görüntüyü sayısallaştırma

2.2. İmge İşlemedeki Temel Operatörler


Temel sayısal imge işleme, toplama, çıkarma, çarpma gibi basit aritmetiksel işlemleri içermektedir.

2.2.1. İmge toplama ve çıkarma

Benzer iki imgeyi birbirine ekleme veya çıkarma Denklem 2.1'deki gibi ifade edilmektedir. Birinci imgedeki her bir piksel diğer imgedeki aynı piksel ile toplanır. Bunun sonucunda elde edilen değer, çıkış imgesindeki aynı piksele geri döndürülür. Toplama işleminin gerçekleşebilmesi için imgeler aynı büyüklük ve sınıfta olmalıdır [1, 12].

$$c[i,j]=a[i,j] \pm b[i,j] \quad (2.1)$$

Giriş imge piksellerine bir sabit ekleyerek, parlaklaştırılmış bir çıkış imgesi elde edilebilir.



(a) Birinci imge



(b) İkinci imge



(c) Birleştirilmiş imge

Şekil 2.3. İmgelerin birleştirilmesi işlemi

2.2.2. İmge döndürme

Bir imgeyi döndürmek, girilen bir açı ile imgenin bir eksen etrafında çevrilmesidir. Bir imgenin döndürülebilmesi için Denklem 2.2 ile imgenin her bir pikselinin çarpılması gerekmektedir. Elde edilen sonuç tekrar aynı piksele aktarılır ve çıkış imge elde edilmiş olur [1, 12].

$$\begin{bmatrix} \cos(x) & \sin(x) \\ -\sin(x) & \cos(x) \end{bmatrix} \quad (2.2)$$

2.2.3. İmgenin negatifini üretme

Bir imgenin negatifini üretme ise, giriş piksellerinin veri tipinin maksimum değeri ile çıkarımında elde edilen sonucun, çıkış piksellerine atanmasıdır. Veri tipinin 0-255 olarak kullanıldığı düşünülürse, negatifini üretmek için denklem 2.3 kullanılır.

$$b[i,j]=255-a[i,j] \quad (2.3)$$





2.3. İmge Dönüşümleri

Bir imgenin alışılmış matematiksel temsili, iki uzaysal değişkenin (x,y) bir fonksiyonudur $f(x,y)$. Belirli bir (x,y) 'deki fonksiyon değeri, o noktadaki imgenin yoğunluğunu temsil eder. İmge işlemede kullanılan önemli dönüşümler ise; Fourier Dönüşümü, Ayırık Fourier Dönüşümü, Ayırık Cosine Dönüşümü, Radon Dönüşümü, Mesafe Dönüşümleridir [14]. Aşağıda bu dönüşümlerden en önemli olan Mesafe Dönüşümleri incelenmiştir.

2.3.1. Mesafe dönüşümü

Mesafe dönüşümü, imgedeki nokta ayrımlarının ölçümelerini sağlar. Kullanılan mesafe ölçüleri Euclidean, City Block, Chessboard, Quasi-Euclidean gibi ölçülerdir [14].

Tablo 2.1 Mesafe Ölçüleri

Metrik Mesafe	Açıklama	Örnekleme
Öklid	Öklid mesafesi iki piksel arasındaki düz bir çizgidir.	
Şehir Bloğu	Şehir bloğu mesafesi, dörtlü piksel komşuluğa dayanan yol ölçüsüdür. Kenarları birbirine dokunan pikseller 1 birim uzakta, köşegenleri birbirine dokunan pikseller 2 birim uzaktır.	
Satranç Tahtası	Satranç tahtası mesafesi, sekizli piksel komşuluğa dayanan yol ölçüsüdür. Pikselin kenar veya köşegenine dokunan pikseller 1 birim uzaktır.	
Sanki-Öklid	Sanki-Öklid yatay, dikey ve köşegen çizgi kısımları sabiti boyunca toplam Öklid mesafesini ölçer.	

2.4. Filtreleme

2.4.1. Doğrusal filtreleme

Filtreleme, bir imgenin özelliklerini artırma-azaltma tekniğidir. Örneğin, bir imgenin belirli bir özelliğini vurgulamak veya diğer özellikleri kaldırmak için filtreleme yapılabilir. Filtreleme, bir komşuluk işlemidir. Bu işlem, giriş imgesindeki piksellere bazı algoritmalar uygulanarak çıkış imgesinin elde edilmesidir [14]. Kullanılan algoritmalar aşağıda sunulmuştur.

a) Katlama : Bir imgeyi doğrusal filtreleme süreci, katlama (Konvulasyon) olarak adlandırılan bir işlem ile yapılır. Katlamada çıkış piksel değeri, komşu piksellerin ağırlıkları toplamı olarak hesaplanır. Örneğin ağırlıklar matrisi;

$$A = \begin{bmatrix} 17 & 24 & 1 & 8 & 15 \\ 23 & 5 & 7 & 14 & 16 \\ 4 & 6 & 13 & 20 & 22 \\ 10 & 12 & 19 & 21 & 3 \\ 11 & 18 & 25 & 2 & 9 \end{bmatrix}$$

ve katlama çekirdeği (kernel)


$$h = \begin{bmatrix} 8 & 1 & 6 \\ 3 & 5 & 7 \\ 4 & 9 & 2 \end{bmatrix}$$

Şekil 2.4 'de (2,4) pikseli için çıkışın nasıl olacağını aşağıda adımlar kullanılarak elde edilebilir.

1. Merkez eleman etrafında Katlama çekirdeği 180° döndürülür.
2. Katlama çekirdeğinin merkez elemanı A(2,4) pikselinin üstüne kaydırılır.
3. Katlama çekirdeğindeki ağırlıkları A'nın pikselleri ile çarpılır.
4. Üçüncü adımdaki sonuçları toplanır.

Böylece (2,4) çıkış pikseli;


$$1.2 + 8.9 + 15.4 + 7.7 + 14.5 + 16.3 + 13.6 + 20.1 + 22.8 = 575$$



b) İlişki: İlişki (Korelasyon) işlemi, katlama ile yakından alakalıdır. İlişkide çıkış pikselinin değeri, komşu piksellerin ağırlıkları toplamı olarak hesaplanır. Aralarındaki fark ise, ilişki ağırlıklar matrisi, hesaplama işlemi esnasında döndürülmez [14]. Şekil 2.5'nin (2,4) pikselinin çıkışı aşağıdaki adımlar kullanılarak bunabilmektedir:


1. Katlama çekirdeğinin merkez elemanı A(2,4) pikselinin üstüne kaydırılır.
2. İlişki çekirdeğindeki her bir ağırlığı A'nın pikselleri ile çarpılır.
3. Tek tek çarpımları toplanır.

$$1.8 + 8.1 + 15.6 + 7.3 + 14.5 + 16.7 + 13.4 + 20.9 + 22.2 = 585$$



Şekil 2.5. Ağırlıklar matrisi (İlişki)

Yukarıdaki işlemlerin kan hücrelerine ve çiçek imgesine uygulandıktan sonra imgeleri nasıl bulanıklaştıkları Şekil 2.6.'de görülmektedir.



Şekil 2.6. (a) Orijinal imge (b) Filtrenilmiş imge

2.4.2. Düzgünleştirme frekans alan filtreleri

Gri seviyedeki bir imgenin kenar ve diğer keskin değişimlerine (gürültü gibi), imgenin Fourier Dönüşümünün yüksek frekans içeriği önemli bir şekilde yardım eder. Bu nedenle düzgünleştirme, verilen bir imge dönüşümünde yüksek frekans elemanlarının belirtilen dağılımını, frekans alanında azaltılarak başarılır. Frekans alanında filtreleme için temel model Denklem (2.4) deki gibidir.

$$G(u, v) = H(u, v) \cdot F(u, v) \quad (2.4)$$

$F(u, v)$ düzgünleştirilecek resmin Fourier Dönüşümüdür. Amaç $F(u, v)$ yüksek frekans bileşenini azaltarak, $G(u, v)$ 'yi veren bir filtre transfer fonksiyonu seçmek için $H(u, v)$ belirlemektir.

Bu bölümde, sıkça kullanılan üç tip filtreleme tekniği incelendi: İdeal, Butterworth, Gaussian. Bu üç tip filtreleme, çok keskin olan dağılımdan ziyade, düzgün olan dağılıma kadar

olan filtreleme fonksiyonunu kapsamaktadır. Butterworth filtresi, dizi olarak çağrılan bir filtreye sahiptir. Bu parametrenin yüksek değerleri için Butterworth filtresi, ideal filtre gibi davranır. Daha düşük diğer değerler içinse, Gaussian filtresi gibi davranır. Bu yüzden Butterworth filtresi aşırı değerler arasında bir dönüşüm gibi görülmektedir [1].

a) İdeal düşük geçiren filtreler




Düşünülebilecek en basit filtre, Fourier Dönüşümü'nün bütün yüksek frekans bileşenlerini kesen bir filtredir. Böyle bir filtre iki boyutlu (2B) ideal düşük geçiren filtre (ILPF) olarak isimlendirilir. Bu filtrenin transfer fonksiyonu Denklem (2.5) deki gibidir.

$$H(u, v) = \begin{cases} 0 & \text{if } D(u, v) \leq D_0 \\ 1 & \text{if } D(u, v) > D_0 \end{cases} \quad (2.5)$$

D_0 , özel negatif olmayan niceliktir. $D(u, v)$ ise, (u, v) noktasında frekans dikdörtgeninin merkezine olan mesafedir. Eğer resmin büyüklüğü $M \times N$ ise, frekans dikdörtgeninin merkezi $(u, v) = (M/2, N/2)$. Bu durumda, her (u, v) noktasından Fourier Dönüşüm merkezine olan uzaklık Denklem (2.6) daki gibidir.

$$D(u, v) = [(u - M/2)^2 + (v - N/2)^2]^{1/2} \quad (2.6)$$

Şekil 2.7(a) u ve v bir fonksiyon olarak $H(u, v)$ 'nin (3B) perspektif çizimini gösterirken, Şekil 2.7(b) resim olarak görüntülenen $H(u, v)$ 'i göstermektedir.



Şekil 2.7. (a) Düşük geçiren filtrenin transfer fonksiyonunun perspektif çizimi **(b)** İmge olarak görüntülenen filtre **(c)** Filtrenin radyan kesiti


b) Butterworth düşük geçiren filtre

N dizilik, orjinden D_0 mesafede kesme frekanslı bir Butterworth düşük geçiren filtrenin (BLPF) transfer fonksiyonu Denklem (2.7) deki gibi tanımlanır.

$$H(u, v) = \frac{1}{1 + [D(u, v) / D_0]^{2n}} \quad (2.7)$$

$$D(u, v) = [(u - M/2)^2 + (v - N/2)^2]^{1/2} \quad (2.8)$$

BLPF ile işlenmiş imgelerin hiçbirinde halkalama görünmez. Bir dizilik Butterworth filtrede halkalama yoktur. İki dizili bir filtrelemede genel olarak filtreleme görünmez. Fakat halkalama yüksek dizili filtrelemede önemli bir faktördür. Şekil 2.8’de değişik dizili BLPF’nin uzaysal temsilleri arasındaki karşılaştırmalar gösterilmektedir. Tek dizili BLPF’de ne halkalama ne de negatif değerler vardır. İki dizilik filtrede, hafif halkalar ve negatif değerler görünür. Fakat bunlar kesin olarak ILPF’den daha az belirgindir [1].




Şekil 2.8. (a) 1 dizili (b) 2 dizili (c) 5 dizili (d) 20 dizili BLPF’nin uzaysal gösterimi

c) Gaussian düşük geçiren filtre

İki boyutlu Gaussian düşük geçiren filtresi (GLPF) Denklem (2.9) da gösterilmektedir.

$$H(u, v) = e^{-D^2(u, v) / 2\sigma^2} \quad (2.9)$$


$D(u, v)$ Fourier dönüşümünün orijinden uzaklığıdır. σ Gaussian eğrileri arasındaki uzunluğun ölçüsüdür. $\sigma = D_0$, olduğunu kabul edilirse, filtre notasyon terimleri ile daha iyi açıklanabilir.



Şekil 2.9. (a) GLPF transfer fonksiyonun perspektif çizimi **(b)** Resim gibi görüntülenmiş filtre **(c)** D_0 değişik değerleri için filtre radyal kesitleri

$$H(u, v) = e^{-D^2(u, v) / 2D_0^2} \quad (2.10)$$

D_0 , sıfır bir kesme frekansıdır. $D(u, v) = D_0$, olduğu zaman filtre maksimum değeri olan 0.607'nin altındadır. Şekil 2.10.(a)'ya GLPF uygulandığı zamanki sonuçlar Şekil 2.10.(b)'deki gibidir. BLPF durumundaki gibi bir düzgünlük dönüşümü, bulurlamada (blur) artan kesme frekans fonksiyonu gibidir. GLPF, aynı kesme frekans değerlerine sahip iki dizili BLPF kadar düzgünleştirmeyi başaramaz. Bu beklenen bir sonuçtur. Çünkü GLPF profili, iki dizili BLPF profili kadar sıkı değildir. Ayrıca sonuçlar karşılaştırıldığında, GLPF'de halkalamanın olmadığı görünür. Bu pratikte önemli bir özelliktir [1].



Şekil 2.10. (a) Orijinal İmge **(b)** GLPF uygulanmış resim


2.4.3. Keskinleştirme frekans alan filtreleri

Bir önceki bölümde, bir resmin Fourier Dönüşümünün yüksek frekans bileşenleri azaltılarak bulurlaştırılabileceği verildi. Çünkü kenar ve gri seviyedeki ani değişimler, yüksek

frekans bileşeni ile ilgilidir. Bir resmi keskinleştirme, frekans alanında yüksek geçiren filtreleme işlemi ile gerçekleştirilebilir. Bu işlem, Fourier dönüşümündeki yüksek frekans bilgileri karıştırılmaksızın, düşük frekans bileşenleri azaltılarak yapılır. Burada amaçlanan, önceki bölümde bahsedilen İdeal düşük geçiren filtrelemenin tam tersini yapmaktır. Yüksek filtreleme transfer fonksiyonu Denklem (2.11) deki gibidir.

$$H_{HP}(u, v) = 1 - H_{LP}(u, v) \quad (2.11)$$

Burada; İdeal, Gaussian ve Butterworth filtreleme ele alındı. Şekil 2.11’de 3B çizimleri, imge temsilleri ve bu filtreler için kesitler gösterilmektedir. Butterworth filtre, ideal filtrelemenin keskinliği ile Gaussian filtrelemenin düzgünlüğü arasındaki bir dönüşümü temsil eder.



Şekil 2.11. (a) Perspektif çizim (b) İmge temsili (c) Filtre kesiti (Üst: İdeal Yüksek Geçiren Filtre, Orta: Butterworth Yüksek Geçiren Filtre, Alt: Gaussian Yüksek Geçiren Filtre).

a) İdeal yüksek geçiren filtre

İdeal yüksek geçiren bir filtre (IHPF) Denklem (2.12)'deki gibi tanımlanır.

$$H(u, v) = \begin{cases} 0 & \text{if } D(u, v) \leq D_0 \\ 1 & \text{if } D(u, v) > D_0 \end{cases} \quad (2.12)$$

Burada D_0 , frekans dikdörtgeninin orijinden ölçülen kesme mesafesidir. $D(u, v)$ ise Denklem (2.14) de tanımlanmıştır. Bu filtre mantıksal olarak ideal düşük geçiren filtrenin tersidir.

İdeal düşük geçiren filtre gibi IHPF'de elektronik elemanlar ile fark edilemez. Fakat bilgisayarlarda uygulanabilir. Bu ilişkiden dolayı ILPF gibi, aynı halka özelliklerine sahip olması beklenir.

b) Butterworth yüksek geçiren filtreleri

N dizili, orijine D_0 mesafede kesme frekanslı BHPF filtresinin transfer fonksiyonu Denklem (2.13) deki gibidir.

$$H(u, v) = \frac{1}{1 + [D_0 / D(u, v)]^{2n}} \quad (2.13)$$

$$D(u, v) = [(u - M/2)^2 + (v - N/2)^2]^{1/2} \quad (2.14)$$

Şekil 2.11.(b)'de orta sütunda, imge temsili ile BHPF fonksiyonu gösterilmiştir. Düşük geçiren filtredeki gibi, BHPF filtresinde IHPF'den daha düzgün davranır. IHPF ve BHPF'nin merkez nokta büyüklükleri benzer olduğu için, küçük nesnelerdeki filtreleme performansları karşılaştırılabilir [1].

c) Gaussian yüksek geçiren filtre

Orijinden D_0 mesafede kesme frekanslı GHPF transfer fonksiyonu Denklem (2.15) deki gibidir.

$$H(u, v) = 1 - e^{-D^2(u, v) / 2D_0^2} \quad (2.15)$$

Şekil 2.11’de üçüncü sütunda perspektif çizim, imge ve bu filtrenin kesitleri gösterilmiştir. Görüldüğü gibi elde edilen sonuçlar diğer iki filtrelemenin sonuçlarından daha düzgündür. Hatta küçük nesneleri ve ince çubukları filtreleme, Gaussian filtresi ile daha belirgindir.

2.5. Kenar Çıkarma

Kenar çıkarmadaki amaç, imgenin içerdiği bilgiyi değerlendirip, nesnenin gereksiz ve tanıma işlemlerinde zaman kaybettiren bilgisini eleyerek, yeterli düzeye indirgemektir. Kenar yakalama, görüntü analizinde ve nesnelerin sınıflandırılmasında çok değerli bilgiler taşıdığından, ilgi çeken bir araştırma alanı olmuştur [27].

Kenarlar görüntüdeki nesnelerin geometrisi hakkında çok önemli bilgiye sahiptir. Parlaklık değerlerindeki ani değişimler ve süreksizlikler görüntü analizinde kullanılan en önemli karakteristik özelliklerden biridir. Bunun nedeni, imge içerisindeki nesnelerin fiziksel büyüklükleri ve geometrik bilgileri bu değişim esas alınarak tespit edilebilir. Yerel olarak imgedeki parlaklığın bir seviyeden diğer bir seviyeye doğru değişim göstermesi, bu noktada parlak kenarların olduğuna işaret eder. Genel parlaklık değişimleri ise parlak sınır bölmelerine işaret eder. Parlak bir kenarın tanımlanması, yumuşak alanlar arasındaki imge genliğindeki değişim olarak adlandırılır.

Kenar çıkarma, örüntü tanıma çok önemli rol oynar. Bu şu şekilde açıklanabilir: İnsan görme sistemi, örüntüleri tanıma süreci içinde nesnenin dış çizgilerini izleyerek bir göz gezdirir. Bu yaklaşımı yapay görme sistemlerine uyarladığımızda, şayet örüntünün sınırları başarılı bir şekilde izlenirse, örüntü tanıma çok daha iyi sonuçlar alınabilir. Böylece tanıma olayında kenar çıkarma önemli bir rol oynar. Çoğu imgeler somut örüntüleri içermez ve bu imgeleri anlamak, onların yapısal özelliklerine bağlıdır. Yapısal özelliklerin çıkarımı ise kenar çıkarma ile ilgilidir.

Kenar çıkarmada önemli olan, örüntünün kenar çizgisinin tek piksel kalınlığında elde edilebilmesidir. Böylece imgeyi işlemek için daha az bilgi kullanıldığından, örüntü tanıma oldukça önemli olan hız problemine zamandan tasarruf sağlanarak çözüm getirilebilir. Aynı zamanda örüntü tanımak için oluşturulacak veri tabanları daha kolay oluşturulabilir. Yıllardır, örüntü kenarı çıkarmak için Sobel, Prewitt, Laplacian gibi kenar sezme yöntemleri kullanılmaktadır. Ama bunların hepsinde, kenar çıkarmada arzulanan nesne kenarının tek bir piksel kalınlığındaki çizgi ile ifadesi mümkün olamamıştır [27].

2.5.1. Süreksizliğin tanımlanması

İmgeyi oluşturan noktaların parlaklık değerlerindeki değişimlerin, belirtilen eşik değerinden daha büyük olması durumunda görüntünün o bölgesinde süreksizlik meydana gelir. Bu bölümde sayısal görüntülerde süreksizliğin üç temel tipinin yakalanmasına dair farklı teknikler üzerinde durulmuştur. Bu üç temel tip; nokta, çizgi ve kenardır. Pratikteki uygulamalarda, süreksizliğin yakalanması için kullanılan en genel yöntem, imge içerisinde bir maskenin çalıştırılmasıdır. Bu olay, Şekil 2.12’de gösterilen 3x3 boyutundaki maskenin, imgedeki alanlara uygulanarak elde edilen sonuçların eski değerler ile değiştirilmesi olarak sunulabilir. İmgedeki her hangi bir noktanın maskelenmesinden elde edilen sonuç o anki değeri ile değiştirilir ve bu işlem imgenin tüm piksel değerlerine uygulanırsa maskelenmiş imge elde edilir. Buna göre her hangi bir pikselin maskelenmiş değeri;

$$R = w_1z_1 + w_2z_2 + w_3z_3 + + w_9z_9 = \sum_{i=1}^9 w_i z_i \quad (2.16)$$

denklemleri ile bulunur. Denklemlerdeki z değeri, piksellerin gri seviye değerlerini gösterir. w değeri ise maskeleyen katsayıdır. Maskeleyenin sonucu, maskelenen alanın orta piksel değerinin değişmesini sağlayacaktır. Maskelenen alan ise o anki pikselin uygun kısmi komşulukları kullanılarak bulunur [2].

w_1	w_2	w_3
w_4	w_5	w_6
w_7	w_8	w_9

Şekil 2.12. Genel 3x3 boyutundaki maskeleyen

-1	-1	-1
-1	8	-1
-1	-1	-1

Şekil 2.13. Arka plandan farklı olan bir noktayı yakalamak için kullanılan maske

a) Nokta yakalama

Nokta yakalama, imgedeki korunmuş veya arka plandan farklı olan noktaların tespit edilmesi işlemine denir. Şekil 2.13’deki maskeleyen kullanılarak orta piksel için elde edilen R

değeri, daha önceden belirtilen T eşik değerinden daha büyükse, görüntüde aranan nokta bulunur.

$$|R| > T \quad (2.17)$$

T eşik değeri negatif olmayan bir değerdir. Burada esas olan, orta pikselin değeri ile belli komşuluktaki değerleri arasında büyük bir fark olan noktanın tespit edilmesidir.

Maskelenmede kullanılan matris, frekans alanında yapılan yüksek frekanslı bileşenlerin filtreleneceği işleminde kullanılan, maskeleme matrisi ile aynıdır.

b) Çizgi yakalama

Nokta yakalama işleminden biraz daha komplekstir. İmge içerisinde tek piksel kalınlığında bir çizgi şeklinde değişim söz konusu ise, bu süreksizliği yakalar. Şekil 2.14.'deki ilk maske ile maskeleme, imge içerisinde yatay eksene paralel bir çizgiyi yakalar. İkinci maske ise yatay eksene $+45^\circ$ lik açıyla değişen pikselleri yakalar. Üçüncü maske şekilde -45° , dördüncüsü ise 90° bir değişim var ise, bunları tespit eder.

-1	-1	-1	-1	-1	2	-1	2	-1	2	-1	-1
2	2	2	-1	2	-1	-1	2	-1	-1	2	-1
-1	-1	-1	2	-1	-1	-1	2	-1	-1	2	-1
Yatay			+45			Düşey			-45		

Şekil 2.14. Çizgi yakalamak için kullanılan maskeler

BÖLÜM 3

3. ÖRÜNTÜ TANIMA


Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir. Örüntü tanıma, insanların çeşitli ses, imge ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarını, insanların yaşantısında da görebiliriz: Hava değişimin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip birçok etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanımı, geçmiş tecrübelerle dayalı öğrenme esaslıdır. Böylece, insanlar pratikte karşılaştığı örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Belirli bir sesi tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin birçoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinelerin yapmasını arzularlar. Örüntü tanıma, böyle akıllı ve öğrenebilen makineleri gerçekleştirmek için, çok boyutlu bir mühendislik disiplindir [15].

Örüntü tanıma olayını şu şekilde irdeleyebiliriz: Aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya imgeleri, bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırmadır. Bu bağlamda, örüntü tanımanın en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir.

Örüntü tanıma tekniklerinin uygulamaları birçok mühendislik, tıp, askeri ve bilim alanına açıktır. Bunlardan bazıları; ses tanıma [16], EEG sınıflama, DTMF haberleşme işaretlerini tanıma ve radar hedef sınıflama [17], biyomedikal kontrol verilebilir. Örüntü tanıma olarak bilinen bu uygulamalar, makine öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır [18]. Örüntü tanıma kavramı, Şekil 3.1’de gösterildiği gibi üç önemli birimden oluşmaktadır [15]:

1. İşaret / Görüntü İşleme: Ön işlem aşamasıdır. İşaret veya görüntünün filtre edildiği, çeşitli dönüşüm ve gösterim teknikleri ile işlendiği, bileşenlerine ayrıldığı veya modellendiği kısımdır.
2. Özellik Çıkarma: İşaret ve görüntünün veri boyutunun indirgendigi ve tanımlayıcı anahtar özelliklerinin tespit edildiği ve aynı zamanda normalizasyona tabii tutulduğu aşamadır. Sistemin başarımında en etkili rolü oynar.

3. Sınıflandırma: Çıkarılan özellik kümesinin indirgendiği ve formüle edildiği tanımlayıcı karar aşamasıdır.




Şekil 3.1. Örüntü tanıma kavramı

3.1. Örüntü Tanıma Probleminin Formülasyonu

Örüntü tanıma probleminin şekilsel amacı, gerçek giriş uzayındaki M adet $\{x_i\}_{i=1}^M$, $x \in X \subset \mathcal{R}^M$ gözlemleri veya ölçümleri, birkaç sınıftan $y \in Y \equiv \{w^{(1)}, w^{(2)}, \dots, w^{(K)}\}$ birine ayırmak suretiyle tanımlayabilmektir. Sınıfsal çıkış, karar uzayındaki her bir $w^{(k)}$ sınıfı temsil etmektedir. $\underline{D}$ operatörü Şekil 3.2. de bir harita olarak gösterilen, her bir ayrıma bir sınıf etiketi atayarak giriş uzayının ayrı bölümlere ayrılmasını sağlayan bir sınıflandırıcıyı veya giriş uzayını birbirleri ile kesişmeyen bölümlere ayırarak her bir sınıfa bir etiket atayıcıyı göstermektedir ($\underline{D} : x \rightarrow y$).

İşaret uzaylarını sınıflamada, işaret örüntüsünün boyutunun çok fazla olması ve gürültü gibi birkaç engelleyici unsur vardır. Bu problemlerden kurtulmak için işareten özellik çıkarımı yapılır. Böylece elde edilen özellik uzayı, giriş işaret uzayı ve çıkış karar uzayı arasında $F \subset \mathcal{R}^N$ olarak betimlenir ($N \leq M$). Bir özellik çıkarıcı $f : X \rightarrow F$ olarak tanımlanır ve sınıflandırıcı ise $g : F \rightarrow Y$ şeklinde verilir. Böylelikle sınıflandırma süreci $d = g \circ f$ olarak gösterilebilir [15].



Şekil 3.2. Karar yüzeyinin özellik uzayının haritası olarak gösterimi


Örüntü tanıma sistemine öğrenme yeteneğinin kazandırılabilmesi için genellikle P adet giriş işareti ve çıkış sınıf etiketi içeren (x,y) eğitim çiftinden oluşan $\mathcal{T}$ eğitim kümesi kullanılır.

$$\mathcal{T} = \left\{ \left(x^{(1)}, y^{(1)} \right), \left(x^{(2)}, y^{(2)} \right), \dots, \left(x^{(P)}, y^{(P)} \right) \right\} \quad (3.1)$$

Burada $^{(i)}$ ifadesi eğitim kümesi içindeki i . örüntü – sınıf çiftini göstermektedir.

3.2. Örüntü Tanıma Sistemi

Örüntü tanıma sistemleri gözlenen veya ölçülen verileri tanımlanmasında birçok uygulamanın merkezinde yer alır. Şekil 3.3 de yaygın olarak kullanılan genel anlamda örüntü tanıma sistemi verilmiştir [15]. Algılayıcılar, herhangi bir anda mümkün olan birçok doğal durumlardan biri olabilen bazı fiziksel işlemleri ölçerler. Aşağıdaki blok diyagramın en önemli görevlerinden biri de, elde edilen ölçümlerin hepsinden oluşan giriş uzayından daha az boyutta özellik çıkartmaktır. Sonunda, sınıflandırıcının rolü örüntüyü özelliklerine göre kategorize ederek uygun sınıflara kaydetmektir.



Şekil 3.3. Örüntü tanıma sistemi

3.2.1. Özellik çıkarma

Özellik çıkarma örüntü tanımının en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar odaklanmıştır. Özellik çıkarmanın ana sebepleri:

1. Ölçüm veya örüntü uzayından daha küçük boyuta dönüşmeyi sağlamaktır. Bu sınıflandırıcının küçük hatalar ile eğitimi ve karar aşamasının daha kısa sürede gerçekleşmesi demektir.
2. Boyut olarak daha düşük olan özellik uzayını sınıflandırıcının daha az parametre ile öğrenmesini mümkün hale getirecektir. Bunun yararı örüntü uzayı ile karar uzayı arasındaki dönüşüm aşamasının daha kısa sürede gerçekleşmesidir.
3. Durağan olmayan zaman serilerinde olduğu gibi karmaşık örüntülerin tanımlayıcı karakteristiklerini bulabilmek için özellik çıkarımı şarttır. Böylece karar aşamasının güvenilirliği artacaktır.
4. Örüntü sınıflandırma sisteminin, sistem içi veya dışındaki kontrolsüz girişimlerden etkilenmemesini sağlayacak bir özellik çıkarımı kararlı bir yapının oluşmasında etken olacaktır. Bu tür kararlı özellikler, sınıflandırıcının genelleme ve ayrışım yeteneğinin yüksek olmasında önemlidirler.

Örüntü özelliklerini belirlemede ana problem verilen esas örüntüden en iyi özellikleri seçmektir. Bunun için doğrudan ve dolaylı olmak üzere iki yaklaşım vardır. Birinci yöntem güçlü yapısal bağlantılara sahip olan ve basit yapıya belirli örüntü tanıma problemlerine uygulanabilmektedir. Dolaylı yöntemlerde ise aşağıdaki gibi formüle edilebilen bir dönüşüm veya gösterim tekniği ile daha kullanışlı bir yapıdan özellik çıkarımı yapılmaktadır. Böylece z uzayından, x uzayına bir dönüşüm gerçekleştirilir.

$$x = F(z) \quad (3.2)$$


Durağan olmayan işaretlerin özelliklerinin çıkarımı ile ilgilenildiğinde, özellik çıkarımı için genelde zaman ve frekans bölgesi gösterimi ön plandadır. Böylece karmaşık örüntü yapısının hem geçici ve hem de zamana bağlı olarak frekans değişimlerini içeren tanımlayıcı özellik bilgileri çıkarılabilir. Bu özellikler, işaretin zaman ve frekans bölgelerindeki yerel bilgilerini karakterize eder [15].

3.2.2. Sınıflandırma

Sınıflandırma aşamasının amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Sınıflandırıcının başarımında iyi belirlenmiş özellikler, kilit rolü oynarlar.

Örüntü sınıflandırıcılarını geleneksel ve akıllı olarak gruplara ayırmak mümkündür. Geleneksel sınıflandırma algoritmaları istatistiksel bir yapı olan Bayes karar teorisi üzerine kuruludur. Bunların dezavantajları, özellik uzayını sınıflandırma uzayını dönüştürürken, bir gürültünün çıkması ve her bir sınıf için hata kriterinin belli olmamasıdır. Geleneksel sınıflandırıcılara; çok değişkenli Gauss modelleri, en yakın komşu, maksimum olabilirlik, ikili ağaç sınıflandırıcıları ve Fisher'in doğrusal sınıflandırıcıları örnek olarak verilebilir. Buna karşın akıllı sınıflandırma yapıları genellikle YSA tabanlı olup, günümüzde en yaygın kullanılan ve başarımını ispatlamış çok güçlü sınıflandırıcı türleridirler. Özellikle de genelleme yetenekleri, örüntü tanıma uygulamalarının çok büyük boyutlu verileri açısından önemlidir. Literatürde karşılaşılan çalışmalarda, geleneksel sınıflandırıcılar ile YSA sınıflandırıcılarının kıyaslanması sonucu, YSA sınıflandırıcılarının üstünlüklerinin geleneksel yöntemlere göre tartışılmaz olduğunu görülmüştür [15].

Şekil 3.4'de akıllı sınıflandırma yapısı gösterilmektedir. Eğitim verisi sınıflandırıcının hafızası içinde şifrelenir. Sınıflandırıcı hafızası uyarlanabilen parametrelerden oluşmaktadır.



Şekil 3.4. Akıllı sınıflama yapısı

BÖLÜM 4

4. GELİŞTİRİLEN KARAR DESTEK SİSTEMLERİ

Karar destek sistemleri, son derece yoğun ve değerli bilgilerin biriktirildiği ortamlarda, toplanan verilerin etkin ve çabuk biçimde süzgeçten geçirilip faydalı ve kolay kullanılabilir bilgiler haline getirilmesi sağlar [19].

Bu bölümde, geliştirilen karar destek sistemleri ile histopatolojik imgeleri bölütleme, alanlarını bulma, istenilen hücrelerin sayılarını bulma ve sınıflandırılma kısımları bulunmaktadır. Bölütleme, alan bulma, hücre sayma ve sınıflandırma işlemlerindeki temel amaç, imgede bulunan herhangi bir nesnenin veya imgenin herhangi bir parçasının daha anlaşılabilir bir hale getirilmesi veya imge hakkında yorum yapabilme olayının kolaylaştırılmasıdır. Örneğin; kanserli bir kişiden alınan doku örneğindeki kanserli hücrelerin oranını bulmak için resimdeki hücreler tek tek sayılmaktadır ve bu işlem birkaç saat sürmektedir. Ama bu işlemi, bilgisayar yardımıyla gerçekleştirildiğinde zaman sadece birkaç saniye gibi çok kısa bir sürede tamamlanmaktadır. Bu ise, karar vericinin daha hızlı bir şekilde teşhis koymasını sağlamaktadır. Erken teşhis olayının önemli bir faktör olduğunu düşünürsek, bu gibi işlemlerin önemi daha iyi bir şekilde anlaşılmaktadır. Bu amaçla, MATLAB ortamında (ver. 5.3, The MathWorks Inc.) yazılımlar geliştirilmiştir.

Bölütleme işlemi, imge işlemenin temel adımlarındandır. Bölütleme işlemleri için, histogram temelli, bulanık c-ortalama, klasik c-ortalama, Shannon entropi ve morfolojik işlemler gibi değişik teknikler kullanılmaktadır. Geliştirilen yöntemlerdeki temel amaç imgeyi bozmayan en iyi bölütleme işlemini yapmaktır. Bunun için imgeleri bölütleme işleminden önce veya sonra, imgedeki yıpranmaları azaltıcı filtrelemeler veya açma-kapama gibi morfolojik işlemler uygulanarak, imgenin kalitesinin bozulmamasına çalışılmaktadır [1, 20, 21]. Alan bulma işlemi, bölütlenen imgede istenen bir hücrenin veya örüntünün alanının hesaplanmasıdır. Bu işlem aynı zamanda hücre sayma sürecinin de ön-işlem aşamasını oluşturmaktadır.

Hücre sayılarının ve alanlarının bulunması işlemi ise basit bir matematiksel işlemidir. Toplam piksel sayısı bulunan imgedeki, istenen hücrenin piksel sayısı belirlenir ve toplam piksel sayısı istenen tek hücrenin piksel sayısına bölünerek resimde bulunan hücre sayısı hesaplanmaktadır.

Hücrelerin sınıflandırılmasında resim işlemede çok değişik yöntemler kullanılmaktadır [1, 15, 18, 22, 27]. Burada, kullanılan yöntem ise fractal analiz yöntemidir. Resimlerin ayrı ayrı fractal boyutları bulunarak hangi kümeye ait oldukları belirlenmektedir [7-10, 23, 24]. Geliştirilen karar destek sistemlerinin ayrıntıları aşağıda verilmiştir:

4.1. Histopatolojik İmge


Histopatoloji, doku ve organların doğal yapısında oluşan lezyonların mikroskopisini inceleyen bir bilim dalı olup [28], uygulamada kullanılan histopatolojik imgeler, Fırat Üniversitesi, Fırat Tıp Merkezi, Patoloji bölümünden alınmıştır. Bu histopatolojik imge örüntüleri, hastalardan alınan dokuların mikroskop altında çekilen resimleridir. İmgelerin alınmasında Olympus BX-50 ışık mikroskobuna bağlı, Olympus C-4000Z sayısal kamera kullanılmıştır. Alınan sayısal imgelerin çözünürlük değerleri 2288x1712 piksel ve 72 DPI' dir. Çözünürlük değerinin yüksek olması, bölütleme işleminin daha iyi olmasını sağlamaktadır.

4.2. Histopatolojik İmgelerin Bölütlenmesi

Histopatolojik imgelerin bölütlenmesinde amaç, alan bulma ve hücre sayma işlemi için imgeyi uygun hale getirmektir. Bölütleme işleminde imge önce gri seviyeye ve daha sonra siyah-beyaz hale getirilmektedir. Siyah-beyaz hale dönüştürülen imge alan bulma ve hücre sayılarını elde etmede gereksiz olan kısımlardan arındırılmış olur. Bu ise imge işlemede bilgisayarın daha kısa bir sürede sonuca ulaşması anlamına gelmektedir. Ayrıca bölütleme işlemi ile resmin istenmeyen kısımlardan arındırılması, hekimlere kararlarını vermede, destek sağlayacak daha iyi bir imge sunumu verecektir.

4.2.1. Histogram temelli görüntü bölütleme tekniği

Sezgisel özellikleri ve kolayca uygulanabilir oluşu, imge eşiklemeyi, imge bölütleme uygulamaları içinde merkezi bir konuma yerleştirmiştir [1]. Şekil 4.1(a)'daki gri seviye histogramının, karanlık bir arka plana ve daha aydınlık bir örüntüye sahip olan $f(x,y)$ imgesine ait olduğunu varsayarsak, bu durumda arka planın ve nesnenin piksellerinin gri seviyesi değerlerinin iki baskın bölgede guruplaştığı görülecektir. İmgenin, arka plandan ayrıştırılmasının en basit yolu, bu iki gurubu ayırabilecek bir T eşik değerinin seçilebilmesidir. Sonra herhangi bir (x,y) noktası ki, $f(x,y) > T$ ise nokta nesneye aittir, aksi durumda nokta arka plan ögesidir. Şekil 4.1(b)'de bu yaklaşımın en genel hali görülmektedir. Burada birden fazla seviyeli eşikleme ile bir (x,y) noktası, eğer $T_1 < f(x,y) < T_2$ ise birinci nesneye, $f(x,y) > T_2$ ise ikinci nesneye ve $f(x,y) < T_1$ ise arka plan olarak ayrıştırılmaktadır.



Şekil 4.1. Gri seviyesi histogramı (a) Tek eşik değer (b) Çok seviyeli eşik değer

Eşikleme, ayrıca bir $T=T[x,y, p(x,y), f(x,y)]$ fonksiyonunun işlevi olarak gösterilebilir. Bu durumda $f(x,y)$, (x,y) noktasının gri-seviyesi değerini, $p(x,y)$ ise o noktasının yerel bir özelliğini gösterir. Örneğin merkezi (x,y) ve onun komşuluğunda olan diğer piksellerin ortalama değerini gösterebilir. Eşiklenmiş bir imge şu şekilde tanımlanır:

$$g(x,y) = \begin{cases} 1 & f(x,y) > T \\ 0 & f(x,y) \leq T \end{cases} \quad (4.1)$$


Böylece 1 olarak etiketlenen pikseller nesneyi gösterirken, 0 ile etiketlenen pikseller arka planı gösterecektir. T değeri sadece $f(x,y)$ değerine bağlı ise, buna global eşikleme denir. Diğer taraftan T hem $f(x,y)$ hem de $p(x,y)$ değerlerine bağlı ise bu da yerel eşikleme olarak adlandırılır. Ayrıca eğer T , x ve y uzaysal koordinatlara bağlı ise, bu tür eşikleme dinamik veya uyarlamalı olarak adlandırılır [3].

Temel global eşikleme

Eşikleme teknikleri içerisinde en sade olanı, kullanılan tek bir T eşik değeri ile imge histogramını bölütleyen tekniktir. Bu durum Şekil 4.1(a)'da gösterilmiştir. Burada bölütleme, görüntünün piksel piksel taranarak her bir piksellin parlaklık değerinin seçilen eşik değerden büyük veya küçük oluşuna göre arka plan veya örüntü olarak etiketlenmesi ile gerçekleştirilir. Bu tekniğin başarımı, imge histogramının ne kadar iyi bölütlenebilmesi ile doğrudan ilgilidir. İmgenin histogramından maksimum ve minimum gri-seviyesi arasında seçilen bir T eşik değeri ile imge bölütlenmektedir. T eşik değerinden küçük gri-seviyesi değerine sahip bütün pikseller 0 yani siyah, bu değerden büyük pikseller ise 255 yani beyaz olarak yeniden düzenlenir [3].


4.2.2. Histogram ile bölütleme uygulaması

Histogram temelli yapılan imge bölütleme işleminde amaç imgeyi eşikleyebileceğimiz en uygun T değerini bulmaktır. Bu eşikleme değerini bulmadan önce, imge eğer renkli ise resim $[0-256]$ gri renk tonu aralığına indirgenmektedir. Sonra imgeyi eşikleyecek en uygun T değeri bulunur ve bu T değeri kullanılarak $[0,256]$ değer aralığında bulunan imge $[0,1]$ aralığına normalize edilir. Şekil (4.2)'de $[0,1]$ aralığına indirgenen bir imge görülmektedir.



Şekil 4.2. (a) $[0-256]$ gri seviyeli imge (b) Siyah beyaz imge

Siyah-beyaz seviyeye indirgenen imgedeki gürültü kaldırılıp ve daha iyi bir görüntünün elde edilmesi için resme değişik filtreler uygulanır. Filtreler sonucunda imgede meydana gelebilecek kusurları gidermek için açma-kapama gibi bazı morfolojik yöntemler kullanılır. Kapama işlemi kullanılarak imgede meydana gelen kusurlar büyük bir oranda giderilebilir. Böylece bölütleme işlemi ile daha düzgün bir sonuç elde edilmiş olmaktadır. Şekil 4.3'de siyah-beyaz imgelerin bölütleme işlemi sonucu elde edilen imgeler görülmektedir.



Şekil 4.3. (a) Histopatolojik kanserli imge (b) Bölütlenmiş histopatolojik kanserli imge
(c) Histopatolojik hepatitli imge (d) Bölütlenmiş histopatolojik hepatitli imge

4.2.3. Klasik c-ortalama görüntü bölütleme tekniği

Klasik c-ortalama’da verilerin her birisi, yalnız bir kümeye atanacak şekilde, klasik mantık ile sınıflandırılır. Bu bölütler (kümeler) ayrıca verilerin parçalara ayrılması şeklinde de değerlendirilir [3]. Böylece bölütler;

$$\bigcup_{i=1}^c A_i = X \quad (4.2)$$

$$A_i \cap A_j = \emptyset \quad (4.3)$$

$$\emptyset \subset A_i \subset X, \text{ bütün } i \text{ için} \quad (4.4)$$

ile ifade edilir. Burada A_i seti ($i=1,2,\dots,c$), X ’in klasik bölütlenmiş durumu ve görüntü kümesi $X = \{x_1, x_2, x_3, \dots, x_n\}$ sonlu set verilerini içermektedir. Küme veya ayırma sayısı c ile gösterilmektedir. Kümeler arasında girişim olmaktadır. Yani:

$$\bigvee_{i=1}^c X_{A_i}(x_k) = 1 \text{ bütün } k\text{'lar için} \quad (4.5)$$

$$X_{A_i}(x_k) \wedge X_{A_j}(x_k) = 0 \text{ bütün } k\text{'lar için} \quad (4.6)$$

$$0 < \sum_{k=1}^n X_{Ai}(x_k) < n \text{ bütün } i\text{'ler için} \quad (4.7)$$

olur. $X_{Ai}(x_k)$ karakteristik fonksiyon klasik mantıkta

$$X_{Ai}(x_k) = \begin{cases} 1 & x_k \in A_i \\ 0 & x_k \notin A_i \end{cases} \quad (4.8)$$

ile ifade edilir.

Veri x_k , yalnız bir c kümesine ait olur. Notasyonun basitleştirilmesi için i . küme içerisinde j . verinin üyelik ataması $X_{ij} \equiv X_{Ai}(x_k)$ ile tanımlanmıştır. U matrisi, X_{ij} ($i = 1, 2, 3, \dots, c$; $j = 1, 2, 3, \dots, n$) elemanlarının birleşiminden oluşan c satırlı ve n kolonlu bir matristir.

Verilerin küme içerisine parçalanmasının en iyi şekilde yapılabilmesi için, $J(U, v)$ amaç fonksiyonunun minimizasyonu göz önüne alınarak gerçekleştirilir.

$$J(U, v) = \sum_{k=1}^n \sum_{i=1}^c X_{ik} (d_{ik})^2 \quad (4.9)$$

burada d_{ik} , k . veri x_k ile i . küme merkezi v_i arasındaki Öklid mesafe ölçüsü olup,

$$d_{ik} = d(x_k - v_i) = \|x_k - v_i\| \quad (4.10)$$

v_i ($v_1, v_2, v_3, \dots, v_c$) küme merkezleridir.

Klasik c -ortalama iteratif optimizasyon yöntemi, aşağıda verilen algoritma ile gerçekleştirilir:

1. U matrisine başlangıç değerleri atanır.
2. Küme merkezleri hesaplanır.

$$v_i = \frac{\sum_{k=1}^n X_{ik} x_k}{\sum_{k=1}^n X_{ik}} \quad (4.11)$$

3. $U^{(r)}$ yeniden güncellenir.


$$X_{ik} = \begin{cases} 1 & d^{(r)}_{ik} = \min\{d^{(r)}_{jk}\}, \text{ bütün } j \in c \text{ için} \\ 0 & \text{diğer} \end{cases} \quad (4.12)$$

4. Eğer $\|U^{(r+1)} - U^{(r)}\| < \epsilon$ ise iterasyon sonlandırılır, tersi durumda $r=r+1$ yapılarak ikinci maddeye geçilir [3].

4.2.4. Klasik c -ortalama ile bölütleme uygulaması

Klasik c -ortalama bölütleme işlemlerinde iyi sonuç veren bir algoritmadır. Klasik c ortalama ile bölütleme uygulaması gerçekleştirmek için yukarıda anlatıldığı gibi önce küme

merkezleri belirlenir. Bu küme merkezlerine her pikselin uzaklığı hesaplanır. En yakın uzaklığa göre pikseller gruplandırılır. Sonra yeniden küme merkezleri hesaplanır. Tekrardan piksellerin yeni küme merkezlerine uzaklıkları hesaplanır ve yeniden en yakın küme merkezine atama yapılarak pikseller gruplandırılır. Bu tekrar işlemi gruplarda bir değişiklik olmayınca durdurulur. Şekil 4.4’de histopatolojik imgede kanserli hücre örüntülerinin klasik c-ortalama ile bölütlenmiş durumları görülmektedir.



Şekil 4.4. (a) Orijinal imgeler (b) Klasik c-ortalama ile bölütlenmiş imgeler

4.2.5. Bulanık c-ortalama görüntü bölütleme tekniği

Bulanık bölütleme de klasik bir yaklaşım olan bulanık c-ortalama (FCM) algoritması kullanılarak gerçekleştirilir. İlk olarak Dunn tarafından tanıtılan ve Bezdek [32] tarafından geliştirilen FCM, klasik bölütleme tekniklerinde olduğu gibi en küçük kare hatasının minimizasyonu üzerine kurulan bir tekniktir [3]. FCM, imgedeki pikseller ile küme merkezi arasındaki mesafeyi ve piksellerin kümelerdeki üyelik değerlerini temel alan bir amaç fonksiyonunun iteratif olarak minimizasyonu ile gerçekleştirir.

Sınırlı sayıda bir küme ele alındığında $X = (x_1, x_2, x_3, \dots, x_n)$, $x_j \in \mathbb{R}^p$, $(j=1, 2, 3, \dots, n)$ imge X küme seti c sayısı ile ifade edilen kümelerle parçalanacaktır. Bölütleme sonucunun iyi

olması için amaç fonksiyonunun minimize edilmesi gerekir. Amaç fonksiyonu aşağıdaki ifadeyle gösterilmiştir.

$$J(\mu_{ij}, v_i) = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^m d(x_j, v_i) \quad (4.13)$$

$$\sum_{i=1}^c \mu_{ij} = 1, 1 \leq j \leq n \quad (4.14)$$

Bölütleme algoritmasının bulanıklılığı, m ile kontrol edilmektedir. İyi bir m değerinin seçiminde teorik bir ifade olmamakla birlikte genel olarak $1.1 < m \leq 5$ arasında bir değer seçilmesi çok daha uygundur.

Denklem 4.14'deki n , görüntüdeki piksel sayısını, μ_{ij} , j . pikselin i . kümedeki üyelik değeri, v bölüt merkezleri ve $d(x_j, v_i)$ ise piksellerin küme merkezleri ile arasındaki $d_{ji} = \|x_j - v_i\|$ olan Euclidean mesafesidir. Amaç fonksiyonunda minimizasyon probleminin çözümü için, amaç fonksiyonun v_i 'ye göre kısmi türevi alınır ve μ_{ij} 'ye göre kısmi türev alınarak aşağıdaki ifade bulunur.

$$v_i = \frac{\sum_{j=1}^n \mu_{ij}^m x_j}{\sum_{j=1}^n \mu_{ij}^m}, \quad i = 1, 2, \dots, c \quad (4.15)$$

$$\mu_{ij} = \frac{\left(\frac{1}{\|x_j - v_i\|} \right)^{1/(m-1)}}{\sum_{k=1}^c \left(\frac{1}{\|x_j - v_k\|} \right)^{1/(m-1)}}, \quad i = 1, 2, \dots, c; j = 1, 2, \dots, n \quad (4.16)$$







Denklem 4.15 ve 4.16'daki denklemler analitik olarak çözülemez. Bununla birlikte, FCM algoritmasında amaç fonksiyonun minimum olması için iteratif yaklaşımlar yapılır. Bu iteratif yaklaşımda μ_{ij} ve v_i değerleri hesaplanarak minimum amaç fonksiyonu bulunur. Algoritmanın başında c küme sayısı, m bulanıklık değeri, ε iterasyon kriteri olarak sabit değerlerinin belirlenmesinden sonra, v_i küme merkezleri rasgele atanmaktadır. Her pikselin küme merkezi ile olan uzaklığı hesaplanarak üyelik değerleri bulunmaktadır. Üyelik değerleri bulunan piksellerin yeni küme merkezleri hesaplanmaktadır. Yeni bulunan küme merkeziyle bir önceki bulunan küme merkezi arasındaki fark hesaplanıp ε iterasyon kriteri ile karşılaştırılarak iterasyona devam edilir veya durulur. Algoritma ile sonunda, yeni üyelik değerleri ve bölüt merkezleri bulunmaktadır. Üyelik değerleri piksellerin hangi kümeye ait olduğunu kesin olarak belirlemek için kullanılmakta ve bölütlenmiş görüntüyü ortaya çıkarabilmek için her bir piksel

maksimum üyelik derecesine sahip olduğu kümeye atanmaktadır. FCM algoritması aşağıdaki verilmiştir;

- Küme sayısı c , m 'yi ve ε iterasyon kriteri seçilir ve başlangıç küme merkezleri atanır, $v^{(0)}$
- μ_{ij} 'yi hesapla, Denklem (4.16) ile μ_{ij} hesaplanır.
- $v^{(l+1)}$ değeri hesaplanır.
- $\Delta = \|v^{(l+1)} - v^{(l)}\|$, eğer $\Delta > \varepsilon$ ise $L=L+1$ yapılır ve ikinci adıma geri gidilir. Eğer $\Delta \leq \varepsilon$ ise iterasyon durdurulur.
- Piksellerin yeni üyelik değerlerine ve küme merkezlerine göre imge oluşturulur [3].


4.2.6 Bulanık c-ortalama görüntü bölütleme uygulaması

Her pikselin küme merkezlerine uzaklığının hesaplanarak pikselin yeni üyelik derecesine göre tekrardan küme merkezinin bulunması ile gerçekleştirilen bulanık c-ortalama işleminin sonucu Şekil 4.5'de görülmektedir. İmgedeki gürültünün bölütleme işleminin kalitesini azalttığı bir gerçektir. Gürültünün imgeden ayrıştırılması için bölütleme işleminden önce veya sonra değişik filtreler uygulanarak imgeden ayrıştırılması sağlanmaktadır. İmgenin gürültüden ayrıştırılması için medyan filtre kullanılmaktadır [1]. Medyan filtre, komşusu olan 8 pikselin ortalamasını pikselin yeni değeri olarak atamaya dayalı bir filtreleme işlemidir. Şekil 4.5 (b) medyan filtre uygulanmadan bulanık c-ortalama ile yapılan bölütleme uygulamasını göstermektedir. İmgeye bir kez medyan filtre uygulandıktan sonraki bölütleme işleminin sonucu, Şekil 4.5 (d)'de görülmektedir. Medyan filtre işlemi, gürültü ayrıştırılana kadar tekrarlanır. Tekrar sayısı imgenin orijinalliğini bozmayacak sayıda olmalıdır. Sırayla 2-3-4 kez medyan filtre uygulandıktan sonraki bölütleme işlemi Şekil 4.5 f, h, j'de görülmektedir. Şekil 4.5 (j) görüldüğü gibi medyan filtreden sonra gerçekleştirilen bölütleme işlemi, daha kaliteli bir sonuç vermiştir.

İmgeler	Bölütlenmiş İmgeler
	
(a)	(b)
	
(c)	(d)
	
(e)	(f)
	
(g)	(h)
	
(i)	(j)

Şekil 4.5. Bulanık c-ortalama uygulaması

Şekil 4.5’de iki küme merkezi kullanılarak yapılan bölütleme işlemi gösterilmiştir. Şekil 4.6’da ise, üç küme merkezi kullanılarak gerçekleştirilen bulanık c-ortalama ile bölütleme uygulaması verilmiştir.



Şekil 4.6. (a,c) Kanserli histopatolojik imgeleri (b,d) Bulanık c-ortalama ile bölütlenmiş imgeler

4.2.7. Shannon entropi ile bölütleme tekniği

Entropi kavramı, bir sistemin düzenliliğini ölçmek amacı ile termodinamik fiziğinde iyi bilinen bir kavramdır. Ayrıca, entropi kavramı bir olayın içerdiği bilginin ortalama miktarını ölçmek amacı ile de kullanılmaktadır. İmge işlemede yaygın olarak kullanılan entropi hesaplama türleri : Shannon, Norm, Eşik yöntemleridir [15]. Shannon Entropi ise en popüler entropi ölçülerinden biridir. Bilim, teknoloji gibi birçok alanda Shannon entropinin faydalı olduğu görülmüştür. $s_i = 1, 2, \dots, n$ ’e kadar olan bir olasılık sistemini göz önüne alalım. p_i , i . elemanın olasılık değeridir [25].

$$i = 1, 2, \dots, n \quad - \sum_{i=1}^n p_i = 1 \quad P_n = (p_1, p_2, \dots, p_n) \subset P$$

P sonlu kümedeki bütün olasılık dağılım kümesini gösterir.

$$H^1 s_n : P \rightarrow [0, \infty).$$

Ayrık olasılık dağılımı P_n için entropi tanımı denklem (4.17) den türetilir.

$$H^1 s_n = (P_n) = - \sum_{i=1}^n p_i \log p_i \quad (4.17)$$

Bütün entropi tanımları için log değeri $\log_2$ olarak alınmaktadır. $H^1 s_n$ 'in simetri, süreklilik, genişleyebilirlik gibi ilginç özellikleri vardır. İmge bölütleme için Denklem (4.18) de önemli bir özellik verilir.

$$H^1 s_n(p_1, p_2, \dots, p_n) \leq H^1 s_n\left(\frac{1}{n}, \dots, \frac{1}{n}\right) \quad (4.18)$$

Bütün $n \in \mathbb{N}$ için $H^1 s_n$ uniform dağılım için maksimum değer elde eder [25].

Entropi ölçüleri ile bölütleme algoritması

Literatüre bakıldığında örüntü-alt taban sınıflamasında entropi kriter olarak kullanılmaktadır [25]. s 'in eşikleme değeri olduğunu düşünülürse, s imgeyi iki parçaya böler. $[0, s]$ arası gri seviye değerleri alt tabanı temsil eder. $[s+1, l+1]$ gri seviye aralığı örüntüyü temsil eder. Bölütlenmiş imgenin Shannon entropisi Denklem (4.19) daki tanımlanmaktadır.

$$H^1(s) = - \sum_{g=0}^s \left\{ \frac{p(g)}{P_s} \log \frac{p(g)}{P_s} \right\} - \sum_{g=s+1}^{l-1} \left\{ \frac{p(g)}{1-P_s} \log \frac{p(g)}{1-P_s} \right\} \quad (4.19)$$



$p(g)$ gri seviye g 'nin meydana gelme olasılığıdır. $P_s = \sum_{g=0}^s p(g)$ $[0, s]$ aralığındaki gri seviye

değerlerinin meydana gelme olasılıklarının toplamıdır [25]. Bu olasılık değerleri kullanılarak imgede örüntü-alt-taban ayrımı gerçekleştirilmektedir.

4.2.8. Shannon entropi ile bölütleme uygulaması

Shannon Entropi yöntemi ile imgeyi en iyi bölütleyecek eşik değerini bulmak esastır. Shannon Entropide imge önce gri seviyeye dönüştürülür. Gri seviyeye dönüştürülen imgenin histogramı elde edilir. İmgenin histogramı kullanılarak her pikselin olasılığı belirlenir. Bütün piksellerin olasılıkları belirlendikten sonra Denklem (4.19) kullanılarak imgeyi bölütleyecek en iyi eşikleme değeri elde edilir. Elde edilen bu eşikleme değeri kullanılarak imge

bölütlenmektedir. Shannon Entropi yöntemi eşikleme değeri seçiminde oldukça iyi sonuçlar vermektedir. Şekil 4.7’de Shannon Entropi yöntemi kullanılarak gerçekleştirilen bölütleme uygulamalarının sonuçları görülmektedir.

İmgeler	Bölütlenmiş İmgeler
	
(a)	(b)
	
(c)	(d)

Şekil 4.7. Shannon entropi kullanılarak histopatolojik imgede gerçekleştirilen bölütleme uygulaması


Shannon Entropi yöntemi ile gerçekleştirilen bölütleme işleminde Şekil 4.7 (a)’daki imgenin eşikleme değeri 110, Şekil 4.7 (c)’deki resmin eşikleme değeri 125 olarak bulunmuştur.

4.2.9. Kohonen ağları imge bölütleme tekniği


Kendi kendini düzenleyen öznitelik haritaları, eğitici olmayan durumda giriş örüntülerinin analizi ve kodlanması için otomatik bir yöntemden meydana gelen yapay sinir ağlarıdır. Kendini düzenleme algoritması, beyinde bulunan haritalara benzer. Beyindeki duyu yollarının önemli bir düzenleme prensibi, nöronların yerleşmesinin sıralı olması ve algılanan dış uyarının bazı fiziksel özelliklerini yansıtmalarıdır. Mesela, duyma yolunun her seviyesinde, sinir hücreleri ve fiberler, belli frekanslara en yüksek cevabı veren nöron dikkate alınarak anatomik yapıda düzenlenmiştir. Duyma yolundaki bu düzenleme, beynin duyma kabuğuna

kadar gitmektedir. Beyinde alt seviye düzenlemesinin büyük bir kısmı genetik olarak önceden belirlenmiş olmasına rağmen, daha yüksek seviyedeki düzenlemenin bir kısmının kendi kendini düzenlemeyi sağlayan algoritmalar tarafından, öğrenme esnasında meydana geldiği düşünülmektedir. Kohonen, beyindekine benzer, kendi kendini düzenleme öznelilik haritası adını verdiği bir ağ modeli sunmuştur [27].

Kohonen yapay sinir ağının, giriş verisinin bir haritasını gösterdiği söylenebilir. Bu yapay sinir ağında yapısal olarak benzer girişler, yapısal olarak birbirine yakın çıkışlar üretir. Kohonen algoritması, yarışmacı öğrenme algoritması olarak da adlandırılır. Yarışmacı öğrenme, giriş örüntü setini sınıflandırmak için kullanılabilen belirgin ve genel özellikleri keşfetmek için bir yol sağlar. Yarışmacı kategoriye bağlı öğrenme kurallarının hepsinde ortak özellik, bir yarışma stratejisinin işlem elemanlarının tamamına veya bir kısmına uygulanmasıdır. Bu yarışma sonucu, kazanan işlem elemanının ağırlıkları değiştirilir. Basit işlem elemanlarından oluşan Kohonen yapay sinir ağı, Şekil 4.8'de gösterildiği gibidir. Burada N çıkış işlem elemanı ($z_1, z_2, \dots, z_N$) sayısı, $x_i = (x_1, x_2, \dots, x_n)$ n boyutlu giriş örüntü vektörü, $w_i = (w_{i1}, w_{i2}, \dots, w_{in})$ her çıkış işlem elemanının ağırlık vektörü olup, w_{ij} ise x_j girişi ile i . işlem elemanı arasındaki ağırlıktır. Ağırlık vektörünün başlangıç değerleri keyfi seçilebildiği gibi, ilk giriş örüntü vektörü ağırlıklar olarak da alınabilir. Temelde Kohonen yapay sinir ağı, her çıkış birimine (bu birimlere sınıf da diyebiliriz) giriş vektörünün bir elemanının bağlanması ile meydana gelir. Böylece farklı çıkış birimleri farklı girişlere duyarlı hale gelebilir. Kohonen yapay sinir ağının yapısal sistem modeli Şekil 4.9'da gösterilmiştir. Şekilde de görüleceği üzere Kohonen yapay sinir ağı giriş ve çıkış gibi iki katmanına sahiptir.



Şekil 4.8. Kohonen 'in kendi kendini düzenleme haritasının ağ birimleri




Şekil 4.9. Kohonen sistem modeli

Giriş örüntüleri doğal nesnelerin gözlenmesinden türetildiği için, giriş örüntü vektörü ayrık zamanda $x = x(t)$ olarak formüle edilir. Buna karşılık $w_i(t)$ ise farklı işlem elemanlarının zamana bağlı değişken ağırlık vektörleridir.


Bir biyolojik sinir sisteminin dış uyarıya cevabı, tek bir sinir hücresi üzerinde yoğunlaşmış olmasına rağmen, çok sayıda geri besleme bağlantısından oluşan oldukça karmaşık etkileşimler ile belirlenir. Yani komşu sinir hücreleri arasında yerel bir etkileşim söz konusudur.

Benzer şekilde Kohonen yapay sinir ağına, gelen giriş örüntü vektörüne cevabı, çıkış katmanındaki herhangi bir işlem elemanı üzerinde yoğunlaşmış olmasına rağmen, fazla sayıda geri besleme bağlantısı sonucu oluşan etkileşimler ile sistemin çıkışı belirlenir. Komşu işlem elemanları arasında yerel bir etkileşim vardır. En yakın komşular birbirini pozitif yönde etkilerken, birbirinden uzak komşuluktaki işlem elemanları birbirini negatif olarak etkilerler. Bu tip etkileşime "meksika şapkası fonksiyonu" denir (Şekil 4.10).



Şekil 4.10. Meksika şapkası fonksiyonu

Kohonen yapay sinir ağı, iki boyutlu bir yapıya sahiptir. İki boyutlu ağ içindeki etkileşimlerin yapısı, hangi işlem elemanlarının komşu olduklarını belirler. Ağırlık vektörünün başlangıçtaki keyfi dağılımı, giriş örüntü vektörlerinin ağ tarafından öğrenilmeye başlanması ile kendi kendine ayarlanır. Giriş örüntülerine karşı istenen en iyi cevabı veren işlem elemanı etrafında, bir $Nc(t)$ komşuluk kümesi oluşur. Bu komşuluk kümesi iki boyutlu düzlem üzerinde, dikdörtgen vb. yapılarda oluşabilir (Şekil 4.11).



Şekil 4.11. Bir işlem elamanının yapısal komşuluğu ($t_1 < t_2 < t_3$)

Herhangi bir çıkış işlem elamanının, verilen bir dairesel yarıçap ile bütün komşulukları belirlenebilir.

Kohonen 'in kendi kendini düzenleyen haritaları tarafından incelenen nesneler, x vektörü ile simgelenmektedir. Bu x vektörü, giriş örüntüsünün özniteliklerini içeren vektör olup, iki boyutlu düzlemsel çıkış uzayında haritalandırılır. Sonuçta benzer örüntüler iki boyutlu düzlemsel çıkış uzayında birbirine yakın yerlere yerleşirler. Böylece yapay sinir ağının öğrenme işlemi, eğiticişiz bir şekilde sağlanmış olur. Öğrenme gerçekleştirildikten sonra benzer giriş örüntülerinin, çıkış düzleminde birbirine yakın haritalandığı gözlenebilir. Buna karşılık birbirine benzemeyen giriş örüntüleri birbirinden uzağa haritalanırlar.

Aşağıda Kohonen'in kendi kendini düzenleyen öznitelik haritasını sağlayan algoritmanın işlem adımları verilmiştir :

- 1. adım :** N tane giriş düğümlerinden M tane çıkış düğümlerine olan ağırlıklar küçük rastgele değerlere ayarlanır ve komşuluğun ilk yarıçap (eşik) değeri belirlenir.
- 2. adım :** Yeni giriş uygulanır.
- 3. adım :** Girişin, tüm çıkış düğümlerine (sınıflara) olan mesafesi hesaplanır.

$$d_j = \sum_{i=1}^N (x_i(t) - w_{ij}(t))^2 \quad (4.20)$$

d_j : Giriş ile j . çıkış düğümü arasındaki mesafe,

$x_i(t)$: x giriş vektörünün i . elemanının t anındaki değeri,

$w_{ij}(t)$: i . girişten j . çıkış düğümüne olan ağırlığın t anındaki değerini göstermektedir.

- 4. adım :** Minimum mesafeye sahip çıkış düğümü belirlenir. En küçük d_j mesafesine sahip j . çıkış düğümü seçilir.

- 5. adım :** j . çıkış düğümüne ve komşularına ait ağırlıklar yeniden hesaplanır.

Yeni ağırlıklar;

- yarışmayı kazanan çıkış düğümleri için,

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) \cdot (x_i(t) - w_{ij}(t)), \forall i \in N_c(t) \quad (4.21)$$

- yarışmayı kaybeden çıkış düğümleri için,

$$w_{ij}(t+1) = w_{ij}(t), \forall i \notin N_c(t) \text{ olur.}$$






$\alpha(t)$: zamanla azalan bir kazanç terimi. ($0 < \alpha(t) < 1$)

$N_c(t)$: zamanla değişen komşuluk kümesi.

6. adım : 2. adıma gidilerek işlemler tekrarlanır [27].

4.2.10. Kohonen ağırları ile bölütleme uygulaması

Kohonen ağırları yapıları gereği, kaliteli bir bölütleme algoritması sunulmaktadır. İmgenin pikselleri giriş elemanları olarak kabul edilen sistemde piksellerin yani girişlerin her biri çıkışa yani sınıflara olan uzaklıkları hesaplanmaktadır. Mesafeler belirlendikten sonra minimum mesafeye sahip olan çıkış düğümü belirlenir. En küçük mesafeye sahip çıkış düğümü seçildikten sonra yeniden bu çıkışa ait ağırlıklar hesaplanır ve böylece bir yarışmacı stratejisi şeklinde olan Kohonen ağırları ile bölütleme işlemi gerçekleştirilir. Kohonen ağırları kullanılarak elde edilen bölütleme işlemi Şekil 4.12’de gösterilmektedir.

İmgeler	Bölütlenmiş İmgeler
	
	
	

Şekil 4.12. Kohonen Ağları ile histopatolojik imgelerin bölütlenmesi

4.3. Histopatolojik İmgelerde Alan Bulma

Bölüm 4.2’de histopatolojik imgelerin bölütlenmesi işlemi değişik yöntemler kullanılarak gerçekleştirilmiştir. Yapılan bu bölütleme işleminin bir sonraki adımı alan bulma işlemidir. Alan bulma bir örüntünün veya herhangi bir bölgenin alanını belirleme işlemidir. Alan bulma yöntemi kullanılarak imgeden elde edilen değerler ile imge hakkında yorumlar yapılabilmektedir. İmgenin yorumlanmasını kolaylaştıran alan bulma yöntemi ile örneğin; histopatolojik bir imgede kanserli bir doku alanının yüzde kaç oranında olduğu veya histopatolojik imgede kaç tane hücrenin kanserli hücre olduğunu tespit etmek gibi işlemlerde alan bulma yönteminden faydalanılmaktadır. Bilgisayar ortamında yapılan alan bulma işlemi


doktorlara veya bu konu ile ilgilenen kişilere, imgeyi yorumlamada zaman tasarrufu sağlayacaktır.

Alan bulma işlemindeki değerlerin gerçeğe yakın olması için, bölütlenmiş imgenin iyileştirilmesi gerekebilir. İyileştirilmesi gereken imgelere bazı filtreler veya morfolojik işlemler uygulanabilir. Bu şekilde gerçeğe daha yakın değerler elde edilebilecektir. Bu kısımda bölütleme işleminden sonra imgeye uygulanan açma-kapama işlemi anlatılmaktadır.

Açma-kapama işlemi

Açma (Opening) işlemi genellikle örüntü dış hatlarını yumuşatır, çıkıntıları yok eder. Kapama (Closing) işlemi ise dış hat bölümlerini yumuşatmaya meyillidir. Kapama işlemi genellikle dar açıklıkları birbirine kaynaştırır, küçük delikleri yok eder ve dış hatlardaki boşlukları doldurur. A kümesini B şekillendirme elemanı ile açma $A \circ B = (A \ominus B) \oplus B$ gibi ifade edilir. Böylece A 'yı B ile açma A 'nın B tarafından aşındırılmasıdır. Benzer şekilde A kümesini B şekillendirme elemanı ile kapama $A \bullet B = (A \oplus B) \ominus B$ gibidir. A 'yı B ile kapamak basit olarak A 'nın B tarafından genişletilmesidir. Açma işleminin geometrik olarak basit bir açıklaması vardır. B şekillendirme elemanını yuvarlanan bir top olarak düşünelim. $A \circ B$ 'nin sınırları B 'deki noktalar ile saptanır. B , A 'nın sınırları içerisinde en uzak noktaya kadar döndürülür. Açma işlemi geometrik şekline uyan teorik formülasyon kümesine yol gösterir. A 'nın B tarafından açılmasını ifade eden bu formülasyon A 'ya uyan bütün B dönüşümlerinin birleşimi olarak elde edilir. Açma işlemi aşağıdaki gibi ifade edilebilir [1].


$$A \circ B = \cup \{ (B)_z \mid (B)_z \subseteq A \}$$



Şekil 4.13. (a) A 'nın iç sınırları boyunca dönen B şekillendirme elemanı (b) Açma işleminin sonucu (c) Tamamlanmış açma işlemi


Kapamanın basit bir geometrik açıklaması vardır. B 'yi Şekil 4.14'un dışında yuvarladığımızı düşünelim. B 'yi, A 'nın sınırları dışında yuvarlama sonucunda topun A 'nın

yüzeyine temas etmediği yerlere kapama işlemi gerçekleştirilir. Şekil 4.14 kapamanın temel geometrik özelliğini gösterir.



Şekil 4.14. (a) A kümesinin dış sınırları boyunca yuvarlanan şekillendirme elemanı B **(b)** Kapama işleminin gerçekleştirileceği alan **(c)** Tamamlanmış kapama işlemi

Şekil 4.15 açma ve kapama işlemlerini gösterir. Şekil 4.15(a) A kümesini gösterir. Şekil 4.15(b) şekillendirme elemanı olan diskin erozyon işlemi boyunca çeşitli durumlarını gösterir. Şekil 4.15(c)'de B işlemi sonucu görülmektedir. Bu erozyon işlemi ile Şekil 4.15'deki iki ana parçanın birbirinden ayrıldığı görülmektedir. Bu iki ana parçanın birbirinden ayrılmasının sebebi, şekillendirme elemanının çapından küçük olmasıdır. Şekil 4.15(d)'de erozyona uğramış kümenin genişletilmiş şekli gösterilmektedir. Şekil 4.15(e) açma işleminin sonucunu göstermektedir.








Şekil 4.15. Açma-Kapama işleminin yapılışı

Benzer şekilde Şekil 4.15 (f) aynı şekillendirme elemanı ile A 'nın açma sonucunu gösterir. İçe bakan köşeler yuvarlanır. Dışa bakan köşeler ise değiştirilmez [1].

4.3.1. Histopatolojik imgelerde alan bulma uygulaması

Şekil 4.16(b)'de, denklem (4.19) Shannon Entropi yöntemiyle bulunan 120 eşikleme değeri ile eşiklenmiş imge görülmektedir. Şekil 4.16(c)'de ise bölütlenmiş imgenin açma-kapama işlemi ile iyileştirilmiş hali görülmektedir. İmgede de görüldüğü gibi iyileştirme işlemi

sayesinde imge pürüzlerden arındırılmış ve daha anlaşılır hale getirilmiştir. Bu aşamadan sonra, iyileştirilmiş imgedeki siyah noktalı pikseller sayılarak alan bulunmuştur.

İmgeler	Bölütlenmiş İmgeler	İyileştirilmiş İmgeler
		
(a)	(b)	(c) Alan=18966 piksel
		
(d)	(e)	(f) Alan=13667 piksel
		
(g)	(h)	(i) Alan=11938 piksel

Şekil 4.16. Alan bulma uygulaması



4.4. Histopatolojik İmgelerde Hücre Sayma

Hücre sayma işlemi basit bir matematiksel işlemdir. Hücre sayma işleminde amaç, işlenen imgede kaç tane hücre olduğunu belirleyip doktorun doğru teşhis sürecini hızlandırmaktır. Normalde hücre sayma işlemi elle yapılmaktadır. Yani mikroskop ortamından

fotoğraf makinesi yardımıyla alınan imgeler bu işle sorumlu kişiler tarafından tek tek sayılarak belirlenmektedir. Bu işle, işlem zamanını oldukça uzun sürmesi anlamına gelmektedir. Fakat geliştirilen bilgisayar ortamında yapılan hücre sayma işlemi, çok daha kısa sürede gerçekleşmektedir. Sürenin kısılması doğal olarak bakılan hasta sayısı gibi parametreleri etkileyeceğinden önemlidir. Geliştirilen hücre sayma yöntemleri şu adımlardan oluşmaktadır: Bölütleme, iyileştirme, alan bulma, bir hücrenin alanını bulma, toplam alanı bir hücrenin alanına bölme.

4.4.1. Histopatolojik imgelerde hücre sayma uygulaması

Geliştirilen hücre sayısı belirleme işleminde, belirli bir hata payı bulunmaktadır. Bunun nedeni imgedeki her hücrenin aynı büyüklükte olmamasından kaynaklanmaktadır. Bölütleme işleminden geçirilip daha sonra alan bulma işlemi ile alanı hesaplanan ve son olarak da hücre sayım işlemi yapılan Şekil 4.17'deki histopatolojik imgede toplam 58 tane kanserli hücre bulunduğu hesaplanmıştır. Doktor tarafından gözetlenen gerçek hücre sayısı ise 62 tanedir. %6.5 oranındaki hatanın teşhis aşamasında tolere edilebilecek bir hata oranı olduğu uzmanlar tarafından belirtilmiştir. Gerçek hücre sayısı tek tek sayarak belirleme işlemi 5 dakika sürmüştür. Fakat bilgisayar ortamında yapılan sayma işlemi ise birkaç saniye almıştır.

Histopatolojik İmge	Hücre Sayısı (Geliştirilen Yöntem)	Hücre Sayısı (Doktor)
 (a)	58	62
 (b)	170	185

Şekil 4.17. Geliştirilen yöntemin kıyaslaması

4.5. Histopatolojik İmgelerde Sınıflandırma

Gerçekleştirilen bölütleme, alan bulma ve hücre sayma işleminden sonra en son aşama ise imgelerin sınıflandırılması işlemidir. Sınıflandırma işlemi, imgeleri belirlenen değerlerine göre hangi gruba ait olduğunun belirlenmesidir. Bu işlem, bilgisayarın karar vericilere imgedeki hücrenin ne tip bir hücre olduğunu söylemesi işlemidir. Sınıflandırma işlemleri için çok farklı sınıflandırıcılar kullanılmaktadır. Bunların en çok kullanılanları YSA, Bulanık mantık, Karar Ağaçları gibi sınıflandırıcılardır [7, 10]. Bu bölümde, fractal analiz ve karar ağaçlarına dayalı geliştirilen sınıflandırma işlemini içeren karar destek sistemi sunulmuştur.









4.5.1. Fractal analiz

Fractallar, Öklid geometrisi kullanarak tanımlamanın imkânsız olduğu çoğu doğal yapıların biçimlerini karakterize etmek için kullanılan düzensiz geometrik yapılardır. Fractal boyut, çoğu medikal doku özelliklerini yorumlamakta kullanılan özellik aracıdır. Kanseri ve normal hücreleri nicel ölçülerinin benzerliğine dayalı olarak kullanılan fractal boyut yeni bir fıkirdir [7]. Bununla birlikte doğal şekil ve nesneler tam olarak aynı biçimde gösterilemez. Fakat onlar, boyut olarak küçültüldüğü zaman oldukça benzer görünürler. Kutu sayma boyutu öz-benzerlik (self-similarity) boyutları ile ilgilidir ve birçok durumda aynı sayıyı verir. Benzer yapılarda ölçeklendirme faktörü r ve kutu sayısı $N(r)$ arasında Denklem 4.22'deki gibi bir ilişki vardır [7-10, 23, 24].

$$D_f = \frac{\log(N(r))}{\log(1/r)} \quad (4.22)$$

İmge r ölçeklendirme faktörüne bölünür ve aynı özellikte olan kutu sayıları sayılır. Ölçeklendirme faktörü r küçültülerek işlem devam ettirilir [7]. Bu süreçte her r değeri için, kutu sayıları belirlenir. r ölçeklendirme faktörünün kutu sayılarına göre grafiği çizdirilir. Grafikten elde edilen eğim, imgenin fractal boyutunu verir.

Herhangi bir imgenin fractal boyutunu belirleyebilmek için bölütlenmesi gerekmektedir. İmgeyi bölütlemek için kullanılacak eşikleme değerini ise Shannon entropi yöntemi kullanarak elde edilmektedir. Elde edilen eşikleme değerlerine göre bölütlenen imgeler r ölçeklendirme faktörü ile bölümlere ayrılmaktadır ve daha sonra benzer olan kutu sayıları belirlenmektedir. Şekil 4.18'de fractal boyutu bulunan imgeler gösterilmektedir. Şekil 4.18'deki imgelerin denklem (4.19) Shannon Entropi kullanılarak elde edilen eşikleme değerleri Tablo 4.1'de gösterilmektedir.

İmgeler	Bölütlenmiş İmgeler
	
(a)	(b)
	
(c)	(d)
	
(e)	(f)
	
(g)	(h)

Şekil 4.18. Histopatolojik imgeler

. Tablo 4.2’de ise r ölçeklendirme faktörüne göre bölünen ve kutu sayıları belirlenen değerler gösterilmektedir.

Tablo 4.1. Eşik Değeri

İmgeler	Eşik Değeri
Şekil 4.18 (a)	110
Şekil 4.18 (b)	123
Şekil 4.18 (c)	115
Şekil 4.18 (d)	95
Şekil 4.18 (e)	138
Şekil 4.18 (f)	137
Şekil 4.18 (g)	119
Şekil 4.18 (h)	135

Tablo 4.2. İmgelerin kenar uzunluğu-kutu sayıları ve fractal boyutları

Ölçeklendirme								
Faktörü (r)	2	4	8	16	32	64	128	Fractal Boyut (D_f)
İmgeler	Kutu Sayısı $N(r)$							
Şekil 4.18 (a)	2919	1154	445	152	42	9	1	-0,0868
Şekil 4.18 (b)	3128	1214	463	161	42	9	1	-0,0861
Şekil 4.18 (c)	3278	1264	460	145	41	9	1	-0,0856
Şekil 4.18 (d)	2490	996	384	140	41	9	1	-0,0886
Şekil 4.18 (e)	1928	797	346	132	41	9	1	-0,0916
Şekil 4.18 (f)	1999	836	364	143	42	9	1	-0,0911
Şekil 4.18 (g)	1701	688	289	114	40	9	1	-0,0931
Şekil 4.18 (h)	1980	824	357	143	41	9	1	-0,0914

r ölçeklendirme faktörü ile kutu sayılarının birbirine göre grafiği çizdirilerek elde edilen eğim değerleri Tablo 4.2’de gösterilmektedir. Elde edilen eğim her imgenin fractal boyutunu göstermektedir.

Yukarıda da görüldüğü gibi histopatolojik imgelerin, fractal boyutu ile hepatitsiz hücrelerin fractal boyutları arasında oldukça açık olup, fark vardır. Bu fractal boyut değerleri kullanılarak histopatolojik imgenin hepatitli olup olmadığına karar verilmektedir.

4.5.2. Karar ağaçları

Karar ağaçlarında veriler oluşturulduktan sonra ağaca kökten yaprağa doğru inilerek kurallar (*IF-THEN rules*) yazılabilir. Bu şekilde kural çıkarma, veri madenciliği çalışmasının

sonucunun anlamlandırılmasını sağlar. Bu kurallar uygulama konusunda uzman bir kişiye gösterilerek sonucun anlamlı olup olmadığı denetlenebilir [26].


Karar ağacı temelli analizlerin yaygın olarak kullanıldığı sahalar,

- Belirli bir sınıfın muhtemel üyesi olacak elemanların belirlenmesi,
- Çeşitli vakaların yüksek, orta, düşük risk grupları gibi çeşitli kategorilere ayrılması,
- Gelecekteki olayların tahmin edilebilmesi için kurallar oluşturulması,
- Parametrik modellerin kurulmasında kullanılmak üzere çok miktardaki değişken ve veri kümesinden faydalı olacakların seçilmesi,
- Sadece belirli alt gruplara özgü olan ilişkilerin tanımlanması,
- Kategorilerin birleştirilmesi ve sürekli değişkenlerin kesikliye dönüştürülmesidir.

Karar ağacı temelli tipik uygulamalar ise,

- Hangi demografik grupların mektupla yapılan pazarlama uygulamalarında yüksek cevaplama oranına sahip olduğunun belirlenmesi,
- Bireylerin kredi geçmişlerini kullanarak kredi kararlarının verilmesi,
- Geçmişte işletmeye en faydalı olan bireylerin özelliklerini kullanarak işe alma süreçlerinin belirlenmesi,
- Tıbbi gözlem verilerinden yararlanarak en etkin kararların verilmesi,
- Hangi değişkenlerin satışları etkilediğinin belirlenmesi,
- Üretim verilerini inceleyerek ürün hatalarına yol açan değişkenlerin belirlenmesidir [26].

Böyle bir karar listesinin hazırlanması herhangi bir tıp uygulamasında önemli bir adımı oluşturur ve bu kurallara göre kolayca bir karar ağacı çizilebilir [30]. Bu şekilde hazırlanan kurallara göre bir karar algoritması bilgi kazanım kavramında bir karar ağacını oluşturur [29].



Şekil 4.19 Karar ağacı yapısı

Geliştirilen karar destek sisteminde, fractal analiz sonucunda elde edilen fractal boyut değerleri, bir kurallı ve iki kararlı yapıyı içeren karar ağacı yapısı ile imgelerin hangi sınıfa ait olduğu tespit edilmiştir. Fractal değerler, uzman kişi tarafından belirlenen değere göre sınıflandırıldığı zaman imgelerin sınıfları belirlenmiş olur. Yapılan çalışmalar sonucunda fractal boyutu -0,0900'den büyük olan imgeler hepatitli, histopatolojik imge, -0,0900'den küçük değerli olan imgeler ise hepatitsiz olarak sınıflandırılmaktadır. Sonuçlar Tablo 4.3'de görülmektedir. -0.0900 değeri ise, yapılan uygulamalar sonucu hekim görüşü dikkate alınarak bulunmuştur.

Tablo 4.3. Karar Ağaçları ile Sınıflandırma

İmgeler	Fractal Boyut	Sınıflandırma
Şekil 4.18 (a)	-0,0868	Hepatitli
Şekil 4.18 (b)	-0,0861	Hepatitli
Şekil 4.18 (c)	-0,0856	Hepatitli
Şekil 4.18 (d)	-0,0886	Hepatitli
Şekil 4.18 (e)	-0,0916	Hepatitsiz
Şekil 4.18 (f)	-0,0911	Hepatitsiz
Şekil 4.18 (g)	-0,0931	Hepatitsiz
Şekil 4.18 (h)	-0,0914	Hepatitsiz

BÖLÜM 5

5. SONUÇ VE DEĞERLENDİRME

Bu tez çalışmasında histopatolojik imgeleri değerlendirmeye yardımcı olacak, bölütleme, alan bulma, hücre sayma ve sınıflandırma yöntemler önerilerek, karar destek sürecini destekleyici bilgiler elde edilmiştir.

Sonuçların İrdelenmesi

1. Yapılan uygulamalarda, her imgenin aynı bölütleme tekniği ile bölütlenemeyeceği görülmüştür. Alt-taban ve nesne değerleri birbirine çok yakın imgelerde bölütleme işlemi yapılırken, kullanılan algoritmaların bazı hatalı değerler verdiği belirlenmiştir. Uygulamalarda dikkat çeken diğer bir kısım ise, bölütleme işleminde, yapılan yanlışlıkların alan bulma, hücre sayma ve sınıflandırma işlemlerinde etkili olduğu saptanmıştır.
2. Bölütleme işleminden sonra, alan bulma işlemi gerçekleştirilmektedir. Alan bulma işlemi, histopatolojik imgenin, dokunun yüzde kaçını kapladığını bulmada kullanılmaktadır. Bulunan değerler, hastalığın hangi aşamada olduğu konusunda karar vermede, karar vericiye sağlıklı bilgi sunmaktadır. Alan bulma işleminin, daha kaliteli olması için bölütlenmiş imgenin bazı filtreleme işlemlerinden geçirilmesi gerektiği anlaşılmıştır. Filtreleme yapılmadan gerçekleştirilen işlem basamaklarında bulunan değerlerin gerçek değerlerden uzaklaştığı saptanmıştır.
3. Hücre sayma işlemi, bilgisayar ortamında çok hızlı gerçekleştirilmektedir. Uzman kişilerin el ile sayma işlemi uzun zaman almaktadır. Geliştirilen yöntem ile sayma işlemi birkaç saniye sürmüştür. Örneğin, bir imgede, uzman kişinin belirlediği hücre sayısı 62 iken geliştirilen yöntemin bulduğu değer 58'dir. Burada %93.5 oranında bir doğruluk elde edilmiştir. Uygulamada yapılan %6.5'lik hatanın doktor tarafından tolere edilebilecek bir hata olduğu uzmanlar tarafından belirtilmiştir.
4. Sınıflandırma işlemi ile karar verme işlemi doğrudan bilgisayar tarafından yapılmıştır. Bu değerlendirme doktorlar için doğrudan bir karar sonucu değil, karar sürecine etki edecek bir bulgudur. Geliştirilen karar vericinin başarımı 40

histopatolojik imge üzerinde deęerlendirilmiř ve ortalama %91.5 başarı saęlanmıřtır.

Sonu olarak, tıbbi alanlarda imge rnt tanıma temelli geliřtirilen karar destek sistemleri ile histopatolojik imgelerin yorumlanmasında byk kolaylıklar saęlanacaktır. řyle ki; geliřtirilen byle bir bilgisayarlı imge rnts tanıma sisteminin yardımı ile imgelerin analiz ve sınıflandırılması sayesinde eřitli hastalıkların tanı bulma srelerinde doktoralara daha gvenilir ve saęlıklı veriler sunulması saęlanarak, tanı koymada nemli bir yardımcı unsur olarak karar destek sistemleri gerekleřtirilebilir. Bu sistemler, histopatolojik imgelerin deęerlendirmesinin yanı sıra, tıbbi alanda (mikrobiyoloji, biyokimya, v.s.) benzer imgelerin analizine de uygulanabilir.

Yayınlar

FBAP-985 (Fırat niversitesi Bilimsel Arařtırma Projeleri Birimi) nolu proje ile desteklenen bu tez alıřması, bir adet konferans yayını [31] ile sonulanmıřtır.

KAYNAKLAR

- [1] Gonzales, R. C., Woods R. E., Digital Images Prossesing, Prentical Hall, 2001
- [2] Talu, F., Görüntü Bölmeleme İşlemi İçin Klasik Ve Güncel Tekniklerin Karşılaştırılması, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2002.
- [3] Şengür, A., Sayısal Görüntü Bölütleme Teknikleri ve Uygulamaları, , Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Semineri, 2004.
- [4] Connolly, G. P., Cell imaging and morphology: application to studies of inherited purine metabolic disorders, Pharmacology & Therapeutics, 90, 267-281, 2001.
- [5] Kara, S., Şener, F., Okandan, M., Yıldırım, M., Patolojik doku örneklerinin bilgisayar tabanlı analizi, Sinyal İşleme ve İletişim Uygulamaları, 246-249, 2003.
- [6] Petersen, M.E., Arts T., Recognition of radiopaque markers in X-ray images using a neural network as nonlinear filter, Pattern Recognition Letters, 20(5), 521-533, 1999.
- [7] Esgiar, A. N., Sharif, B. S., Naguib, R. N. G., Bennett, M. K., Murray, A., Texture descriptions and classification for pathological analysis of cancerous colonic mucosa, Seventh International Conference on Image Processing And Its Applications, 1(13-15), 335-338, 1999.
- [8] Bauer, W., Mackenzie, C. D., Cancer detection via determination of fractal cell dimension, Pattern Formation and Solitons, IEEE, 9506003, 07/1995.
- [9] Esgiar, A. N., Naguib, R. N. G., Sharif, S., Bennett, M. K., and Murray, A., Fractal Analysis in the Detection of Colonic Cancer Images, IEEE Transactions on Information Technology in Biomedicine, 6 (1), 54-58, 2002.
- [10] Schüpp, S., Elmoataz, A., Fadili, J., Herlin, P., Bloyet, D., Image segmentation via multiple active contour models and fuzzy clustering with biomedical applications, 15th International Conference on Pattern Recognition Proceedings, 1(3-7), 622-625, 2000.
- [11] Adamsen, J. F., Digital image processing of satellite images and aerial photos, Journal of Applied Geophysics, 29(1), 63, 1992.
- [12] Pitas, I., Digital image processing algorithms and applications, John Wiley&Sons Inc., 2000.
- [13] Tatar, Y., BMÜ 537 İleri Sayısal Görüntü İşleme Ders Notları, Fırat Üniversitesi, 2004.
- [14] The MathWorks Inc. Image Processing Toolbox ,User Guide version 2, Matlab ver 5.3.
- [15] Türkoğlu, İ., Durağan olmayan işaretler için zaman-frekans entropilerine dayalı akıllı örüntü tanıma, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 2002.
- [16] Phan, F., Tzanakou, E.M. and Sideman, S., 2000, Speaker identification using neural networks and wavelets, IEEE Engineering in Medicine and Biology, 19(1), 92-101, 2000.

- [17] Türkoğlu, İ. ve Hanbay, D., Yapay sinir ağı ve HFD kullanarak DTMF sinyal örüntülerini tanıma sistemi, Elektrik-Elektronik-Bilgisayar Mühendisliği 9.Ulusal Kongresi, 431-434, Kocaeli, 19-23 Eylül 2001.
- [18] Duda, R.O. and Hart, P.E., Pattern Classification and Scene Analysis. Stanford Research Institute, 1989.
- [19] Özata, M., Aslan, Ş., Klinik Karar Destek Sistemleri ve Örnek Uygulamalar, Afyon Kocatepe Üniversitesi, Kocatepe Tıp Dergisi, 5 (1), 11-19, 2004.
- [20] Nedzved, A., Ablameyko, S., Pitas, I., Morphological segmentation of histology cell images, 15th International Conference on Pattern Recognition, 1(3-7), 500-503, 2000.
- [21] Ruberto, C. D., Dempster, A., Khan, S., Jarra, B., Segmentation of blood images using morphological operators, 15th International Conference on Pattern Recognition, 3(3-7), 397-400, 2000.
- [22] Avcı, E., Akıllı Radar ile Hedef Tanıma Sistemi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 2005.
- [23] Purintrapiban, U. and Kachitvichyanukul, V., Detecting Patterns in Process Data with Fractal Dimension, Computers and Industrial Engineering, 45 (4), 653-667, 2003.
- [24] Foroutan-pour, K., Dutilleul, P., Smith, D. L., Advances in the implementation of the box-counting method of fractal dimension estimation, Applied Mathematics and Computation, 105(2,3), 195-210, 1999.
- [25] Karmeshu, Entropy Measures, Maximum Entropy Principle and Emerging Applications, SpringerVerlag, Berlin Heidelberg, NewYork, 2003.
- [26] Doğan Ş., Veri Madenciliği ve Bioinformatik Uygulamaları, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Semineri, 2005.
- [27] Türkoğlu, İ., Yapay Sinir Ağları ile Nesne Tanıma, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 1996.
- [28] Yenerman, M., Genel Patoloji, Nobel Tıp Kitabevleri, İstanbul, 1994.
- [29] Kusiak A., Dixon B., Shah S. Predicting survival time for kidney dialysis patients: a data mining approach, Computers in Biology and Medicine, 35(4), 311-327, 2005.
- [30] Tan, K.C., Yu Q., and Lee T.H., Evolutionary Computing for Knowledge Discovery in Medical Diagnosis, Artificial Intelligence in Medicine, 27(2), 129-154, 2003.
- [31] Toraman, S., ve Türkoğlu, İ., Histopatolojik İmgelerin Akıllı Yapılar İle Bölütlenmesi, Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu, 81-84, İstanbul, 2006.
- [32] Bezdek, J. C., 1980. A Convergence Theorem for the Fuzzy ISODATA Clustering Algorithms, IEEE Transaction on Pattern Analysis and Machine Intelligence, pp.1-8.

EK-1

OLYMPUS C4000 Sayısal Kamera Özellikleri

- Çözünürlük: 4 Megapiksel (2048 x 1536)
- Arabirim bağlantıları : USB ve seri bilgisayar bağlantıları
- Zoom: 3x optik, 2x sayısal
- Otomatik ve manuel odaklama
- Hafıza tipi: Smart Media
- Hafıza: 16 MB
- CCD size : 1.8 inch
- LCD ekran size : 1.8 inch, TFT renkli
- Çözünürlük mod sayısı : 15
- Görüntü kayıt türleri : JPEG, TIFF
- Hareketli görüntü kayıt maksimum süresi: 60sn
- PC ve MAC uyumlu
- Doğrudan yazıcıya gönderebilme
- Yazılımlar: Adobe PhotoDeluxe, Enroute QuickStitch, Olympus Camedia Master
- İşletim Sistemi: Microsoft Windows 9x, XP
- 4 adet NiMH 2100mAh şarj olabilir AA Batarya
- Olympus BX-50 Mikroskobuna uyumlu.