

KARAR AĞAÇLARI VE FRAKTAL ANALİZ KULLANILARAK HİSTOPATOLOJİK İMGELERİN SINIFLANDIRILMASI

İbrahim TÜRKOĞLU ve Suat TORAMAN

Elektronik ve Bilgisayar Eğitimi Bölümü, Teknik Eğitim Fakültesi, Fırat Üniversitesi, 23119, Elazığ
iturkoglu@firat.edu.tr, sxtoraman@hotmail.com

(Geliş/Received: 11.10.2006; Kabul/Accepted: 24.08.2007)

ÖZET

Bu çalışmada, histopatolojik imgelerden çeşitli hastalıkların tanınması işleminde, hekime yardımcı olacak ve kolaylık sağlayacak bir karar destek sistemi tasarlanmıştır. Geliştirilen karar destek sistemi, örüntü tanıma temellidir. Örüntü tanıma sürecinin, özellik çıkarım aşaması Fraktal analiz ve sınıflandırma aşaması içinse karar ağaçları kullanılmıştır. Hepatitli hastaların histopatolojik imgeleri ile geliştirilen sistemin başarısı değerlendirilmiştir. 50 hasta verisi üzerinde geliştirilen sistemin doğruluk yüzdesi %92 olarak bulunmuştur.

Anahtar Kelimeler: Örüntü tanıma, histopatoloji, fraktal analiz, karar ağaçları, uzman sistem.

HISTOPATHOLOGICAL IMAGES CLASSIFICATION BY USING DECISION TREES AND FRACTAL ANALYSIS

ABSTRACT

In this study, a decision support system is designed which helps the physicians and facilitates their works for detection of various diseases from histopathological images. The developed decision support system is based on pattern recognition. The feature extraction stage of the pattern recognition system is realized by using fractal analysis and a decision tree classifier is used for classification stage. The performance of the proposed pattern recognition system is evaluated with the histopathological images which are taken from hepatic patients. The correct classification rate is 92 % for 50 patient's data.

Keywords: Pattern recognition, histopathology, fractal analysis, decision trees, expert system.

1.GİRİŞ (INTRODUCTION)

İmge(görüntü, resim), bir nesnenin sunumudur. İmge işleme ise bir imgeden başka bir imgenin elde edilmesi için kullanılan tekniklerin bütünüdür. İmge işleme teknikleri, imgenin insan veya bilgisayar tarafından anlaşılabilmesi yada yorumlanabilmesini sağlamak için kullanılır. İmge işleme, imge ile ilgili üç temel problemin çözümü için geliştirilmiştir [1]. Bunlar;

- Veri transferinin kolaylaştırılması için imge sayısallaştırma, kodlama ve depolama
- İmge zenginleştirme ve iyileştirme,
- Makine görmesinin ilk basamağını oluşturan imge bölütlemidir.

Bölütleme işlemi, imgedeki herhangi bir nesneyi veya imgenin herhangi bir parçasının arka plandan

ayrılmasıdır [2]. Bölütleme işleminin önemi, daha sonra yapılacak birçok imge işleme algoritmalarında kullanılmasından kaynaklanmaktadır. İmge bölütleme işlemi birçok alanda başarıyla uygulanmıştır ve literatürde kullanılan birçok yönteme rastlanmaktadır [3-8]. Bölütleme işlemi sonrasında gerçekleştirilecek sınıflandırma işlemi için, özellik çıkarımı yapılmaktadır. Fraktal Analiz yöntemi özellik çıkarma süreçlerinde kullanılmaktadır. Fraktal Analiz, Euclidean geometrisi kullanarak tanımlamanın imkânsız olduğu çoğu doğal yapıların biçimlerini karakterize etmek için kullanılan düzensiz geometrik yapılardır [9]. Fraktal analiz değişik alanlarda başarı ile uygulanmıştır. Tıp alanında dokularda oluşan kütleyi belirlemede [10], göğüs ultrason imgelerinin sınıflandırılmasında [11], yaşlı insanların kalp atış değişkenliğinin ve ölüm oranının belirlenmesinde [12] ve IP ağ trafiğinin analizinde [13] uygulamaları mevcuttur.

Örüntü tanıma tekniğinin diğer bir basamağı ise sınıflandırma işlemidir. Sınıflandırma işlemi, imgenin hangi gruba ait olduğunun belirlenmesi sürecidir. Kaliteli bir sınıflandırma işleminin yapılabilmesi, önceki adımların doğruluğuna bağlıdır. Bu nedenle, imge işleminin ilk aşamalarında yapılacak bir hata, imge sınıflandırma basamağının yanlış sonuç üretmesine neden olacaktır. İmge sınıflandırma işlemi birçok alanda başarı ile uygulanmıştır. Tıp alanında hücrelerin sınıflandırılmasında [6-14], kalp sinyallerinin sınıflandırılmasında [15], uydudan çekilen kent resimlerinin tanınmasında [16,17] kullanılmıştır.

Sınıflandırma işlemini için literatürde birçok yönteme rastlanmaktadır. Bu yöntemlerden birisi de karar ağaçları sınıflandırıcısı'dır. Karar ağaçları, öğrenme sürecinin ayrık değerli hedef fonksiyonunu tahmin etmek için kullanılan bir metottur [18].

Bu çalışmada, fraktal analiz ile özellik çıkarma ve karar ağaçları ile imge sınıflandırma uygulaması yapılmıştır. Uygulama için hepatitli histopatolojik imgeler kullanılmıştır. Bilgisayar ortamına aktarılan herhangi bir doku imgesinin hepatitli bir dokuya ait olup olmadığı imgenin fraktal boyutuna bakılarak tespit edilmektedir.

2. TEORİK BAKIŞ (THEORETICAL VIEW)


Bu bölümde, sunulan histopatolojik imgeleri sınıflandırma sistemi için teorik esaslar alt bölümler halinde verilmektedir.

2.1.Örüntü Tanıma (Pattern Recognition)

Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. Aslında, örüntü tanıma biliminin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarını insanların yaşantısında da görebiliriz: hava değişiminin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip birçok etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanınması, geçmiş tecrübelerine 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 disiplini [19].

Örüntü tanıma kavramı, Şekil 1. de gösterildiği gibi iki önemli birimden oluşmaktadır:

- **Özellik Çıkarma/Seçme:** İşaret ve görüntünün veri boyutunun indirgenmesi, tanımlayıcı anahtar özelliklerinin tespit edildiği ve aynı zamanda normalizasyona tabii tutulduğu aşamadır. Sistemin başarımında en etkili rolü oynar.
- **Sınıflandırma:** Çıkarılan özellik kümesinin indirgenmesi ve formüle edildiği tanımlayıcı karar aşamasıdır.



Şekil 1. Örüntü tanıma sistemi (Pattern recognition system)

2.2. Histopatolojik İmgeler (Histopathological Images)

Histopatoloji, doku ve organların doğal yapısında oluşan lezyonların mikroskopisini inceleyen bir bilim dalıdır [20]. Hızla gelişen teknolojiye tıp bilimi de faydalanmaktadır. Bilgisayar teknolojisinin, özellikle bazı işlemleri hızlı yapması ve zamandan tasarruf sağlaması önemini arttırmıştır. Tıbbi imgelerin sayısal ortama aktarılmasında, mikroskoplara bağlanan sayısal kameralar kullanılmaktadır. Mikroskop altında çekilen resimlere, histopatolojik imge denilmektedir. Histopatolojik imgelere literatürde, mide tahrişlerini tespit edilmesi [20], gözdeki damar çatlaklarını belirlenmesi [3] gibi çalışmalarda karşılaşılmaktadır.

2.3. Fraktal Analiz (Fractal Analysis)

Fraktallar, öklid geometrisi kullanarak tanımlamanın imkânsız olduğu çoğu doğal yapıların biçimlerini karakterize etmek için kullanılan düzensiz geometrik yapılardır. Fraktal geometrinin bir başka önemli özelliği de, fraktal boyut olarak adlandırılan bir matematiksel parametredir. Bu nesne kadar büyütülürse büyütülsün ya da bakış açısı ne kadar değiştirilirse değiştirilsin, hep aynı kalan fraktalların bir özelliğidir. Fraktal boyut, biçim, doku, sayı, renk, tekrarlanma, benzerlik, rassallık, düzenlilik ve heterojenlik gibi bir imgenin veya olayın özelliklerini tanımlamakta kullanılan tanımlayıcı özellikleri nicelleştirir [21]. Bu nedenle, fraktal boyut birçok medikal doku özelliklerini yorumlamakta kullanılan bir özellik aracı olmuştur [7].

En yaygın fraktal boyut hesaplama yöntemi olarak kutu sayma yöntemi kullanılmaktadır. Bu yöntemde şekil veya görüntü belirli bir büyüklükteki kutularla kaplanır. Kutuların farklı ölçükleri için her defasında şeklin bir parçasının bulunduğu kutu sayıları sayılır ve kutu ölçükleri ile dolu kutu sayılarına log-log en küçük kareler uygulanır. Bulunan denklemin eğimi fraktal boyut olarak tanımlanır. Kutu sayma yöntemi, öz-benzeşim boyutları ile ilgilidir ve birçok durumda aynı sayıyı verir. Benzer yapılarda ölçükendirme faktörü r ve kutu sayısı $N(r)$ arasında Denklem 1'deki gibi bir ilişki vardır.

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

İmge, r ölçeklendirme faktörüne bölünür ve aynı özellikte olan kutu sayıları sayılır. Ölçeklendirme faktörü r küçültülerek işlem devam ettirilir. Bu süreçte her r değeri için, kutu sayıları belirlenir. r ölçeklendirme faktörünün kutu sayılarına göre grafiği çizdirilir. Grafikten elde edilen eğim, imgenin fraktal boyutunu (D_f) verir [22].

Fraktal boyutun kullanımı, benzer veya farklı özelliğe sahip örüntülerin belirlenmesi açısından önemli kolaylıklar sağlamaktadır [23]. Bunlar;

- Fraktal boyut aşırı derecede duyarlı bir ölçüdür.
- Fraktal boyut eğer grafiğin şekli değişirse, aritmetik ortalama ve standart sapmanın sabit kaldığı durumlarda da değişir.
- Fraktal boyut yöntemi, diğer yöntemlere göre daha yüksek korelasyon katsayısına sahiptir.

2.4. Karar Ağaçları (Decision Trees)


Tahmin edici ve tanımlayıcı özelliklere sahip olan karar ağaçları, veri madenciliğinde kuruluşlarının ucuz olması, yorumlanmalarının kolay olması, veri tabanı sistemleri ile kolayca entegre edilebilmeleri ve güvenilirliklerinin daha iyi olması nedenleri ile sınıflama modelleri içerisinde en yaygın kullanıma sahiptir [24]. Karar ağacı temelli analizlerin yaygın olarak kullanıldığı sahalarda: belirli bir sınıfın muhtemel üyesi olacak elemanların belirlenmesi, çeşitli vakaların yüksek, orta, düşük risk grupları gibi kategorilere ayrılması, gelecekteki olayların tahmin edilebilmesi için kurallar oluşturulması ve parametrik modellerin kurulmasında kullanılmak üzere çok miktardaki değişken ve veri kümesinden faydalı olacakların seçilmesi. Karar ağaçlarını oluşturacak kuralların yapısal biçimi Tablo 1'de verilmiştir.

Burada her bir karar sınıfı Ω ile gösterilirken, Ψ ise her bir sınıfa ulaşan sonucu göstermektedir. Şekil 2'de karar ağacı yapısı görülmektedir.

Karar ağaçlarının, diğer sınıflama tekniklerine (yapay sinir ağı, bulanık mantık, Bayes tekniği, v.b.) göre en önemli üstün tarafı, bilgiden çıkarılan kuralın anlaşılır bir şekilde yazılabilmesidir. Ayrıca, karar ağaçlarının kuralları kesinlik belirtirken, diğerleri yaklaşımsal sonuçlar üretmektedirler [18].

Tablo 1. Kural üretme (Rule extraction)

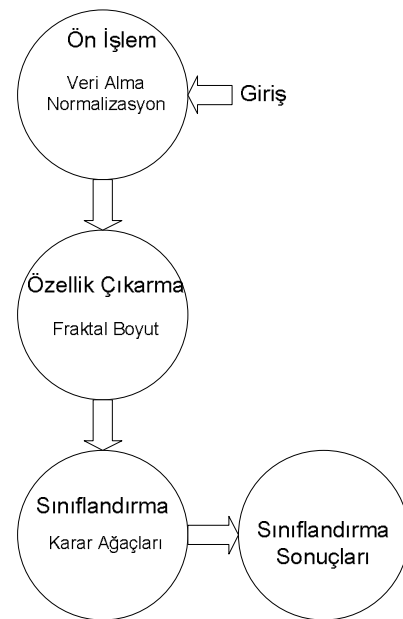
Eğer (kural1) ise (karar1)
Değilse (kural2) ise (karar2)
...
...
kural = <a1> ve ... ve <an>
karar = Ψ , $\Psi \in [\Omega_1 \dots \Omega_m]$



Şekil 2. Karar ağacı yapısı (Structure of decision tree)

3. Geliştirilen Yöntem (Developed Method)

Şekil 3'de geliştirilen histopatolojik imge örüntüsü tanıma sisteminin yapısı sunulmuştur. Geliştirilen yöntemin üç aşaması bulunmaktadır. Birinci aşamada, histopatolojik imgelerin alınması ve Shannon Entropi yöntemi ile bölütleme [25] tabi tutulduğu ön-işlem süreci bulunmaktadır. İkinci aşamada, histopatolojik imgelerin fraktal analiz ile karakterize edilmekte, özelliklerinin çıkarımı ve seçimi gerçekleştirilmektedir. Son aşamada ise, özellik çıkarma sürecinde elde edilen bilgiler ile birlikte uzman hekimin imge üzerindeki teşhis değerlendirmesi esas alınarak oluşturulan karar ağacı ile sınıflama yapılmaktadır.



Şekil 3. Histopatolojik imgeleri değerlendirme sistemi (The evaluation system of histopathological images)

Şekil 3'deki yapı esas alınarak önerilen sistemin her bir süreci için MATLAB bilgisayar ortamında (Ver. 5.3, The MathWorks Inc.) yazılımlar geliştirilmiştir.


3.1. İmgelerin Alınması (Image Acquisition)

Uygulamada kullanılan histopatolojik imgeler, Fırat Üniversitesi, Fırat Tıp Merkezi, Patoloji bölümünden alınmıştır. Bu histopatolojik imge örüntüleri, hepatitli hastalardan alınan karaciğer dokularının mikroskop altında çekilen resimleridir. İmgelerin alınmasında Olympus BX-50 ışık mikroskobuna bağlı, Olympus C-4000Z sayısal fotoğraf makinesi kullanılmıştır. Alınan sayısal imgelerin çözünürlük değerleri 2288x1712 piksel ve 72 dpi dir. Çözünürlük değerinin yüksek olması bölütleme işleminin daha iyi olmasını sağlamaktadır.

3.2. Özellik Çıkarma (Feature Extraction)


Özellik çıkarma örüntü tanıma sistemlerinin en önemli basamaklarından biridir. İmgenin tanımlayıcı anahtar özelliklerinin tespit edildiği ve aynı zamanda normalizasyona tabii tutulduğu aşamadır. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Histopatolojik imgeler için geliştirilen ön-işlem sürecini (1, 2 ve 3 adım) takiben özellik çıkarma yapısı aşağıdaki adımlardan oluşmaktadır.

Adım-1: İmge gri seviyeye dönüştürülür (Şekil 4).



Şekil 4. (a) Hepatitli İmge (Hepatitis image) (b)Hepatitsiz İmge (Non-hepatitis image)

Adım-2:Gri seviyedeki her pikselin olasılık değeri $p(g)$ belirlendikten sonra imgeyi bölütleyecek en iyi eşikleme değeri Shannon Entropi yöntemi Denklem 2 ile elde edilir [23] (Şekil 5).




Şekil 5. İmgelerin eşik değerleri (Threshold values of images)

$$H^1(s) = -\sum_{g=0}^s \left\{ \frac{p(g)}{P_s} \log \frac{p(g)}{P_s} \right\} - \sum_{g=s+1}^{l-1} \left\{ \frac{p(g)}{1-P_s} \log \frac{p(g)}{1-P_s} \right\} \quad (2)$$

Adım-3:Elde edilen eşikleme değeri kullanılarak imge bölütlenir (Şekil 6).

$$p(x) = \begin{cases} 0 & f(x, y) \leq H^1(s) \\ 1 & f(x, y) \geq H^1(s) \end{cases} \quad (3)$$



Şekil 6. Bölütlenmiş imgeler (Image segmentation)


Adım-4:Bölütleme işleminden geçirilen imgenin Fraktal boyutunu bulmak için, imge r ölçeklendirme faktörüne bölünür ve aynı özellikte olan kutu sayıları $N(r)$ sayılır. Ölçeklendirme faktörü r küçültülerek işlem devam ettirilir [8,22]. Her ölçeklendirme faktörü r değeri için kutu sayıları belirlenir (Tablo 2). Ölçeklendirme faktörü r ve $N(r)$ kutu sayısı değerleri belirlenen imgelerin Fraktal boyutlarını bulmak için Şekil 7'deki gibi grafiği çizdirilip Denklem (1)'de değerler yerine konularak fraktal boyut bulunur. Bu işlemler her imge için tekrarlanarak, imgelerin özellik çıkarımı gerçekleştirilir.

Tablo 2. Ölçeklendirme faktörü: r - Kutu sayısı: $N(r)$
(Scaling factor: r - Box number: $N(r)$)


r	2	4	8	16	32	64	128	Df
$N(r)$								
Hepatitli Şekil 7.a	2912	1157	447	153	42	9	1	-0,8688
$N(r)$								
Hepatitsiz Şekil 7.b	1928	797	346	132	42	9	1	-0,0915

3.3. Sınıflandırma (Classification)

Sınıflandırma işleminin amacı fraktal analiz kullanılarak elde edilen özellik çıkarım metodunun etkinliğini göstermektir. Bu amaçla özellik vektörü yardımı ile Şekil 4.'deki imgelerin hepatitli veya normal olarak Tablo 3 de verilen kural yapısına göre çalışan karar ağacı sınıflayıcısı ile sınıflandırılması gerçekleştirilmiştir. Sınıflandırma işlemi için 25 adet hepatitli ve 25 adet hepatitsiz imge kullanılmıştır. Sınıflandırma işleminin sonuçları, Tablo 4'de görülmektedir.



(a) Hepatitli imge (Hepatitis image)



(b) Hepatitsiz imge (Non-hepatitis image)

Şekil 7. Ölçeklendirme faktörü - Kutu sayısı grafiği
(Graphics of Scaling factor - Box number)

Karar kuralı çıkarmada fraktal boyutu karşılaştırmak için kullanılan -0.0900 değeri, uzman hekimin tanı bulguları sonucunda ortaya çıkan bir referans değeridir.

Tablo 3. Kural yapısı (Structure of Rule)

*Eğer (Df > -0.0900) ise (Ψ = Hepatitli)
Değilse (Ψ = Hepatitsiz)*

Tablo 4. Karar ağacı ile sınıflandırma (Classification with decision tree)

	Hepatitsiz	Hepatitli
Toplam Örnek Sayısı	25	25
Doğru Sınıflandırma	22	24
Yanlış Sınıflandırma	3	1
Ortalama tanıma yüzdesi %	88	96

4. SONUÇ VE DEĞERLENDİRME (RESULT AND EVALUATION)

Geliştirilen bu sınıflama yapısı ile insanların karaciğer dokularından alınan parçaların imgelerinin fraktal analizi ile bulunan fraktal boyutlarının, uzman hekimin tanı süreci içerisinde anlamlı bir bulgu olduğu ortaya çıkarılmıştır. Bu amaçla, fraktal analiz sonuçları ile hekim tanı bulgusu ışığında teşhise yön verecek kurallar bulunarak, karar ağacının yapısı içerisinde yerleştirilmiştir.

Tıbbi alanlarda örüntü tanıma temelli olarak geliştirilen imge değerlendirme sistemi ile histopatolojik imgelerin yorumlanmasında büyük kolaylıklar sağlanacaktır. Şöyle ki; böyle bir bilgisayarlı imge örüntüsü değerlendirme sisteminin yardımı ile imgelerin analiz ve sınıflandırılması sayesinde çeşitli hastalıkların tanı bulma süreçlerinde hekimlere daha güvenilir ve sağlıklı veriler sunulması sağlanarak, tanı koymada önemli bir yardımcı unsur olarak karar destek sistemleri gerçekleştirilebilir. Geliştirilen bu sistem ile histopatolojik imgelerin değerlendirilmesinin yanı sıra, tıbbi alanda (mikrobiyoloji, biyokimya, v.s.) benzer imgelerin analizine de uygulanabilecektir.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Histopatolojik imgeleri bize sağlayarak değerlendirmesine yardımcı olduğu için Prof. Dr. İbrahim ÖZERCAN'a (Fırat Üniversitesi, Fırat Tıp Merkezi, Patoloji Bölümü) teşekkür ederiz. Bu çalışma Fırat Üniversitesi tarafından desteklenmiştir (Proje No: FÜBAP-985).

KAYNAKLAR (REFERENCES)

1. Pitas I., **Digital image processing algorithms and applications**, John Wiley&Sons Inc., 2000.
2. Gonzalez R.C., Woods R.E., **Digital image processing**, Prentice Hall, 2002.
3. Giansanti R., Fumelli P., Passerini G., et al., "Imaging system for retinal change evaluation", **IPA97 Conference**, Pub.No. 443, 1997.
4. Kara S., Şener F., Okandan M., et al., "Patolojik doku örneklerinin bilgisayar tabanlı analizi", 246-249, **SIU**, 2003.
5. 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, May, 1999.
6. Esgiar A.N., Sharif B.S., Naguib R.N.G., et al., "Texture descriptions and classification for pathological analysis of cancerous colonic mucosa", **7th International Conference on Image Processing And Its Applications**, 1(13-15), 335-338, 1999.
7. Bauer W., Mackenzie C.D., "Cancer detection via determination of fraktal cell dimension", **Pattern Formation and Solitons**, 9506003, 07/1995.
8. Esgiar A.N., Naguib R.N.G., Sharif S., et al., "Fraktal Analysis in the Detection of Colonic Cancer Images", **IEEE Transactions on Information Technology in Biomedicine**, 6(1), March 2002.
9. Tzanakou E.M., **Supervised and unsupervised pattern recognition**, CRC Press LLC, 2000.
10. Rangayyan R. M., Nguyen T. M., "Pattern classification of breast masses via fraktal analysis of their contours", **International Congress Series**, 1281, 1041-1046, 2005.

11. Chen D., Chang R., Chen C., et al., "Classification of breast ultrason images using fraktal feature", **Journal of Clinical Imaging**, 29, 235-245, 2005.
12. Hotta N., Otsuka K., Murakami S., et al., "Fraktal analysis of heart rate variability and mortality in elderly community-dwelling people – Logitudinal Investigation fort he Longevity and Aging in Hokkaido County (LILAC) study", **Biomedicine & Pharmacotherapy**, 59, 45-48, 2005.
13. Masugi M., "Multi-fraktal analysis of IP-network traffic based on a hierarchical clustering approach", **Communications in Nonlinear Science and Numerical Simulation**, 12(7), 1316-1325, 2006.
14. Huang K., Murphy R.F., "Automated classification of subcellular patterns in multicell images without segmentation inti single cells", **IEEE Transactions on Medical Imaging**, 12(3), 478 – 485, 1993.
15. Türkoğlu İ., Arslan A., İlkay E., "Kalp kapak hastalıklarının teşhisi için bir karar destek sistemi", **Sakarya Üniversitesi, Fen Bilimleri Enstitüsü Dergisi**, 6(2), 57-64, Temmuz, 2002.
16. Dell'Acqua F., Gamba P., Trianni G., "Semi-automatic choice of scale-dependent features for satellite SAR image classification", **Pattern Recognition Letters**, 27, 244-251, 2006.
17. Gamanya R., De Maeyer P., De Dapper M., "An automated satellite image classification desing using object-oriented segmentation algorithms:A move towards standardization", **Expert Systems with Applicatons**, 32(2), 616-624, 2007.
18. Mitchell T.M., **Machine learning**, MIT press and the McGraw-Hill Companies Inc., Singapore, 1997.
19. Türkoğlu İ., Arslan A., ve İlkay E., "A pattern recognition system for diagnose of the heart mitral valve diseases based on wavelet packet and neural network", **Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi**, 14(1), 1-10, 2002.
20. Yenerman M., **Genel Patoloji**, Nobel Tıp Kitabevleri, İstanbul, 1994.
21. Herbert J.F., Cameron J.L., Matthew W.D., "Is There Meaning in Fractal Analysis?", **Complexity International**, 6, 1999.
22. Foroutan-pour K., Dutilleul P., Smith D.L., "Advances in the implementation of the box-counting method of fraktal dimension estimation", **Applied mathematics and computation**, 105, 195-210, 1999.
23. Gürsakal N., Oğuzlar A., Şentürk A., "Döviz Kuru Grafiklerinin Fraktal Boyutlarının Belirlenmesi", **III. Ulusal Ekonometri ve İstatistik Sempozyumu Bildirileri**, Bursa, 1997
24. Sugumaran V., Muralidharan V., Ramachandran K.I., "Feature selection using Decision Tree and classification through Proximal Support Vector Machine for fault diagnostics of roller bearing", **Mechanical Systems and Signal Processing**, 21(2), 930-942, 2007.
25. Karmeshu, **Entropy Measures, Maximum Entropy Principle and Emerging Applications**, SpringerVerlag, Berlin Heidelberg, NewYork, 2003.