



Gri Seviyeli Eş-oluşum Matrisleri Kullanılarak Sayısal Mamogram Görüntüsünden Doku Özniteliklerinin Çıkarılması ve Yapay Sinir Ağı ile Kitle Tespiti

Using Gray Level Co-occurrence Matrices Obtaining Texture Features From Mammogram And Determination of The Mass Via Artificial Neural Network

Volkan Göreke¹, Esmâ Uzunhisarcıklı², Aysegül Güven³

¹ Cumhuriyet Üniversitesi Sivas Meslek Yüksek Okulu Bilgisayar Teknolojileri Bölümü vgoreke@cumhuriyet.edu.tr

² Erciyes Üniversitesi Kayseri Meslek Yüksekokulu Otomasyon Bölümü uzunhise@erciyes.edu.tr

³ Erciyes Üniversitesi Biyomedikal Mühendisliği aguven@erciyes.edu.tr

Özetçe

Meme kanseri göğüs hücrelerinden başlayan kötü huylu (malignant) tümördür. Mamogram, memenin düşük radyasyon kullanılarak elde edilen X-Ray görüntüsüdür. Mamogram görüntüsünden kitle tespitinde hekime yardımcı olmak amacıyla farklı teknikleri kullanan bilgisayar yardımıyla teşhis ve tespit

(Computer aided diagnosis-CAD) sistemleri üzerinde çalışmalar devam etmektedir. Bu sistemler; görüntü ön işleme (image preprocessing), görüntü iyileştirme, öznitelik çıkarma ve sınıflandırma olarak isimlendirilen temel aşamalara sahiptir. Mamogram görüntülerinden bilgisayar yardımıyla kitle tespitinde farklı mimarilere sahip yapay sinir ağları içeren sistemler kullanılabilir. Bu çalışmada MIAS veri tabanından alınan 218 adet görüntü kullanılmıştır. Görüntülerin 74'ü kitle (benign veya malignant) içermektedir. Bu görüntüler üzerinde ön işleme, görüntü iyileştirme, öznitelik çıkarma işlemleri yapılmış bu öznitelikler kullanılarak tasarlanan yapay sinir ağı ile kitle tespit edilmeye çalışılmıştır. Çalışmada Gri Seviye Eş Oluşum Matrisleri (Gray-Level Co-occurrence Matrices, GLCM) görüntüden öznitelik çıkarmak için kullanılmıştır. Elde edilen kontrast, homojenlik, enerji öznitelikleri kullanılarak ileri beslemeli yapay sinir ağı eğitimi ve test gerçekleştirilmiştir. Yapılan 10 teste ait sonuçların ortalaması alınarak başarımlar değerlendirilmiştir. Başarımlar yaklaşık olarak duyarlılık için %96, özgüllük için %96 olarak bulunmuştur.

Abstract

Breast cancer is a malignant (cancer) tumor that starts from cells of the breast. A mammogram is an X-ray of the breast, using very low levels of radiation. In the mass detection, to assist physicians, studies that use different techniques are ongoing on the computer aided diagnosis systems (CAD). These systems have main phases that their names are image pre-processing (image preprocessing), image enhancement, feature extraction and classification. To determination of mass, in the computer aided diagnosis systems (CAD) can be used artificial neural networks that have different architecture. In this study, we used 218 images of mammogram that were obtained MIAS database. 74 images of total images contain mass (benign or malignant). Gray-Level Co-occurrence Matrices (GLCM) was used to obtain properties from these images. Using 3 texture features, these features are contrast, homogeneity, energy feed-forward neural network was trained and tested. We obtained sensitivity value %96 and specificity value %96.

1. Giriş

Meme kanseri göğüs hücrelerinden başlayan kötü huylu (malignant) tümördür [1]. Dünya sağlık örgütü raporlarına göre

meme kanseri geçen birkaç on yıl için dünyada kadınlar arasında önemli bir ölüm nedeni olmuştur. Kanser belirtileri düşük seviyeli radyasyon içeren X Ray kullanılarak elde edilen mamogram görüntüleri ile tespit edilebilir [2]. Mamografi günümüzde meme kanserinin tespitinde en çok kullanılan en güvenilir tekniktir [1].

Çok sayıda farklı tipte mamografik anormallik olmasına rağmen bu anormallikler çoğunluk olarak ya mikro kireçleme (micro-calcification) ya da kitledir (mass). Mikro kireçlemeler genellikle kümeler veya çapı yirmi ile birkaç yüz mikron arasında olan ayrı yapılar halinde görülebilir [3]. Kiteller göğüste lezyon içeren bir alandır [4] ve büyüklük, şekil, konum, kontrast gibi bulgularla ilişkili olarak karakterize edilir [3].

Son yıllarda radyolojik görüntülerin yorumlanmasında uzman hekime yardımcı olmak amacıyla bilgisayar hesaplamasına dayanan pek çok çalışma gerçekleştirilmiştir [5,8]. Bu bilgisayar yardımıyla tespit ve teşhis (Computer aided diagnosis-CAD) sistemleri modern tıpta uzman hekim için ikinci bir bilgi kaynağı ve meme kanseri gibi hastalıkların tanımlanmasında artan bir başarı oranı sağlamaktadır [5,6,9,10]. Danışmanlı öğrenme metodu kullanan yapay sinir ağları aday bölgelerin tümörlü (mass) kitle olarak sınıflandırılması için CAD sistemlerinde de kullanılan temel bir tekniktir [6].

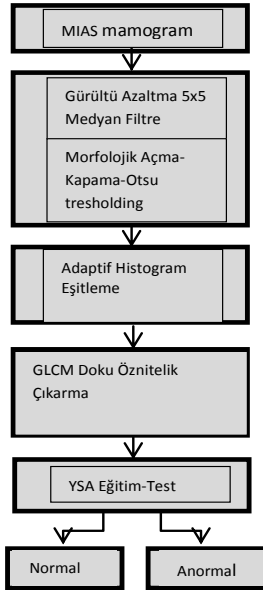
Bu çalışmada MIAS veri tabanından elde edilen 218 adet kitle (tümör) içeren ve normal olarak isimlendirilen tümör içermeyen mamogram görüntüleri üzerinde ön işleme, görüntü iyileştirme işlemleri gerçekleştirilmiş veri tabanında piksel koordinatları ile belirtilen kitle bölgelerinden ve normal görüntülerden rastgele seçilen 16x16 piksel boyutundaki alanların GLCM kullanılarak üç doku özelliği çıkarılmıştır. Bu öznitelikler kullanılarak kitle (benign veya malignant) tespiti için tasarlanan yapay sinir ağı (YSA) yapısı kullanılmıştır.

2. Materyal ve Metot

Çalışmaya ait işlem basamakları görüntü girişi, görüntü ön işleme, kontrast iyileştirme, öznitelik çıkarma, yapay sinir ağı eğitimi ve test aşamaları Şekil 1'de kullanılan yöntemlere bağlı olarak verilmiştir.

Biyomedikal Görüntü İşleme ve Yapay Zeka Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)




Şekil 1: Çalışmaya ait işlem basamakları

2.1 Görüntü Girişi

Bu çalışmada kullanılan görüntüler bilimsel araştırmalar için açık erişime sahip MIAS (An open access Mammographic Image Analysis Society) veri tabanından alınmıştır. Her bir görüntü 1024x1024 piksel ve azaltılmış 200 mikron piksel kalınlığına sahiptir.

Kitle içeren örnek bir görüntüye uygulanan her bir işlem basamağı sonucunda elde edilen görüntüler, işlem sırasına göre aşağıdaki şekiller ile verilmiştir.



Şekil 2: MIAS veri tabanından mdb015 isimli mamogram görüntüsü

2.2 Görüntü Ön İşleme

Görüntü ön işleme adımlarının amacı arka plan aşırı etkileri ortadan kaldırarak anormalliklerin aranma sürecini sınırlandırmak ve tespitini kolaylaştırmaktır [11, 7].


MIAS veri tabanından alınan görüntüler gürültü, etiket bilgisi ve sayısallaştırma gürültüleri (bazı düz çizgiler) içermektedir. İstenmeyen bu bileşenlerin görüntü üzerinden kaldırılması filtreleme ve morfolojik işlemler ile gerçekleştirilmiştir. Görüntü ön işleminin önemini göstermek için mdb015 görüntüsü üzerinde ön işlem uygulanmadan öz nitelik çıkarılmış ön işlem sonrasındaki elde edilen öz nitelik değerleri ile birlikte tablo 1'de verilmiştir. Ön işlem uygulanmadan elde edilen değerler yapay sinir ağı için kitle belirlenmesinde anlamlı veri grubunu oluşturmamaktadır.

Tablo 1: Ön işlemsiz ve ön işlemlili öz nitelik karşılaştırması

Mdb015	Kontrast	Homojenlik	Enerji
ön işlemsiz	0	1	1
ön işlemlili	0.0221	0.9890	0.9566

2.2.1 Medyan filtre

Yaygın olarak kullanılan istatistiksel bir filtredir ve komşu piksellerin sıralanıp ortadaki piksel değerinin medyan değeri olarak kullanılmasına dayanır [12]. Her çıkış pikseli giriş merkez pikselin 5x5 komşuluğunda bir medyan değeri içerir. Sayısallaştırma gürültüleri 2 boyutlu medyan filtre ile giderilmiştir [13]. Şekil 2 de verilen örnek görüntü için medyan filtre uygulama sonucu Şekil 3 de verilmiştir.




Şekil 3: Medyan filtre uygulanmış görüntü

2.2.2 Morfolojik işlemler-eşikleme (thresholding)

Morfoloji, nesne çıkarma ve gürültü kaldırma işlemleri için kullanılır. En temel morfolojik işlemler nesne kenarlarına piksellerin eklenmesi olan açma ve nesne kenarlarından piksellerin kaldırılması olan kapama işlemleridir [8]. Otsu'nun 1979'da tanıttığı yöntem gri ölçekli görüntünün piksel değerlerini 0 ve 1 olarak iki sınıfa ayırmak için optimum bir eşik değeri arar [14]. Görüntüye Otsu global eşikleme (thresholding) uygulanarak binary görüntüye çevrildikten sonra morfolojik açma kapama işlemleri ile etiket gibi istenmeyen bileşenlerden arındırılmıştır. Şekil 3 de verilen görüntü için global eşikleme sonucu şekil 4 de, şekil 4 de verilen görüntü için morfolojik işlem uygulama sonucu ise şekil 5 verilmiştir.



Şekil 4: Global eşikleme uygulanarak elde edilen binary görüntü



Şekil 5: Morfolojik işlemler uygulanmış görüntü

2.3 Kontrast İyileştirme


Kontrast iyileştirme işlemi kontrast sınırlı adaptif histogram eşitleme (contrast limited adaptive histogram equalization, CLAHE) tekniği kullanılarak gerçekleştirilmiştir.

Biyomedikal Görüntü İşleme ve Yapay Zeka Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

2.3.1 Kontrast sınırlı adaptif histogram eşitleme

Bu yöntemde pikseller, dört en yakın komşuları kullanılarak haritalanır. Bi-linear enterpolasyon ile alt bölgeler birleştirilirken, bölgeler komşuluklarına göre gruplara ayrılır. Bu yöntem hem görüntü azaltma işleminde hem de homojen alanlardaki kenar gölge etkilerini ortadan kaldırmak için medikal görüntüler üzerinde kullanılır [15]. Şekil 5 de verilen görüntü için adaptif histogram eşitleme uygulanmış görüntü şekil 6 ile verilmiştir.



Şekil 6: Adaptif histogram eşitleme uygulanmış görüntü

2.4 Öznitelik Çıkarma

Bu çalışmada Haralick doku öznitelikleri GLCM kullanılarak hesaplanmıştır. GLCM ikinci dereceden bileşik durum olasılık yoğunluk fonksiyonunun $P(i, j | d, \theta)$, tahminine dayanır. Bu matris pikseller arasındaki uzaklık d ve açı θ iken gri seviyesi i 'den gri seviyesi j 'ye geçme olasılığını gösterir [16]. Bu çalışmada görüntü tanımada iyi bir başarımlı sağlayan [17] $d=1$ ve $\theta=0$ parametreleri için enerji, kontrast ve homojenlik olmak üzere üç doku özelliği çıkarılmıştır.

Tablo 2'de ilk 5 öznitelik kitle içeren (hasta) görüntüler son 5 öznitelik ise kitle içermeyen (normal) görüntülere aittir. Şekil 7'deki görüntü MIAS veri tabanında belirtilen kitlenin merkez koordinatı başlangıç noktası seçilerek ve kitle içeren 16×16 boyutundaki alan kesilerek elde edilmiştir. Görüntüden çıkarılan kontrast, homojenlik, enerji doku özniteliklerine ait değerler tablo 2'nin ilk sırasında verilmiştir.



Şekil 7: MIAS veri tabanında belirtilen kitle koordinatlarına göre çıkarılmış 16×16 piksellik görüntüsünün büyütülmüş hali

2.4.1 Doku analizi

Doku analiz metotları medikal görüntülerin analiz ve yorumlanmasında kullanılmaktadır. Doku, piksel yoğunluğunun istatistiksel özniteliklerinin bir kümesidir. Farklı yerlerdeki iki farklı piksel arasındaki gri seviyesi farklılıkları karşılaştırılır [16]. Doku öznitelikleri eş oluşum matrislerine dayanan istatistiksel öznitelikler kullanılarak hesaplanabilir [18].

Gri seviye eş oluşum matrisi (Gray Level Co- Occurrence Matrices - GLCM) ikinci derece istatistiksel görüntü özniteliklerinin hesaplanmasında en iyi bilinen doku analizi araçlarından biridir. Bu doku öznitelikleri görüntü sınıflandırma ve segmentasyon amacıyla kullanılan Haralick doku öznitelikleri olarak bilinir [19]. Özniteliklere ait eşitlikler aşağıda verilmiştir.

Gri seviye eş oluşum matrisleri belli bir yönde ve aralarında belli bir uzaklık bulunan bir çift gri seviyeli pikselin birbirlerine göre oluşma sıklıklarını ifade eden matrislerdir. GxG gri seviyeli eş-oluşum matrisi P 'nin öteleme vektörü $d = (dx, dy)$ için eşitlik 4 ile tanımlanmaktadır.

$$\text{Enerji}, \sum_{i,j} p_{ij}^2 \quad (1)$$

$$\text{Kontrast}, \sum_{i,j} |i - j|^2 p_{ij} \quad (2)$$

$$\text{Homojenlik}, \sum_{i,j} \frac{p_{ij}}{1 + |i - j|} \quad (3)$$

$$p(x, y) = \left| \left\{ (r, s), (t, v) : I(r, s) = x, I(t, v) = y \right\} \right| \quad (4)$$

Burada I , $N \times N$ boyutunda ve G gri seviyeli bir görüntü $(r, s), (t, v) \in N \times N, (t, v) = (r + dx, s + dy)$ ve $| \cdot |$ ise kümenin boyudur.

Tablo 2: GLCM matrisinden elde edilen doku öznitelikleri

	Görüntü	Kontrast	Homojenlik	Enerji
Kitle1	Mdb015	0.0221	0.9890	0.9566
Kitle2	Mdb023	0.0588	0.9706	0.7722
Kitle3	Mdb090	0.0074	0.9963	0.9854
Kitle4	Mdb081	0.0221	0.9890	0.9284
Kitle5	Mdb206	0.0478	0.9761	0.7669
Normal1	Mdb003	0.2279	0.8860	0.3253
Normal2	Mdb014	0.2610	0.8695	0.3413
Normal3	Mdb043	0.2206	0.8897	0.2684
Normal4	Mdb123	0.2022	0.8989	0.2359
Normal5	Mdb234	0.2353	0.8824	0.3337


2.5 Yapay Sinir Ağı

Genel olarak yapay sinir ağı, ağı oluşturan nöron gibi birbirine bağlı basit işlem elemanlarının oluşturduğu bir bilgi işlem sistemi olarak düşünülebilir. Giriş katmanı, gizli (ara) katman ve çıkış katmanından oluşan yapay sinir ağı danışmanlı veya danışmansız öğrenme yoluyla beklenen çıkışları üretmek için global karmaşık davranışlar sergileyebilir. Biyolojik sinir sisteminden esinlenerek, öğrenme süreci nöronlar arasındaki bağlantı gücü veya ağırlıkları ayarlamaktır [6].

Bir nöronun temel yapısı teorik olarak şekil 8'deki gibi modellenilebilir. Burada $X \{x_i, i=1, 2, \dots, n\}$ nöron girişi, Y çıkışı ifade etmektedir. Her bir giriş ağırlığı ile çarpılır, bias değeri eklenir ve f transfer/aktivasyon fonksiyonuna giriş olarak aktarılır. Giriş ile çıkış arasındaki ilişki aşağıdaki eşitlik 5 ile ifade edilir. Medikal görüntü işlemede birkaç farklı mimaride yapay sinir ağı olsa da en çok kullanılan mimari bilgi akışı ileri yönde olan ileri beslemeli ağıdır (Feed-forward network) [20]. Güvenilir bir ağ yapısını oluşturulmasında yeteri kadar verinin olmadığı durumlarda çapraz doğrulama (cross-validation) tekniğine dayalı bir yöntem kullanılabilir [21].

Bu çalışmada özel bir ileri beslemeli yapay sinir ağı mimarisi olan çok katmanlı algılayıcı ağ (multilayer perceptron) yapısı kullanılmıştır. Tasarlanan yapay sinir ağı bir gizli katmana sahiptir. Gizli katman üç nöron, çıkış katmanı ise bir nörona oluşmaktadır. Gizli katmanın transfer fonksiyonu tanjant sigmoid, çıkış katmanı transfer fonksiyonu ise doğrusaldır. Öğrenme algoritması olarak Levenberg-Marquardt geri yayılım algoritması seçilmiştir. Ağın eğitiminde 10 fold çapraz doğrulama tekniği kullanılmıştır. Bu yöntemde veri 10 kümeye ayrılır her seferinde 1 küme test kalanlar eğitim için kullanılır. Bu şekilde 218 verinin tamamının testi yapılmıştır. Yapay sinir ağının 3 girişi görüntülere ait kontrast, homojenlik ve enerji doku özniteliklerinden oluşmaktadır. Bu özniteliklere bağlı olarak ağın çıkışı kitle içeren görüntüler için 1 sayısal değeri kitle içermeyen görüntüler için 2 sayısal değeri olarak belirlenmiştir.

$$Y = f \left(\sum_{i=1}^n w_i x_i + b \right) \quad (5)$$



Şekil 8: Bir nöronun temel yapısı

Biyomedikal Görüntü İşleme ve Yapay Zeka Uygulamaları

2. Gün 26 Eylül 2014 Cuma (14.45-16.15)

3. Uygulama ve Başarımlar

3.1 Test ve başarımlar ölçümü

Gerçekleştirilen testlere ait örnek bir grafik şekil 9 ile verilmiştir. Grafikte “o” sembolü veri seti içerisinde gerçekte kitle içeren ve kitle içermeyen görüntüleri ifade etmektedir. Yapay sinir ağının test işlemi sonucunda bu veriler üzerinde bulduğu sonuçlar ise “*” sembolü ile gösterilmektedir.


Gerçekleştirilen teste ait başarımlar ölçümü sistemin duyarlılığı ve özgüllüğü hesaplanarak yapılabilir. Duyarlılık ve özgüllük sırasıyla eşitlik 6 ve eşitlik 7 ile matematiksel olarak tanımlanır [22]. Eşitliklerde,

TP: Gerçekte kitle olup kitle olarak belirlenen olgulardır.

FN: Gerçekte kitle olup kitle olarak belirlenemeyen olgulardır.

FP: Gerçekte kitle olmadığı halde testin kitle dediği olgulardır.

TN: Gerçekte kitle olmayan test sonucunun da kitle değil dediği olgulardır.



Şekil 9: Yapay sinir ağı test grafiği

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (6)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (7)$$

Sonuç ve Yorum

Elde edilen sonuçlara göre yapay sinir ağı kullanımı özellikle CAD sistemleri için uygun bir yöntem olabilir. Burada sinir ağının girişi için daha fazla öznetelik ve daha fazla katmana sahip ağ mimarileri kullanılarak sadece kitle değil kitlenin benign veya malignant tip olup olmadığını da belirlenebilir.

Literatürde yer alan bir çalışmada mevcut iki ticari CAD sistemi olan ImageChecker sürüm 3.1 ve R2 Technology sürüm 8.3'e ait kitle tespiti için duyarlılık hesabı yapılmış sırasıyla %92.3 ve % 96.2 değerleri bulunmuştur [23]. Çalışmamızda yapılan 10 teste ait sonuçların ortalaması alınarak başarımlar değerleri hesaplanmıştır. Başarımlar değerleri yaklaşık olarak duyarlılık için %96, özgüllük için %96 olarak bulunmuştur. Çalışmamız, üzerinde yapılabilecek bazı düzenleme ve geliştirmeler ile ileride ticarileşebilir olduğu görülmektedir.

Kaynakça

- [1] González, Fabio A. ve Romero, E., *Biomedical Image Analysis and Machine Learning Technologies: Applications and Techniques*, IGI Global, USA, 2010
- [2] Agrawal, P. Vatsa, M. Singh, R. “Saliency based mass detection from screening mammograms”, *Signal Processing*, 99, 29–47, 2014
- [3] Oliver, A. Freixenet, J. Marti, J. Perez, E. Pont, J. Denton, E. Zwiggelaar R. “A review of automatic mass detection and

segmentation in mammographic images”, *Medical Image Analysis*, 14, 87–100, 2010

[4] Wei, C. H. Chenb, S. Y. Liub, X. “Mammogram retrieval on similar mass lesions”, *Computer Methods and Programs in Biomedicine*, 106, 234–248, 2012

[5] Sampaio, B W Diniz, M E Silva, A C Paiva, A C Gattlass, M “Detection of masses in mammogram images using CNN, geostatistic functions and SVM”, *Computers in Biology and Medicine*, 41, 653–664, 2011

[6] Ren, J. “ANN vs. SVM: Which one performs better in classification of MCCs in mammogram imaging”, *Knowledge-Based Systems*, 26, 144–153, 2012

[7] Dheeba, J. Singh, N. A. Selvi, S.T., “Computer-aided detection of breast cancer on mammograms: A swarm intelligence optimized wavelet neural network approach” *Journal of Biomedical Informatics*, 49, 45–52, 2014

[8] Mohameda, H. Mai S. Mabroukb, M. S. Sharawy, A., “Computer aided detection system for microcalcifications in digital mammograms”, *Computer Methods and Programs in Biomedicine*, 116, 226–235, 2014

[9] Gomez, S. Tabanera, M. R. Bolivar, A. V. Miranda, M. S. Mazo, A. B. Diaz, M. R. Miravate, P. M. Asturiano, E. L. Cacho, P. M. Macias, T. D. “Impact of a CAD system in a screen-film mammography screening program: A prospective study”, *European Journal of Radiology*, 80, 317– 323, 2011

[10] Tang, J. A. Rangayyan, R.M. Xu, J. El Naqa, I.E. Yang, Y. “Computer-aided detection and diagnosis of breast cancer with mammography: Recent advances”, *IEEE Transactions on Information Technology in Biomedicine*, 13, 236 – 251, 2009

[11] Maitra, I. K. Nag, S. Bandyopadhyay, S. K. “Technique for preprocessing of digital mammogram”, *Computer Methods and Programs in Biomedicine*, 107, 175–288, 2012

[12] Dhawan, A.P. Editor Akay, M., *Medical Image Analysis*, Wiley, J & Sons, Inc Canada, 2011

[13] Nixon, M. Aguado, A, *Feature Extraction & Image Processing*, Elsevier Ltd, UK, 2008

[14] Liu, C. C. Tsai, C. Y. Liu, j. Yu, C. Y. Yu, S. S.”, A pectoral muscle segmentation algorithm for digital mammograms using Otsu thresholding and multiple regression analysis” , *Computers and Mathematics with Applications*, 64, 1100–1107, 2012

[15] Maitra, K. I. Nag, S. Bandyopadhyay, S. K. “Technique for preprocessing of digital mammogram”, *Computer Methods and Programs in Biomedicine*, 107, 175–188, 2012

[16] Demirhan, A. Güler, I. “Özörgütlemeli Harita Ağları Ve Gri Düzey Eş Oluşum Matrisleri İle Görüntü Bölütleme”, *Gazi Üniv. Müh. Mim. Fak. Der.*, 25 No 2, 258–291, 2010

[17] Eleyhan, A. Demirel, H. “Co-occurrence matrix and its statistical features as a new approach for face recognition”, *Turk J Elec Eng & Comp Sci*, 19, 1, 2011

[18] Ramos, R. P. Nascimento, M. Z. Pereira, D. C. “Texture extraction: An evaluation of ridgelet, wavelet and co-occurrence based methods applied to mammograms”, *Expert Systems with Applications*, 39, 11036–11047, 2012

[19] Tahir, M. A. Bouridane, A. Kurugöllü, F. Amira, A.”, Accelerating The Computation Of Glcm And Haralick Texture Features On Reconfigurable Hardware”, *International Conference on Image Processing (ICIP)*, 2004, 2857–2860

[20] Jiang, J. Trundle, P. Ren, J., “Medical image analysis with artificial neural networks”, *Computerized Medical Imaging and Graphics*, 34, 617–631, 2010

[21] Saltan, M. Terzi, S. “Modeling deflection basin using artificial neural networks with cross-validation technique in backcalculating flexible pavement layer modül”, *Advances in Engineering Software*, 39, 588–592, 2008

[22] Islam, M. J. Ahmedi, M. Ahmed, M. A. S. “An Efficient Automatic Mass Classification Method In Digitized Mammograms Using Artificial Neural Network”, *International Journal of Artificial Intelligence & Applications (IJAA)*, 1, 1–13, 2010

[23] Kim, S. J. Moon, W. K. Kim, S. Y. Chang, M. J. Kim, S. M. Cho, N. “Comparison of two software versions of a commercially available computer-aided detection (CAD) system for detecting breast cancer”, *Acta Radiologica*, 52, 482 – 490, 2010