

Akciğer Bölgesinin Bölütlenmesinde Karmaşık Değerli Sınıflayıcıların Karşılaştırılması

Murat Ceylan^{1,*}, Yüksel Özbay¹ ve Osman Nuri Uçan²

¹ Selçuk Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 42075 Konya, Türkiye

² İstanbul Aydın Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 34295 İstanbul, Türkiye

* Corresponding author: mceylan@selcuk.edu.tr

Özet. Görüntü bölütleme, bilgisayar ile görü algoritmalarının en önemli adımıdır. Bir görüntüyü anlamlı bölümlere ayırmak olarak adlandırılan bölütleme sırasında yapılabilecek bir hata işlemin sonraki bölümlerine de artarak etki etmektedir. Bu çalışma ile akciğer bölgesinin bölütlenmesi için yeni bir yaklaşım olan karmaşık değerli sınıflayıcıların 3 tipi karşılaştırılmıştır. Bunlar; karmaşık-değerli yapay sinir ağı (KDYSA), karmaşık-değerli dalgacık yapay sinir ağı (KDDYSA) ve karmaşık dalgacık dönüşümü (KDD) ile kombine edilmiş KDYSA'dır. Bu yapılar, Akciğer Görüntüsü Veritabanı Konsorsiyumu'ndan alınan görüntüler kullanılarak test edilmiştir. Elde edilen sonuçlar, KDDYSA'nın %38.59 ortalama doğruluk oranı ile başarısız olduğunu ortaya koymuştur. Buna karşılık, KDYSA akciğer bölgesini %75.66'lık bir doğruluk oranı ile bölütleyebilmiştir. Çalışma sonucunda karşılaşılan en çarpıcı sonuç ise KDD-KDYSA yapısı ile elde edilmiş ve test görüntüleri %100'lük doğruluk ile bölütlenmiştir. Üstelik her bir görüntü için sadece 4,5 saniyeye ihtiyaç duyulmuştur. Sonuçlar akciğer bölgesinin bölütlenmesi işlemi için KDD-KDYSA'nın uygun olduğunu ortaya koymuştur.

Anahtar Kelimeler. Akciğer bölgesinin bölütlenmesi, karmaşık dalgacık dönüşümü, karmaşık-değerli yapay sinir ağı.

Abstract. Image segmentation is an important step in many computer vision algorithms. The objective of segmentation is to obtain an optimal region of convergence. Error in this stage will impact all higher level activities. In this study, three types of complex-valued classifier were compared to the segmentation of lung region. These classifiers are complex-valued artificial neural network (CVANN), complex-valued wavelet artificial neural network (CVWANN) and complex valued artificial neural network with complex wavelet transform (CWT-CVANN). To test the performance of the proposed systems, Lung Image Database Consortium (LIDC) dataset was used. Obtained results shown that lung region segmentation done using CVWANN and CVANN with worst accuracy rates as 38.59% and 75.66%, respectively. On the other hand, CWT-CVANN structure segmented lung region

Received July 6, 2010; accepted May 16, 2011.

Bu makale, 29-30 Nisan 2010 tarihlerinde Çankaya Üniversitesi'nin Ankara yerleşkesinde yapılmış olan 3. Çankaya Üniversitesi Mühendislik ve Teknoloji Sempozyumu'nda sunulan ve sadece geniş bildiri özeti bölümü hakem sürecinden geçerek bu sempozyum kitapçığında yayımlanan bir makalenin revize edilmiş şekli olup Sempozyum Değerlendirme Komitesi tarafından yayımlanmak üzere Çankaya University Journal of Science and Engineering dergisine gönderilmesi önerilmiş ve derginin bağımsız hakem değerlendirmeleri sonucunda yayıma kabul edilmiştir.

with 100% accuracy rate. Moreover, this structure required only 4.5 second per image for segmentation task. Thus, it is concluded that CWT-CVANN is a comprising method in lung region segmentation problem.

Keywords. Lung region segmentation, complex wavelet transform, complex-valued artificial neural network.

1. Giriş

Bölütleme işleminin genel amacı bir görüntüyü sınıflara ayırmak, özelliklerine veya karakteristiklerine bağlı olarak homojen alt kümelere bölmektir [1]. Medikal görüntüleme de bölütleme, özellik çıkartılması ve görüntüden sayısal değerlerin elde edilmesi vb. işlemler için oldukça önemlidir. Bölütleme aşamasında yapılacak hata görüntü işleme adımlarının ilerleyen bölümlerine artarak etki etmektedir.

Literatürde bölütleme tekniklerinin çok çeşitli türleri tartışılmıştır [2-5]. Bununla birlikte, bütün görüntü uygulamalarında geçerli olabilecek standart bir bölütleme tekniği mevcut değildir. Bölütleme teknikleri dört temel sınıfa ayrılabilirler:

- 1- Otomatik olmayan, yarı otomatik veya otomatik [6],
- 2- Piksel tabanlı veya alan tabanlı [7],
- 3- Düşük seviye bölütleme (eşikleme, alan geliştirme) veya model tabanlı bölütleme (özellik haritası teknikleri, dinamik programlama vb.) [8],
- 4- Klasik (eşikleme, kenar tabanlı vb. teknikler), istatistiksel, bulanık veya yapay sinir ağları (YSA) teknikleri [9].

Bu klasik metotlar karşılaştırıldığında, YSA tekniklerinin uygun bir donanım ile paralel işlem yapabilme, gürültü toleransı ve adapte edilebilirlik gibi avantajlara sahip olduğu görülmektedir.

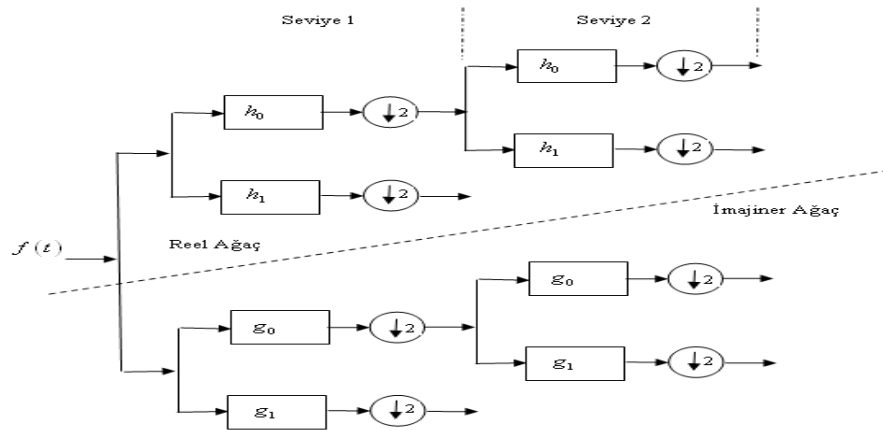
YSA'lar görüntü bölütleme de kullanıldığında piksel sınıflamayı temel alırlar [10-13]. Sha ve Sutton sayısal beyin görüntülerinin sınıflandırılması ve bölütlenmesi için bir YSA sistemi önermişlerdir [14]. Otomatik bölütleme için diğer bir YSA uygulaması ise Nattkemper *ve ark.* [15] tarafından gerçekleştirilmiştir. Hibrit YSA, hücresele YSA, bulanık kümeleme yaklaşımı, genel regresyon YSA gibi farklı YSA tipleri, çeşitli medikal görüntülere uygulanmıştır [16-22]. Dokur [23] ile Kurnaz *ve ark.* [24,25], manyetik rezonans (MR), bilgisayarlı tomografi (BT) ve ultrason görüntülerinin bölütlenmesi amacı ile kendi geliştirdikleri artırılmış YSA'yı uygulamışlardır. Bölütleme için kendinden-organizeli metodun kullanımı ise [26-27] tarafından önerilmiştir.

Bu çalışmada akciğer bölgesinin bölütlenmesi için önerilen KDYSA, karmaşık-değerli girişler, ağırlıklar, eşikler ve çıkışlara sahip bir tür YSA'dır. KDYSA, hem sinyal işleme alanında [28-30] hem de görüntü işleme alanında [30-32] farklı uygulamalara sahiptir.

2. Materyal ve Metot

2.1. Görüntü veri tabanı. Önerilen sistemlerin değerlendirilebilmesi amacı ile Akciğer Görüntü Veri Tabanı Konsorsiyumu (Lung Image Database Consortium-LIDC)'ndan alınan 20 görüntü kullanılmıştır [33]. Her bir BT diliminde yer alan görüntüler 512×512 piksel boyutuna sahiptirler. Her bir dilim 0.625 mm inceliğinde elde edilmiştir.

2.2. Karmaşık dalgacık dönüşümü (KDD). Ayrık dalgacık dönüşümü (ADD) oldukça geniş bir uygulama sahasına sahiptir. Sinyal ve görüntü sıkıştırma, özellik çıkarma, gürültü giderme, kanal kodlama, türbülans analizi, finansal analiz, kısmi diferansiyel denklemlerin nümerik çözümleri, dalgacık ağları uygulama alanlarına genel örnekler olarak verilebilir. ADD'nin bu denli geniş kullanım alanına sahip olmasına rağmen bazı "önemli" problemleri de barındırdığı görülmüştür. Bu problemler, değişim duyarlılığı, yönlülük eksikliği ve faz bilgisinin eksikliğidir [34, 35]. Belirtilen tüm bu problemlerin varlığı sebebi ile, N. Kingsbury [35] tarafından Dual-Tree Complex Wavelet Transformü (İkili-Ağaç Karmaşık Dalgacık Dönüşümü) ortaya atılmıştır (Şekil 1).



ŞEKİL 1. İkili-ağaç karmaşık dalgacık dönüşümü.

Şekil 1 incelendiğinde dönüşüm mimarisinin iki koldan oluştuğu görülmektedir. Üst kol, üst ağaç, reel kısmı ifade etmektedir. Alt kol, alt ağaç, ise imajiner kısmı ifade etmektedir. Şekilde 2. seviye için dönüşüm ağacı çizilmiştir. Her bir seviyede, sinyal (görüntü) boyutu 2'ye bölünmektedir. Sonuçta 2. seviyede elde edilmek istenen karmaşık sinyal,

$$S = h_0^{(2)}(n) + jg_0^{(2)}(n) \quad (1)$$

şeklinde yazılabilir. Şekil 1 ve Eşitlik (1)'de, 0 indisi ile alçak geçiren filtre çıkışı, 1 indisi ile de yüksek geçiren filtre çıkışı ifade edilmektedir.

2.3. Karmaşık değerli YSA (KDYSA). Bu bölümde, karmaşık geriye yayılım (KGY) algoritması çok katmanlı karmaşık değerli yapay sinir ağlarına (KDYSA) uygulanmıştır [36]. KGY algoritmasında, giriş sinyalleri, ağırlıklar, eşik değerleri ve çıkış sinyallerinin tamamı karmaşık sayılardan oluşmaktadır (Şekil 2). Nöronun Y_n aktif değeri şu şekilde tanımlanabilir:

$$Y_n = \sum_m W_{nm} X_m + V_n. \quad (2)$$

Eşitlik (2)'de, W_{nm} , n nöronu ile m nöronu arasındaki karmaşık değerli bağlantı ağırlığıdır. X_m , m nöronunun karmaşık değerli giriş sinyali ve V_n ise n nöronunun karmaşık değerli eşik değeridir.

Karmaşık değerli çıkış sinyalini elde edebilmek için Y_n aktif değeri, reel ve imajiner kısım olarak aşağıda gösterildiği gibi iki bileşene dönüştürülür:

$$Y_n = x + iy = z. \quad (3)$$

Burada i , $\sqrt{-1}$ değerini ifade etmektedir. Her bir nöronun çeşitli çıkış fonksiyonları göz önünde bulundurulduğunda, çıkış fonksiyonu aşağıdaki eşitlik kullanılarak tanımlanabilir:

$$f_C(z) = f_R(x) + if_R(y). \quad (4)$$

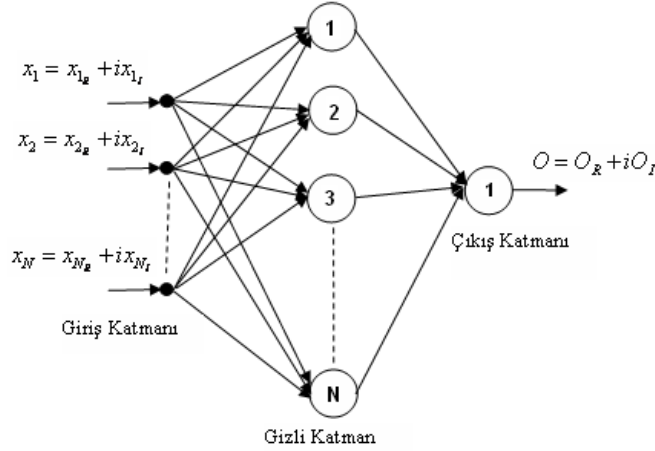
Burada,

$$f_R(u) = \frac{1}{1 + \exp(-u)} \quad (5)$$

genel ifadesi sigmoid fonksiyonu olarak adlandırılmaktadır [36].

Şekil 2 incelendiğinde de görülebileceği gibi KDYSA yapısı, karmaşık sayılar ile işlem yapan bir YSA modelidir. Bu modele göre KDYSA'ya giriş olarak karmaşık değere sahip vektörler verilmektedir. Giriş katmanı ile gizli katman ve gizli katman ile çıkış katmanı arasında yer alan ağırlık değerlerinin de karmaşık değerliklere sahip olması

ve (4)'de verilen eşitliğe uygun şekilde aktivasyon fonksiyonunun kullanılması ile karmaşık değerli çıkış vektörleri elde edilmektedir.



ŞEKİL 2. Giriş katmanı, gizli katman ve çıkış katmanı karmaşık değerli sayılardan oluşan örnek bir KDYS model.

2.4. Karmaşık değerli dalgacık YSA (KDDYSA). KDDYSA, KDYS'nın gizli katmanında aktivasyon fonksiyonu olarak logaritmik sigmoid yerine bir dalgacık fonksiyonunun kullanılması ile oluşturulmaktadır [37]. Çalışmada dalgacık fonksiyonu olarak Meksika Şapkası (Mexhat) dalgacık fonksiyonu kullanılmıştır ve bu fonksiyon aşağıdaki gibi tanımlanabilir:

$$\psi_{\text{Mexhat}} = (1 - ax^2)e^{-bx^2}. \quad (6)$$

Bu çalışmada Eşitlik (6)'da yer alan a ve b , sırasıyla 0.1 ve 2 olarak seçilmiştir.

KDDYSA'nın matematiksel modeli, Eşitlik (2)-(5)'e Eşitlik (6)'nın uygulanması ile elde edilmiştir.

3. Bölütleme Performansının Değerlendirilmesi

Medikal görüntü bölütleme çalışmalarında ortak problem, bölütleme sonuçlarının geçerliliğini değerlendirebilmek için bir metoda ihtiyaç duyulmasıdır. Sonuçların görsel olarak yorumlanması oldukça öznel bir değerlendirme olarak kalmaktadır. Bu çalışmada, akciğer bölgesi pikselleri ile akciğeri çevreleyen bölgeye ait pikselleri içeren görüntüler için KDYS'nın bölütleme (sınıflama) sonuçları Ceylan *ve ark.* [32] tarafından önerilen algoritma ile değerlendirilmiştir. Görüntünün bütünü (512×512

piksel) içerisinde doğru olarak sınıflanan piksellerin sayısı aşağıdaki algoritma ile hesaplanmıştır:

EĞER

$$I_H - I_C \leq 0.05$$

İSE,

Doğru sınıflanan piksel (DSP) sayısını 1 arttır,

DEĞİLSE,

Yanlış sınıflanan piksel (YSP) sayısını 1 arttır.

Burada, I_H ve I_C sırasıyla ağın hedefini ve KDYSA'ların elde ettiği sonuçları göstermektedir. Bu algoritmada I_H ve I_C arasındaki hata 0.05 olarak ifade edilmiştir. Bu hata ifadesi, ağın çıkışlarının '1'e (siyah-beyaz görüntünün beyaz kısmı) ve '0'a (siyah-beyaz görüntünün siyah kısmı) çok küçük hatalar ile yakınsamasından kaynaklanmaktadır.

Sonuç olarak, önerilen metotların doğruluk oranları (DO) aşağıdaki eşitlik ile belirlenmiştir:

$$\text{Doğruluk Oranı (\%)} = (\text{DSP}/(\text{DSP}+\text{YSP})) \times 100. \quad (7)$$

DSP ve YSP'lerin toplamı, piksellerin toplam sayısına eşittir ($512 \times 512 = 262144$).

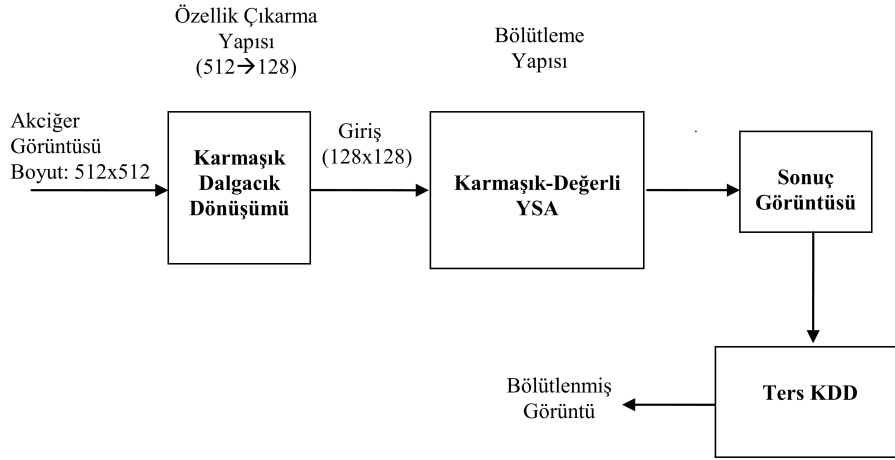
4. Sonuçlar

Bu çalışmada, akciğer bölgesinin bölütlenmesi amacı ile üç farklı KDYSA yapısı önerilmiştir: KDYSA, KDDYSA ve özellik çıkarıcı (KDD) ile karmaşık-değerli sınıflayıcı (KDYSA) içeren KDD-KDYSA.

KDYSA ve KDDYSA'nın kullanıldığı yapılarda, 512×512 boyutuna sahip akciğer görüntüleri ve bunların bölütlenmiş hedef görüntüleri herhangi bir ön işlem uygulanmadan kullanılmıştır. LIDC'den alınan 20 görüntüden 10 tanesi, ağların eğitime işlemleri için kullanılmış, geriye kalan ve ağın hiç görmediği 10 görüntü ile de sistem test edilmiştir.

KDD-KDYSA yapısında ise, KDYSA'nın performansını artırabilmek amacı ile akciğer görüntüleri iki seviyeli KDD'nden geçirilmiş ve elde edilen özellik vektörleri KDYSA'ya giriş olarak verilmiştir. Önerilen sistem Şekil 3'te gösterilmektedir. İki seviyeli KDD ile görüntü boyutları 512×512 'den 128×128 'e düşürülmüş ve bu özellik çıkarma bloğunun eklenmesi ile gerek KDYSA'nın giriş vektörünün boyutuna bağlı olarak işlem hızındaki değişim gerekse işlem doğruluğu, diğer yapılar ile

karşılaştırılmıştır. Optimum ağ yapıları deneysel olarak, öğrenme oranı için 1, gizli düğüm sayısı için 10 olarak elde edilmiştir. Tüm ağ yapıları en çok 10 iterasyon için çalıştırılmıştır. KDD-KDYSA yapısı ile test aşaması sona erdiğinde 128×128 boyutunda elde edilen sonuç görüntüsü ters KDD ile tekrar 512×512 boyutuna getirilmiş ve diğer önerilen yapılarda olduğu gibi Eşitlik (7) kullanılarak performans değerlendirilmesi gerçekleştirilmiştir.



ŞEKİL 3. Akciğer bölütlemesi için önerilen KDD-KDYSA yapısı.

Test sonuçları Tablo 1’de karşılaştırmalı olarak yer almaktadır. Bu tabloya göre KDDYSA, en kötü doğruluk oranına sahiptir. Toplam 262144 pikselden sadece 101179 tanesi ilgili bölgeye ait olarak sınıflandırılabilmiştir. KDYSA ise KDDYSA’ dan daha iyi sonuçlar elde etmiştir. Ortalama doğruluk %75.66’dır. Tablo 1’den de görülebileceği gibi en dikkat çekici sonuçlar KDD-KDYSA ile elde edilmiştir. 262144 pikselin tamamı doğru olarak sınıflandırılmış ve böylece ortalama doğruluk %100 olarak hesaplanmıştır. KDYSA ile karşılaştırıldığında elde edilen bu yüksek başarı oranının, özellik çıkarma işleminin uygulanması ile ortaya çıktığı ve KDD’nin biyomedikal görüntülerin boyutlarının azaltılmasında (özelliklerinin çıkartılmasında) kullanılabilir olduğu görülmektedir.

TABLO 1. 10 test görüntüsü için ortalama doğruluk oranları.

KDYSA			KDDYSA			KDD-KDYSA		
DSP	YSP	DO(%)	DSP	YSP	DO(%)	DSP	YSP	DO(%)
198342	63802	75.66	101179	160965	38.59	262144	0	100


Tablo 2’de ise ağ yapılarının görüntü başına harcadığı zaman gösterilmektedir. KDD-KDYSA yapısı, en iyi doğruluk oranını elde etmekle beraber tek bir görüntünün

bölütlenmesi için sadece 4.54 saniye harcarken hem KDYSA hem de KDDYSA yapısı ise yaklaşık 100 saniyeye ihtiyaç duymuştur. Yani KDDYSA veya KDYSA ile tek bir görüntü bölütlenirken, KDD-KDYSA ile 22 görüntünün bölütlenmesi bitirilecektir.

TABLO 2. Ağ yapılarının görüntü başına harcadığı işlem zamanları.

Bölütleme Zamanı (saniye)		
KDYSA	KDDYSA	KDD-KDYSA
98.7	96.63	4.54

Şekil 4, LIDC veri tabanından rastgele seçilen bir görüntü için KDYSA ve KDD-KDYSA çıkışlarını göstermektedir. KDYSA (Şekil 4(c)) yapısı ile akciğer bölgesinin çevresinde küçük bozuklukların ortaya çıktığı görülmektedir. Bu bozulmalar ortalama doğruluk oranının düşük çıkmasına neden olmaktadır.



ŞEKİL 4. (a) orijinal görüntü, (b) bölütlenmiş görüntü (hedef), (c) KDYSA çıkışı, (d) KDD-KDYSA çıkışı .

Elde edilen tüm bu sonuçlar akciğer bölgesinin bölütlenmesi işleminde KDD-KDYSA'nın oldukça başarılı ve uygulanabilir olduğunu ortaya koymuştur. Böylece akciğer görüntüleri üzerine uygulanabilecek bir bilgisayarlı teşhis sisteminin ilk adımı elde edilen bu başarı ile tüm teşhis sisteminin başarısı artırılmış olacaktır.

Kaynaklar

- [1] I. N. Backman (Editor-in-Chief), *Handbook of Medical Imaging*, Academic Press 2000.
- [2] J. C. Bezdek, L.O. Hall and L. P. Clarke, Review of MR image segmentation techniques using pattern recognition, *Medical Physics* **20** (1993), 1033–1048.
- [3] K. S. Fu and J. K. Mui, A survey on image segmentation, *Pattern Recognition* **13** (1981), 3–16.
- [4] R. M. Haralick and L. G. Shapiro, Survey: image segmentation techniques, *Computer Vision, Graphics, and Image Processing* **29** (1985), 100–132.
- [5] A. Mitiche and J. K. Aggarwal, Image segmentation by conventional and information-integrating techniques: a synopsis, *Image and Visual Computing* **3** (1985), 50–62.
- [6] N. Shareef, D. L. Wand and R. Yagel, Segmentation of medical images using LEGION, *IEEE Transactions on Medical Imaging* **18** (1999), 74–91.
- [7] G. J. Awcock and R. Thomas, *Applied Image Processing*, McGraw-Hill, New York 1996.
- [8] P. Suetens, E. Bellon, D. Vandermeulen, M. Smet, G. Marchal, J. Nuyts and L. Mortelman, Image segmentation: methods and applications in diagnostic radiology and nuclear medicine, *European Journal of Radiology* **17** (1993), 14–21.
- [9] J. C. Rajapakse, J. N. Giedd and J. L. Rapport, Statistical approach to segmentation of single-channel cerebral MR images, *IEEE Transactions on Medical Imaging* **16** (1997), 176–186.
- [10] A. P. Dhawan, *Medical Image Analysis*, Wiley-Interscience, USA 2003.
- [11] A. P. Dhawan and L. Arata, Segmentation of medical images through competitive learning, *Computer Methods and Programs in Biomedicine* **40** (1993), 203–215.
- [12] A. Sarwal and A. P. Dhawan, Segmentation of coronary arteriograms through radial basis function neural network, *Journal of Computing and Information Technology* **6** (1998), 135–148.
- [13] M. Ozkan, B. M. Dawant and R. J. Maciunas, Neural-network based segmentation of multi-modal medical images: a comparative and prospective study, *IEEE Transactions on Medical Imaging* **12** (1993), 534–544.
- [14] D. D. Sha and J. P. Sutton, Towards automated enhancement, segmentation and classification of digital brain images using networks of networks, *Information Sciences* **138** (2001), 45–77.
- [15] T. W. Nattkemper, H. Wersing, W. Schubert and H. Ritter, A neural network architecture for automatic segmentation of fluorescence micrographs, *Neurocomputing* **48** (2002), 357–367.
- [16] A. Papadopoulos, D. I. Fotiadis and A. Likas, An automatic microcalcification detection system based on a hybrid neural network classifier, *Artificial Intelligence in Medicine* **25** (2002), 149–167.

- [17] Z. Dokur and T. Olmez, Segmentation of ultrasound images by using a hybrid neural network, *Pattern Recognition Letters* **23** (2002), 1825–1836.
- [18] D. L. Vilarino, D. Cabello, X. M. Pardo and V. M. Brea, Cellular neural networks and active contours: a tool for image segmentation, *Image and Vision Computing* **21** (2003), 189–204.
- [19] I. Middleton and R. I. Damper, Segmentation of magnetic resonance images using a combination of neural networks and active contour models, *Medical Engineering and Physics* **26** (2004), 71–86.
- [20] M. I. Rajab, M. S. Woolfson and S. P. Morgan, Application of region-based segmentation and neural network edge detection to skin lesions, *Computerized Medical Imaging and Graphics* **28** (2004), 61–68.
- [21] L. Cinque, G. Foresti and L. Lombardi, A clustering fuzzy approach for image segmentation, *Pattern Recognition* **37** (2004), 1797–1807.
- [22] J. C. Fu, S. K. Lee, S. T. C. Wong, J. Y. Yeh, A. H. Wang and H. K. Wu, Image segmentation feature selection and pattern classification for mammographic microcalcifications, *Computerized Medical Imaging and Graphics* **29** (2005), 419–429.
- [23] Z. Dokur, A unified framework for image compression and segmentation by using an incremental neural network, *Expert Systems with Applications* **34** (2008), 611–619.
- [24] M. N. Kurnaz, Z. Dokur and T. Olmez, Segmentation of remote-sensing images by incremental neural network, *Pattern Recognition Letters* **26** (2005), 1096–1104.
- [25] M. N. Kurnaz, Z. Dokur and T. Olmez, An incremental neural network for tissue segmentation in ultrasound images, *Computer Methods and Programs in Biomedicine* **85** (2007), 187–195.
- [26] A. Wismuller, F. Vietze, J. Behrens, A. Meyer-Baese, M. Reiser and H. Ritter, Fully automated biomedical image segmentation by self-organized model adaptation, *Neural Networks* **17** (2004), 1327–1344.
- [27] S. H. Ong, N. C. Yeo, K. H. Lee, Y. V. Venkatesh and D. M. Cao, Segmentation of color images using a two-stage self-organizing network, *Image and Visual Computing* **20** (2002), 279–289.
- [28] M. Ceylan, R. Ceylan, F. Dirgenali, S. Kara and Y. Özbay, Classification of carotid artery Doppler signals in the early phase of atherosclerosis using complex-valued artificial neural network, *Computers in Biology and Medicine* **37** (2007), 28–36.
- [29] Y. Özbay and M. Ceylan, Effects of window types on classification of carotid artery Doppler signals in the early phase of atherosclerosis using complex-valued artificial neural network, *Computers in Biology and Medicine* **37** (2007), 287–295.
- [30] A. Hirose (Editor), *Complex-Valued Neural Networks: Theories and Applications*, World Scientific 2003.
- [31] A. Pande and V. Goel, Complex-valued neural network in image recognition: a study on the effectiveness of radial basis function, *Proceedings of World Academy of Science, Engineering and Technology* **26** (2007), 220–225.
- [32] M. Ceylan, Y. Özbay, O. N. Uçan and E. Yıldırım, A novel method for lung segmentation on chest CT images: complex-valued artificial neural network with complex wavelet transform, *Turkish Journal of Electrical Engineering & Computer Sciences* **18** (2010), 613–624.

- [33] S. G. Armato 3rd, G. McLennan, M. F. McNitt-Gray, C. R. Meyer, D. Yankelevitz, D. R. Aberle, C. I. Henschke, E. A. Hoffman, E. A. Kazerooni, H. MacMahon, A. P. Reeves, B. Y. Croft and L. P. Clarke, Lung image database consortium: developing a resource for the medical imaging research community, *Radiology* **232** (2004), 739–748.
- [34] P. D. Shukla, *Complex Wavelet Transforms and Their Applications*, PhD Thesis, The University of Strathclyde 2003.
- [35] I. W. Selesnick, R. G. Baraniuk and N. Kingsbury, The Dual-Tree complex wavelet transform, *IEEE Signal Processing Magazine* **22** (2005), 123–151.
- [36] T. Nitta, A back-propagation algorithm for complex numbered neural networks, *Proceedings of 1993 International Joint Conference on Neural Networks* (1993), 1649–1652.
- [37] Y. Ozbay, S. Kara, F. Latifoglu, R. Ceylan and M. Ceylan, Complex-valued wavelet artificial neural network for Doppler signals classifying, *Artificial Intelligence in Medicine* **40** (2007), 143–156.

