

Artımsal yapay sinir ağları kullanılarak ultrasonik görüntülerin bölütlenmesi

Mehmet Nadir KURNAZ*, Tamer ÖLMEZ

İTÜ Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Programı, 34469, Ayazağa, İstanbul

Özet

Bu çalışmada, yapay US görüntüsü iki yeni artımsal yapay sinir ağı (ArÖz ve GArÖz) kullanılarak bölütlenmiştir. Öznitelik vektör elemanları, iki boyutlu ayrık kosinüs dönüşümü (2B-AKD) uygulanarak sadece alçak frekansları temsil eden katsayıların alınması (4x4 benek büyüklüğündeki pencereleler) sonucunda oluşturulmuştur. Böylece hem öznitelik vektör boyutu azalmış hem de görüntüde var olan gürültülerin etkisi azaltılmıştır. Artımsal öz-düzenlemeli (ArÖz) ağın düğüm sayısı, eğitim sırasında ihtiyaca göre otomatik olarak belirlenmektedir. Ağın eğitiminden önce belirlenen eşik değeri (E_D) düğüm sayısını kontrol etmektedir. Ağın en iyi düğümlerini belirlemek için sıkıştırma temelli bir yöntem geliştirilmiştir. Ağın eğitimi tamamlandıktan ve düğümler belirlenip etiketlendikten sonra, hem bölütleme işlemi hem de sıkıştırma işlemi paralel olarak gerçekleştirilmektedir. Ağ tarafından üretilen tüm düğümlerin ağırlıkları ve etiketleri kod sözcüğünü oluşturmak için kullanılmaktadır. Genetik algoritmalar ile eğitilen artımsal öz-düzenlemeli (GArÖz) ağ, US görüntüdeki karmaşık doku dağılımını en iyi temsil edecek düğümleri bulmakta ve düğüm sayısını azaltmaktadır. Genetik havuzun derinliği 20 dizi olarak seçilmiş ve eğitim kümesinden rasgele alınan vektörler ile genetik havuz oluşturulmuştur. Ağın eğitiminde kullanılan uyumluluk fonksiyonu, aday düğüm ile temsil edilen vektörlerin hatasını en aza indirgeyerek yeni aday düğümün eğitim kümesinden en fazla vektörü temsil etmesine olanak sağlamaktadır. Her iki ağın yapay kist görüntüsünü bölütleme başarımları karşılaştırmalı olarak incelenmiştir. GArÖz ağının daha az düğüm kullanarak daha yüksek başarımlar verdiği gözlenmiştir.

Anahtar Kelimeler: Görüntü bölütleme, ultrason, artımsal yapay sinir ağı, genetik algoritmalar.

*Yazışmaların yapılacağı yazar: Mehmet Nadir KURNAZ. mnkurnaz@itu.edu.tr; Tel: (212) 285 66 35.

Bu makale, birinci yazar tarafından İTÜ Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Programında tamamlanmış olan "Artımsal yapay sinir ağları kullanılarak ultrasonik görüntülerin bölütlenmesi" adlı doktora tezinden hazırlanmıştır. Makale metni 04.12.2006 tarihinde dergiye ulaşmış, 11.01.2007 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 01.02.2009 tarihine kadar dergiye gönderilmelidir.

Segmentation of ultrasound images by using incremental neural networks

Extended abstract

Computer aided segmentation systems are being used in order to help physicians in diagnosis. Mainly, two operations must be implemented for computer aided segmentation; 1) feature extraction, 2) segmentation. Feature extraction is the process in order to determine the different tissue characteristics of the image. However, segmentation is performed for extraction of different (discriminating) tissues found in the image.

In this study, two novel incremental artificial neural networks, incremental self-organizing map (ISOM) and incremental self-organizing map trained by genetic algorithms (GISOM), are proposed for the segmentation of tissues in ultrasound (US) images. The elements of the feature vectors are formed by using the discrete cosine transform (DCT). The performances of the ISOM and the GISOM network are investigated for segmentation of the phantom cyst image.

Feature vectors are formed by applying 2D-DCT and then taking only the coefficients (windows of 4x4 pixels) that represent low frequencies. Thus, the vector size is decreased and also the effect of noise in the image becomes minimum. There are two critical parameters that must be taken into account in extraction of features from US images when DCT is used. First one is the size of the window and the other one is the number of coefficients that will be used in feature vector after transform. Selection of big window size increases the frequency resolution but decreases the time resolution. On the other hand, selection of small window size increases the time resolution whereas decreasing the frequency resolution. In such case, a paradox of satisfying time or the frequency resolution arises. Selection of window size depends on the structural characteristics of tissue like coarseness and repetition. Window size must be enlarged as tissue becomes coarser. However, if the window size is chosen very large, since the probability of occurrence of different tissues in the same window will be higher, identification of the tissue becomes more difficult. Furthermore, using large windows causes heavier computational costs so training times are getting longer. When the window size is very small, tissue characteristics are lost. Therefore, the selected window must have a size that is capable of identifying the tissue sufficiently.

The ISOM is an incremental unsupervised neural network. The topology of the ISOM is not necessarily to be predefined. The topology and the number of nodes of the ISOM are automatically determined during the training. Only a threshold value (E_D) needs to be estimated before the training of the network. The threshold value controls the number of classes (tissues) in the US images. Low threshold value reveals the details (different tissues) in the segmented image. ISOM network searches for the optimum nodes to discriminate between tissues in the feature space. A compression-based method that is developed for this purpose is firstly proposed in the study. Both segmentation and compression processes can be accomplished in parallel after the training of the network is completed, nodes are determined and labeled. The weights and labels of all the nodes generated by the network are used to form the codewords stored in the codebook. Codewords stored in the codebook are coded by using Huffman coding and sent to the receiver. The mean square error (MSE) value of the compressed image obtained by this method changes depending on the E_D value. MSE values decreases when E_D value is set to a low value, and increases for high E_D values. It is observed that ISOM network produces high-performance segmentations for low values of MSE.

In order to find the nodes that best represent complex tissue distribution in US images and to decrease the number of nodes, incremental self-organizing neural network trained by genetic algorithms (GISOM) is firstly proposed in this study. The weights of only the first layer nodes are searched by genetic algorithms. Nodes are determined during the training depending on need, and the optimum nodes are searched. Each node in the pool represents a unique different tissue. Fitness value calculation, reproduction, crossover and mutation operations are performed in each generation. The string that gives the best fitness value after 20 generations is assigned as the new node of the network. The fitness function used in the training of the network enables the new candidate node to represent the most number of vectors in the training set by minimizing the error of vectors represented by candidate node.

The GISOM network gave the best performances with less number of nodes compared to the other network.

Keywords: Image segmentation, ultrasound, incremental neural networks, genetic algorithms.

Giriş

Ultrason (US) görüntüleme kullanım kolaylığı, düşük maliyeti, taşınabilir ve güvenli bir yöntem olması nedeniyle, tıp alanında tanı ve tedavi amacıyla sıklıkla kullanılmaktadır. Daha çok karın (batın) içi organların incelenmesinde, kadın hastalıklarında, gebelik ve doğum takibinde, kalp işlevlerinin ve yapısının incelenmesinde, meme dokusunun incelenmesinde, damar-tiroid-testis-göz vb. organ ve yapıların incelenmesinde kullanılmaktadır. Hastalığın tanısını koymak için, doktor ilgili organdan elde ettiği US görüntüleri incelemekte ve görüntü üzerindeki farklı dokuları el ve göz ile ayırt etmeye çalışmaktadır. Bu işleme manüel bölütleme adı verilmektedir. Manüel bölütleme deneyim gerektiren, yorucu ve zaman alıcı bir işlemdir.

Günümüzde, tanı koymada doktora yardımcı olacak bilgisayar destekli bölütleme sistemleri kullanılmaktadır. Bilgisayar destekli bölütleme için temel olarak iki işlemin gerçekleştirilmesi gerekir; 1) öznelik çıkartma, 2) bölütleme. Öznelik çıkartma işlemi, görüntünün sahip olduğu farklı dokusal özelliklerin belirlenmesi için yapılan işlemlerdir. Bölütleme ise görüntüde var olan farklı (ayırt edici) dokuların ortaya çıkarılması amacıyla gerçekleştirilir.

Literatürde, özneliklerin çıkartılması için pek çok yöntem kullanılmaktadır. Bu yöntemleri istatistiksel temelli, model temelli (yapısal) ve filtreleme temelli (spektral) olmak üzere üç ana grupta toplayabiliriz. En sık kullanılan istatistiksel temelli yöntemler gri seviyeli var-oluş matrisleri (Sivaramakrishnaa vd., 2002), komşuluk gri-ton fark matrisleridir (Vince vd., 2000). Gaussyen Markov rasgele alan modeli (Manjunath ve Chellappa, 1991) ve fraktal modeller (Bhanu Prakash vd., 2002) model temelli öznelik çıkartma yöntemleri için örnek olarak verilebilir. Filtreleme temelli yöntemlerden Fourier dönüşümü (Ogawa vd., 1998), ve dalgacık dönüşümü (Yoshida vd., 2003) literatürde sıkça kullanılmaktadır.

Yapay sinir ağlarının literatürde görüntü tanıma amacıyla sıkça kullanıldığı gözlenmektedir. Genel olarak ağların bir uzaydan diğer bir uzaya

geçiş amacıyla kullanıldığı söylenebilir. Eğitim kümesindeki vektörler kullanılarak iki uzay arasındaki lineer olmayan transfer fonksiyonuna adım adım yaklaşılar.

Bu çalışmanın amacı, US görüntüsündeki doku dağılımını en iyi tanımlayan öznelikleri bulmak ve mümkün olduğunca az parametre ile gerçekleştirilebilen yüksek başarımlı yeni yapay sinir ağları geliştirmektir. Çalışmada ayrık kosinüs dönüşümü (AKD), US görüntülerindeki dokulara ilişkin özneliklerin çıkartılması amacıyla kullanılmıştır. Bölütleme işleminin gerçekleştirilmesi için öznelik uzayındaki karmaşık dağılımı birbirine en çok benzeyen ve birbirinden en uzak bölgelerde yoğunlaşmayı (öbekleşme) sağlayacak yapay sinir ağları araştırılmış ve bu amaçla iki yeni artımsal ağ geliştirilmiştir: 1) Yarışmalı öğrenme mekanizmasına sahip artımsal öz-düzenlemeli (ArÖz) ağ, 2) Genetik algoritmalarla eğitilen artımsal öz-düzenlemeli (GArÖz) ağ. Önerilen her iki ağın düğüm sayısı, eğitim aşamasında ihtiyaca göre otomatik olarak belirlenmekte ve en iyi düğümler araştırılmaktadır.

Öznelik çıkartma

Bu çalışmada dokusal özneliklerin çıkartılması amacıyla US görüntüler üzerinde 8x8 büyüklüğünde hareketli pencereler kullanılmış ve her bir pencereye (ilgilenilen alt görüntü) 2-B AKD uygulanmıştır. Elde edilen 64 katsayıdan alçak frekansları temsil eden 16 katsayı (C_1, C_2, \dots, C_{16}) alınarak öznelik vektörleri oluşturulmuştur (Şekil 1). Alçak frekans katsayıları görüntünün kaba gösterimini sağlar ve sadece bu katsayıların seçilmesiyle hem bellekten büyük oranda kazanç sağlanmış hem de gürültü bastırılmış olur. Diğer katsayılar yüksek frekansları temsil ederler ve görüntüdeki ayrıntı bilgisini içerirler.

Artımsal Öz-düzenlemeli (ArÖz) ağ

ArÖz ağı denetimsiz öğrenme yapısına sahip, yarışmalı öğrenme mekanizmasını kullanan bir ağıdır. Şekil 2'de ArÖz ağının yapısı gösterilmiştir. Ağ iki katmandan oluşmaktadır. Şekildeki k terimi öznelik vektör boyutunu belirtir.

Ağdaki ilk katman, düğüm ağırlıkları ile giriş vektörü arasında minimum mesafeyi bulmada kullanılırken; ikinci katman, ağdaki düğümlerin ait oldukları sınıfı tanımlamak için kullanılır. *Kazanan hepsini alır* kuralı, çıkışta sadece bir düğümün aktif olmasını sağlar. Aktif olan düğümlerin etiketleri indeks katmanında saklanır. Ağın düğüm sayısı eğitim sırasında otomatik olarak belirlenir ve öznitelik vektörleri (düğümler) eğitim sırasında homojen olarak dağılır.

C_1	C_2	C_3	C_4				
C_5	C_6	C_7	C_8				
C_9	C_{10}	C_{11}	C_{12}				
C_{13}	C_{14}	C_{15}	C_{16}				

$$\underline{X}^T = [C_1, C_2, \dots, C_{16}]$$

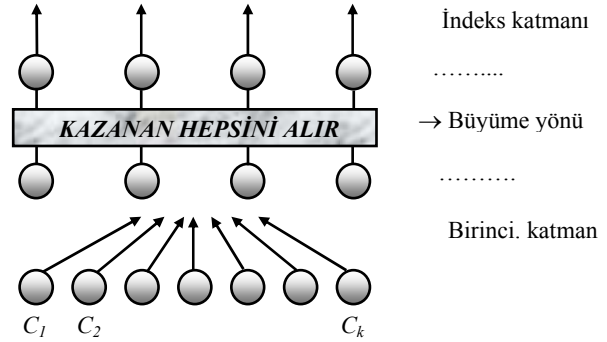
Şekil 1. 8×8 'lik ilgilenilen alt görüntüden seçilen 2B-AKD katsayıları. 64 AKD katsayısından sadece 16'sının (C_1, C_2, \dots, C_{16}) seçilerek, 16 boyutlu öznitelik vektörü oluşturulur \underline{X} , öznitelik vektörünü gösterir

Ağın eğitiminde etiketlenmemiş öznitelik vektör kümesi kullanılmaktadır. Bu nedenle küme, eğitici kullanılmadan dağılım istatistiğini verecek şekilde kolaylıkla büyütülebilmektedir. Özellikle görüntü üzerinde analiz gerçekleştirilecekse, görüntüdeki tüm benekler eğitim kümesi vektörlerini oluşturmak için kullanılır. Bu yaklaşım, kümenin istatistiksel bilgi içeriğini kolaylıkla artırma olanağı sağlayacaktır.

Eğitim kümesinden alınan ilk öznitelik vektörü, ağın birinci düğümü olarak ele alınır. Eğitim kümesinden alınan ikinci vektör ile birinci düğüm arasında Öklid mesafesi hesaplanır. Bu mesafe önceden belirlenen bir eşik değerinden (düğüm eşiği; E_D) büyükse, ikinci vektör ağın ikinci düğümü olarak ele alınır. Eğitim kümesinden alınan ilk öznitelik vektörü, ağın birinci

düğümü olarak ele alınır. Eğitim kümesinden alınan ikinci vektör ile birinci düğüm arasında Öklid mesafesi hesaplanır. Bu mesafe, girilen öznitelik vektörünün ağda yeni bir düğüm oluşturup oluşturmayacağını belirlemek için eşik değeri (E_D) ile karşılaştırılır. Bu mesafe, E_D 'den küçük ise birinci düğümün ağırlıkları (1) eşitliği kullanılarak değiştirilir.

$$w_{ji}(k+1) = w_{ji}(k) + \eta(k).(x_i(k) - w_{ji}(k)) \quad (1)$$



Şekil 2. ArÖz ağının yapısı

w_{ji} , giriş vektörüne en yakın j -inci düğümün i -inci ağırlığını; x_i , girilen öznitelik vektörünün i -inci elemanı; $\eta(k)$ ise kazanç terimini göstermektedir. Mesafe E_D 'den büyük ise, girilen öznitelik vektörü ağın yeni bir düğümü olarak atanır. Aynı zamanda bu düğüm için yeni bir indeks tayin edilir. Eğitim kümesinden alınan her öznitelik vektörü için, öznitelik vektörü ve ağın düğümleri arasında Öklid mesafeleri hesaplanır. Bulunan en küçük mesafe, seçilen eşik değerinden (E_D) büyükse öznitelik vektörü ağın yeni düğümü olarak düşünülecektir. Aksi durumda, öznitelik vektörüne en yakın mesafedeki düğümün ağırlıkları (1) eşitliği ile değiştirilecektir. Eğitim, kümedeki tüm vektörler için analiz tamamlandığında sonlandırılır.

Aşağıda ArÖz ağının eğitim algoritması verilmiştir. İterasyon sayısı eğitim kümesindeki vektör sayısı olarak tanımlanır. İndeks sayacı (düğüm sayacı) 1'e eşitlenir. E_D değeri belirlenir.

Adım 1) Eğitim kümesinden bir öznitelik vektörü al ve ağın düğümü olarak ata. Yeni atanan düğüm için ikinci katmanda ilgili düğümün ağırlığına düğüm sayacının değerini ver.

Adım 2) Eğitim kümesinden sırayla bir öznitelik vektörü al.

Adım 3) Giriş öznitelik vektörü ile ağıın düğümleri arasındaki mesafeleri aşağıdaki ifadeyi kullanarak hesapla.

$$D_j = \sum_{i=1}^n (x_i - w_{ji}(k))^2 \quad (2)$$

x_i , giriş vektörünü; w_{ji} ise j -inci çıkışın ağırlık vektörünü temsil etmektedir.

Adım 4) En küçük uzaklığa sahip j -inci düğümü bul, j -inci düğümün kullanım sayacını bir artır.

Adım 5) En küçük uzaklık önceden belirlenen eşik değerinden küçük ise, j -inci düğümün ağırlıklarını aşağıdaki ifadeyi kullanarak değiştir.

$$w_{ji}(k+1) = w_{ji}(k) + \eta(k).(x_i(k) - w_{ji}(k)) \quad (3)$$

Kazanç terimi olarak ifade edilen $\eta(k)$, 0 ile 1 arasında ve zamanla azalacak şekilde değer alır. Aksi durumda, giriş öznitelik vektörünü ağıın yeni düğümü olarak ata. Düğüm sayacının değerini bir artır. İkinci katmanda yeni düğümün ağırlığına, düğüm sayacının değerini ver.

Adım 6) İterasyon sayısını azalt. İterasyon sayısı sıfıra eşit değil ise adım 2'ye git. Aksi takdirde eğitim algoritmasını durdur.

Düğüm sayısı, eşik değeri (E_D) ile kontrol edilmektedir. E_D değerinin küçük seçilmesi durumunda üretilen aşırı düğüm sayısını kontrol etmek amacıyla, eğitim işleminden sonra histogram incelemesi yapılır. Ağıın eğitimi sırasında, üretilen her düğümün kullanılma sayısı kullanım sayacında saklanır. Eğitim süresince ağı girilen her giriş vektörüne en yakın mesafedeki düğümün kullanım sayacındaki değeri bir artırılarak, üretilen her düğüm için kullanım sayıları elde edilir.

ArÖz ağıının eğitimi tamamlandıktan sonra, yeni sınıfları araştırmak için ikinci bir eşik değeri (E_H) kullanılır (Kurnaz vd., 2007). Düğüm kul-

lanım sayacındaki değer, tüm vektör sayısının belirli bir oranının altında ise düğüm ağıdan çıkarılır. Böylece belirli bir yüzdenin üzerinde kullanılan düğümler sınıf olarak tanımlanacak ve bölütleme işleminde sadece bu düğümler kullanılacaktır. Örneğin, kullanıcı görsel olarak görüntüde 2 sınıf tespit etmişse, E_H değerini 2'den fazla aday düğüm kazanacak biçimde belirler. Bu yolla kullanıcı, olası sınıfları veya olası herhangi bir sınıfı temsil edecek düğümleri (bir sınıfın veya dokunun birden fazla düğümle temsil edilmesi durumu) inceleme olanağı bulabilmektedir. Başarımı yüksek bölütleme elde etmek için bu işlem birkaç kez tekrarlanabilir. E_H değeri (ve aynı zamanda E_D değeri) ayarlanarak olası yeni sınıfların (görüntüdeki farklı dokular) araştırılması mümkün olur. E_H değerinin esnek biçimde ayarlanabilir olması, kullanıcıya görüntüde var olan farklı dokuları keşfedebilmesine olanak sağlayan bir yol olarak düşünülür.

Eğitim tamamlandıktan ve düğümler belirlenip etiketlendikten sonra bölütleme işlemine geçilir. Görüntüdeki her bir beneğe ait öznitelik vektörleri ağıın girişine verilir. Birinci katmandaki düğümler ile giriş vektörü arasında Öklid mesafeleri hesaplanır. İkinci katmanda düğümlerin sınıf etiketleri saklanmaktadır. Minimum mesafedeki düğümün sınıf etiketi ağıın kararı olarak kullanılır.

E_H değeri, bölütlenmiş görüntüde ortaya çıkan farklı dokuların sayısını kontrol etmektedir. E_H değerinin üstünde kalan düğümlerin sayısı bölütlenmiş görüntüdeki doku sayısına eşittir. Bölütleme gerçekleştirildikten sonra kullanıcı gerek duyarsa, bölütlenmiş görüntüdeki dokuları bilgisayar faresi yardımıyla kolaylıkla birleştirebilir.

ArÖz ağı ile vektör nicemleme ve görüntü sıkıştırma

Dönüşüm temelli bir kayıplı sıkıştırma yöntemi ile görüntünün sıkıştırılması tipik olarak üç adımda gerçekleştirilir: 1) Görüntü, öncelikle Fourier, kosinüs veya dalgacık dönüşümü gibi bir yöntem kullanılarak ayrıştırılır. 2) Dönüşümden elde edilen katsayılar nicemleme işlemi gerçekleştirilir ve kod sözcükleri elde edilir.

3) Son olarak, kod sözcüklerine Huffman veya aritmetik kodlama gibi bir sıkıştırma yöntemi uygulanarak görüntü sıkıştırılmış olur (Base vd., 2005).

Bir görüntüde birbirine yakın olan benekler arasında büyük oranda benzerlik veya tekrarlama vardır. Dönüşüm temelli görüntü sıkıştırmada temel olarak bu özellik kullanılır. Vektör nicemleme ile görüntü sıkıştırma işlemleri de görüntüdeki ardışık blokların birbirine oldukça benzer yapıda olması gerçeğine dayanmaktadır. Görüntü üzerindeki benekler, bloklar halinde (bir vektör nicemleme algoritması yoluyla) nicemleniyorsa bu işleme *vektör nicemleme* adı verilir. Yarışmalı öğrenme mekanizmasına sahip yapay sinir ağları vektör nicemleme tekniklerine oldukça benzerdir ve literatürde yoğun biçimde tartışılmıştır (Amerijckx vd., 1998).

ArÖz ağı yarışmalı öğrenme mekanizmasını kullanan bir ağıdır. Dolayısıyla, ArÖz ağı aynı zamanda bir vektör nicemleme yöntemi olarak düşünülebilir. Ağın eğitimi tamamlandıktan ve düğümler belirlenip etiketlendikten sonra, hem bölütleme işlemi hem de sıkıştırma işlemi paralel olarak gerçekleştirilebilir. ArÖz ağı ile US görüntülerin sıkıştırılması için eğitim işleminin tüm görüntü ile gerçekleştirilmesi gerekir. ArÖz ağı kullanılarak US görüntülerin sıkıştırılmasında aşağıdaki adımlar gerçekleştirilir:

Adım 1) Orijinal görüntüden bloklar şeklinde alt görüntüler oluşturulur.

Adım 2) Her bir bloğa dönüşüm işlemi uygulanır ve öznitelik vektör uzayı (eğitim kümesi) oluşturulur.

Adım 3) ArÖz ağı kullanılarak eğitim işlemi gerçekleştirilir.

Adım 4) Düğümlerin ağırlıkları ve görüntü blokları arasında Öklid mesafesi hesaplanır.

Adım 5) En yakın düğümün etiketi bloğun kod sözcüğü olarak atanır ve kod kitabında saklanır.

Adım 6) Kod kitabında (*codebook*) saklanan kod sözcükleri (*codewords*) Huffman kodlama kullanılarak kodlanır ve alıcıya gönderilir.

Sıkıştırılmış görüntüyü açma (geri çatma) aşamasında, gerçek görüntüye ait her blok ile kod kitabındaki kod sözcükleri karşılaştırılır ve Öklid mesafesi hesaplanır. En yakın mesafedeki kod sözcüğü vektörüne ters dönüşüm işlemleri gerçekleştirilir. Ters dönüşümden elde edilen alt görüntü blokları gerçek görüntünün benek grubu olarak atanır. Tüm alt görüntü blokları için bu işlemler tekrarlanarak geri çatılmış görüntü elde edilir.

ArÖz ağının bölütleme başarımının değerlendirilmesinde, sıkıştırılmış görüntülerin ortalama karesel hata (OKH) değeri bir ölçüt olarak düşünülebilir. Ağın eğitiminden önce belirlenen eşik değeri (E_D) düğüm sayısını kontrol etmektedir. Düğüm sayısı, E_D değerinin küçük seçilmesi durumunda artacak, büyük seçilmesi durumunda azalacaktır. Sıkıştırılmış görüntünün OKH değeri E_D değerine bağlı olarak değişmektedir. E_D değerinin küçük seçilmesi durumunda sıkıştırılmış görüntünün OKH değeri azalmakta, büyük seçilmesi durumunda ise artmaktadır. Yani, küçük E_D değeri kullanılarak gerçekleştirilen sıkıştırma ile daha kaliteli US görüntüler elde edilmektedir. Küçük OKH değerleri, öznitelik uzayını en iyi temsil edecek düğümlerin üretilmesini sağlar. OKH değeri ne kadar küçükse, öznitelik uzayını en iyi temsil edecek düğümler üretilir ve yüksek başarımli bölütleme gerçekleştirilmiş olur.

Sıkıştırılmış US görüntüsünün kalitesini gösteren ortalama karesel hata (OKH) değeri aşağıdaki gibi hesaplanabilir (Farrelle, 1990):

$$OKH = \frac{1}{M \cdot N} \sum_{n_1=1}^M \sum_{n_2=1}^N [f(n_1, n_2) - \hat{f}(n_1, n_2)]^2 \quad (4)$$

Denklemden $f(n_1, n_2)$ ve $\hat{f}(n_1, n_2)$, $1 \leq n_1 \leq M$, $1 \leq n_2 \leq N$; sırasıyla $M \times N$ büyüklüğündeki orijinal ve sıkıştırılmış görüntüyü gösterir.

Genetik algoritmalar ile eğitilen artımsal öz-düzenlemeli (GARÖz) ağ

Literatürde genetik algoritmalar ile eğitilen karma yapılı yapay sinir ağlarının, çeşitli problemlerin çözümü için sıklıkla kullanıldığı gözlenmektedir (Dokur ve Ölmez, 2001). Genetik algoritmalar ile yapay sinir ağlarının birlikte kullanımı genellikle üç şekilde gerçekleştirilmektedir. Birinci tip uygulamada genetik algoritmalar, yapay sinir ağlarının eğitiminde kullanılacak en uygun öznitelikleri araştırır. İkinci tip uygulamada genetik algoritmalar, incelenen ağın eğitim algoritmasında bulunan parametrelerin belirlenmesinde kullanılır. Üçüncü tip uygulamada ise ağın ağırlık katsayıları ve topolojisi ya birlikte ya da ayrı ayrı genetik algoritmalar ile bulunur (Rooij vd., 1996). Çalışmada önerilen GARÖz ağı üçüncü tip uygulamaya uygun olarak geliştirilmiştir. Ağın sadece birinci katmanındaki ağırlıkları genetik algoritmalar ile bulunmaktadır. US görüntülerindeki doku dağılımını en iyi temsil edecek düğümler, eğitim aşamasında ihtiyaca göre kontrollü olarak belirlenmekte ve en iyi düğüm pozisyonları araştırılmaktadır.

Şekil 3'te GARÖz ağının yapısı gösterilmiştir. Ağ iki katmandan meydana gelir. Ağın içindeki düğümlerin yapısı aşağıdaki denklemlerle ifade edilir.

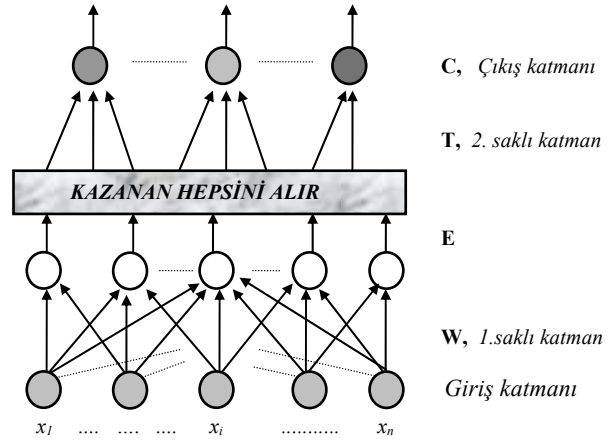
$$D_j = \sum_{i=1}^n (x_i - w_{ji})^2$$

$$E_e = \begin{cases} 1 & D_e = \min_j \{D_j\} \\ 0 & \text{aksi takdirde} \end{cases}$$

$$\text{Çıkış katmanı} = C_c = \sum_e E_e \cdot T_{ec} \quad (5)$$

x_i , giriş vektörünün i . elemanını (i . giriş düğümü); w_{ji} , birinci saklı katmandaki j . düğüm ile i . giriş düğümü arasındaki bağlantıyı; E_e , birinci katmandaki düğümlerin çıkışını; T_{ec} , ise sadece 0 veya 1 değerini alan OR'lama işlemi gerçekleştiren bağlantı katsayısını gösterir.

İlk katman, düğüm ağırlıkları ile giriş vektörü arasında minimum mesafeyi bulmada kullanılırken, ikinci katman ağdaki düğümlerin ait oldukları sınıfı tanımlamak için kullanılır. İkinci katmandaki ağırlıklar başlangıçta 0 değerini alır, öğrenme esnasında bu bağlantılar 1'lenir. İkinci katman, aynı sınıftan çıkışları lojik olarak OR'lamak için kullanılmaktadır.



Şekil 3. GARÖz ağının yapısı

Bölütleme işlemi sırasında, ağ tarafından üretilmiş düğümler ile giriş vektörleri arasında Öklid mesafesi hesaplanır. Giriş vektörünün etiketi giriş uzayındaki vektöre en yakın düğümün etiketi olarak atanır.

Şekil 4'te GARÖz ağının eğitimi için kullanılan genetik havuz gösterilmiştir. Genetik algoritmalar ile ağın birinci katmanındaki düğümlerin ağırlık değerleri bulunmaktadır. Düğümler, eğitim sırasında otomatik olarak tek tek belirlenir. Havuzdaki her bir düğüm farklı bir dokuyu temsil etmektedir. Çalışma içerisinde düğüm sayısı 8, genetik havuzun derinliği 20 dizi seçilmiştir. Her nesilde 4 işlem gerçekleşir: Uyumluk değeri hesabı, kopyalama, çaprazlama ve mutasyon işlemleri.

GARÖz ağının eğitiminde kullanılan uyumluluk fonksiyonu (UF) aşağıda tanımlanmıştır.

$$UF_j = UF_{j1} + \frac{1}{1 + UF_{j2}} \quad (6)$$

Düğüm	1. boyut	2. boyut	n. boyut
1. aday →	w ₀	w ₁	w _n
i. aday →
20. aday→	8 ikili	8 ikili	101...111

Şekil 4. GARÖz ağının eğitiminde kullanılan genetik havuz

UF_{j1} ve UF_{j2} , havuzdaki j -inci aday düğümün (j -inci dizinin) birinci ve ikinci uyumluluk fonksiyonlarını göstermektedir. UF_{j1} j -inci aday düğümün eğitim kümesinde temsil ettiği vektörlere normalize mesafesini, UF_{j2} ise j -inci aday düğümün eğitim kümesinde temsil ettiği vektörlerin normalize sayısını hesaplamak için kullanılmaktadır. Bu fonksiyonlar aşağıdaki gibi ifade edilebilir.

$$UF_{j1} = \frac{\sum M_j}{\#\{TEV_j\} \times VB} \quad (6a)$$

$$UF_{j2} = \frac{\#\{TEV_j\}}{\#\{E\}} \quad (6b)$$

$\sum M_j$, havuzdaki j -inci aday düğümün eğitim kümesinde temsil ettiği vektörlere mesafelerinin toplamını; $\#\{TEV_j\}$, j -inci aday düğümün eğitim kümesinde temsil ettiği vektör sayısını; VB , öz-nitelik vektör boyutunu; $\#\{E\}$, eğitim kümesindeki toplam vektör sayısını temsil etmektedir.

Başlangıçta havuz, birinci katmandaki ilk düğümün ağırlıklarını temsil eden dizilerden oluşturulur. Her nesilde havuz içindeki tüm dizilere 4 genetik işlem uygulanır. 20 nesil sonunda, en iyi uyumluluk değeri veren dizi ağın sabitleşmiş düğümünü oluşturmak için kullanılır. Gelecek nesillerde sabitleşmiş düğümün ağırlıkları araştırılmaz. İkinci düğümü temsil etmek üzere eğitim kümesinden rasgele vektörler alınarak genetik havuz yeniden oluşturulur. İkinci düğümü bulmak için eğitim kümesindeki tüm vektörler kullanılarak havuzdaki her bir dizi için uyumluluk değeri hesaplanır. Uyumluluk değeri hesabındaki amaç fonksiyonu, hem aday düğüm ile temsil edilen vektörlerin hatasını en aza indir-

geyecek hem de yeni aday düğümün eğitim kümesinden en fazla vektörü temsil edecek şekilde oluşturulmuştur. Genetik havuzdaki dizi boyları eğitim süresince değiştirilmez, sabit tutulur. Genetik algoritmalar ile eğitim kümesindeki doku dağılımını en iyi temsil edecek düğümler bulunur.

GARÖz ağının eğitiminde kullanılan adımlar aşağıda verilmiştir. Düğüm sayısı belirlenir (doku dağılımını en az bir düğümlerle temsil edilir). İterasyon sayısı 1'e kurulur.

Adım 1) Eğitim kümesinden rasgele vektörler alarak genetik havuzu oluştur. Nesil sayısını belirle.

Adım 2) Eğitim kümesindeki tüm vektörleri kullanarak, havuzdaki her bir dizi için uyumluluk değerini hesapla.

Adım 3) Havuz içindeki tüm dizilere kopyalama, çaprazlama ve mutasyon işlemlerini uygula. Nesil sayacını 1 azalt. Nesil sayacı sıfıra eşit değilse adım 2'ye git.

Adım 4) Nesil sayacını başlangıç değeri ile kur. Havuz içinde en yüksek uyumluluk değerini veren diziyi bul.

Adım 5) En iyi uyumluluk değerini veren diziyi, ağın sabitleşmiş düğümünü oluşturmak üzere havuzdan al.


Adım 6) İterasyon sayısını 1 artır. İterasyon sayısı düğüm sayısına eşit değil ise adım 1'e git. Aksi takdirde eğitim algoritmasını durdur.

Bilgisayarla benzetim sonuçları

Çalışmada geliştirilen yöntemler yapay (fantom) US görüntüsünün bölütlenmesi için denenmiştir. Şekil 5'te, vücut içinde oluşmuş hastalıklı doku-yu (kist) taklit eden yapay kist görüntüsü gösterilmektedir. Doktor tarafından yapılan manüel bölütlemeye, görüntü kist ve zemin olmak üzere iki farklı dokuya bölütlenmiştir. Test kümesi her iki dokudan 100'er vektör alınarak oluşturulmuştur.

Şekil 6 ve 7'de, sırasıyla ArÖz ve GARÖz ağları ile elde edilen bölütleme sonuçları, 3 ve 2 bölüt

(doku sayısı) için gösterilmiştir. ArÖz ağıının en iyi düğümlerini bulmak amacıyla gerçekleştirilen sıkıştırma işleminden elde edilen görüntü Şekil 8a'da gösterilmiştir. Sıkıştırılmış görüntünün OKH değeri 98.09 olarak bulunmuştur.



Şekil 5. Manuel bölütlenmiş yapay kist görüntüsü

ArÖz ağıının düğümlerinin sayısı E_D değerine bağlı olarak eğitim sırasında otomatik olarak belirlenmektedir. Birkaç deneme yapılarak E_D değeri kestirilebilmektedir. Kullanıcı, öncelikle görüntü üzerinde birbirine benzeyen dokuları tespit eder. Sonra, bilgisayar faresi yardımıyla benzer iki doku için öznitelik vektörleri oluşturulur. Daha sonra, eşik değeri (E_D) aşağıdaki gibi hesaplanır.

$$\underline{X}_1^T = [C_1^1, C_2^1, \dots, C_i^1], \underline{X}_2^T = [C_1^2, C_2^2, \dots, C_i^2]$$

$$E_D \leq \|\underline{X}_1 - \underline{X}_2\| \quad (7)$$

Burada \underline{X}_1 ve \underline{X}_2 , sırasıyla birinci ve ikinci dokulara ait öznitelik vektörlerini temsil etmektedir. C_i^m ise m -inci dokuya ait i -inci öznitelik vektör elemanını göstermektedir.

ArÖz ağıının eğitiminde kullanılan E_D değeri 120 seçilmiştir. Buna göre, ağıın eğitimi sonunda 301 düğümler üretilmiştir. Her bir düğümlerin kullanım sayısına ilişkin düğümler histogramı Şekil 8b'de gösterilmiştir. Histogram eşik değerinin (E_H) 55 seçilmesiyle düğümler sayısı 3'e indirgenir ve böylece görüntü 3 farklı dokuya bölütlenir (Şe-

kil 6a). Her bir düğümler farklı bir dokuyu temsil ettiğinden, bölütlenmiş görüntü üzerindeki doku sayısı (bölüt sayısı) düğümler sayısına eşittir. Farklı dokuların bilgisayar faresi ile birleştirilmesi sonucunda, görüntü iki farklı dokuya bölütlenir (Şekil 6b). GARÖz ağıının bölütleme sonuçları 3 ve 2 bölüt için Şekil 7a,b'de gösterilmiştir.

Tablo 1'de, ArÖz ve GARÖz ağılarının başarımlar sonuçları verilmiştir. Genetik algoritmalar ile eğitilen ağıın (GARÖz) daha az düğümler ile daha yüksek başarımlar verdiği gözlenmiştir. Buna karşın, GARÖz ağıının eğitimi daha uzun zaman almaktadır.


Tablo 1. ArÖz ve GARÖz ağılarının başarımları

Ölçüt	ArÖz	GARÖz
DS	301	8
BS ₁	3	3
BS ₂	2	2
Bölütleme başarımları (%)	94	97
Eğitim zamanı (s)	1.52	4.94


DS : Eğitim sonunda üretilen düğümler sayısı
 BS₁ : Bölüt sayısı (E_H değerine bağlı)
 BS₂ : Bölüt sayısı (BS₁'de verilen dokuların birleştirilmesi sonucunda elde edilir)

Sonuçlar

Bu çalışmada, ultrason görüntülerin bölütlenmesi için artımsal öz-düzenlemeli ağı (ArÖz) ve genetik algoritmalar ile eğitilen artımsal öz-düzenlemeli ağı (GARÖz) önerilmiştir. Öznitelik vektörleri, iki boyutlu ayırık kosinüs dönüşümü (2B-AKD) kullanılarak oluşturulmuştur. Ağıların bölütleme başarımları yapay kist görüntüsü için karşılaştırılmıştır. ArÖz ağıının düğümler sayısı, eğitim işleminden önce belirlenen eşik değerine (E_D) bağlı olarak değişmektedir. E_D değerinin küçük tutulması çok sayıda düğümler oluşmasına sebep olmaktadır. Bu durum, öznitelik uzayında dağılımın daha ayrıntılı tanımlanmasına olanak sağlar. E_D değerinin büyük tutulması dağılımın kaba temsil edilmesine neden olur. E_D değerinin küçük seçilmesi durumunda üretilen aşırı düğümler sayısı, eğitim işleminden sonra düğümler kullanım sayılarına ilişkin histogramın




a)




b)

Şekil 6. ArÖz ağının bölütleme sonuçları a) bölüt sayısı=3, b) bölüt sayısı=2




a)

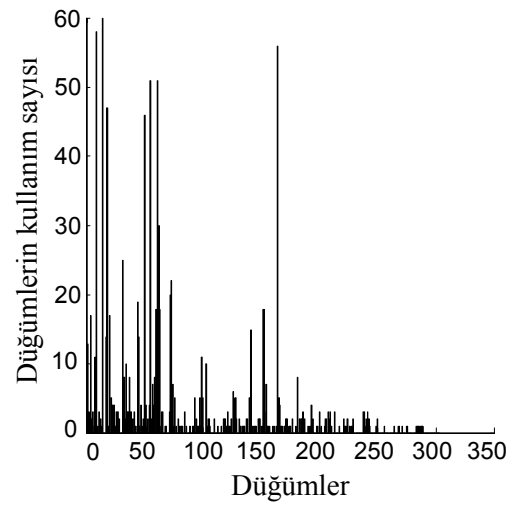


b)

Şekil 7. GArÖz ağının bölütleme sonuçları a) bölüt sayısı=3, b) bölüt sayısı=2



Şekil 8a. ArÖz ağı ile sıkıştırılmış görüntü



Şekil 8b. ArÖz ağı tarafından üretilen düğümlere ilişkin histogram

incelenmesi ve histogram eşik değerinin (E_H) belirlenmesi ile kontrol edilmektedir. E_D ve E_H değerlerinin esnek biçimde ayarlanabilir olması, kullanıcıya görüntüde var olan farklı dokuların keşfedebilmesine olanak sağlamaktadır.

ArÖz ağının en iyi düğümlerini bulmak için sıkıştırma temelli bir yöntem önerilmiştir. Eğitim tamamlandıktan ve düğümler belirlenip etiketlendikten sonra, bölütleme ve sıkıştırma işlemleri paralel olarak gerçekleştirilmektedir. Küçük OKH değerlerine sahip sıkıştırılmış görüntüler için en iyi düğümler üretilmiş ve daha yüksek başarımlar gözlenmiştir.

Genetik algoritmalar ile eğitilen artımsal öz-düzenlemeli (GARÖz) ağ, US görüntülerindeki karmaşık doku dağılımını en iyi temsil edecek düğümleri bulmakta ve düğüm sayısını azaltmaktadır. Ağın sadece birinci katmanındaki ağırlıkları genetik algoritmalar ile bulunmaktadır. Düğümler, eğitim sırasında ihtiyaca göre kontrollü olarak belirlenmekte ve en iyi düğüm pozisyonları araştırılmaktadır. Genetik algoritmaların yapay sinir ağıları ile kullanımında karşılaşılan en büyük problem, eğitimin uzun zamanda gerçekleşmesidir. Genetik havuzdaki dizi boylarının aşırı derecede büyük olması, araştırmanın optimum bölgeye yaklaşmasını geciktirici etki yapar. ArÖz ağının genetik algoritmalarla eğitilmesinde, genetik havuzdaki her dizi sadece bir düğümü temsil etmektedir. Dizilerin (öznitelik vektörleri) boyu küçük olduğu için aranan bölgelere yakınsama hızla gerçekleşmektedir.

Ağların eğitimi tamamlandıktan sonra, bölütleme işlemine geçmeden önce düğümlerin etiketlenmesi gerekir. Kullanıcı, etiketleme işlemine karışmadığı durumda ağın her düğümü bir sınıfı (dokuyu) temsil edecektir. Gerektiği zaman kullanıcı, düğümleri bir sınıf altında toplama imkânı elde edebilir. Yapay kist görüntüsünde belirgin iki doku olduğundan, doku sayısı 2 olacak şekilde farklı dokular bilgisayar faresi yardımıyla birleştirilmiştir.

Özniteliklerin çıkartılması için, 8x8 büyüklüğündeki pencerelere 2B-AKD uygulanarak sadece alçak frekansları temsil eden katsayıların

alınması (4x4 benek büyüklüğündeki pencereler) öznitelik vektör boyutunun azalmasını sağlamaktadır. Bu sayede dokunun özellikleri daha az katsayı ile temsil edilebilmektedir ve bu durum eğitim zamanının azalmasına yol açmaktadır. Öte yandan, yüksek frekanslı katsayıların atılması, görüntüde var olan gürültülerin etkisini en aza indirmektedir.

Çalışmada, genetik algoritmalar ile eğitilen ağın (GARÖz) daha az düğüm (8 düğüm) kullanarak daha yüksek başarımlar verdiği gözlenmektedir. Doktorlar tarafından yapılan değerlendirmeler sonucunda, elde edilen bölütleme sonuçlarının manuel bölütleme ile benzeştiği tespit edilmiş ve tanı koymaya yardımcı olabileceği kabul görmüştür (Mihmanlı, 2006; Kantarcı, 2006; Salmashioğlu, 2006).

Sonuç olarak, ArÖz ve GARÖz ağlarının US görüntülerindeki farklı dokuları ayırabilme yeteneğine sahip olduğu gözlenmiştir. ArÖz ağı, US görüntüsüne benzer özellik gösteren uzaktan algılama görüntülerin bölütlenmesi için kullanılabilir (Kurnaz vd., 2005). Benzer şekilde, GARÖz ağının karmaşık doku yapısına sahip görüntülerin bölütlenmesi için yapısında herhangi bir değişikliğe gerek duyulmadan kullanılabilirliği öngörülebilir.

Kaynaklar

- Amerijckx, C., Verleysen, M., Thissen, P. ve Legat, J., (1998). Image compression by self-organized Kohonen map, *IEEE Transactions on Neural Networks*, **9**, 3, 503–507.
- Base, A.M., Janckea, K., Wismüller, A., Foo, S. ve Martinetz, T., (2005). Medical image compression using topology-preserving neural networks, *Engineering Applications of Artificial Intelligence*, **18**, 4, 383–392.
- Bhanu Prakash, K.N., Ramakrishnan, A.G., Suresh, S. ve Chow, T.W.P., (2002). Fetal lung maturity analysis using ultrasound image features, *IEEE Transactions on Information Technology in Biomedicine*, **6**, 1, 38-45.
- Dokur, Z. ve Ölmez, T., (2001). ECG beat classification by a novel hybrid neural network, *Computer Methods & Programs in Biomedicine*, **66**, 167-181.

- Farrelle M.P., (1990). *Recursive Block Coding for Image Data Compression*, Springer-Verlag, Heidelberg.
- Kantarıcı, F., (2006). Kişisel görüşme, Cerrahpaşa Tıp Fakültesi Radyoloji Anabilim Dalı Öğretim üyesi.
- Kurnaz, M.N., Dokur, Z. ve Ölmez, T., (2005). Segmentation of remote-sensing images by incremental neural network, *Pattern Recognition Letters*, **26**, 8, 1096–104.
- Kurnaz M.N., Dokur Z. ve Ölmez T., (2007). An incremental neural network for tissue segmentation in ultrasound images, *Computer Methods and Programs in Biomedicine* (Basım aşamasında).
- Manjunath, B.S. ve Chellappa, R., (1991). Unsupervised texture segmentation using Markov random fields, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **13**, 5, 478-482.
- Mihmanlı, İ., (2006). Kişisel görüşme, Cerrahpaşa Tıp Fakültesi Radyoloji Anabilim Dalı Öğretim üyesi.
- Ogawa, K., Fukushima, M., Kubota, K. ve Hisa, N., (1998). Computer-aided diagnostic system for diffuse liver-diseases with ultrasonography by neural networks, *IEEE Transactions on Nuclear Science*, **45**, 6, 3069-3074.
- Salmashoğlu, A., (2006). Kişisel görüşme, İstanbul Tıp Fakültesi Radyodiagnostik Anabilim Dalı Öğretim üyesi.
- Sivaramakrishnaa, R., Powell, K.A., Lieber, M.L., Chilcote, W.A. ve Shekhar, R., (2002). Texture analysis of lesions in breast ultrasound images, *Computerized Medical Imaging and Graphics*, **26**, 303–307.
- Rooij, A.J.F., Jain, L.C. ve Johnson, R.P., (1996). *Neural Network Using Genetic Algorithms*, World Scientific, Singapore.
- Vince, D.G., Dixon, K.J., Cothren, R.M. ve Cornhill, J.F., (2000). Comparison of texture analysis methods for the characterization of coronary plaques in intravascular ultrasound images, *Computerized Medical Imaging and Graphics*, **24**, 221–229.
- Yoshida, H., Casalino, D.D., Keserci, B., Coskun, A., Ozturk, O. ve Savranlar, A., (2003). Wavelet-packet-based texture analysis for differentiation between benign and malignant liver tumours in ultrasound images, *Physics in Medicine and Biology*, **48**, 3735–3753.