

Ultrasonik Görüntülerin Artımsal Yapay Sinir Ağı ile Bölütlenmesi

Tamer Ölmez, Zümray Dokur
İstanbul Teknik Üniversitesi
Elektronik ve Haberleşme Mühendisliği Bölümü
Maslak, İstanbul.
olmez@ehb.itu.edu.tr

Özet: *Bu çalışmada ultrasonik görüntülerin geliştirilen denetimsiz artımsal bir yapay sinir ağı (DAYSA) kullanılarak bölütlenmesi anlatılmaktadır. Öznitelik vektörlerini oluşturmak için beneklerin bir komşuluğundaki gri seviyelerine, Fourier dönüşümü uygulanır. Bulunan katsayıların mutlak değerleri, öznitelik vektörünün elemanları olarak kullanılır.*

Fourier katsayılarının yapay sinir ağları ile birlikte kullanımı ile ultrasonik görüntülerde bilinmeyen doku ve oluşumların ortaya çıkması sağlanacaktır. Çalışmada ultrasonik görüntülerin bölütlenmesi için DAYSA ve Kohonen ağı karşılaştırmalı olarak incelenmektedir.

1. Takdim

Literatürde ultrasonik görüntülerin sınıflandırılması için değişik öznitelik çıkartma yöntemleri kullanılmaktadır. Yöntemlerin büyük bir çoğunluğu, doku özelliklerinin ortaya çıkartılmasına yöneliktir.

Uzay-ölçek analizinde Gabor, dalgacık dönüşümü [1] ve Wigner dağılımının [2] sıkça kullanıldığı gözlenmektedir. Ancak bu yöntemlerde dokuları temsil eden ölçek değerlerinin önceden belirlenmiş olması gerekmektedir. İkinci dereceden istatistiksel metodlarla gerçekleştirilen analizlerde varlık matrisinin sıkça kullanıldığı gözlenmektedir [3]. Varlık matrisin çok sayıda parametrenin önceden belirlenmesi gerekmektedir. Aynı zamanda bu yöntem çok sayıda katsayı üretmektedir.

Çalışmada hesap yükünü arttırmayacak, fazla parametre ihtiyacı olmayan ve kullanışlı bir öznitelik çıkartma yöntemi önerilmektedir. Aynı zamanda, denetimsiz artımsal yapay sinir ağı ile bilinmeyen dokuların ortaya çıkartılması imkanı elde edilecektir.

2. Denetimsiz Artımsal Yapay Sinir Ağı (DAYSA)

Şekil 1’de DAYSA’nın yapısı gösterilmiştir. DAYSA; Kohonen ağı [4] gibi iki katmandan meydana gelir. Ağın içindeki düğümlerin yapısı aşağıdaki denklemlerle ifade edilir.

$$D_j = \sum_{i=1}^n (x_i - w_{ji}(k))^2 \quad E_e = \begin{cases} 1 & D_e = \min_j \{D_j\} \\ 0 & \text{aksi takdirde} \end{cases} \quad (1)$$

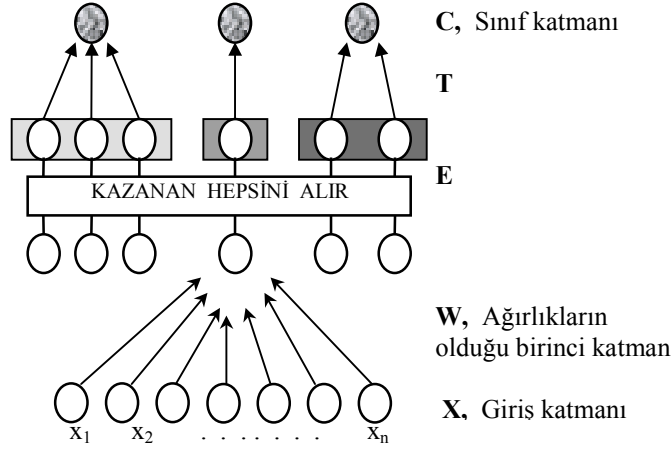
$$\text{Çıkış katmanı} = C_c = \sum_e E_e \cdot T_{ec}$$

E_e , birinci katmandaki düğümlerin çıkışını; T_{ec} , ise sadece 0 veya 1 değerini alan OR’lama işlemini gerçekleyen 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, eğitim tamamlandıktan sonra bir etiketleme işlemi ile belirlenir. İkinci katman, aynı sınıfın çıkışlarını lojik olarak OR’lamak için kullanılır.

2.1 DAYSA'nın Eğitimi

Ağın eğitiminde etiketlenmemiş öznitelik vektörleri kullanılmaktadır. Bu nedenle küme, eğitici kullanılmadan dağılım istatistiğini verecek şekilde kolaylıkla büyütülebilmektedir. Görüntüdeki tüm benekler eğitim kümesi vektörlerini oluşturmak için kullanılmaktadır. Bu yaklaşım ile eğitim kümesinin istatistiksel bilgi içeriği zenginleştirilir.



Şekil 1 DAYSA'nın yapısı

Eğitim kümesinden alınan ilk öznitelik vektörü, ağın birinci düğümü olarak ele alınır. Eğitim kümesinden alınan ikinci vektör ile birinci düğüm arasında Euclidean mesafesi hesaplanır. Bu mesafe önceden belirlenen bir eşik değerinden büyükse ikinci vektör, ağın ikinci düğümü olarak ele alınır. Bu mesafe eşik değerinden küçük ise, birinci düğümün ağırlıkları (2) eşitliği kullanılarak değiştirilir.

$$w_{ji}(k+1) = w_{ji}(k) + \eta(t) \cdot (x_i - w_{ji}(k)) \quad (2)$$

Eşitlikte w_{ji} , j. düğümün i. ağırlığını; x_i öznitelik vektörünün i. elemanını göstermektedir

Eğitim kümesinden alınan her öznitelik vektörü için, öznitelik vektörü ve ağın düğümleri arasında Euclidean mesafeleri hesaplanır. Bulunan en küçük mesafe, seçilen eşik değerinden büyükse öznitelik vektörü ağın yeni düğümü olarak düşünülecektir. Aksi durumda, öznitelik vektörüne en yakın mesafedeki düğümün ağırlıkları (2) eşitliği kullanılarak değiştirilecektir. Eğitim, kümedeki tüm vektörler için analiz tamamlandığında sonlandırılır.

Aşağıda DAYSA'nın eğitim algoritması verilmiştir. İterasyon sayısı, eğitim kümesindeki vektör sayısı olarak tanımlanır. Düğüm sayacı bire eşitlenir.

Adım 1) Eğitim kümesinden bir vektör alınır ve ağın düğümü olarak atanır. İkinci katmanda düğümün ağırlığına, düğüm sayacının değerini ver.

Adım 2) Eğitim kümesinden sırayla bir öznitelik vektörü al.

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

$$D_j = \sum_{i=1}^n (x_i - w_{ji}(k))^2 \quad (3)$$

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

Adım 3) Minimum uzaklığa sahip j. düğümü bul. j. düğümün kullanım sayacını bir attır.

Adım 4) Bulunan mesafe önceden belirlenen eşik değerinden küçükse, j. düğümün ağırlıklarını aşağıdaki ifadeyi kullanarak değiştir.

$$w_{ji}(k+1) = w_{ji}(k) + \eta(t) \cdot (x_i - w_{ji}(k)) \quad (4)$$

Kazanç terimi olarak ifade edilen $\eta(t)$, 0 ile 1 arasında ve zamanla azalacak şekilde değer alır. Adım 5' git.

Aksi durumda, giriş öznitelik vektörü ağın yeni düğümü olarak atanır. Düğüm sayacının değerini bir attr. İkinci katmanda yeni düğümün ağırlığına, düğüm sayacının değerini ver.

Adım 5) İterasyon sayısını azalt. İterasyon sayısı sıfıra eşit değil ise adım 2'e git. Aksi takdirde eğitim algoritmasını durdur.

Düğüm sayısı eşik değeri ile kontrol edilmektedir. Eşik değerinin küçük tutulması çok sayıda düğüm oluşmasına sebep olacaktır. Bu durum, öznitelik uzayında dağılımın daha ayrıntılı tanımlanmasına olanak sağlar. Eşik değerinin büyük tutulması dağılımın kaba temsil edilmesine neden olur.

Eğitim tamamlandıktan sonra sınıflama işlemine geçmeden önce düğümlerin etiketlenmesi gerekir. Kullanıcı etiketleme işlemine karışmadığı durumda ağın her düğümü, bir sınıfı temsil edecektir. Ayrıca, kullanıcıya düğümleri bir sınıf altında toplanma imkanı verilmektedir.

Ağın ürettiği aşırı sayıda düğüm, kullanım sayacı tarafından kontrol edilmektedir. Düğüm kullanım sayacındaki değer, tüm vektör sayısının belirli bir oranının altında ise düğüm, ağdan çıkartılır. Böylece belirli bir yüzdenin üzerindeki topluluklar, sınıf olarak tanımlanacaktır.

3. Method:

Eğitim kümesi, görüntüdeki tüm benekler kullanılarak oluşturulur. İterasyon sayısı, görüntüdeki benek sayısı olarak belirlenir. Her bir benek için bir öznitelik vektörü oluşturulur. Bu işlemde seçilen beneğin etrafındaki gri seviyeler kullanılarak Fourier katsayıları hesaplanır. Daha sonra katsayıların mutlak değerleri alınarak öznitelik vektörü oluşturulur. Bu işlem ile elde edilen öznitelik vektörleri kullanılarak yapay sinir ağları eğitilir.

DAYS A'nın düğüm sayısını kontrol etmek için eğitime başlamadan önce bir eşik belirlenir. Eğitim algoritması, düğümler arasındaki 'euclidean' mesafenin belirli bir eşikten küçük olup olmadığını araştırır. Eşik değeri belirlendikten sonra DAYS A görüntüdeki tüm benekler kullanılarak eğitilir.

Sınıflama işleminde beneğe ait öznitelik vektörü ile ağ düğümleri arasındaki mesafe araştırılır. Öznitelik vektörüne en yakın düğüme ait etiket, beneğin etiketi olarak atanır ve bu değer kullanılarak görüntü oluşturulur.

4. Bilgisayar Sonuçları:

Şekil 2.a' da böbrek kistine ait ultrasonik görüntü gösterilmektedir. 60000 eşik değeri ile DAYS A 5 düğüm üretmiştir. Dolayısıyla, ultrasonik görüntü 5 sınıfa ayrılmıştır. Şekil 2.b'de DAYS A kullanılarak bölütlenen ultrasonik görüntü gösterilmektedir. Fourier katsayıları ile deneticisiz artımsal yapay sinir ağının birlikte kullanımı, yeni ağın sınıflama performansını arttırmıştır.

Şekil 2.c'de Kohonen ağı kullanılarak bölütlenen ultrasonik görüntü gösterilmektedir. Kohonen ağının düğüm sayısı, eğitimden önce belirlenmektedir ve 6x6 olarak seçilmiştir. Ultrasonik görüntü 5 sınıfa ayrılmıştır.


DAYS A, Kohonen ağına göre daha az düğüm ile daha yüksek sınıflama başarımı verdiği gözlenmiştir.

Kaynaklar:


- [1] Mallat S. , "A theory for multiresolution signal decomposition: The wavelet representation ", IEEE Transactions on PAMI 11, (1989) 674-693.
- [2] Reed T.R., Wechsler H., "Segmentation of texture images and gestalt organization using spatial/spatial-frequency representations", IEEE Transactions on PAMI, 12, (1990) 1-12.
- [3] Haralick R.M., Shanmugan K., Dinstein I., "Texture feature for image classification", IEEE Tran.on Systems, Man, and Cybernetics, 3, (1973) 610-621.
- [4] Kohonen T., "An introduction to neural computing", Neural Networks, vol. 1, (1988) 3-16.



Şekil. 2.a. Böbrek kistinın ultrasonık görüntüsü



Şekil. 2.b. Böbrek kist görüntüsünün DAYSA ile bölütlenmesi



Şekil. 2.c. Böbrek kist görüntüsünün Kohonen ağı ile bölütlenmesi