

ÖĞRENMELİ HÜCRESEL YAPAY SİNİR AĞI İLE MR GÖRÜNTÜSÜNÜN BÖLÜTLENMESİ

Abdullah Bal¹ Halit Pastacı¹ Osman Nuri Uçan²

¹ Elektrik Mühendisliği Bölümü, Elektrik-Elektronik Fakültesi, Yıldız Teknik Üniversitesi, 80750, Beşiktaş-İstanbul bal@yildiz.edu.tr hpastaci@yildiz.edu.tr

² Elektrik-Elektronik Mühendisliği Bölümü, İstanbul Üniversitesi, Avcılar-İstanbul uosman@istanbul.edu.tr

Anahtar Kelimeler : Hücresel yapay sinir ağı, Dinamik öğrenme algoritması, MR görüntüsü, Görüntü bölütleme


ÖZET

Dinamik yapay sinir ağlarının özel bir çeşidi olan hücresel yapay sinir ağı (HYSA), iki boyutlu bir dizi oluşturacak şekilde sıralanmış hücrelerden meydana gelmiştir. Hücre yapılarındaki ağırlık katsayı şablonları ve giriş kümesinin çıkış ile değişmesi HYSA ile ileri beslemeli ağlar (İBA) arasındaki en önemli farklılıklardır. Bu farklılıklardan dolayı HYSA'nın mimarisine uygun öğrenme algoritmalarının geliştirilmesi zorunluluğu vardır. Bu çalışmada, HYSA için geliştirilmiş dinamik bir öğrenme algoritması ve bu algoritmanın manyetik rezonans (MR) görüntüsü bölütlenmesinde kullanımı incelenmiştir. Sonuçlar Sobel ve Canny yöntemleri ile karşılaştırılmıştır.

1.GİRİŞ

Hücrelerin ağırlık katsayılarının çalışılan düzlem üzerinde değişmez bir bağlantı ağı oluşturması ve iki boyutlu filtre yapılarına benzemesi, HYSA'nın görüntü işleme ve görüntü tanıma konularında başarılı bir şekilde kullanılmasına olanak sağlamıştır. Görüntü verilerinin çok büyük rakamlar ile ifade edilebilmesine karşılık HYSA, görüntü işlemede çok hızlı bir şekilde işlem yapabilme özelliğine sahiptir. Bu özellik gerçek zamanda görüntü işlemede büyük öneme sahiptir. Ön işleme elemanı olarak görüntü bölütleme, kenar belirleme gibi özellik çıkarımında HYSA'nın kullanılabilmesi ayrıca önemli bir kullanım alanıdır. Aynı zamanda, yerel bağlantı özelliği sayesinde kolaylıkla tümleşik devre olarak da gerçekleştirilmektedir.

İleri beslemeli yapay sinir ağlarının aksine HYSA'daki her hücre yakın komşuluğundaki hücrelerle belli bir komşuluk ilişkisi altında bağlantı halindedir. Şekil-1'de her bir hücrenin sadece çevresindeki hücrelerle bağlantı halinde olduğu 4x4 boyutunda bir hücresel yapay sinir ağı görülmektedir [1-2].



Şekil-1 4x4 Boyutunda bir hücresel yapay sinir ağı gösterimi.

Bir hücresel yapay sinir ağının görüntü işlemedeki temel fonksiyonu herhangi bir giriş görüntüsünü istenilen amaca uygun olarak bir çıkış görüntüsüne dönüştürmesidir. Burada çıkış görüntüsü hücresel yapay sinir ağları ilk haliyle ele alındığında her piksel (nokta) değeri -1 ve $+1$ olacak şekilde sınırlandırılır. Ancak buna karşılık giriş görüntüleri uygun gerilim değerleri de sağlandıktan sonra, çoklu gri seviyelerine de sahip olabilirler. Verilen bir giriş görüntüsü ile başlatılan veya sürülen herhangi bir geçici rejim sonrasında, hücresel yapay sinir ağından geçirilmiş görüntü, gerekli koşullar sağlandığı takdirde her zaman bir kararlı durum sabit noktasına yakınsamaktadır.

Görüntü işleme uygulamalarının farklılık arz etmesi, HYSA'nın ağırlık şablonlarında uygulamaya yönelik değişmesini gerektirmektedir. Bu ise istenilen giriş-çıkış ilişkisini verebilecek şekilde ağırlıkların ayarlanması anlamına gelmektedir. Ayarlama işlemi için bir çok öğrenme yöntemleri geliştirilmiş ve geliştirilmektedir. Bu çalışmada ise geriye yayılım ve adimsal düşünüm algoritmalarına dayanan dinamik bir öğrenme algoritması üzerinde çalışılmıştır.


Çalışmanın ikinci kısmında, tıbbi görüntüleme de sıkça kullanılan manyetik rezonans (MR) görüntülerinin bölütlenmesi gerçekleştirilmiştir. Görüntü bölütleme, tıbbi görüntülerin işlenmesinde bir çok kullanım alanı olan önemli bir yöntemdir. Anjiogramda damar çeperlerinin tespiti, yaralardaki sertleşmelerin ölçülmesi, cerrahi gösterimler, cerrahi planlamalar, tümör tespiti, tümör hacminin ölçülmesi ve terapiye verdiği cevabın belirlenmesi, fonksiyonel haritalama, kan hücrelerinin sınıflanması, beyin gelişiminin izlenmesi gibi birçok alanda uygulamaları vardır. Tıbbi görüntüleme de ise bölütleme, özellik çıkartımı, görüntü ölçümleri ve görüntünün gösteriminde önemlidir. Kemik, kas ve kan damarlarındaki kanser, doku zedelenmesi gibi patolojik bölgeleri ayırmada kullanılır.

Radyasyon terapisinde ise amaç tümöre radyasyon vererek tümörü yok etmektir. Bu işlem esnasında

tümörün etrafındaki sağlıklı organların radyasyon almaması gerekmektedir. Bunun için tümör şeklinin, boyutlarının, çevresinin tam olarak belirlenmesi ve radyasyon ışınlarının konfigürasyonunun bu sonuçlara göre optimum olarak ayarlanması istenir [3,4,5] Bu işlem manuel olarak yapıldığı gibi otomatik olarak yapılması üzerine birçok algoritmalar geliştirilmektedir. Sunulan çalışma ile MR bölütleme için kenar belirlemede öğrenmeli HYSYA'nın kullanımı ve performans analizi yapılmıştır.

2. HÜCRESEL YAPAY SİNİR AĞI

Hücresel yapay sinir ağlarındaki her bir hücre ağırlıklı toplama yapan doğrusal bir giriş birimi, doğrusal dinamik bir ara birim ve n parçalı (genellikle üç parçalı) orjine göre simetrik bir çıkış biriminden oluşan mimariye sahiptir (Şekil 2).



Şekil 2 Bir HYSYA hücresinin dinamik yapısı

Şekil 2'de görünen HYSYA hücre mimarisinin matematiksel bağıntısı şu şekilde ifade edilir:

$$x_{i,j}(n+1) = \sum A y_{i,j}(n) + \sum B u_{i,j} + I \quad (1)$$

$$y_{i,j}(n) = \frac{e^{x_{i,j}(n)} - e^{-x_{i,j}(n)}}{e^{x_{i,j}(n)} + e^{-x_{i,j}(n)}} \quad (2)$$

Bu ifadede $u_{i,j}$ başlangıç görüntüsü, $y_{i,j}(n)$ kararlı durumdaki çıkış görüntüsü, A ve B şablon katsayıları, I eşik değerine karşılık gelmektedir.

Bu mimarinin ilk ortaya çıkışı devresel bir gösterim ile olmuştur. Bu devredeki hücrelerin her biri doğrusal ve doğrusal olmayan dirençler, kapasiteler, akım ve gerilim kontrollü kaynaklar içerirler. Teorik açıdan hücresel yapay sinir ağları çok boyutlu olarak tanımlanabilmelerine rağmen bu çalışmada özellikle görüntü işleme uygulamaları üzerinde durulduğundan tek hücre yapısı kullanılmıştır. Ancak istenildiği takdirde elde edilen sonuçlar kolaylıkla daha yüksek boyutlu durumlara genelleştirilebilir.

3. DİNAMİK ÖĞRENME ALGORİTMASI

HYSYA mimarisinin uygulama alanına göre belirlenmesi gereken A,B şablonları ve uygun I eşik değeri için geliştirilen dinamik öğrenme algoritmasında İBA'da geniş kullanımı olan geriye yayılım ve adimsal düşünme algoritmalarından yararlanılmıştır. Adimsal düşünme algoritmasında aktivasyon fonksiyonunun türevine gerek duyulduğundan dolayı HYSYA çıkış fonksiyonu yerine hiperbolik tanjant sigmoid fonksiyonu tercih edilmiştir. HYSYA mimarisinde $y(n+1)$ çıkışı durumunda $y(n)$ giriş olarak kullanılmasından dolayı öğrenme aşamasında hata minimuma yakınsayamamaktadır. Bu problemi çözmek için başlangıç giriş değeri olan $x_{i,j}^2$ girişi her işlem adımında sabit giriş olarak alınmıştır.

A ve B şablon değerlerinin geriye yayılım ile optimum olarak ayarlanması için bağlantı ağırlık katsayıları matrisi ω vektörü (7)'deki gibi seçilmiştir.

$$A = \begin{bmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_6 \\ a_7 & a_8 & a_9 \end{bmatrix} \quad (3)$$

$$B = \begin{bmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_6 \\ b_7 & b_8 & b_9 \end{bmatrix} \quad (4)$$

$$a_1 = a_9, a_2 = a_8, a_3 = a_7, a_4 = a_6 \quad (5)$$

$$b_1 = b_9, b_2 = b_8, b_3 = b_7, b_4 = b_6 \quad (6)$$

$$\omega = [a_1 \ a_2 \ a_3 \ a_4 \ a_5 \ b_1 \ b_2 \ b_3 \ b_4 \ b_5 \ I]^T \quad (7)$$

Burada A ve B filtreleri 3 x 3'lük olmalarına karşılık simetri kabulü yapılmış ve (5) ve (6) eşitlikleri kullanılarak ayarlanması gereken ağırlık katsayıları 19 yerine 11'e indirgenmiştir [6-7].

Geriye yayılım algoritmasındaki ortalama karesel hata ifadesi şu şekildedir:

$$E(\omega) = \frac{1}{2} \sum_N \sum_{i,j} (y_{i,j}^k(\infty) - t_{i,j}^k)^2 \quad (8)$$

Yaklaşık ortalama karesel hata için adımsal düşüm algoritmasının ağırlık güncelleme ifadesi:

$$\omega(k+1) = \omega(k) - \alpha \cdot \frac{\partial E(\omega)}{\partial \omega^k} \quad (9)$$

şeklinde dir.

Kısmi türevin bulunmasında zincir kuralı kullanarak:

$$\frac{\partial E(\omega)}{\partial \omega^k} = (y_{i,j}^k(\infty) - t_{i,j}^k) \frac{\partial y_{i,j}^k(\infty)}{\partial \omega^k} \quad (10)$$

$$\frac{\partial y_{i,j}^k(\infty)}{\partial \omega^k} = \frac{\partial F(x_{i,j}^k(\infty))}{\partial x_{i,j}^k(\infty)} \frac{\partial x_{i,j}^k(\infty)}{\partial \omega^k} \quad (11)$$

bulunur. Burada kullanılan F fonksiyonu hiperbolik tanjant fonksiyonudur. Bu fonksiyon ile HYSA'nda kullanılan çıkış y fonksiyonu hemen hemen aynı kabul edilmiştir.

$$F(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (12)$$

$$\frac{\partial F(x_{i,j})}{\partial x_{i,j}} = \frac{4}{(e^{x_{i,j}} + e^{-x_{i,j}})^2} \quad (13)$$

$$\frac{\partial x_{i,j}^k(\infty)}{\partial \omega^k} = Y_{i,j}^k \quad (14)$$

Bu eşitlikler ışığında (9) ifadesi şu şekilde yazılabilir:

$$\omega(k+1) = \omega(k) - \alpha Y_{i,j}^k \cdot \frac{4}{(e^{x_{i,j}^k} + e^{-x_{i,j}^k})^2} (y_{i,j}^k(\infty) - t_{i,j}^k)$$

$y_{i,j}(\infty)$ kararlı durum çıkışı ile hedeflenen çıkış t_{ij} arasındaki hatanın sıfır olması durumunda algoritma sonuçlanır [8].

4. MR GÖRÜNTÜSÜNÜN BÖLÜTLENMESİ


Dinamik öğrenme algoritması ile gerçekleştirilen eğitim işlemi sonucunda bulunan A,B ve I değerleri aşağıda verilmiştir.

$$A = \begin{bmatrix} -0.2036 & -0.3922 & -0.2036 \\ -0.4100 & -3.3761 & -0.4100 \\ -0.2036 & -0.3922 & -0.2036 \end{bmatrix}$$


$$B = \begin{bmatrix} 0.0357 & -0.0726 & -0.0357 \\ -0.0726 & -0.0363 & -0.0726 \\ 0.0357 & -0.0726 & 0.0357 \end{bmatrix}$$

$$I = -0.6239$$

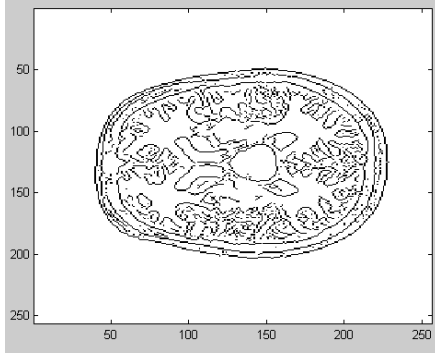
Bu katsayıların kullanımı ile insan kafasına ait MR görüntüsünün kenarlarının belirlenmesi ve özellikle ortadaki ventriküler yapının ortaya çıkarılması sağlanmıştır. Bulunan sonuçlar Canny ve Sobel yöntemlerinin sonuçları ile karşılaştırmalı olarak Şekil 3'de verilmiştir.




a)



b)



c)



d)

Şekil-3. a) 256 x 256 insan kafasına ait MR görüntüsü
b) HYSA sonucu, c) Canny sonucu, d) Sobel sonucu

5-SONUÇLAR

Bu çalışmada, tıbbi görüntülerin bölütlenmesine yönelik HYSA için dinamik öğrenme algoritması geliştirilmiş ve manyetik rezonans görüntüsü üzerinde uygulama gerçekleştirilmiştir. Elde edilen sonuçlar ile klasik kenar belirleme sonuçları karşılaştırıldığında dinamik öğrenme algoritmalı HYSA'nın başarılı olduğu görülmüştür. HYSA'nın öğrenmeli yapısı, klasik yöntemlere göre önemli bir avantaj sağlamaktadır. Bu avantaj kullanılarak tıbbi görüntü işlemenin diğer alanlarında da başarılı bir şekilde kullanılabilceği bu çalışma ışığında söylenebilir.

KAYNAKLAR

[1] CHUA, L. O. ve YANG, L.,(1988) 'Cellular Neural Networks: Theory', Ieee Transactions On Circuits and Systems, 35, (10), pp. 1257 – 1272.

[2] CIMAGALLI V., (1993), "Cellular Neural Networks: A Review", Proceedings Of Sixth Italian Workshop on Parallel Architectures and Neural Networks, Vietri Sul Mare, Italy, 1-31.

[3].BANKMAN, I. N., Handbook of Medical Imaging, (2000), Academic Press, London, UK

[4]. BECK, R.M, DOLLE, M., HOFER, H., PERNER, P., HEYWANG, S.H. (2001), "High Performance Implementation of a Similarity-Based Image Segmentation Algorithm for Brain/Liquor Determination Automatic Segmentation of CT-Scans to Determine Brain/Liquor Ratios", Image Processing and Parallel Computing in Medical Applications, 37-43

[5]. BEOLCHI, L., KUHN, M. H., (1995), Medical Imaging, IOS Press, USA

[6]. GÜZELİŞ C., and KARAMAHMUT S., 'Recurrent perceptron learning algorithm for CNNs with application to edge detection', IEEE Int. Conf. Neural Networks '95, pp.1134-1139, Perth, December 1995

[7] ÇELEBİ, M.E.and GÜZELİŞ, C., 'Image Restoration Using Cellular Neural Network', Electronic Letters, 1997, 33,(1), pp. 43-45

[8]. HAGAN, T.M., DEMUTH, H. B. and BEALE, M, Neural Networks Design, 1995, PWS Publishing Company, Boston, USA