

SÜLEYMAN DEMİREL ÜNİVERSİTESİ
MÜHENDİSLİK - MİMARLIK FAKÜLTESİ

IX. MÜHENDİSLİK SEMPOZYUMU

ELEKTRONİK VE HABERLEŞME
MÜHENDİSLİĞİ BİLDİRİLERİ KİTABI

(29-31 MAYIS 1996)

ISPARTA

Yaklaşımı	
E. KARAKAŞ, E. ÖZDEMİR	93
Histerzis Çevrimli Endüktans İçeren Devrelerin Analizi	
S.HERDEM, Y.DEMİR, M.KÖKSAL	101
Seri Uyartımlı Senkronlanan Motorda En İyi Performansın Elde Edilmesi	
M. İ.BAYINDIR, M.ÖZDEMİR	107
DC Motorlarla Gerçeklenen, Adım Motorlarına Alternatif İki Eksenli	
Pozisyonlama Sistemi	
B. KARAGÖZ, E. ÖLÇER	113
Fi dönüşümünün 2 Boyuta Genelleştirilmesi	
İ. ERER	119
Lineer Bir Devrenin Transfer Foksiyonunun Bulunmasına Yeni Bir Yaklaşım:	
Extra Eleman Yöntemi	
A.B.YILDIZ, N.ABUT	125
Ayrık Devre Modellerine Dayalı Düğüm Yöntemini Kullanarak Güç	
Elektronığı Devrelerinin Analizi	
A.B.YILDIZ, N.ABUT, M.Z.BİLGİN	129
Altı Serbestlik Derecesine Sahip Bir Atalet Sensörün MLP Kullanılarak	
Modellenmesi	
Ş.SAĞROĞLU, C.ÇİFTLİKLİ	135
İnterpolasyonsuz Bilgisayarlı Tomografi	
A.GÖNÜLLÜ, S.KENT	141
Difraksiyon Tomografisi için Wavelet Teorisine Dayalı Bir Çözüm	
İ.ERER, M.KARTAL	145
Transformatörlerin Histerzis Karakteristiklerinin Elde Edilmesinde	
Eri Belirleme Yöntemi	
O.ÇERTEZCİ, N.YUMUŞAK, M.S.FIRAT	149
Yüksek Frekanslarda Transformatörlerin Durum Uzak Denklemleri	
İle Modellenmesi	
O.ÇERTEZCİ, N.YUMUŞAK, M.S.FIRAT	155
Elektrik Ark Fırlanının Şebeke Üzerinde Etkileri	
İ.GÜNEY	161
Yarısmacı Öğrenme Kuralları İle Bozuk Örüntüleri Tanıma	
İ.Türkoğlu, A.ARSLAN	165
Yapay Sinir Ağlarının Kontroldeki Yeri	
M.İNAL, K.ERKAN, E.BÜTÜN	171
Klasik Denetleyiciler Ve Bulanık Denetleyiciler	
N.ABUT, B.ÇAKIR	177
Bir Otomatik Kazanç Ayarlı P.I.D. Denetleyici Uygulaması	
M.TÜRE, T.AYDIN	183
İç Aydınlatma Aygıtlarının Otomatik Kontrolü	
S.FADİL, N.KANDEMİR	189
Toplamalı Asansör Sistemlerinde Kat Bilgisinin Mikrodenetleyici İle Tesbiti	
M.KARA, S.BOZKURT	195
Elektrik Sayaçlar İçin Bilgisayar Destekli Test Sistemi	
H.M.SERT, M.ALTUNER	201
Nesne Birleştirme İçin İki Yöntem	
A.ARSLAN, A.ÇINAR	205
İşaret Modellemesi İçin Optimum Wavelet Analiz Fonksiyonlarının Kullanımı	
İ.ERER, T.GÜNEL	211

YARIŞMACI ÖĞRENME KURALI İLE BOZUK ÖRÜNTÜLERİ TANIMA

İbrahim TÜRKOĞLU*, Ahmet ARSLAN**

*Fırat Üniversitesi Müh. Fak. Elk-Elektronik Müh. Böl., 23119 ELAZIĞ

**Fırat Üniversitesi Müh. Fak. Bilgisayar Müh. Böl., 23119 ELAZIĞ

Özet: Örüntü tanıma problemine olan ilgi, Yapay Sinir Ağları (YSA) ve bilgisayar teknolojisinin gelişmesi ile, son yıllarda hızlı bir şekilde artmıştır. Özellikle YSA'nın geniş boyutlardaki matematiksel işlem kapasitesinin olması bunda etken olmuştur. YSA'nın bu işlem kapasitesini elde etmek için çeşitli YSA modelleri geliştirilmiştir. Bunların en tanınmış olanları; Grossberg'in uyarlamalı rezonans kuramı (ART) modeli, Kohonen'in kendini düzenleme haritası, Hopfield ağı, çok katmanlı algılayıcı ve Widrow'un ADALINE modelleridir.

Örüntü tanıma işlemi ise; algılanan örüntülerin daha önce tanımlanmış bir veya birden fazla kategoriye göre sınıflandırılmasıdır.

Bu çalışmada, yarışmacı öğrenme (Competitive Learning) kuralını kullanan Kohonen'in kendini düzenleme haritasının YSA modelinin bilgisayar simülasyonu gerçekleştirilecektir. Bu modele, bozuk olmayan alfabetik örüntüler öğretilecek ve sonrada bu örüntülerin bozuk (gürültülü veya eksik) halini tanıyabilmesi test edilecektir.

NOISY PATTERN RECOGNITION WITH COMPETITIVE LEARNING RULE

Abstract : In recent years, the interest to pattern recognition is increased rapidly due to the development of Artificial Neural Network (ANN) and computer technology. Especially, the large processing capabilities of the ANN are become effective in this area. A number of ANN models are developed to provide the processing capabilities of the ANN. Some of these models are; Grossberg's Adaptive Resonance Theory (ART) model, Kohonen's Self-organizing feature maps, Hopfield Network, Multilayer Perceptron and Widrow's Adaline models.

Pattern recognition is the classification of sensed samples in the defined categories.

In this study, the computer simulation of Kohonen's Self-organizing feature map is implemented by using competitive learning rules. The non-noisy alphabetic samples is learned to this model and then the recognition capabilities of this model are tested for noisy or non-complete samples.

Giriş

Alışlagelmiş bilgisayarların bir karakteristiği, istenen çıkışı üretmek için, tam olarak doğru girişlere ihtiyaç göstermeleridir. Öte yandan YSA'ları girişlerinde değişimler olsa bile doğru çıkışı üretebilirler. Yani, sistem daha önceden tam o tipten hiçbir şey görmemiş olmasına rağmen, aynen insanlar gibi tanıyam olmayan örüntüleri (harf, rakam, ...v.s.) tanıyabilmektedir. Çalışmalar insanların çoğunun bir metindeki harflerin yansıdan fazlası silinmiş olsa bile, o metni okuyabildiğini göstermiştir (Özmetler, 1989).

YSA modelleri üzerinde, yapay zekanın çeşitli alanlarında insanunkine yakın bir davranış elde etmek amacı ile yıllardır çalışılmaktadır. Bir YSA, insan sinir sisteminin bazı fonksiyonlarını modelleyen ve onun bazı yeteneklerini yakalayarak işleyen basit işlem elemanlarının (nöronların) yoğun bir paralel dizisidir. Her bir işlem elemanı, belirli sayıda ki basit sayısal bilgileri girdi olarak almakta ve basit sayısal bilgi olarak çıktı üretmektedir. Birçok işlem elemanı çıkışı, diğer işlem elemanları için girdi olarak kullanılarak geniş yapay sinir ağları meydana getirilir. YSA'larının bu çok büyük boyutlardaki işleme yeteneğine sahip olduğunun anlaşılması üzerine, özellikle örüntü ve ses tanıma problemlerine olan ilgide artış meydana gelmiştir.

YSA ile yapılan örüntü tanıma işlemi iki aşamadan meydana gelir. İlk aşamada, örüntü ile ilgili çeşitli bilgileri içeren öznitelik vektörü çıkarılır. İkinci aşamada ise, çıkarılmış bulunan bu öznitelik vektörü sınıflandırmayı sağlamak için YSA'na verilir.

Şimdiye kadar en azından 50 tane farklı YSA modeli araştırmalarda keşfedilmiş veya uygulamalar için geliştirilmiştir. Bunların her biri belli uygulama alanlarında başarılı olmuşlardır (Özmetler, 1989).

YSA ile örüntü tanıma işleminde, YSA örüntünün öznitelik vektörünü göz önüne alarak kendisine en yakın özniteliklere sahip olan sınıfa dahil eder. Yani tanıma

işlemi aslında, örüntülerin sınıflandırılmasından çok farklı bir işlem değildir (Taşkiran v.d., 1993).


Çoğu örüntü tanıma çalışmalarında karşılaşılan önemli problemler; gürültü ve örüntünün bir kısmının herhangi bir nedenden dolayı gözükmemesidir. Bu problemler, nedeni ile örüntü tanımada, klasik scri programlama teknikleri ile genelde yeterli başarı sağlanamamaktadır. YSA'ları ise insan sinir sistemine benzer bir yapı sergilediklerinden dolayı, tanıma işlemi için umut vericidir (Ünlüakın ve Gürgen, 1993).

Bu çalışmada da, YSA'larının yukarıda bahsedilen üstünlüklerinden ötürü örüntü tanımada karşılaşılan problemlere uygulanarak başarılı sonuçlar elde edilmiştir.

Metot

Genel olarak örüntü tanıma yaklaşımları istatistiksel ve geometriksel olmak üzere ikiye ayrılır (Karlık ve Pastacı, 1993). Herhangi bir örüntüyü tanımlama işlemini de genel olarak iki kısımda inceleyebiliriz; tanınması istenen örüntünün ilk önce öznitelik vektörü çıkarılır daha sonra ise bu öznitelik vektörü YSA'na verilerck sınıflandırılıp örüntünün tanınması sağlanır. Bu çalışmamızda istatistiksel örüntü tanıma yaklaşımını, eğitimcisz (unsupervised) öğrenme ve ikili özellik çıkarımına uyguladık.

İstatistiksel yaklaşım, örüntü tanıma algoritmaları için temel teşkil etmektedir. Aynı sınıfa ait örüntüler istatistiksel olarak tanımlanan benzer özelliklere sahiptir. İstatistiksel yaklaşımda, özniteliksel olarak nitelendirilen karakteristik ölçümler örüntü örneklerinden çıkarılır. Her örüntü bir vektör ile tanımlanır (Türkoğlu, 1995). Örnek olarak 5x5 boyutunda matrisel yapıya sahip olan A alfabetik örüntüsü için öznitelik vektörünün çıkarımı şekil 1' de gösterildiği gibidir.



$V_i = \{ \begin{array}{l} 1, \text{ Eğer şekil kesiyorsa} \\ 0, \text{ Diğer durumlarda} \end{array} \}$

$V_i = [1, 1, 1, 1, 1, 0, 0, 0, 1, 1, 1, 1, 1, 1, 1, 0, 0, 0, 1, 1, 0, 0, 0, 1]$

Şekil 1. A alfabetik örüntüsü ve öznelik vektörü


Örüntü sınıflandırıcısı ise, herhangi bir örüntünün çeşitli özelliklerini (öznelik vektörü gibi) göz önüne alarak kendisine en yakın özelliklere sahip olan sınıfı bulur. Örüntü tanıma sisteminde sınıflandırıcı olarak yarışmacı öğrenme kuralını kullanan Kohonen'in kendi kendini düzenleyen öznelik haritaları kullanılmıştır.

Yarışmacı kategoriye bağlı öğrenme kurallarının hepsinde ortak özellik bir yarışma stratejisinin işlem elemanlarının tamamına veya bir kısmına uygulanmasıdır. Bu yarışma sonucu kazanan işlem elemanının ağırlıkları değiştirilir.

Kendi kendini düzenleyen öznelik haritaları, eğitici olmadığı durumlarda giriş sinyallerinin analizi ve kodlanması için otomatik bir metottan meydana gelir. Kohonen, kendini düzeltme işlemini bir YSA olarak ortaya koymuştur. Bu yapay sinir ağında topolojik olarak benzer girişler, topolojik olarak birbirine yakın çıkışlar üretir. Kohonen'in kendi kendini düzenleyen öznelik haritası, giriş sinyallerinin çeşitli özelliklerinin düzenlenmiş iç gösterimini oluşturan özel niteliklere sahiptir. Bu algoritma aynı zamanda yarışmacı öğrenme olarak adlandırılır. Yarışmacı öğrenme, örüntü setini sınıflandırılabilir için kullanılabilen belirgin ve genel özellikleri keşfetmek için bir yöntem sağlar (Duda ve Hart, 1989).


Basit işlem elemanlarından oluşan Kohonen YSA şekil 2'de gösterildiği gibidir. Burada N çıkış işlem elemanı ($z_1, z_2, \dots, z_N$) sayısı, $X_i = (x_1, x_2, \dots, x_n)$ n boyutlu

giriş örüntü vektörü, $W_i = (w_{i1}, w_{i2}, \dots, w_{in})$ her çıkış işlem elemanının ağırlık vektörü olup, w_{ij} ise x_j girişi ile i. işlem elemanı arasında ki ağırlıktır.



Şekil 2. Kohonen'in kendi kendini düzenleme haritasının ağ birimleri

Ağırlık vektörünün başlangıç değerleri keyfi seçilebildiği gibi, ilk giriş örüntü vektörü ağırlıklar olarak alınabilir. Temelde Kohonen YSA'ı, her çıkış birimine (bu birimlere sınıf da diyebiliriz) giriş vektörünün her elemanının bağlanması ile meydana gelir. Böylece farklı çıkış birimleri farklı girişlere duyarlı hale gelebilir. Kohonen YSA sistem modelinin topolojik yapısı şekil-3 de gösterilmiştir. Şekilden de görüleceği üzere kendini düzenleyen nitelik haritaları yalnız bir katmana (çıkış katmanına) sahiptir.



Şekil 3. Kohonen sistem modelinin topolojik yapısı

Kohonen işlem elemanının giriş yoğunluğu:


$$I_i = D(w_i, x)$$

$D(u, v)$: Uzaklık ölçüm fonksiyonu

Öklit uzaklığı

$$D(u - v) = |u - v| = \sqrt{(u - v)^2}$$

Her bir işlem elemanının giriş yoğunluğu hesapladıktan sonra bir yarışma ile en küçük giriş yoğunluğuna sahip olan eleman bulunup çıkışı $Z_i = 1$ yapılır. Kohonen YSA'nın dışarıya cevabı tek bir nöron üzerinde yoğunlaşmış olmasına rağmen, fazla sayıda geri besleme bağlantısı sonucu oluşan etkileşimler ile çıkış belirlenir. Komşu nöronlar arasında yerel bir etkileşim vardır. En yakın komşular birbirini pozitif yönde etkilerken, diğer yandan birbirinden uzak komşuluktaki nöronlar birbirlerini negatif olarak etkilerler. Bu tip etkileşime "Meksika şapkası fonksiyonu" denir (şekil 4).



Şekil 4. Meksika şapkası fonksiyonu

Aşağıda Kohonen'in kendini düzenleyen nitelik haritasını sağlayan algoritmanın işlem adımları verilmiştir :

- 1 - Ağırlık vektörlerini başlangıç değerlerine ayarla ve komşuluğun ilk yarıçap (eşik) değerini belirle.
- 2 - Yeni giriş örüntüsünü uygula.
- 3 - Öklit uzaklık formülünden yararlanarak giriş ile her j çıkış değeri arasındaki dj mesafelerini hesapla.

$$dj = \sum_{i=1}^N [X_i(t) - W_{ij}(t)]^2$$

$X_i(t)$: X'in i. elemanının t anındaki değeri

$W_{ij}(t)$: i.girişten j.çıkış düğümüne olan ağırlığın t anındaki değerini göstermektedir.

- 4 - Minimum dj öklit mesafesine sahip j.çıkış düğümünü seç.
- 5 - j düğümüne ve komşularına ait ağırlıkları yeniden hesapla. Yani ağırlıklar;

yanışmayı kazanan örüntüler için

$$W_{ij}(t+1) = W_{ij}(t) + \alpha(t) \cdot [X_i(t) - W_{ij}(t)] \quad \forall i \in N_c(t)$$

yanışmayı kaybeden örüntüler için

$$W_{ij}(t+1) = W_{ij}(t) \quad \forall i \in N_c(t)$$

$\alpha(t)$: Zamanla azalan bir karar terimidir. ($0 < \alpha < 1$)

$N_c(t)$: Zamanla değişen komşuluk kümesi


6 - Adım 2'ye giderek tekrarla (Zurada, 1992).

Bozuk Alfabetik Örüntüleri Tanıma Amacı İle Geliştirilen Program

Giriş örüntüleri 5x7 matris formundaki veri tabanına yerleştirilen 26 temel alfabetik karakter örüntülerinin bozuk olmayan biçimlerini öğrendikten sonra, bu alfabetik örüntülerin bozuk (eksik veya gürültülü) biçimlerini tanıyabilecek bir YSA programı geliştirilmiştir. Her bir örüntü 35 kare içine yerleştirildiğinden giriş örüntü vektörünün boyu $n=35$ olup, çıkış katmanında işlem elemanı (sınıf) sayısı $N=26$ kadardır.

Böylece her giriş örüntüsü için çıkışta 26 değişik değer üretilmektedir. Bu değerler giriş örüntüsünün her karakter sınıfına olan öklit uzaklığıdır. Dolayısı ile giriş örüntüsü, aralarında minimum minimum öklit uzaklığı bulunan sınıfa dahil edilerek tanımlanır.

Giriş örüntüleri 5x7'lik veri tabanının üzerinde mouse ile simüle edilerek YSA'na girdi olarak verilmiştir. Bu model esas alınarak alfabetik örüntülerin eğitilmiş YSA tarafından tanınabilmesi için, Borland C++ programlama dilinde bir program geliştirilmiştir. Şekil-5 de geliştirilen programın akış şeması verilmiştir.



Şekil 5. Kohonen YSA'da örüntü tanıma programının akış diyagramı

Bozuk Örüntü Tanıma Deneyleri ve Elde Edilen Sonuçlar

Geliştirilen bilgisayar programında şekil-6 daki örüntüler YSA'na giriş olarak verilmiş ve başarılı sonuçlar alınmıştır. Şekildeki ilk sütun örüntünün bozuk olmayan hali olup, diğer sütünlardaki örüntüler bozuk olanlardır. Her örüntünün altında o örüntünün en çok benzediği örüntüler (veya sınıflar) yüzde olarak belirtilmiştir.


Sonuç

Bu çalışmada 5x7'lik bir giriş veri tabanı oluşturularak, şimdiye kadar daha çok eğitici (supervised) YSA ve klasik yöntemler ile yaklaşılacak örüntü tanıma problemine, eğitici (unsupervised) bir YSA olan Kohonen'in kendini düzenleyen haritası ile yaklaşmıştır. Gerçekleştirilen bu sistem ile gürültülü ve eksik örüntüler yüksek oranlarda tanınabilmektedir. İlk aşamada, veri tabanında oluşturulan alfabetik örüntüler %100 oranında YSA'ya öğretilmiştir. Daha sonra ki

aşamada ise veri tabanından YSA'na verilen örüntülerde %34 oranında meydana gelen bozulmalara rağmen örüntü doğru bir şekilde tanınmıştır. Bu haliyle eğitici YSA'ları örüntü tanıma için umut vadecidirler.

Kaynaklar

- Duda, R.O., Hart, P.E. 1989. Pattern Classification and Scene Analysis. Stanford Research Institute. California - U.S.A. (Kitap)
- Karlık, B., Pastacı, H. 1993. Yapay Sinir Ağlarında T/C Tanıma Problemi. Elektrik Mühendisliği 5. Ulusal Kongresi (Bildiriler Kitabı). TRABZON. s. 847-852.
- Öztemerler, E. 1989. Yapay Nöral Ağları. Yüksek Lisans Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü. İSTANBUL.
- Taşkıran, C., Göktürk, M., Morgül, A. 1993. İmgelerin Bilgisayar Ortamında Otomatik Olarak Sınıflandırılması ve Tanınması. Elektrik Mühendisliği 5. Ulusal Kongresi (Bildiriler Kitabı). TRABZON. s.819-823.
- Türkdoğan, İ. 1995. Nesne Tanımaya İlişkin Yaklaşımların İncelenmesi. Yüksek Lisans Semineri, F.Ü. Fen Bilimleri Enstitüsü. ELAZIĞ.
- Ünlüakın, A.U., Gürgeç, F.S. 1993. Yapay Nöron Ağları ile Klasik Sınıflandırma Teknikleri Arasında Bir Karşılaştırma. Elektrik Mühendisliği 5. Ulusal Kongresi (Bildiriler Kitabı). TRABZON. s.275-278.
- Zurada, M.J. 1992. Introduction to Artificial Neural Systems. West Publishing Company. New York. U.S.A. (Kitap)

				
%100 A %87 H	%75 A %65 R	%81 A %67 H	%87 A %74 H	%50 A %45 O
				
%100 C %83 E	%74 C %70 L	%67 C %56 L	%81 C %67 E	%50 C %45 D
				
%100 E %85 C	%75 E %70 S	%69 E %64 C	%75 E %60 C	%55 E %40 H
				
%100 K %58 M	%86 K %53 M	%75 K %50 M	%80 K %55 C	%64 K %51 F
				
%100 Z %60 C	%83 Z %57 C	%65 Z %55 X	%78 Z %55 G	%50 Z %40 X

Şekil 6. Bazı bozuk örütüler ve YSA tarafından tanınma yüzdeleri