

İYONOSFER RADAR YANSIMASININ İSTATİSTİKSEL SİNİR AĞLARI İLE SINIFLANDIRILMASI

Bülent BOLAT¹

Tülay YILDIRIM²

^{1,2}Elektronik ve Haberleşme Mühendisliği Bölümü

Elektrik-Elektronik Fakültesi

Yıldız Teknik Üniversitesi, 34349, Beşiktaş, İstanbul

¹e-posta: bbolat@yildiz.edu.tr

² e-posta: tulay@yildiz.edu.tr

Anahtar Sözcükler: Radyal Tabanlı Fonksiyon Ağları, Genel Regresyon Ağları, Olasılıksal Ağlar, Temel Bileşen Analizi

ÖZET

Bu bildiride iyonosfer radar yansımaları istatistiksel sinir ağları ile sınıflandırılmıştır. İlk aşamada Radyal Tabanlı Fonksiyon Ağları, Genel Regresyon Ağları ve Olasılıksal Ağlar iyonosfer verisi ile eğitilmiş ve sonuçlar karşılaştırılmıştır. Daha sonra, veri üzerinde Temel Bileşen Analizi uygulanarak giriş verisinin boyutu %56 azaltılarak ağların boyutu küçültülmüş, bu küçülmeye karşılık ağların doğruluklarının göreceli olarak az miktarda değiştiği gösterilmiştir.

1. GİRİŞ

Bu çalışmada, iyonosfer radar yansıma veri seti [1,2], farklı istatistiksel yapay sinir ağları ile sınıflandırılmış ve sonuçlar irdelenmiştir. İyonosfer radar yansıma veri seti Goose Bay Labrador, Kanada'daki bir radar istasyonunda yapılan gözlemler ile elde edilmiştir. Radar sistemi toplam gücü 6.4 KW olan yüksek frekanslı bir anten dizisinden oluşmaktadır. Anten dizisinin hedefi, atmosferin iyonosfer tabakasındaki serbest elektronlardır. Toplanan veri "iyi" ve "kötü" olarak etiketlenen iki grupta toplanmıştır. İyi radar dönüşleri, atmosferdeki serbest elektronların oluşturduğu belirli örüntülerin varlığını göstermektedir. Kötü dönüşler ise bu örüntülerin yokluğunu gösterir.

İyonosfer veri kümesi üzerine yapılmış geçmiş çalışmalarda çeşitli yapay sinir ağı yapıları kullanılmıştır. Aha ve Kibler [3] C4 algoritması ile %94, IB3 algoritması ile %96.7 doğruluk oranına ulaşıldığını bildirmiştir. Destek Vektör Makinesi kullanan Vincent ve Bengio [4] doğru sınıflama oranını %93.4 olarak elde etmiştir. En yüksek doğruluk ise Yıldırım ve Özyılmaz [5] tarafından Konik Kesit Fonksiyonlarını kullanarak %97.7 olarak elde edilmiştir. Bu çalışmada Radyal Tabanlı Fonksiyon Ağları, Genel Regresyon Ağları ve Olasılıksal Ağlar kullanılarak karşılaştırma yapılmıştır.

2. RADYAL TABANLI FONKSİYON AĞLARI

Radyal tabanlı fonksiyon ağlarında (Radial Based Functions - RBF) temel fikir, bir grup radyal taban fonksiyonu istenen f fonksiyonuna yaklaşacak şekilde ağırlıklandırılarak toplamaktan ibarettir [6]. RBF üç katmanlı bir yapıdır. Giriş katmanı giriş vektör uzayı ile, çıkış katmanı da örüntü sınıfları ile ilişkilidir. Böylelikle tüm yapı, gizli katmanın yapısı ve gizli katman ile çıkış katmanı arasındaki ağırlıkların belirlenmesine indirgenir. Gizli katmandaki nöronların aktivasyon fonksiyonları bir C_j merkezi ve σ_j bant genişliği ile belirlenir. Aktivasyon fonksiyonu,

$$\varphi_j(X) = \exp\left(-\frac{\|X - C_j\|^2}{2\sigma_j^2}\right) \quad (1)$$

eşitliği ile tanımlanan bir Gauss eğrisidir. Çıkış katmanındaki j. nöronun çıkışı için genel eşitlik ise şu şekildedir:

$$s_j(X) = \sum_{i=1}^K w_{ij} \varphi_i(X) + b_j \quad (2)$$

Burada w_{ij} gizli nöron i ve çıkış nöronu j arasındaki ağırlık katsayısıdır [7].

3. GENEL REGRESYON SİNİR AĞLARI

Genel regresyon sinir ağları (General Regression Neural Networks - GRNN) RBF ağlarının merkez ve bant genişliklerinin eğitime verisinin deterministik fonksiyonları olarak belirlendiği özel bir durumdur. Başka bir deyişle, bu tür ağlarda eğitim için iteratif yöntemler kullanılmaz.

GRNN ağlarda bir x_i eğitime girişi, ağdaki Gauss çekirdeklerden birinin merkezi olarak atanır. Herhangi

bir giriş vektörü x için i . RBF biriminin çıkışı şu şekilde hesaplanır:

$$\beta_i = \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \quad (3)$$

Burada σ kullanıcı tarafından belirlenen yumuşatma parametresidir. Herhangi bir x girişi için ağırlık çıkışı y şu şekilde hesaplanır:

$$y = \sum_{i=1}^K \alpha_i y_i \quad (4)$$

Burada α katsayıları şu şekilde hesaplanır:

$$\alpha_i = \frac{\beta_i}{\sum_{i=1}^K \beta_i} \quad (5)$$

Eğer giriş vektörü x , herhangi bir x_i eğitme vektörüne yakın ise, x_i 'ye ilişkin α_i en büyük olacak ve istenen çıkış y , x_i 'ye ilişkin y_i çıkışına yaklaşacaktır [8].

4. OLASILIKSAL SINIR AĞLARI

Olasılıksal sınır ağları (Probabilistic Neural Network - PNN) Bayes-Parzen kestiriciler olarak da bilinir. K_1 ve K_2 sınıflarından birine ait, m -boyutlu bir x vektörü olsun. K_1 ve K_2 sınıflarına ait olasılık yoğunluk fonksiyonları $F_1(x)$ ve $F_2(x)$ olsun. Bayes Teoremi'ne göre x vektörü,

$$\frac{F_1(x)}{F_2(x)} > \frac{L_1 P_2}{L_2 P_1} \quad (6)$$

eşitsizliği doğru ise K_1 , eşitsizliğin tersi doğru ise K_2 sınıfına aittir. Burada P_1 ve P_2 , K_1 ve K_2 sınıflarının görülme olasılığıdır. L_1 , x vektörünün K_1 sınıfına ait iken K_2 olarak yanlış sınıflama oranı; L_2 ise x vektörünün K_2 sınıfına ait iken K_1 olarak yanlış sınıflama oranıdır ve maliyet fonksiyonu olarak adlandırılır. Buradan görüleceği gibi, $F_1(x)$, $F_2(x)$, L_1 ve L_2 'nin bilinmesi durumunda x vektörünün en yüksek olasılıkla hangi sınıfa ait olduğu tespit edilebilir [9]. PNN'lerde sınıflara ait yoğunluk fonksiyonları Parzen pencereleri [10] kullanılarak aşağıdaki şekilde bulunur:

$$F(x) = \frac{1}{(2\pi)^{m/2} \sigma^m n} \sum_{i=1}^n \exp\left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}\right] \quad (7)$$

Burada n eğitim verisi sayısı, m giriş uzayının boyutu, i örüntü numarası ve σ ise ayarlanabilir bir yumuşatma terimidir.

5. İYONOSFER VERİ TABANI

İyonosfer radar yansımaları verisi Goose Bay, Labrador anten sistemi ile elde edilmiştir. Sistem toplam gücü 6.4 KW olan 16 adet yüksek frekans antenden oluşmaktadır. Anten dizisinin hedefi iyonosferdeki serbest elektronlardır. "İyi" radar dönüşleri, bu elektronların iyonosferdeki varlığını göstermektedir. "Kötü" dönüşler ise elektronların yokluğunu göstermektedir. Alınan sinyaller bir özilişki fonksiyonu kullanılarak değerlendirilmiştir. Ele alınan veri tabanında 17 adet dönüş sinyali kullanılmıştır. Dönen sinyallerin sıra numarası ve dönüş süreleri özilişki fonksiyonunun girişini oluşturmaktadır. Özilişki fonksiyonunun çıkışı karmaşık bir sayı dizisidir. Böylelikle veri tabanındaki her bir örnek 17 çift gerçel sayı ile ifade edilmiştir.

İyonosfer veri tabanı, 351 adet örnekten oluşmaktadır. Bu örneklerin 223 tanesi "iyi", geri kalanı "kötü" olarak etiketlenmiştir. Her bir örnek 34 adet [-1 1] aralığında sürekli değerler ile temsil edilmiştir.

6. UYGULAMA

Simülasyonlar, MATLAB 6.5 Neural Network Toolbox ile yapılmıştır. Veri tabanı, 100 adet "iyi", 100 adet "kötü" etiketli veri ile eğitilmiş, geri kalan 151 örnek test için kullanılmıştır. İlk aşamada, her üç ağ da herhangi bir ek işlem yapmadan eğitme verileri ile eğitilmiş ve kalan veriler ile test edilmiştir. En uygun bant genişlikleri deneme yoluyla bulunmuştur. Bu değerler RBF için 1.4, GRNN için 0.67 ve PNN için 0.07 olarak bulunmuştur. Tablo 1 bu adıma ilişkin eğitme ve test doğruluklarını göstermektedir

İkinci aşamada ise veri tabanına Temel Bileşen Analizi (Principal Component Analysis - PCA) uygulanarak giriş vektörlerinin boyutu küçültülmüştür. Giriş vektörü uzunluğu 15 olacak şekilde PCA uygulandığında elde edilen sonuçlar ise Tablo 2'de verilmiştir.

Tablo 1. Ağların Doğru Sınıflandırma Yüzdeleri

	PNN	GRNN	RBF
Eğitme	%100	%97.5	%100
Test	%95.36	%94.7	%92.72

Tablo 2. PCA Uygulandıktan Sonra Ağların Doğru Sınıflandırma Yüzdeleri

	PNN	GRNN	RBF
Eğitme	%100	%97	%100
Test	%94.7	%96.02	%88.08

7. SONUÇ

Uygulama sonuçlarına göre istatistiksel ağların ortalama doğruluğu %90'ın üzerinde olmuştur. Bu ağların en büyük dezavantajı giriş verisinin boyutu ve eğitime setinin büyüklüğü artırıldığında bellek ve zaman tüketiminin fazla oluşudur. Tablo 1 ve Tablo 2 karşılaştırıldığı zaman, PCA uygulandığında giriş verisinin boyutunun küçüldüğü, buna rağmen ağların doğruluklarının fazla değişmediği, hatta GRNN'in test doğruluğunun arttığı görülmüştür. Bu artışa karşın, eğitim setinin doğruluğu azalmıştır.

Daha ilginç bir durum ise, RBF ağında gözlenmiştir. Bu ağ yapısında, giriş vektörünün boyutu 24 olacak şekilde PCA uygulandığında test doğruluğu %94, eğitime doğruluğu %100 olmuştur.

Bu sonuçların ışığı altında istatistiksel sinir ağları ile yapılan uygulamalarda PCA kullanılarak ağın doğruluğundaki kabul edilebilir seviyedeki bir düşüşe karşılık bellek gereksiniminin önemli miktarda azaltılabildiği görülmüştür. Ayrıca, giriş verisinin boyutunun istatistiksel ağların başarımını etkilediği de söylenebilir. Kullanılan yapılar, iyonosfer radar yansıma verisini literatürdeki diğer ağ yapıları kadar iyi sınıflandırabilmiştir.

KAYNAKLAR

- [1] Sigillito, V. G., Wing, S. P., Hutton, L. V., Baker, K. B., Classification of Radar Returns From the Ionosphere Using Neural Networks. JOHNS HOPKINS APL TECHNICAL DIGEST, Vol.10, pp. 262-266, 1989.
- [2] Blake, C.L., Merz, C.J., UCI Repository of Machine Learning Databases, University of California, Department of Information and Computer Science, <http://www.ics.uci.edu/~mlern/MLRepository.html>.
- [3] Aha, D. W., Kibler, D., Noise-tolerant instance-based Learning Algorithms, PROCEEDINGS OF THE ELEVENTH INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, pp. 794-799, 1989.
- [4] Vincent, P., Bengio, Y., A Neural Support Vector Network Architecture with Adaptive Kernels, PROCEEDINGS OF THE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, Como, Italy, July 2000.
- [5] Yıldırım, T., Özyılmaz, L., Dimensionality Reduction in Conic Section Function Neural Network, SADHANA, Vol. 27 (6), pp. 675-683, 2002.
- [6] Verleysen, M., Hlavackova, K., An Optimized RBF Network For Approximation of Functions, PROCEEDINGS EUROPEAN SYMPOSIUM ON ARTIFICIAL NEURAL NETWORKS, Brussels, Belgium, pp. 175-180, 1994.
- [7] Paredes, V., Vidal, E., A Class-Dependent Weighted Dissimilarity Measure for Nearest Neighbor Classification Problems, PATTERN RECOGNITION LETTERS, Vol. 21, pp. 1027-1036, 2000.
- [8] Wong, H. S., Wu, M., Joyce, R. A., Guan, L., Kung, S. Y., A Neural Network Approach for Predicting Network Resource Requirements in Video Transmission Systems, PROCEEDINGS OF IEEE PACIFIC RIM CONFERENCE ON MULTIMEDIA, 2000.
- [9] Goh, T. C., Probabilistic Neural Network for Evaluating Seismic Liquefaction Potential, IEEE INTERNATIONAL SYMPOSIUM ON INTELLIGENT SYSTEMS, Varna, Bulgaria, Vol. 3, pp.16-20, 2002.
- [10] Parzen E., On Estimation of a Probability Density Function and Mode, ANNALS OF MATHEMATICAL STATISTICS, Vol. 36, pp.1065-1076, 1962.