

RADARLA UÇAK SINIFLANDIRMADA YAPAY SİNİR AĞI YAKLAŞIMI

Cihat ÇEŞMELİ, Tayfun GÜNEL*
Hava Harp Okulu
Havacılık ve Uzay Teknolojileri Enstitüsü
Elektronik Mühendisliği Ana Bilim Dalı
Yeşilyurt/İstanbul
cihatcesmeli@hotmail.com

*İstanbul Teknik Üniversitesi
Elektrik-Elektronik Fakültesi
Elektronik ve Haberleşme Mühendisliği Bölümü
Ayazağa/İstanbul
tgunel@ehb.itu.edu.tr

Özet : Bu çalışmada hava hedeflerine ait radar izlerinin sınıflandırılması için yapay sinir ağı modelleri incelenmiş ve sınıflandırma işlemi için en uygun yöntemin belirlenmesi amaçlanmıştır. Sınıflandırma algoritması olarak da geri yayılım için Levenberg-Marquardt algoritması kullanan ileri sürümlü yapay sinir ağı, olasılıklı ve radyal tabanlı sinir ağları seçilmiştir. Sınıflandırmada kullanılan menzil profilleri bir simülasyon programı (RTBS) vasıtasıyla elde edilmiştir. Öznitelik uzayının sıkıştırılması için parametre olarak, saçıcı noktaların konum veya genlik parametreleri ya da her iki parametrenin karması kullanılmıştır. Ağ yapısı, parametre, bant genişliği, gözlem açısı değişimlerinin kombinasyonlarına bağlı olarak başarımlar gözlemlenmiştir.

1.Giriş

Yapay sinir ağları günümüzde bir çok alanda başarı ile kullanılmaktadır. Radarla uçak tanıma uygulamalarında da yapay sinir ağı uygulamaları mevcuttur. Üç farklı tipte yapay sinir ağının başarımları farklı açılardan incelenerek problemin çözümüne katkı sağlanması amaçlanmaktadır. Yapay sinir ağları kullanılarak radarla uçak sınıflandırmada yüksek çözünürlüklü radarlardan elde edilen bir boyutlu menzil profilleri etkili olarak kullanılmaktadır. Kullanılacak menzil profilleri RTBS (Radar Target Back Scattering Simulation) programı ile elde edilmiştir.

2. Yapay Sinir Ağları

Yapay sinir ağları paralel sistemlerdir. Bir çok nöron eşzamanlı olarak çalışır ve karmaşık bir işlev çok sayıda nöron aktivitesinin bir araya gelmesiyle oluşur. Bu sayede her hangi bir nöron işlevini yitirdiğinde başarımda dikate değer bir düşüş gözlenmez. Yapay sinir ağları genelleme yetenekleri sayesinde eğitim sırasında kullanılmayan girdiler için de anlamlı yanıtlar üretebilirler. Bir başka özellik ise ağ fonksiyonlarının nonlineer olmasıdır. Son özellik olarak sayısal ortamda tasarlanan bir sinir ağı yaklaşımının tümdevre gerçekleştirilebilirliğinin olmasıdır. Ele alınan bir problemin yapay sinir ağları yaklaşımı ile çözümünde tasarımcının önüne çeşitli seçenekler çıkar. İlk seçenek öğrenme mekanizması üzerindedir. Literatürde öğreticili öğrenme ve öğreticisiz öğrenme olarak isimlendirilen iki tip öğrenme stratejisinden bahsedilmektedir [1]. Bu iki yaklaşım arasındaki temel fark istenen çıkış değerlerinin mevcut olup olmamasıdır. Tasarımlar veri akış yönü ve ağ yapısının yapısal farklılıkları şeklinde iki mimari seçeneğe ayrılmaktadır. Eğer ağ üzerinde bilgi akışı sürekli ileri doğru ise bu yapıya sahip ağ modelleri ileri sürümlü , ağ yapısında geribesleme bağlantıları varsa bu tipteki sistemler geribeslemeli olarak adlandırılır [2]. Oluşturulan ağdaki yapısal farkta ise radyal tabanlı ağ, ileri sürümlü geri yayımlı ağ gibi yapı seçenekleri belirleyici etkendir.Tasarımın sunduğu üçüncü önemli seçenek öğrenme algoritmasıdır. Burada parametre güncelleme işlemi için türetilen bilginin hangi yöntemlerle oluşturulduğu, tasarım esnekliğinin ana temasıdır. Uçak tanıma problemi için bu çalışmada çok katmanlı algılayıcı, radyal tabanlı ve olasılıksal sinir ağları kullanılmıştır.

• **Çok katmanlı algılayıcı:** çalışmamızda kullanılan bu ağ çeşidinde hata fonksiyonunu eğimini kullanarak minimize etmeye çalışan Levenberg-Marquardt öğrenme algoritması kullanılmıştır.[5] Bu algoritmada ağ ağırlıkları (1) deki eşitliğe göre güncellenir. (1) eşitliğindeki w ağırlıklarının,

$$w(n+1) = w(n) - \left[\left(\frac{\partial e(n)}{\partial w(n-1)} \right)^T \cdot \left(\frac{\partial e(n)}{\partial w(n-1)} \right) + \mu I \right]^{-1} \cdot \left(\frac{\partial e(n)}{\partial w(n-1)} \right) \cdot e(n) \quad (1)$$

$e(n)$ ağ hataları vektörünü, I birim matrisi, μ Marquardt parametresini ifade etmektedir. Newton algoritması μ büyük bir sayı ise küçük adımlı eğim azalması halini alır.

• **Radyal tabanlı sinir ağı:** (2) eşitliği Gauss merkezci taban fonksiyonu tanımlamaktadır. Her bir fonksiyonun özelliklerini c ifade edilen merkez ve σ ifade edilen varyans olmak üzere iki parametre belirler. (2) denkleminde de anlaşılacağı üzere varyans arttıkça eğri daha da yayvanlaşmakta ve fonksiyonun sayısal olarak duyarlı olduğu bölge genişlemektedir. Buradan alt uzayların ne şekilde büyüyebileceği ya da küçülebileceği hakkında bir sonuç çıkarmak mümkündür [5].

$$\Psi(u, c, \sigma) = \exp \left\{ - \left(\frac{u - c}{\sigma} \right)^2 \right\} \quad (2)$$

• **Olasılıksal sinir ağı:** Olasılıksal sinir ağlarında sınıflara ait yoğunluk fonksiyonları (3) eşitliği kullanılarak bulunur. Burada n eğitim verisi sayısı, m giriş uzayının boyutu, i örüntü numarası ve σ ise ayarlanabilir bir yumuşatma terimidir.

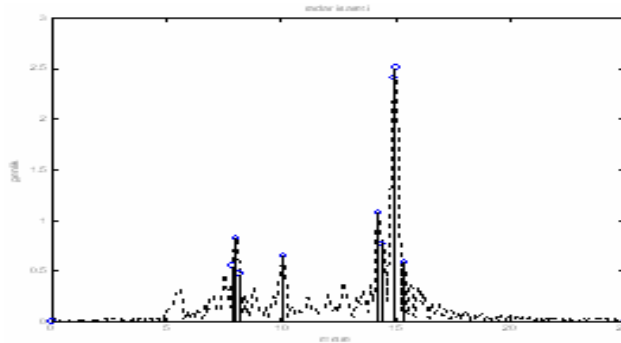
$$F(x) = \frac{1}{(2\pi)^{m/2} \sigma^m n} \sum_{i=1}^n \exp \left[- \frac{(x - x_i)^T (x - x_i)}{2\sigma^2} \right] \quad (3)$$

3. Öznitelik Eldesi

Çalışmada uçak tanıma problemi için dört adet hedefi seçilmiştir. Bunlar F 15, Mig 21, Tornado ve sahte hedeftir. Bu hedeflere ait bir boyutlu menzil profilleri doğrusal frekans modülasyonlu karesel dalga kullanan radar simüle edilerek elde edilmektedir [4]. 256 MHz, 512 MHz ve 1.24 GHz olmak üzere üç farklı bant genişliği kullanılmıştır. Sınıflandırmada kullanılacak tüm hedefler 45 derece burun yukarı yunuslama açısı pozisyonunda ve yatay düzlemde ise hedefler 30 dereceden başlayarak 63.97 dereceye kadar gözlenmişlerdir. Yatay düzlemdeki gözlem açısı aralığı arttırım miktarı ise (1) de verilen eşitlik doğrultusunda hesaplanmaktadır [5].

$$\Delta\phi < \frac{2 * \Delta R}{L} \quad (4)$$


(4) eşitliğindeki $\Delta\phi$ açı arttırım miktarını, ΔR menzil çözünürlüğü değerini, L ise hedefin yatay düzlemdeki en büyük boyutunu, ifade etmektedir. Test verisi olarak kullanılacak menzil profillerine daha sonra 0 dB, 5 dB, 10 dB ve 20 dB işaret gürültü oranlarında (SNR) sıfır ortalamalı beyaz Gauss gürültüsü eklenmiştir. Bir boyutlu menzil profillerinin boyutları yapay sinir ağı uygulamaları için çok büyüktür. Bu yüzden öznitelik uzayının sıkıştırılması gerekmektedir [6]-[8]. Şekil 1 de görüldüğü gibi menzil profillerinden seçilen saçıcı noktalara ait genlik ve mesafe parametrelerinden ayrı ayrı yada her ikisinin karması ile öznitelik vektörleri çıkarılarak sıkıştırma işlemi gerçekleştirilmiştir.




Şekil 1. Menzil profilinde saçıcı noktalar

4. Uygulama


Seçilen sinir ağı modelleri, kullanılan saçıcı nokta sayısı, gözlem açısının arttırım miktarı, radar bant genişliği, öznelik uzayının sıkıştırılması için seçilen saçıcı noktalara ait parametrelerin tercihi (genlik, mesafe veya karma) gibi durumlar göz önüne alınarak, farklı işaret gürültü oranı seviyelerinde sınanmıştır. Bant genişliği değişiminin başarıya etkisi şekil 2 de, gözlem açısı değişiminin etkisi şekil 3 de, parametre seçiminin etkisi şekil 4 de ve ağ mimarilerinin başarımları şekil 5 de gösterilmiştir.




Şekil 2. Bant genişliğine bağlı başarımların değişimi



Şekil 3. Açı arttırımına bağlı başarımların değişimi



Şekil 4. Parametreye bağlı başarımların değişimi



Şekil 5. Ağ mimarisine bağlı başarımların değişimi

5. Sonuç

Yapay sinir ağı kullanılarak radarla uçak tanımda yüksek bant genişliği kullanıldığında başarımların yükseldiği görülmektedir. Daha küçük gözlem açısı kullanımında başarımların artmasıdır. Öznelik çıkarımında saçıcı noktaların genlik parametreleri kullanıldığında en iyi başarımların elde edildiği görülmektedir. Seçilen ağ mimarileri içerisinde çok katmanlı algılayıcı tipindeki ağ ile her türlü durumda en iyi sonuçlar gözlemlenmiştir.

Kaynaklar

- [1]. Haykin, S. Neural Networks. Prentice-Hall, USA, 1999.
- [2]Kaynak, O., Efe, M.Ö. Yapay Sinir Ağı ve Uygulamaları. Boğaziçi Üniversitesi, İstanbul, 2000
- [3]. Zhang Q. J., Gupta K. C. Neural Networks for RF and Microwave Design. Artech House, Norwood, 2000
- [4]. Sirman, Y. D. Computer Simulation of Ariel Target Radar Scattering, Recognition, Detection And Tracking. Artech House, Norwood, 2002
- [5]. Li, H.J., Yang, S.H. "Using range profile as feature vectors", IEEE Trans. on antennas and propagation, 41, (3), s261-268, 1993.
- [6]. Botha, E. C., Barnard, E. and Barnard, C. J. "Feature-Based Classification Of Aerospace Radar Targets Using Neural Network", Neural Networks, 9(1), s.129-142, 1996.
- [7]. Choi L.S., Seo D.K., Bang J. K. ve Kim H.T. Radar Target Recognition Using One Dimensional Evolutionary Programming Based Clean. Waves and Appl., 17 (5), s763-784, 2003.
- [8]. Fuller, D.F., Terzuoli, A.J., Collins, P.J. and Williams, R. "Approach To Object Classification Using Dispersive Scattering Centres". Radar Sonar Navig., 151(2), April 2004.