

TEK SAYIDA HEDEF İZLEMEDE KULLANILAN İLİŞKİLİNDİRME OLASILIKLARININ YAPAY SİNİR AĞLARI İLE HESAPLANMASI

İlke TÜRKMEN¹

Kerim GÜNEY²

¹Uçak Elektrik-Elektronik Bölümü, Sivil Havacılık Yüksekokulu, Erciyes Üniversitesi, 38039, Kayseri

²Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Erciyes Üniversitesi, 38039, Kayseri

¹e-posta: titi@erciyes.edu.tr

²e-posta: kguney@erciyes.edu.tr

Anahtar sözcükler: Hedef İzleme, Veri İlişkilendirme, Yapay Sinir Ağları

ÖZET

Bu çalışmada tek sayıda hedef izlemede kullanılan ilişkilendirme olasılıklarının hesaplanması için yapay sinir ağlarına dayanan bir yaklaşım önerilmiştir. Yapay sinir ağ yapısı olarak çok katlı perseptronlar kullanılmıştır. Önerilen yaklaşımın performansı farklı hedef yörüngeleri kullanılarak test edilmiş ve gürültülü ortamlarda tek sayıda hedefi izlemek için yaygın olarak kullanılan yaklaşımlardan birisi olan olasılıksal veri ilişkilendirme süzgecinin performansı ile karşılaştırılmıştır. Elde edilen sonuçlardan önerilen yaklaşımın tek sayıda hedefi izlemek için başarılı bir şekilde kullanılabilceği gösterilmiştir.

1. GİRİŞ

Hedef izleme; hava savunma, balistik füze savunma, okyanus ve uydu gözleme, hava trafik kontrol sistemleri gibi pek çok alanda karşılaşılan bir konudur [1]. Hedef izlemede temel amaç, izlenecek hedefin konumu, hızı ve ivmesi gibi niceliklerinin mevcut veya gelecek zamanlarda tahmin edilmesidir. Hedef izlemede karşılaşılan en büyük problemlerden birisi izlemede kullanılan sensörden (radar, kızıl ötesi vb.) elde edilen ölçümlerin ilgilenilen hedefe ait olup olmadığına belirlenmesidir. Bu problem literatürde veri ilişkilendirme problemi olarak adlandırılır. Bu problemi çözmek amacıyla geliştirilen yaklaşımlardan birisi olasılıksal veri ilişkilendirme süzgecidir (OVİS). OVİ yaklaşımı [1], literatürde mevcut bulunan veri ilişkilendirme yöntemlerinin çoğunun işlem karmaşıklığını azaltmıştır. Bu sebepten dolayı da hedef izlemede yoğun olarak kullanılmaktadır. Hedef izleme sisteminde kullanılan sensörlerden elde edilen ölçümlerin düzensiz olması durumunda, OVİS'nin izleme hatası artmaktadır. Literatürde, ilişkilendirme olasılıklarının değişik yöntemlerle hesaplandığı çalışmalara [2, 3] rastlamak mümkündür.

Yapay sinir ağları (YSA), öğrenme yeteneği, kolayca farklı problemlere uyarlanabilirliği, genelleme

yapabilmesi, daha az bilgi gerektirmesi, paralel yapılarından dolayı hızlı çalışabilme yeteneği ve kolay bir şekilde uygulanabilmesi gibi pek çok avantajından dolayı mühendisliğin pek çok alanında farklı problemlerin çözümünde kullanılmaktadır. Bu avantajlarından dolayı önceki çalışmalarda [4-8], dairesel, dikdörtgen ve üçgen mikroserit antenlerin çeşitli parametreleri, YSA ile başarılı bir şekilde hesaplanmıştır. Bu çalışmada ise izleme performansını artırmak için ilişkilendirme olasılıkları YSA [9] ile belirlenmiştir. Bu amaçla oldukça basit bu sebeple de yaygın olarak kullanılan bir ağ yapısı olan çok katlı perseptronlar (ÇKP) [9] kullanılmıştır. ÇKP'ler Levenberg-Marquardt [10] öğrenme algoritması ile eğitilmiştir. Aşağıdaki bölümlerde, ilk önce YSA kısaca açıklanacaktır. Daha sonra, ilişkilendirme olasılıklarının hesaplanmasında YSA'nın kullanılması anlatılacak ve farklı test yörüngeleri için gerçekleştirilen simülasyon çalışmalarından elde edilen sonuçlar sunulacaktır.

2. YAPAY SİNİR AĞLARI

YSA, biyolojik sinir sisteminin çalışma prensibi temel alınarak geliştirilmiştir. YSA, nöronların birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar şeklinde düzenlenir. YSA'ların bir çok yapısı mevcuttur [9]. Bu yapılardan ÇKP ağ yapısı bu çalışmada ilişkilendirme olasılıklarının hesaplanması için kullanılmıştır. Temel bir ÇKP, Şekil 1'de gösterildiği gibi giriş katı, çıkış katı ve gizli kat olmak üzere üç ana kattan oluşur.

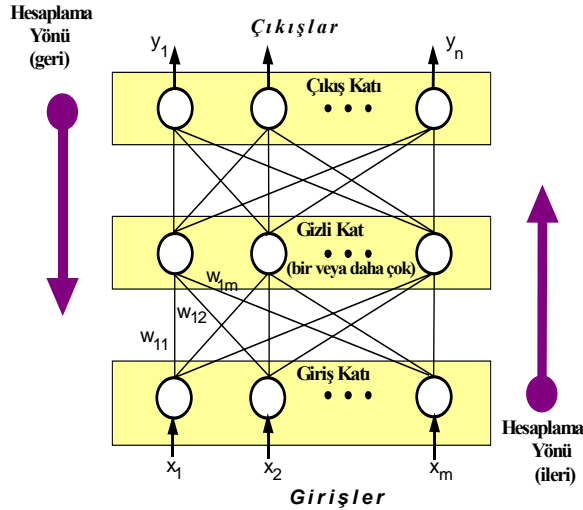
Giriş katındaki işlemci elemanlar veya nöronlar, giriş sinyali x_i 'nin gizli kattaki nöronlara dağıtılmasını sağlarlar. Gizli katta bulunan her bir j indisli işlemci eleman için çıkış; x_i giriş sinyali ile ara kat nöron ağırlığı w_{ji} ile çarpıldıktan sonra toplanır ve toplamın bir f fonksiyonu olarak y_j çıkışı aşağıdaki gibi hesaplanır.

$$y_i = f(\sum w_{ji} x_i) \quad (1)$$

Burada f sigmoidal veya hiperbolik tanjant fonksiyonu gibi basit bir eşik fonksiyonu olabilir. Çıkış katındaki nöronların çıkışları da benzer şekilde hesaplanır. Bir ağı eğitme işlemi, değişik öğrenme algoritmalarını kullanarak ağı ağırlıklarını ayarlamaktan oluşur. ÇKP ağını eğitmede farklı öğrenme algoritmaları kullanılabilir. Bu çalışmada ÇKP'yi eğitmek için danışmanlı öğrenme algoritmalarından birisi olan Levenberg-Marquardt algoritması [10] kullanılmıştır. Levenberg-Marquardt algoritması geriye yayılım algoritmaları arasında en hızlı olanıdır. Hızlı olması ve öğrenme hatasının düşük olması sebebiyle bu öğrenme algoritması tercih edilmiştir. Levenberg-Marquardt öğrenme algoritmasında ağırlık değerleri

$$w_{ji}(t+1) = w_{ji}(t) + [J^T(w)J(w) + \mu I]^{-1} J^T(w)E(w) \quad (2)$$

ifadesi ile belirlenir. (2) eşitliğinde, J Jacobian matrisi, μ sabit bir katsayı, I birim matris, $E(w)$ ise hata fonksiyonudur.



Şekil-1. Temel ÇKP Yapısı

3. YSA İLE İLİŞKİLENDİRME OLASILIKLARININ HESAPLANMASI

Bu bölümde, ilişkilendirme olasılıklarının YSA kullanılarak hesaplanması anlatılmıştır. İzlenecek olan hedefe ait hareket modeli aşağıdaki gibi tanımlanmıştır.

$$\begin{cases} x(t+1) = Fx(t) + w(t) \\ y(t) = Hx(t) + v(t) \end{cases} \quad (3)$$

Burada $x(t)$ durum vektörü, F durum geçiş matrisi, $w(t)$ süreç gürültüsü, $y(t)$ ölçüm vektörü, H ölçüm

matrisi, $v(t)$ ölçüm gürültüsü ve t ayrık zaman anıdır. $(t+1)$ anındaki ölçüm değeri elde edildikten sonra her bir geçerli ölçüm için

$$v_j(t+1) = y_j(t+1) - H\hat{x}(t+1|t) \quad (4)$$

ifadesi ile ölçüm artık vektörü bulunur. (4) eşitliğinde $\hat{x}(t+1|t)$ ifadesi öngörülen durum vektörünü göstermektedir. Güncelleştirilmiş durum vektörünün belirlenmesi için, elde edilen ölçümlerin ilgilenilen hedeflerden kaynaklanma olasılıklarının belirlenmesi gerekir. Bu ilişkilendirme olasılıklarının (β_j) hesaplanması için kullanılan sinir ağı modelinin girişleri, ölçüm artık vektörü v_j 'nin elemanlarının mutlak değerleri $|\tilde{x}_j|$ ve $|\tilde{y}_j|$ 'dir. β_j olasılıklarını hesaplamak için kullanılan sinir ağı modeli Şekil 2'de gösterilmiştir.

Çalışmada kullanılan giriş değişkenleri ($|\tilde{x}_j|$ ve $|\tilde{y}_j|$) 0 ile 1.2 km arasında değerler alabilir. Giriş değişkenlerinin mutlak değerine bağlı olan çıkış değişkeni β_j ise 0 ile 1 arasında bir değer alır. Giriş değişkenlerinin değerleri 0'a yaklaştıkça yani elde edilen ölçüm öngörülen konum değerine yakın olduğunda β_j değeri de 1'e yaklaşır. Çıkış değişkeni β_j 'nin istenilen değerleri, gerçek izler ile tahmin edilen izler arasındaki uyumluluk en iyi olacak şekilde çok sayıda denemeden sonra belirlenmiştir. Sinir ağını eğitmek amacıyla 630 veri kümesi kullanılmıştır.



Şekil-2. İlişkilendirme olasılıklarının hesaplanması için kullanılan sinir ağı modeli

ÇKP'de giriş ve çıkış katlarında lineer, gizli tabakada ise tanjant hiperbolik transfer fonksiyonu kullanılmıştır. Yapılan denemelerden sonra en uygun ağ yapısının 3 işlemci elemanlı üç gizli tabaka kullanıldığı zaman elde edildiği görülmüştür. Bu çalışmada eğitme işlemi için (2) eşitliğindeki μ katsayısı 0.2, epok sayısı ise 400 olarak seçilmiştir.

β_j olasılıkları, YSA ile belirlendikten sonra bu olasılık değerleri ve her bir ölçüm için hesaplanan artık değerleri kullanılarak

$$v(t+1) = \sum_{j=1}^m \beta_j v_j(t+1) \quad (5)$$

ifadesiyle birleştirilmiş artık değeri hesaplanmıştır.

Güncelleştirilmiş durum değeri ise,

$$\hat{x}(t+1|t+1) = \hat{x}(t+1|t) + K(t)v(t+1) \quad (6)$$


ile belirlenmiştir. (6) eşitliğinde $K(t)$ Kalman kazancını göstermektedir. Bu çalışmada önerilen yaklaşım YSA veri ilişkilendirme süzgeci (YSAVİS) olarak adlandırılabilir.

4. SİMÜLASYON ÖRNEKLERİ


Eğitilen YSA modelinin performansını değerlendirmek için üç farklı test yörüngesi kullanılmıştır. Kullanılan hedef yörüngeleri Şekil 3'de gösterilmiştir. Simülasyonlar için ortamın gürültü yoğunluğu 0.1 km^2 , örnekleme zamanı ise 1 s olarak seçilmiştir. Tüm test yörüngeleri için her bir örnekleme zamanında elde edilen geçerli ölçümlerin ilgililen hedeften kaynaklanma olasılıkları eğitilen YSA ile belirlenmiştir. Daha sonra (3), (5) ve (6) eşitlikleri kullanılarak hedeflerin güncelleştirilmiş konumları hesaplanmıştır.

Önerilen yaklaşımın performansını test etmek amacıyla, hedeflerin konum tahminleri, gürültülü ortamlarda tek sayıda hedefi izlemede yaygın olarak kullanılan yöntemlerden birisi olan OVİS ile de elde edilmiştir.


Birinci hedef için, önerilen yaklaşım YSAVİS ve OVİS'den elde edilen RMS hata değerleri Şekil 4'de verilmiştir. Şekil 4'ten görüldüğü gibi ilişkilendirme olasılıkları YSA ile belirlendiği zaman elde edilen RMS hata değeri OVİS'den elde edilen hata değerinden daha küçüktür. Diğer hedefler için elde edilen RMS hata değerleri ile birlikte geçiş olasılıkları YSA ile hesaplandığı zaman izleme performansında OVİS'e göre elde edilen yüzde iyileştirme Tablo 1'de sunulmuştur. Önerilen yaklaşımla elde edilen hata değerlerinin OVİS'den elde edilen hata değerlerinden daha küçük olduğu Tablo 1'den açıkça görülmektedir. YSA durum süzgeci kullanılarak izleme performansında ortalama olarak % 46 oranında bir iyileştirme gerçekleştirilmiştir.



(a) Birinci hedefe ait yörünge

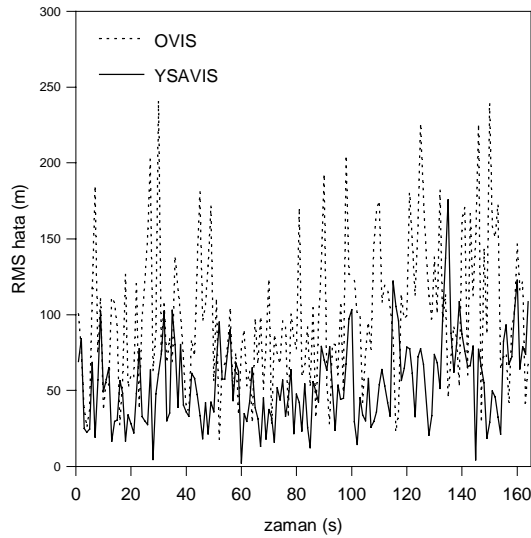


(b) İkinci hedefe ait yörünge



(c) Üçüncü hedefe ait yörünge

Şekil-3. Hedeflere ait yörüngeler



Şekil-4. Birinci hedef için OVİS ve YSAVİS'den elde edilen RMS hata değerleri

Tablo-1. Üç farklı hedef için, YSAVİS ile OVİS'nin performanslarının karşılaştırılması

Hedefler	RMS İzleme Hatası (m)		YSAVİS ile Yüzde İyileştirme (%)
	OVİS	YSAVİS	
1	97.3	54.1	44
2	97.1	53.8	45
3	97.6	50.7	48

5. SONUÇ

Bu çalışmada tek sayıda hedef izlemede kullanılan ilişkilendirme olasılıkları, YSA'ya dayanan bir yöntem ile belirlenmiştir. Bu yöntemin performansını test etmek için birbirinden farklı üç hedef yörüngesi kullanılmıştır. Kullanılan üç hedef yörüngesi için de ilişkilendirme olasılıklarının YSA ile belirlenmesi sonucunda elde edilen konum tahminlerinin, gürültülü ortamlarda tek sayıda hedefi izlemek için yaygın olarak kullanılan OVİS'den elde edilen konum tahminlerinden çok daha iyi olduğu görülmüştür. Bu çalışmada önerilen yöntemin avantajı, ilişkilendirme olasılıklarının basit bir şekilde hesaplanması ve bu olasılıklar kullanılarak elde edilen konum tahminlerinin gerçek değerlerle çok iyi bir uyumluluk içerisinde olmasıdır.

KAYNAKLAR

- [1] Bar-Shalom Y., Multitarget-Multisensor Tracking: Advanced Applications, Artech House, Boston, 1990.
- [2] Sengupta D., Iltis R.A., Neural Solution to the Multitarget Tracking Data Association Problem, IEEE TRANSACTIONS ON AEROSPACE AND ELECTRONIC SYSTEMS, Vol. 25, no. 1, pp. 96-108, 1989.
- [3] Oussalah M., Schutter, J. D., Hybrid Fuzzy Probabilistic Data Association Filter and Joint Probabilistic Data Association Filter, INFORMATION SCIENCE JOURNAL, Vol. 142, pp. 195-226, 2002.
- [4] Güney K., Erler M., Sağiroğlu Ş., Artificial Neural Networks for the Resonant Resistance Calculation of Electrically Thin and Thick Rectangular Microstrip Antennas, ELECTROMAGNETICS, Vol. 20, pp. 387-400, 2000.
- [5] Güney K., Sağiroğlu Ş., Erler M., Comparison of Neural Networks for Resonant Frequency Computation of Electrically Thin and Thick Rectangular Microstrip Antennas, JOURNAL OF ELECTROMAGNETIC WAVES AND APPLICATIONS (JEW), Vol. 15, pp. 1121-1145, 2001.
- [6] Karaboğa D., Güney K., Sağiroğlu Ş., Erler M., Neural Computation of Resonant Frequency of Electrically Thin and Thick Rectangular Microstrip Antennas, IEE PROCEEDINGS-MICROWAVES, ANTENNAS AND PROPAGATION, Pt H, Vol. 146, pp. 155-159, 1999.
- [7] Güney K., Sağiroğlu Ş., Erler M., Generalized Neural Method to Determine Resonant Frequencies of Various Microstrip Antennas, INTERNATIONAL JOURNAL OF RF AND MICROWAVE COMPUTER-AIDED ENGINEERING (Special Issue: Applications of Artificial Neural Networks to RF and Microwave Design), Vol. 12, pp. 131-139, 2002.
- [8] Güney K., Sarıkaya N., Artificial Neural Networks for Calculating the Input Resistance of Circular Microstrip Antennas, MICROWAVE AND OPTICAL TECHNOLOGY LETTERS, Vol. 37, pp. 107-111, 2003.
- [9] Haykin S., Neural Networks: A Comprehensive Foundation, New York: Macmillan College Publishing Company, 1994.
- [10] Hagan M.T., Menhaj M., Training Feedforward Networks with the Marquardt Algorithm, IEEE TRANSACTIONS ON NEURAL NETWORKS, Vol. 5, no. 6, pp. 989-993, 1994.