

YAPAY SİNİR AĞI EKLENMİŞ BENZETİLMİŞ TAVLAMA İZLEYİCİSİ İLE ÇOK SAYIDA HEDEFİ İZLEME

İlke TÜRKMEN¹

Kerim GÜNEY²

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

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

¹e-posta: titi@erciyes.edu.tr

²e-posta: kguney@erciyes.edu.tr

Anahtar sözcükler: Çok Sayıda Hedef İzleme, Yapay Sinir Ağları, Benzetilmiş Tavlama Algoritması

ABSTRACT

In this study, a simulated annealing tracker with neural network is presented for multiple target tracking. The data association problem formulated as an N-dimensional assignment problem is solved using simulated annealing algorithm. It is then proposed the incorporation of a neural network into the simulated annealing tracker in order to increase its tracking performance. A performance evaluation of the simulated annealing tracker with and without neural network is presented using simulation studies. Two different tracking scenarios are considered for this evaluation. It was observed that the estimation results of the simulated annealing tracker with the neural network are better than those obtained from only the simulated annealing tracker and the joint probabilistic data association filter.

1. GİRİŞ

Hedef izleme [1-6]; hava savunma, balistik füze savunma, okyanus ve uydu gözleme, hava trafik kontrol sistemleri gibi pek çok alanda karşılaşılan bir konudur. Çok sayıda hedefi izlemede temel amaç, radar verilerini aynı kaynak tarafından üretilen gözlem kümelerine (izler) ayırmaktır. Hedeflere ait izler oluşturulduktan ve teyit edildikten sonra herbir hedefin dinamiği hesaplanabilir. Literatürde, çok sayıda hedef izleme problemini çözmek amacıyla geliştirilen çalışmalar mevcuttur [1-6]. Ortak olasılıksal veri ilişkilendirme süzgeci (OOVIS) [1] çok sayıda hedef izlemede yaygın olarak kullanılan tekniklerden birisidir. Ancak gürültünün ve hedef sayısının fazla olduğu durumlarda bu yöntemin hesaplama gereksinimi artmaktadır. Hesaplama gereksinimini azaltmak için OOVIS'e çeşitli yaklaşımlar geliştirilmiştir [1]. Ayrıca, gürültülü ortamlarda hedef izlerken karşılaşılan veri ilişkilendirme problemini çözmek için yapay sinir

ağları (YSA), bulanık mantık ve genetik algoritma gibi yapay zeka tekniklerine dayanan yöntemler de geliştirilmiştir [2-6].

Son zamanlarda, veri ilişkilendirme problemini çözmek için atama algoritmalarının kullanılmasının etkili olduğu görülmüştür. Atama algoritmalarında veri ilişkilendirme problemi, tanımlanan bir amaç fonksiyonunun minimize edildiği sınırlamalı bir optimizasyon problemi olarak düşünülmektedir. Bu N boyutlu optimizasyon problemi üç veya daha fazla sayıda taramadaki ölçümlerin ilişkilendirilmesi durumunda NP-zor olarak adlandırılır. Bu şekildeki sınırlamalı optimizasyon problemlerinin çözümü oldukça zordur. Modern sezgisel optimizasyon tekniklerinden birisi olan benzetilmiş tavlama algoritması (BTA) [7], problemde bağımsız, olasılık tabanlı bir algoritmadır ve bu algoritmayı geleneksel optimizasyon metotlarından ayıran önemli özelliklerden birisi, uyguladığı stratejiler ile büyük oranda yerel minimumdan kurtulabilme kabiliyetinin olmasıdır. Bu avantajlarından dolayı bu çalışmada, N boyutlu bir atama problemi olarak formülize edilen veri ilişkilendirme problemi BTA yardımıyla çözülmüştür. Daha sonra, izleme performansını arttırmak için benzetilmiş tavlama izleyicisine (BTİ) YSA [8] eklenmiştir. Önerilen YSA eklenmiş benzetilmiş tavlama izleyicisinin (YSAEBTİ) performansı farklı izleme senaryoları için incelenmiştir. Aşağıdaki bölümlerde ilk önce BTİ kısaca açıklanacak daha sonra YSAEBTİ anlatılarak farklı hedef izleme senaryoları için önerilen yaklaşımdan elde edilen sonuçlar sunulacaktır.

2. BENZETİLMİŞ TAVLAMA İZLEYİCİSİ (BTİ)

Hedef izlemede karşılaşılan veri ilişkilendirme problemi, aşağıdaki eşitlik (1)'de verildiği gibi N-boyutlu bir atama problemi olarak düşünülmüştür.

Minimum:

$$\sum_{i_1=0}^{M_1} \cdots \sum_{i_N=0}^{M_N} c_{i_1, \dots, i_N} \chi_{i_1, \dots, i_N}, \quad (1a)$$

Kısıtlar:

$$\sum_{i_2=0}^{M_2} \cdots \sum_{i_N=0}^{M_N} \chi_{i_1, \dots, i_N} = 1, \quad i_1 = 1, \dots, M_1, \quad (1b)$$

(Birinci taramadan tek bir ölçüm atanmalı)

$$\sum_{i_1=0}^{M_1} \cdots \sum_{i_{k-1}=0}^{M_{k-1}} \sum_{i_{k+1}=0}^{M_{k+1}} \cdots \sum_{i_N=0}^{M_N} \chi_{i_1, \dots, i_N} = 1, \quad i_k = 1, \dots, M_k \text{ ve } k=2, \dots, N-1 \text{ için, (k. taramadan tek bir ölçüm atanmalı)} \quad (1c)$$

$$\sum_{i_1=0}^{M_1} \cdots \sum_{i_{N-1}=0}^{M_{N-1}} \chi_{i_1, \dots, i_N} = 1, \quad i_N = 1, \dots, M_N, \quad (1d)$$

(N. taramadan tek bir ölçüm atanmalı)

$\chi_{i_1, \dots, i_N} \in \{0, 1\}$, tüm i_1, \dots, i_N için.

Burada, c_{i_1, \dots, i_N} kullanılan algılayıcıdan elde edilen ölçüm dizisinin ilgilenilen hedefle ilişkilendirilme maliyeti, χ_{i_1, \dots, i_N} 0 veya 1 değerlerini alan ikili bir karar değişkeni, N ilişkilendirme yapılacak radar taramalarının sayısı ve M her bir taramadaki ölçüm sayısıdır. c_{i_1, \dots, i_N} maliyeti, aşağıdaki gibi birikimli negatif log-olabilirlik formunda yazılabilir:

$$c_{i_1, \dots, i_N} = - \sum_{m=1}^N \ln L_{i_m}(i_1, \dots, i_m) \quad (2)$$

i_1, \dots, i_m dizisinin negatif log-olabilirlik oranı aşağıdaki şekilde ifade edilir.

$$-\ln L_{i_m}(i_1, \dots, i_m) = \frac{1}{2} [z_{i_m} - \hat{z}_{i_1, \dots, i_m}] \cdot S_{i_1, \dots, i_m}^{-1} \cdot [z_{i_m} - \hat{z}_{i_1, \dots, i_m}] + \ln \frac{\lambda_e |2\pi S_{i_1, \dots, i_m}|^{1/2}}{P_D} \quad (3)$$

Burada, z m. taramada ilgilenilen hedefle ilişkilendirilen ölçüm vektörü, \hat{z} S kovaryansına sahip öngörülen ölçüm vektörü, λ_e yanlış alarm yoğunluğu ve P_D algılama olasılığıdır.

N'in 2'den büyük değerleri için eşitlik (1)'deki sınırlamalı optimizasyon probleminin klasik yöntemlerle çözülmesi oldukça zordur. BTA, bu şekildeki sınırlamalı optimizasyon problemlerinin çözümünde kullanılabilecek etkili bir algoritmadır. BTA ilk olarak Kirkpatrick, Gelatt ve Vecchi [7] tarafından önerilmiş, olasılık tabanlı sezgisel bir

algoritma olup katların fiziksel tavlama işlemi ve ayrık optimizasyon problemlerinin çözümü arasındaki benzerlik üzerine dayalıdır. Bu çalışmada BTA için amaç fonksiyonu,

$$E = \text{minimize} \left(\sum_{i_1=0}^{M_1} \cdots \sum_{i_N=0}^{M_N} c_{i_1, \dots, i_N} \chi_{i_1, \dots, i_N} \right) \quad (4)$$

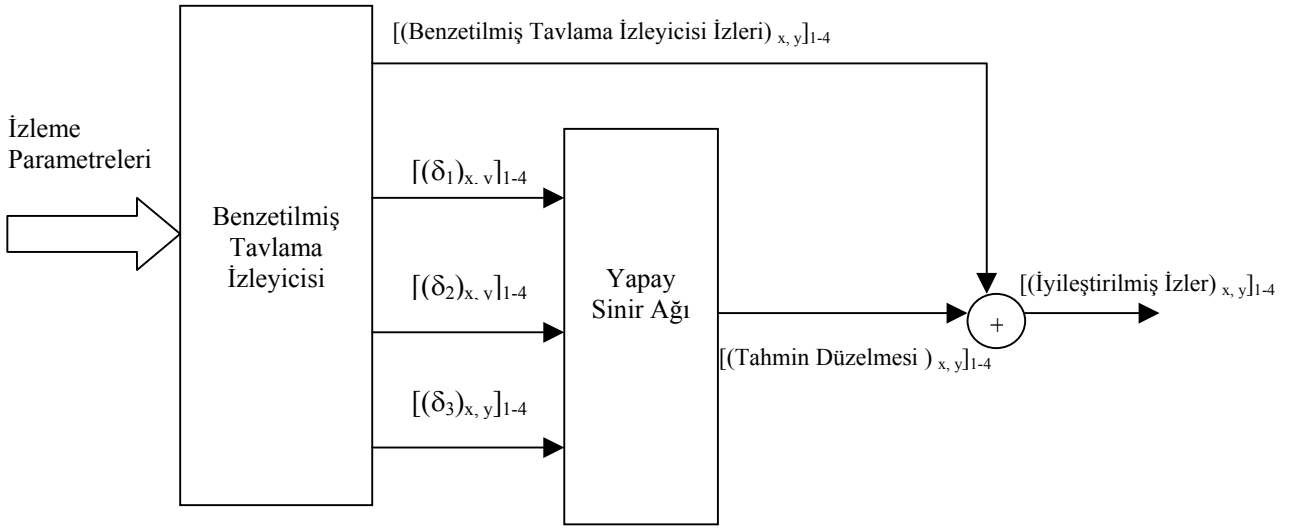
şeklinde tanımlanmıştır. BTİ'de durum tahmini için Kalman süzgeci [1] eşitlikleri kullanılmıştır.

3. YSA EKLENMİŞ BENZETİLMİŞ TAVLAMA İZLEYİCİSİ (YSAEBTİ)

Bu çalışmada BTİ'nin performansını iyileştirmek amacıyla izleyiciye YSA eklenmiştir. Kullanılan YSA'nın girişleri, ölçüm ve tahmin vektörleri arasındaki konum farkı (δ_1), tahmin ve öngörme vektörleri arasındaki konum farkı (δ_2) ve tahmin ve öngörme vektörleri arasındaki hız farkıdır (δ_3). YSA'nın çıkış vektörü, BTİ'nin konum tahmini ile hedefin gerçek konumu arasındaki farktır. YSA ağ yapısı olarak çok katlı perseptronlar (ÇKP) [8] kullanılmıştır. ÇKP'ler oldukça basit bu sebeple de yaygın bir şekilde kullanılan YSA yapılarıdır. ÇKP'ler BTİ'nin çalışması sonucunda elde edilen hata değerini tahmin etmek için uyarlanmıştır. Temel bir ÇKP, giriş katı, çıkış katı ve gizli kat olmak üzere üç ana katmandan oluşur. ÇKP'ler farklı öğrenme algoritmaları kullanılarak eğitilebilirler. Bu çalışmada, ÇKP'ler danışmanlı öğrenme algoritmalarından birisi olan Levenberg-Marquardt [9] algoritması kullanılarak eğitilmiştir. Levenberg-Marquardt algoritması geriye yayılım algoritmaları arasında en hızlı olanıdır. Hızlı olması ve öğrenme hatasının düşük olması nedeniyle bu öğrenme algoritması tercih edilmiştir. Önerilen yöntemin blok şeması Şekil 1'deki gibidir. Önerilen yaklaşım YSAEBTİ olarak adlandırılmıştır.

4. BENZETİM ÖRNEKLERİ

YSAEBTİ'nin izleme performansını test etmek için iki farklı izleme senaryosu kullanılmıştır. Birinci senaryodaki kesişen dört hedefin ve ikinci senaryodaki paralel dört hedefin yörüngeleri, Şekil 2 ve Şekil 3'de gösterilmiştir. Hedeflerin başlangıç durumları Tablo 1'de verilmiştir. YSA'yı eğitmek için bu hedef yörüngelerinin yakınında 640 giriş/çıkış veri kümesi oluşturulmuştur. Eğitim aşamasında, en küçük hata değerini bulmak için yapılan birkaç denemeden sonra en uygun ağ yapısının birinci ve ikinci gizli tabakada 8 adet, üçüncü gizli tabakada 4 adet işlemci elemanın bulunduğu üç gizli tabaka kullanıldığında elde edildiği görülmüştür. Her bir ara katmanda kullanılan transfer fonksiyonu tanjant hiperboliktir. Eğitim için epok sayısı 1000 olarak seçilmiştir.



Şekil-1. YSAEBT'nin blok şeması

Kullanılan hedeflere ait durum uzay modeli

$$X(k+1) = F(k)X(k) + G(k)w(k) \quad (5)$$

$$z(k) = H(k)X(k) + v(k) \quad (6)$$

şeklinde. Burada X durum vektörü, F, H ve G bilinen matrisler, w süreç gürültüsü, v ölçüm gürültüsü ve z(k) ölçüm matrisidir. X durum vektörü $X(k) = [x \ y \ \dot{x} \ \dot{y}]'$ şeklinde tanımlanmıştır. F ve G matrisleri

$$F(k) = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad G(k) = \begin{bmatrix} T^2/2 & 0 \\ 0 & T^2/2 \\ T & 0 \\ 0 & T \end{bmatrix} \quad (7)$$

şeklinde. Burada T örnekleme aralığını göstermektedir. Benzetimlerde kartezyen (x-y) koordinatlarında km cinsinden konum ölçümü yapan bir algılayıcının kullanıldığı kabul edilmiştir ve ölçümler bilgisayar benzetimleri ile oluşturulmuştur. Bu durumda H ölçüm matrisi,

$$H(k) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (8)$$

şeklinde. Algılayıcının x ve y yönündeki ölçüm hatasının standart sapması 0.2 km olarak seçilmiştir. Kullanılan algılayıcıdan her bir T anında 8 ölçüm alındığı kabul edilmiştir. BTA, 5'li gruplar halinde radar taramaları için, algılayıcıdan alınan ölçümlerin hangi hedefe ait olduğunu belirlemek için kullanılmıştır. BTA için çözümler tam sayılardan

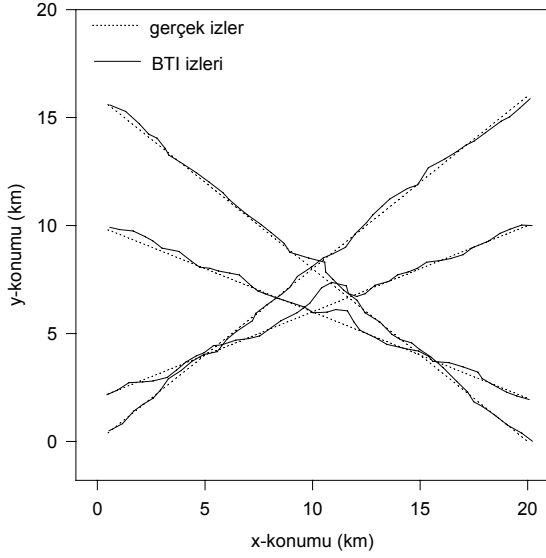
oluşan bir dizi ile ifade edilmiştir. Bu gösterim şu şekilde açıklanabilir: İlk 5 radar taraması için algılayıcıdan elde edilen ölçümlerden birinci hedefe ait olan ölçüm dizisi sırasıyla, 1, 2, 5, 3, 3; ikinci hedefe ait ölçüm dizisi sırasıyla 3, 4, 1, 4, 2; üçüncü hedefe ait ölçüm dizisi sırasıyla 5, 6, 8, 6, 7 ve dördüncü hedefe ait ölçüm dizisi sırasıyla 8, 7, 2, 5, 8 ise bu durumda çözüm, [1, 2, 5, 3, 3, 3, 4, 1, 4, 2, 5, 6, 8, 6, 7, 8, 7, 2, 5, 8] şeklinde 20 elemanlı bir dizidir. Bu çalışmada, BTA için sıcaklık noktalarının sayısı 100, her bir sıcaklıktaki iterasyon sayısı 30 ve sıcaklık azalma parametresi 0.9 olarak alınmıştır.

5. SONUÇ

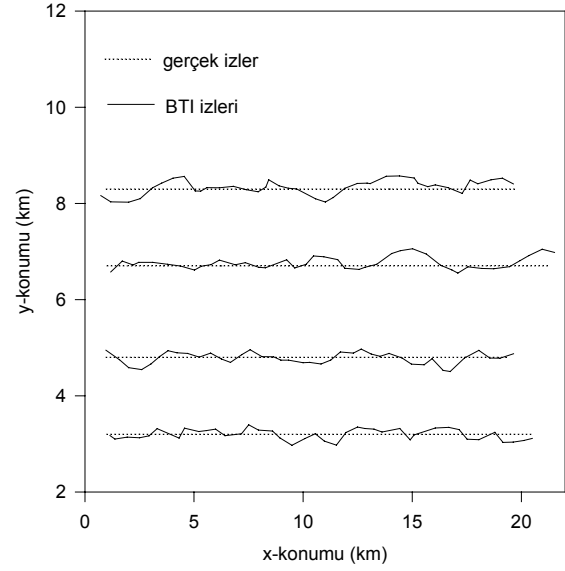
Kullanılan izleme senaryoları için, BTİ'ye YSA eklenmesinin izleme performansına etkisi Şekil 2 ve Şekil 3'de gösterilmiştir. Şekil 2 ve Şekil 3'den açıkça görüldüğü gibi YSAEBTİ ile elde edilen konum tahminleri gerçek değerlere daha yakındır. Her iki izleme senaryosu için BTİ ve YSAEBTİ kullanıldığında elde edilen RMS hata değerleri ve YSA kullanıldığında meydana gelen yüzde iyileştirme Tablo 2'de verilmiştir. Karşılaştırma yapmak amacıyla, verilen izleme senaryoları için hedef izlemede yaygın olarak kullanılan yöntemlerden birisi olan OOVİS yönteminden [1] elde edilen RMS hata değerleri de Tablo 2'de sunulmuştur. YSAEBTİ ile elde edilen yüzde iyileştirme, YSAEBTİ ve karşılaştırılan yöntemin (OOVİS veya BTİ) RMS hataları arasındaki farkın, karşılaştırılan yöntemden (OOVİS veya BTİ) elde edilen RMS hataya oranının yüzde olarak ifade edilmesi şeklinde değerlendirilmiştir. Tablo 2'den açıkça görüldüğü gibi YSAEBTİ ile elde edilen sonuçlar OOVİS ve BTİ'den elde edilen sonuçlardan daha iyidir. YSAEBTİ kullanıldığında OOVİS ve BTİ'e göre ortalama yüzde iyileştirme sırasıyla % 55 ve % 46'dır. BTİ'e YSA

eklenmesinin izleme performansını arttırdığı görülmüştür. YSA'nı eğitme işlemi, Pentium-IV 2 GHz PC ile yaklaşık 10-15 s sürmektedir. Eğitme işleminden sonra, gerçek zamanda hesaplama süresi bir kaç µs dir. Bu nedenle BTİ'ye YSA eklenmesi ek bir hesaplama yükü gerektirmemektedir.

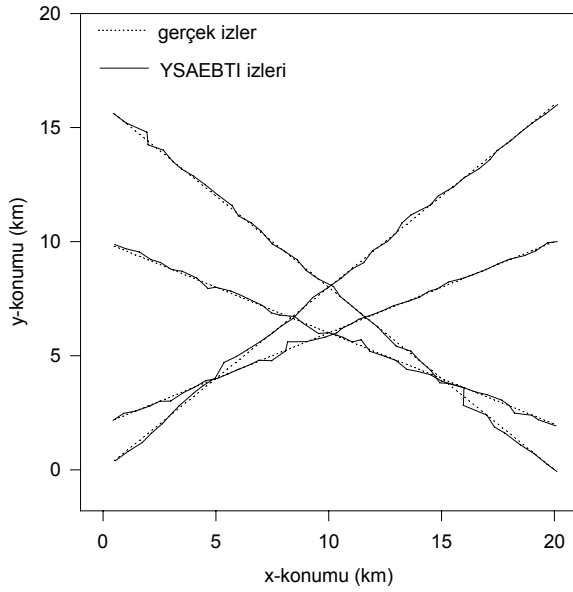
Bu çalışmada, hedef izlemede karşılaşılan veri ilişkilendirme problemi BTA kullanılarak başarılı bir şekilde çözülmüş ve BTİ'ye YSA eklenerek konum tahmininde bir iyileştirme gerçekleştirilmiştir. Önerilen YSAEBTİ yönteminin, hedef izlemede başarılı bir şekilde kullanılabilceği gösterilmiştir.



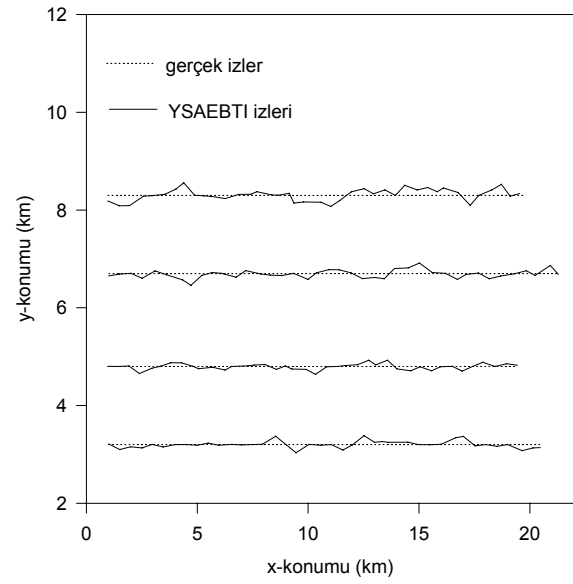
(a)



(a)



(b)



(b)

Şekil-2. Kesişen dört hedef için elde edilen sonuçlar (a) BTİ ve (b) YSAEBTİ

Şekil-3. Paralel dört hedef için elde edilen sonuçlar (a) BTİ ve (b) YSAEBTİ

Tablo-1. Kullanılan izleme senaryolarındaki hedeflerin başlangıç konum ve hızları

Senaryolar		Hedefler	x (km)	y (km)	\dot{x} (km/s)	\dot{y} (km/s)
1	Kesişen dört hedef	1	0	0	0.50	0.4
		2	0	2	0.50	0.2
		3	0	16	0.50	-0.4
		4	0	10	0.50	-0.2
2	Paralel dört hedef	1	0.5	3.2	0.50	0.001
		2	0.5	4.8	0.47	0.001
		3	0.5	6.7	0.52	0.001
		4	0.5	8.3	0.48	0.001

Tablo-2. OOVİS, BTİ ve YSAEBTİ yöntemlerinin performanslarının karşılaştırılması

Senaryolar	Hedefler	RMS İzleme Hataları (km)			YSAEBTİ ile OOVİS'e göre iyileştirme (%)	YSAEBTİ ile BTİ'e göre iyileştirme (%)	
		OOVİS [1]	BTİ	YSAEBTİ			
1	Kesişen dört hedef	1	0.1918	0.1715	0.1084	44	37
		2	0.2877	0.2583	0.1116	61	57
		3	0.2491	0.2058	0.1328	47	35
		4	0.2847	0.2231	0.1187	58	47
2	Paralel dört hedef	1	0.2019	0.1688	0.0734	64	57
		2	0.1822	0.1532	0.0805	56	47
		3	0.2537	0.1995	0.0888	65	55
		4	0.2477	0.2238	0.1439	42	36

KAYNAKLAR

- [1] Bar-Shalom Y., Multitarget-Multisensor Tracking: Principles and Techniques, YBS Publishing, 1995.
- [2] Sengupta D., Iltis R.A., Neural Solution to the Multitarget Tracking Data Association Problem, IEEE TRANSACTIONS ON AEROSPACE AND ELECTRONIC SYSTEMS, Vol. 25, Iss. 1, pp. 96-108, 1989.
- [3] Turkmen I., Guney K., Artificial Neural Networks for Calculating the Association Probabilities in Multi-Target Tracking, IEE PROCEEDINGS-RADAR, SONAR, NAVIGATION, Vol. 151, Iss. 4, pp. 181-188, 2004.
- [4] Iltis R.A., Ting P.Y., Computing Association Probabilities Using Parallel Boltzmann Machines, IEEE TRANSACTIONS ON NEURAL NETWORKS, Vol. 4, Iss. 2, pp: 221-233, 1993.
- [5] Chen Y.M., Huang H.C., Fuzzy Logic Approach to Multisensor Data Association, MATHEMATICS AND COMPUTERS IN SIMULATION, Vol. 52, pp. 399-412, 2000.
- [6] Chen G., Hong, L., A Genetic Based Multi Dimensional Data Association Algorithm for Multi Sensor Multi Target Tracking, MATHEMATICAL AND COMPUTER MODELLING, Vol. 26, Iss. 4, pp. 57-69, 1997.
- [7] Kirkpatrick S., Gelatt C.D., Vecchi M.P., Optimization by Simulated Annealing, SCIENCE, Vol. 220, pp. 671-679, 1983.
- [8] Haykin S. Neural Networks: A Comprehensive foundation, New York: Macmillan College Publishing Company, 1994.
- [9] Hagan M.T., Menhaj M., Training Feedforward Networks with the Marquardt Algorithm, IEEE TRANSACTIONS ON NEURAL NETWORKS, Vol. 5, Iss. 6, pp. 989-993, 1994.