

PAPER DETAILS

TITLE: COMPARISON OF SINGLE MULTIPLICATIVE NEURON ARTIFICIAL NEURAL NETWORK MODELS USING ABC AND BP TRAINING ALGORITHMS

AUTHORS: Faruk ALPASLAN,Erol EGRIOGLU,Çagdas ALADAG,Damla ILTER,Ali DALAR

PAGES: 315-328

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/35656>



ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

**Faruk ALPASLAN¹, Erol EĞRİOĞLU¹, Çağdaş Hakan ALADAĞ², Damla İLTER¹,
Ali Zafer DALAR³**

**TEK ÇARPIMSAL SİNİR HÜCRELİ YAPAY SİNİR AĞI MODELİNİN EĞİTİMİ
İÇİN ABC VE BP YÖNTEMLERİNİN KARŞILAŞTIRILMASI**

ÖZ

Yapay sinir ağları literatürde zaman serisi öngörü problemi için sıkılıkla kullanılmaktadır. Yapay sinir ağlarının, zaman serisi öngörüsü için kullanılan birçok türü vardır. Literatürde ilk kez Yadav vd. (2007) tarafından tek çarpımsal sinir hücresi model önerilmiştir. Tek çarpımsal sinir hücresi model, diğer yapay sinir hücresi modellerinden farklı olarak tek çarpımsal bir birleştirme fonksiyonu kullanmaktadır. Tek çarpımsal sinir hücresi modelini kullanan tek sinir hücresinin, yapay sinir ağının zaman serisi öngörü probleminde başarılı sonuçlar verdiği literatürde iyi bilinen bazı zaman serileri kullanılarak Yadav vd. (2007)'de gösterilmiştir. Tek çarpımsal sinir hücresi modeline dayalı tek hücreli ve ileri beslemeli bir yapay sinir ağının zaman serilerini tahmin etmede oldukça başarılı sonuçlar ürettiği bilinmektedir. Bu çalışmada İstanbul Altın Borsası ve İMKB 100 endeksi zaman serileri tek çarpımsal sinir hücresi model yapay sinir ağ ile çözümlenmiştir. Çözümlemede tek çarpımsal sinir hücresinin eğitimi için yapay arı kolonisi algoritması ve geri yayılım öğrenme algoritması yöntemleri kullanılarak, elde edilen sonuçlar karşılaştırılmıştır.

Anahtar Kelimeler: Yapay arı kolonisi, Geri yayılım algoritması, Öngörü, Tek çarpımsal sinir hücresi modeli, Eğitim algoritması

COMPARISON OF SINGLE MULTIPLICATIVE NEURON ARTIFICIAL NEURAL NETWORK MODELS USING ABC AND BP TRAINING ALGORITHMS

ABSTRACT

In the literature, artificial neural networks have been frequently used for the problem of time series forecasting. There are many types of artificial neural networks in prediction of time series. Single multiplicative neuron model is firstly proposed in literature by Yadav et al. (2007). Single multiplicative neuron model uses single multiplicative aggregation function unlike the other artificial neuron models. Single neuron which uses single multiplicative neuron model was shown that in Yadav et al. (2007) successful results were obtained in time series forecasting problem of artificial neural network by using well-known time series in literature. It has known that single neuron and feed forward neural networks based on single multiplicative neuron model obtained quite successful results in time series prediction. In this study, İstanbul gold exchange and Index 100 for the stocks and bonds

¹, Ondokuz Mayıs Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü, Kurupelit Kampüsü, Atakum, Samsun
E-posta: damlailter@yahoo.com E-mail: falpas@omu.edu.tr , erole@omu.edu.tr

², Hacettepe Üniversitesi, Fen Fakültesi, İstatistik Bölümü, 06800 Beytepe, Ankara
E-posta: aladag@hacettepe.edu.tr

³, Giresun Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü, Gazipaşa Yerleşkesi, Debboy Mevkii, Giresun
E-posta: ali.zafer.dalar@giresun.edu.tr

exchange market of Istanbul time series are analyzed by using single multiplicative neuron model artificial neural networks. In analyze, artificial bee colony algorithm and back propagation algorithm methods are used for the training of single multiplicative neuron, and obtained results are compared.

Keywords: Artificial bee colony, Back propagation algorithm, Forecasting, Single multiplicative neuron model, Training algorithm

1. GİRİŞ

Zaman serilerinin öngörülmesinde kullanılan yapay sinir ağları (YSA), belirsizliğe olasılıksal ya da bulanık türde bir yaklaşımı olmayan yöntemlerdir. YSA'nın belirsizliğe yaklaşım içermemesi ve olasılıksal modellerde olduğu gibi sağlanması zor varsayımlara ihtiyaç duymaması en önemli avantajlarıdır. Gerçek hayat zaman serileri genellikle doğrusal olmayan yapıları içerdiginden ARIMA, SARIMA gibi doğrusal modeller ile çözümlenmesi zor olabilmektedir. YSA aktivasyon fonksiyonu sayesinde doğrusal olmayan zaman serilerini çözümlenmesine olanak sağlamaktadır. Zaman serilerinin çözümlenmesinde kullanılan YSA türleri; çok katmanlı algoritmacı, Elman tipi geri beslemeli sinir ağları, radyal temelli yapay sinir ağları ve son yıllarda kullanılan tek çarpımsal sinir hücresi model YSA'dır. YSA ile zaman serilerinin öngörülmesi üzerine literatürde Zhang vd. (1998) çalışmasında detaylı bir şekilde verilmiştir. Tek çarpımsal sinir hücresi modelinin en önemli avantajlarından biri, diğer YSA modellerinin aksine gizli tabaka birim sayısının belirlenmesine ihtiyaç duymasıdır. Ayrıca tek çarpımsal sinir hücresi model YSA tek sinir hücresinden oluştugundan, diğer YSA türlerine göre daha basit ağ yapısına sahiptir. Tek çarpımsal sinir hücresi modeli, diğer YSA'lardan daha iyi öngörü sonuçları ürettiği, Yadav vd. (2007)'de gösterilmiştir. Tek çarpımsal sinir hücresi model YSA, basit yapısı ve iyi öngörü performansı nedeniyle literatürde sıkça kullanılmaya başlanmıştır. Tek çarpımsal sinir hücresi modelinde, öngörü performansını etkileyen önemli bir faktör eğitim algoritmasıdır. Tek çarpımsal sinir hücresi model eğitimi için literatürde farklı yöntemler kullanılmaktadır. Yadav vd. (2007)'de tek çarpımsal sinir hücresi model YSA'nın eğitimi için geri yayılım öğrenme (BP) algoritmasını önerirken, Zhao ve Yang (2009) ve Samanta (2011) çalışmalarında parçacık sürü optimizasyonu algoritmasını kullanmıştır. Çok katmanlı algoritmacının eğitimi için yapay arı kolonisi (ABC) algoritması Karaboga ve Akay (2007), Karaboga vd. (2007), Kumbhar ve Krishnan (2011) ve Öztürk ve Karaboga (2011) çalışmalarında kullanılmıştır. Mammadov ve Taş (2006) ve Mammadov vd. (2008) çalışmalarında ise ileri beslemeli sinir ağlarının eğitimi farklı eğitim algoritmaları önerilmiştir. Literatürde ilk kez İlter (2012) çalışmasında tek çarpımsal sinir hücresi YSA modeli eğitimi için ABC algoritması kullanılmıştır.

Bu çalışmada, İstanbul Altın Borsası ve İMKB 100 endeksi zaman serileri tek çarpımsal sinir hücresi model YSA ile çözülmüştür. Çözümlemeye tek çarpımsal sinir hücresi model eğitimi için ABC algoritması ve BP algoritması yöntemleri kullanılarak, elde edilen sonuçlar karşılaştırılmıştır. Çalışmanın ikinci bölümünde YSA'lar ile nasıl öngörü elde edileceği algoritma yardımıyla verilmiştir. Üçüncü bölümde tek çarpımsal sinir hücresi model ve bu modelin eğitiminde kullanılan ABC ve BP algoritması yöntemleri özetlenmiştir. Dördüncü bölümde ise İstanbul Altın Borsası ve İMKB 100 Endeksi zaman serileri için uygulamadan elde edilen sonuçlar, tablolar ve şekillere yardımıyla verilmiştir. Son bölümde ise elde edilen sonuçlar tartışılmıştır.

2. YAPAY SİNİR AĞLARI İLE ÖNGÖRÜ

YSA ile zaman serisi öngörüsü elde etmek için uygulanması gereken işlemler adımlar halinde bir algoritma haline getirilebilir. YSA yöntemiyle zaman serilerinde öngörü elde etmeyi, Günay vd. (2007)'de verildiği gibi 7 adımda özetlemek mümkündür.

Algoritma 1. YSA ile Öngörü

Adım 1. Verinin ön işlenmesi

İlk olarak verilerin küçük aralığa dönüştürülmesi gerçekleştirilir. x_i , girdi değerlerini göstermek üzere lojistik aktivasyon fonksiyonu kullanılacaksa, girdi değerleri.

$$x'_i = \frac{x_i - \text{Min}(x_i)}{\text{Maks}(x_i) - \text{Min}(x_i)} \quad (1)$$

şeklinde [0,1] aralığına dönüştürülebilir.

Adım 2. Veri organizasyonu

Eğitim ve test kümelerinin büyülüüğünün veri kumesinin yüzde kaçı olacağına karar verilir. Genelde verinin % 10 veya % 20'si, test kumesi olarak kullanılmaktadır.

Adım 3. Modelleme

Girdi sayısı, gizli tabaka sayısı, gizli tabakadaki birim sayısı ve çıktı tabakasındaki birim sayısı, bu birimlerde kullanılacak aktivasyon fonksiyonu, öğrenme algoritması ve bu algoritmanın parametreleri ve performans ölçütü belirlenerek, kullanılacak YSA modeli kurulur. Tek çarpımsal sınır hücresi YSA modeli kullanıldığında, gizli tabaka birim sayısının belirlenmesi gerekmemektedir.

Adım 4. Girdi değerlerinin oluşturulması

YSA'nın girdi değerleri gecikmeli zaman serileridir. X_t zaman serisi için girdi değerleri oluşturulurken, girdi tabakasındaki birim sayısı m ile gösterilsin. m tane gecikmeli zaman serisi $X_{t-1}, X_{t-2}, \dots, X_{t-m}$ şeklinde oluşturulur.

Adım 5. En iyi ağırlık değerlerinin hesaplanması

Eğitim kumesi üzerinden, seçilen öğrenme algoritması ile en iyi ağırlık değerleri bulunur. Elde edilen en iyi ağırlık değerleri kullanılarak, kurulan YSA modelinin çıktı değerleri hesaplanır.

Adım 6. Performans ölçütünün hesaplanması

YSA'nın test kumesi tahminleri elde edilir. Adım 5'te elde edilen çıktı değerlerine ve bu adımda elde edilen değerlere, Adım 1'de uygulanan dönüşüm tersi uygulanır. Bu dönüşüm sonucu elde edilen değerler sırasıyla, eğitim kumesinin tahminlerini ve test kumesinin tahminlerini oluşturur. Test kumesinin tahminleri ile test kumesindeki verilerin arasındaki farka dayalı olarak, seçilen performans ölçütü hesaplanır. Literatürde en yaygın kullanılan performans ölçütlerinden biri aşağıda formülü verilen hata kareleri ortalaması karekök (HKOK) değeridir.

$$HKOK = \sqrt{\sum_{i=1}^n (x_t - \hat{x}_t)^2} \quad (2)$$

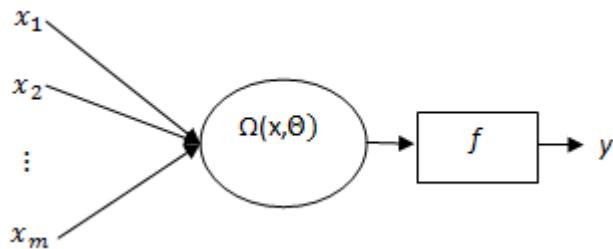
Adım 7. Öngörü

Son olarak, Adım 5'te bulunan en iyi ağırlık değerleri kullanılarak, test kumesinden sonraki zamanlar için yani gelecek için öngörü değerleri, yine iteratif öngörü ya da doğrudan öngörü yöntemlerinden biri kullanılarak elde edilir.

3. TEK ÇARPIMSAL SİNİR HÜCRESİ YSA MODELİ

Tek çarpımsal sınır hücresi model, zaman serilerinin tahmini ve fonksiyon yaklaşımı için kullanılan bir sınır ağı modelidir. Model, uzayın farklı boyutlarındaki lineer fonksiyonların çarpımına dayalı olan çok terimli bir mimarı meydana getirmektedir (Zhao ve Yang, 2009).

Yadav vd. (2007), tek çarpımsal sınır hücresi modelini önermiştir. Bu modelde, sınır hücresinin girdi sinyali çarpım fonksiyonu ile hesaplanmaktadır. Modelde tek bir sınır hücresi vardır ve ileri beslemeli sınır ağından farklı olarak sınır hücresine gelen sinyale toplama işlemi değil çarpma işlemi uygulanmaktadır. $\Omega(x, \Theta)$ fonksiyonu ağırlıklandırılmış girdilerin çarpımından ibarettir (Aladağ, 2011). Tek çarpımsal sınır hücresi model mimarı Şekil 1'de gösterilmiştir.



Şekil 1. Tek çarpımsal sinir hücresi model mimarisi

Burada $\Theta = (w_1, w_2, \dots, w_m, b_1, b_2, \dots, b_m)$ 'dır. Şekil 1'de verilen m girdili ($x_i, i = 1, 2, \dots, m$) tek çarpımsal sinir hücresi model YSA'da $2m$ adet ağırlık bulunmaktadır. Bunlardan m tanesi girdilere ($w_i, i = 1, 2, \dots, m$), m tanesi de bu girdilerin yanlarına karşılık ($b_i, i = 1, 2, \dots, m$) gelen ağırlıklardır. Aktivasyon fonksiyonunun aşağıda verilen lojistik fonksiyon olarak alındığını varsayıyalım.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

bu durumda sinir hücresi *net* değeri aşağıdaki gibi elde edilir.

$$net_i = \Omega(x, \Theta) = \prod_{i=1}^m (w_i x_i + b_i), \quad i = 1, 2, \dots, n \quad (4)$$

$$y_i = f(net_i), \quad i = 1, 2, \dots, n \quad (5)$$

böylece ağıın çıktısı *net* değerinin aktivasyon fonksiyonundan geçmesiyle $y = f(net)$ olarak elde edilir. Tek çarpımsal sinir hücresi modeli, tüm öğrenme örnekleri için hesaplanan çıktı değerleri ile hedef değerler arasındaki farktan hesaplanan aşağıda verilen kareler toplamı gibi bir ölçüt olarak alınabilir.

$$HKT = \sum_{i=1}^n (d_i - y_i)^2 \quad (6)$$

burada d_i ve y_i sırasıyla i . öğrenme örneğine karşılık gelen hedef değeri ve ağıın çıktısını göstermektedir. Tek çarpımsal sinir hücresi modelinin eğitiminde kullanılan ABC ve BP algoritmaları alt bölümde özetlenmiştir.

3.1 ABC Algoritması ile Tek Çarpımsal Sinir Hücresi Modelinin Eğitimi

Doğada var olan, zeki davranışlar içeren süreçlerin incelenmesi, araştırmacıları yeni optimizasyon metotları geliştirmeye sevk etmiştir. Karaboğa, arıların yiyecek arama davranışını modelleyerek ABC algoritmasını geliştirmiştir (Karaboğa, 2005). ABC algoritması, yiyecek kaynakları bulmada gerçek arıların davranışlarından esinlenerek ortaya çıkmıştır (Tsai vd., 2009). ABC'de daha kâşif, gözcü ve işçi arılar olmak üzere 3 tip temsilci bulunur. Karaboğa ABC algoritmasını temel aldığı modelde, basitlik amacıyla bazı kabuller yapmaktadır. Bunlardan ilki, her bir kaynağın nektarının sadece bir görevli arı tarafından alınıyor olmasıdır. Yani görevli arıların sayısı toplam yiyecek kaynağı sayısına eşittir. Bir diğeri de, işçi arıların sayısının gözcü arıların sayısına eşit olduğudur. Elbette bu farklı olabilir. Nektarı tükenmiş kaynağın görevli arısı artık kâşif arı haline dönüştürmektedir (Karaboğa, 2011).

ABC algoritmasının performansı, diğer iyi bilinen modern parçacık algoritmalarla benzetilmiştir. Bunlara genetik algoritma ve parçacık sürü optimizasyonu örnek gösterilebilir. Anlaşılması kolay ve sonuçları güvenilirdir. Sinir ağlarının eğitiminde ABC algoritmasının performansı XOR, şifre kodlu, 3 parça eşit kriterli problemlerde yüksek dereceli gradyent tabanlı optimizasyon algoritmalarına karşı örnek sınıflandırmalar tarafından test edilmiştir (Karaboğa ve Öztürk, 2009).

Literatürde, tek çarpımsal sinir hücresi modelinin eğitimi için ABC algoritması henüz kullanılmamıştır. Bu çalışmada, tek çarpımsal sinir hücresi modelinin eğitimi için ABC algoritması aşağıda verilen adımlar ile uygulanmaktadır. ABC'deki yiyecek kaynaklarının her biri, tek çarpımsal sinir hücresi modelin ağırlıklarını temsil etmektedir. Örneğin; tek çarpımsal sinir hücresi modelinin iki girdisinin olduğu durumda, yanlarla birlikte toplam dört ağırlığın optimum değerinin bulunması gereklidir. Bu durumda, bir yiyecek kaynağının dört pozisyonu bulunmaktadır. Tek çarpımsal sinir hücresi modelinin n adet girdisi olduğunu varsayıyalım. Bu durumda $2n$ adet ağırlığın optimum değeri bulunacaktır. Algoritmanın adımları aşağıdaki gibidir:

Algoritma 2. ABC Algoritması

Adım 1. Yiyecek kaynaklarının sayısı (SN) ve $limit$ değeri belirlenir. Bir kaynağın pozisyonlarının sayısı $2n$ adettir.

Adım 2. Başlangıç pozisyonları, (z_{\min}^j , z_{\max}^j) aralığında sürekli düzgün dağılımdan üretilir.

Adım 3. Her bir kaynağın uygunluk değeri hesaplanır. Uygunluk değeri her bir kaynağın ağırlıkları ile hesaplanan çıktılarından bulunan HKOK değeridir.

Adım 4. Görevli arı işlemleri uygulanır.

Görevli arıların her biri için;

$$v_{ij} = z_{ij} + \phi_{ij}(z_{ij} - z_{kj}) \quad (7)$$

(7) formülünü kullanarak yeni v_i çözüm üret. f_i değerlerini hesapla. Açı gözlü seçim sürecini uygula. Başarısızlık indeksini güncelle. Başarısızlık indeksi ilk iterasyonda her kaynak için sıfırdır. Açı gözlü seçim işleminin uygulanmasında, eğer üretilen yeni kaynak eski kaynaktan iyi değilse kaynağın başarısızlık indeksi arttırılır. Aksi halde ise kaynağın başarısızlık indeksi sıfırlanır.

Adım 5. Gözcü arı işlemleri uygulanır.

Her bir kaynak için aşağıda verilen formül ile olasılıklar hesaplanır.

$$p_i = \frac{f_i t_i}{\sum_{n=1}^{SN} f_i t_n} \quad (8)$$

Olasılıklara göre (7) formülünü kullanarak yeni v_i çözüm üret. f_i değerlerini hesapla. Açı gözlü seçim sürecini uygula. Başarısızlık indeksini güncelle.

Adım 6. En iyi kaynak hafızaya alınır.

Adım 7. Kâşif arı işlemleri uygulanır.

Eğer bir kaynak için başarısızlık indeksi *limit* değerinden büyük ise (9) formülü ile kaynak yeniden rastgele olarak üretilir.

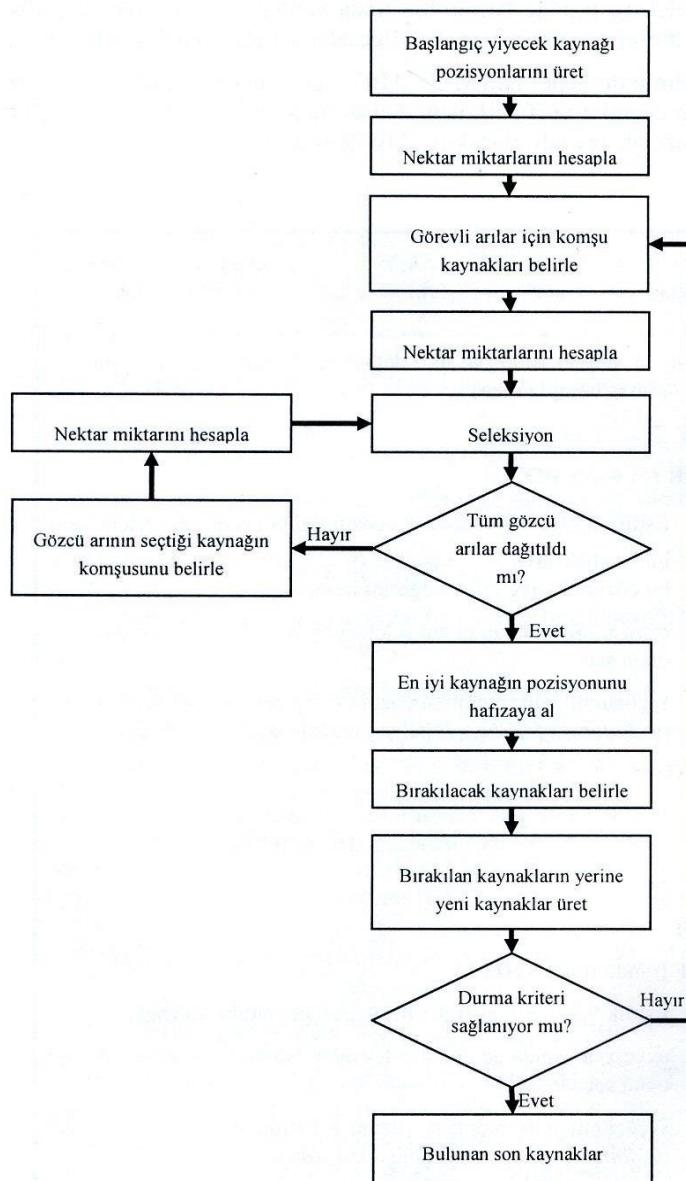
$$z_i^j = z_{\min}^j + \text{rand}(0,1)(z_{\max}^j - z_{\min}^j) \quad (9)$$

Başarısızlık indeksleri sıfırlanır.

Adım 8. Durdurma koşulları kontrol edilir. Durdurma koşulları sağlanmışsa Adım 9'a geçilir. Sağlanmamışsa Adım 4'e geri dönülür.

Adım 9. En iyi kaynak optimum çözüm olarak alınır.

ABC algoritmasının uygulanmasının akış diyagramı Şekil 2'de verilmiştir.



Şekil 2. ABC algoritmasının akış diyagramı (Şen, 2004)

3.2. BP Algoritması ile Tek Çarpımsal Sinir Hücresi Model YSA'nın Eğitimi

BP algoritması gradyent tabanlı bir eğitim algoritmasıdır. BP algoritmasında ağırlıkların değişimi, hatanın ağırlıklara göre kısmi türevlerinden elde edilir. Bu nedenle, tek çarpımsal sinir hücresi modelinde kullanılan aktivasyon fonksiyonunun türevleri kolay elde edilebilir olmalıdır. Yadav vd. (2007)'de lojistik aktivasyon fonksiyonu kullanıldığı durum için ağırlık ve yanların değişimi için gerekli formülleri türetmiştir. Yadav vd. (2007)'de minimum yapılmaya çalışılan fonksiyon (10)'da verilmiştir.

$$E = \frac{1}{2n} \sum_{i=1}^n (y_i - d_i)^2 \quad (10)$$

burada d_i i . öğrenme örneği için hedef değerdir. Ağırlıkların değişimi ise (11) ve (12)'deki formüllere göre gerçekleştirilir.

$$\Delta w_i = -\eta \frac{\partial E}{\partial w_i} = -\eta y(y-d)(1-y) \frac{u}{(w_i x_i + b_i)} x_i, \quad w_i = w_i + \Delta w_i \quad (11)$$

$$\Delta b_i = -\eta \frac{\partial E}{\partial b_i} = -\eta y(y-d)(1-y) \frac{u}{(w_i x_i + b_i)}, \quad b_i = b_i + \Delta b_i \quad (12)$$

Burada η öğrenme parametresi ve $u = \prod_{i=1}^n (w_i x_i + b_i)$ 'dır. Tek çarpımsal sinir hücresi model YSA'nın eğitimi için geri yayılım algoritması aşağıda verilen algoritmadaki gibi uygulanabilir.

Algoritma 3. BP Algoritması

Adım 1. $\Theta = (w_1, w_2, \dots, w_m, b_1, b_2, \dots, b_m)$ parametreleri için rastgele başlangıç değerleri üretilir.

Adım 2. Tüm öğrenme örnekleri için (4) formülünden net_i , $i = 1, 2, \dots, n$ değerleri hesaplanır.

Adım 3. Tüm öğrenme örnekleri için ağıjn çıktıları y_i , $i = 1, 2, \dots, n$ hesaplanır.

Adım 4. Bu çıktılara göre (10)'daki formülden E değeri hesaplanır. Eğer $E < \varepsilon$ ise algoritma durdurulur. Aksi takdirde Adım 5'e geçilir. Burada ε değeri 10^{-2} gibi alınabilen hata toleransı değeridir.

Adım 5. (11) ve (12) formüllerine göre ağırlık ve yan değerleri güncellenir ve Adım 2'ye geri dönülür.

4. UYGULAMA

Uygulamada “İstanbul Altın Borsası” ve İMKB 100 endeksi verileri (İstanbul Menkul Kıymetler Borsası) kullanılmıştır.

4.1. İstanbul Altın Borsası Zaman Serisi için Uygulama

Uygulamada 04.01.2010 - 05.04.2012 tarihleri arasındaki “İstanbul Altın Borsası” verileri kullanılmıştır. Zaman serisinin grafiği Şekil 3'te verilmiştir.



Şekil 3. 04.01.2010 - 05.04.2012 tarihleri arasındaki “İstanbul Altın Borsası” zaman serisi

Toplam gözlem sayısının % 20'si alınarak zaman serisinin son 112 gözlemi test verisi olarak ayrılmış, ilk 451 gözlem ise eğitim amacıyla kullanılmıştır. Uygulamada girdi olarak kullanılan gecikmeli değişkenler 1., 2., 3., 4. ve 5. dereceden olarak alınmıştır. Tek girdili modelde 1. dereceden gecikmeli değişken bulunurken, üç girdili modelde 1., 2. ve 3. dereceden gecikmeli değişkenler bulunmaktadır. Uygulamada kullanılan parametre seçimlerine göre ortaya çıkan her bir durum için yöntemler 100 farklı rastgele başlangıç ile tekrarlanmıştır. Tekrarlar sonucunda eğitim ve test kümeleri için elde edilen HKOK ve HMYO (Hatanın Mutlak Yüzdelik Ortalaması) değerlerine ait tanımlayıcı istatistikler tablolar halinde verilmiştir. Girdi sayısı 1 ile 5 arasında değiştirilerek hem ABC hem de BP algoritması için 100 tekrardan elde edilen HKOK ve HMYO değerleri sırasıyla Tablo 1 ve Tablo 2'de verilmiştir.

Tablo 1. “İstanbul Altın Borsası” zaman serisi için ABC ve BP algoritmalarından elde edilen HKOK değerleri

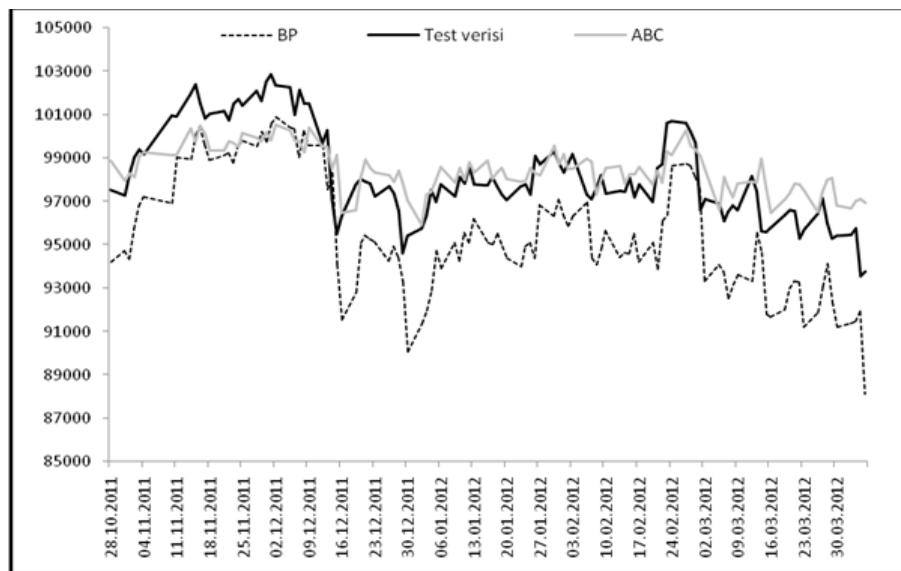
m	HKOKegt			HKOKtest			
	min	mean	std	min	mean	std	
1	ABC	16103,30	16108,80	7,26	27486,40	28836,43	481,46
	BP	9079,45	30105,27	10022,28	2999,05	31362,89	18068,92
2	ABC	3072,85	3404,04	351,29	2866,29	5926,15	1296,48
	BP	14821,42	32329,43	10232,07	10082,35	30945,98	17940,96
3	ABC	2041,88	3227,19	855,78	1429,78	3141,68	1485,41
	BP	14858,20	32236,03	10156,60	10084,07	27999,84	17988,03
4	ABC	2087,78	4869,11	1921,15	1685,00	5379,55	3257,98
	BP	14904,90	31318,36	10699,01	10084,07	31546,26	17176,59
5	ABC	2482,66	6006,53	2459,82	1604,94	7040,96	3797,12
	BP	14954,21	30154,10	10079,56	10084,07	29159,91	17168,06

Tablo 1 incelenirse, $m=1$ olduğunda yani girdi sayısı 1 olduğunda ABC algoritması BP algoritmasına göre daha düşük ortalama HKOKegt ve HKOKtest değerine sahiptir. Ayrıca hem eğitim hem de test kümesi için ABC algoritmasının standart sapma değeri de BP'ye göre oldukça düşüktür. Ancak $m=1$ olduğunda eğitim ve test kümesi için BP algoritması daha düşük minimum HKOK değerini vermiştir. Diğer girdi sayıları için ABC algoritması BP'ye göre eğitim ve test kümeleri için elde edilen HKOK değerlerinden hesaplanan tanımlayıcı istatistiklerine göre daha düşük ortalama, minimum ve standart sapma değerine sahiptir. ABC yöntemi ile eğitim yapıldığında en iyi test sonucu, girdi sayısının 3 olduğu durumda elde edilmiştir. BP algoritmasından ise en iyi test sonucu, girdi sayısının 1 olduğu durumda elde edilmiştir.

Tablo 2. “İstanbul Altın Borsası” zaman serisi için ABC ve BP algoritmalarından elde edilen HMYO değerleri

m	HMYOegt			HMYOtest			
		min	mean	std	min	mean	std
1	ABC	0,1861	0,1914	0,0019	0,2784	0,2922	0,0049
	BP	0,1368	0,3807	0,1924	0,0835	0,3211	0,1851
2	ABC	0,0360	0,0407	0,0042	0,0269	0,0590	0,0133
	BP	0,1757	0,4306	0,1935	0,0998	0,3118	0,1833
3	ABC	0,0245	0,0397	0,0111	0,0116	0,0288	0,0153
	BP	0,1761	0,4303	0,1916	0,1008	0,2809	0,1842
4	ABC	0,0246	0,0581	0,0248	0,0138	0,0505	0,0346
	BP	0,1766	0,4125	0,1969	0,1008	0,3136	0,1765
5	ABC	0,0296	0,0719	0,0306	0,0135	0,0682	0,0394
	BP	0,1772	0,3904	0,1862	0,1008	0,2876	0,1751

Tablo 2 incelenirse, $m=1$ olduğunda ABC algoritması BP algoritmasına göre daha düşük ortalama HMYOegt ve HMYOtest değerine sahiptir. Ayrıca hem eğitim hem de test kümesi için ABC algoritmasının standart sapma değeri de BP'ye göre oldukça düşüktür. Ancak $m=1$ olduğunda eğitim ve test kümesi için BP algoritması daha düşük minimum HMYO değerini vermiştir. Diğer girdi sayıları için ABC algoritması BP'ye göre eğitim ve test kümeleri için elde edilen HMYO değerlerinden hesaplanan tanımlayıcı istatistiklerine göre daha düşük ortalama, minimum ve standart sapma değerine sahiptir. ABC yöntemi ile eğitim yapıldığında en iyi test sonucu, girdi sayısının 3 olduğu durumda elde edilmiştir. BP algoritmasından ise en iyi test sonucu, girdi sayısının 1 olduğu durumda elde edilmiştir. ABC ve BP yöntemlerinin test kümesi için elde edilen HKOK ölçüdü değerlerine göre en iyi durumları için, test kümelerinden elde edilen öngörülerin gerçek değerler ile birlikte grafiği Şekil 4'te verilmiştir.

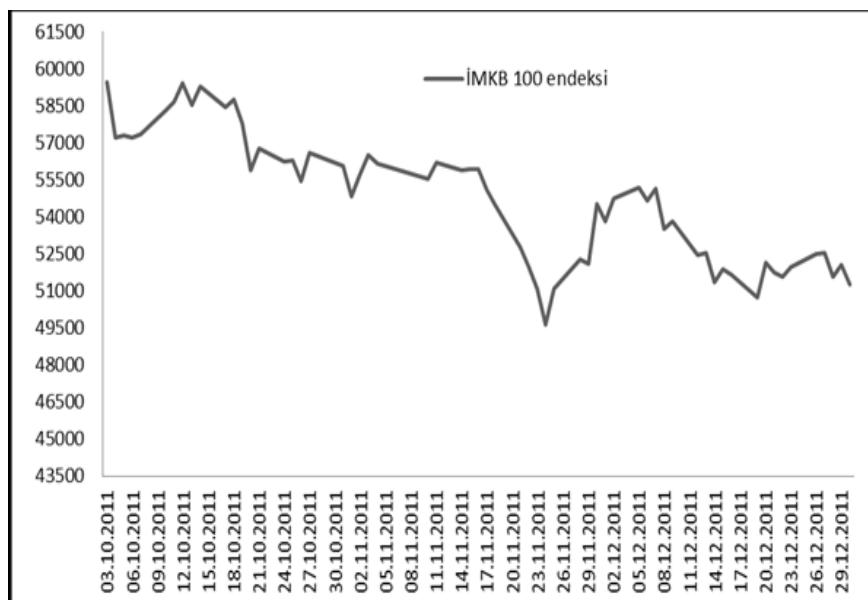


Şekil 4. “İstanbul Altın Borsası” zaman serisi için ABC ve BP ile eğitilmiş tek çarpımsal sinir hücresi model YSA’dan elde edilen öngörülerin gerçek değerler ile birlikte grafiği

Şekil 4 incelenirse; ABC ile eğitilmiş tek çarpımsal sinir hücresi model YSA’dan elde edilen öngörülerin gerçek değerlerle BP algoritmasına göre daha iyi uyum sağladığı söylenebilir.

4.2. İMKB 100 Endeksi Zaman Serisi için Uygulama

Uygulamada 03.10.2011 - 30.12.2011 tarihleri arasındaki “İMKB 100 Endeksi” verileri kullanılmıştır. Zaman serisinin grafiği Şekil 5’té verilmiştir.



Şekil 5. 03.10.2011 - 30.12.2011 tarihleri arasındaki “İMKB 100 Endeksi” zaman serisi

Toplam gözlem sayısının % 20’si alınarak zaman serisinin son 6 gözlemi test verisi olarak ayrılmış, ilk 55 gözlem ise eğitim amacıyla kullanılmıştır. Uygulamada girdi olarak kullanılan gecikmeli değişkenler 1., 2., 3., 4. ve 5. dereceden olarak alınmıştır. Tek girdili modelde 1. dereceden gecikmeli değişken bulunurken, üç girdili modelde 1., 2. ve 3. dereceden gecikmeli değişkenler

bulunmaktadır. Uygulamada kullanılan parametre seçimlerine göre ortaya çıkan her bir durum için yöntemler 100 farklı rastgele başlangıç ile tekrarlanmıştır. Tekrarlar sonucunda eğitim ve test kümeleri için elde edilen HKOK ve HMYO değerlerine ait tanımlayıcı istatistikler tablolar halinde verilmiştir. Girdi sayısı 1 ile 5 arasında değiştirilerek hem ABC hem de BP algoritması için 100 tekrardan elde edilen HKOK ve HMYO değerleri sırasıyla Tablo 3 ve Tablo 4'te verilmiştir.

Tablo 3. “İMKB 100 Endeksi” zaman serisi için ABC ve BP algoritmalarından elde edilen HKOK değerleri

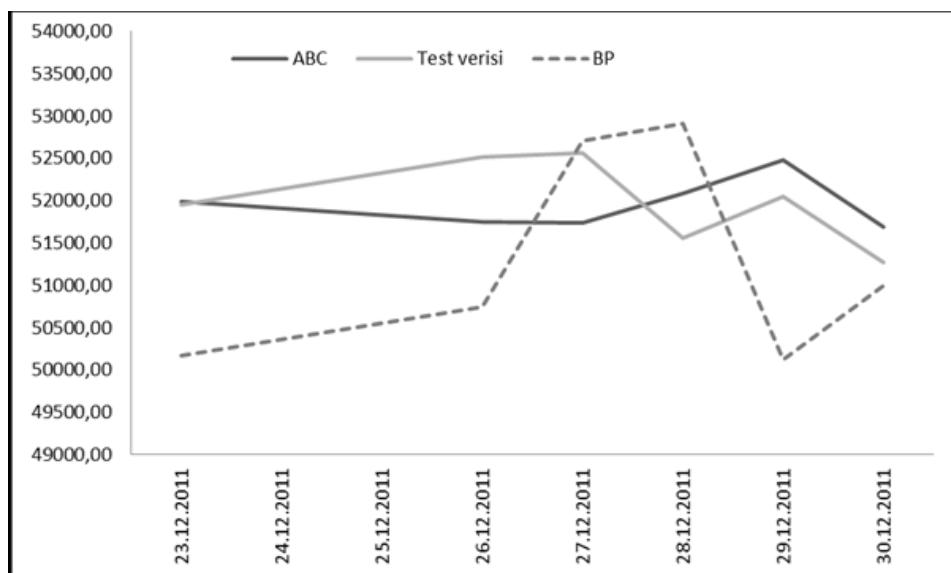
m	HKOKegt			HKOKtest			
	ABC	min	mean	std	min	mean	std
1	ABC	2420,69	2653,18	391,05	2437,71	3559,09	724,93
	BP	1601,09	5334,41	831,98	1413,47	4688,98	2553,62
2	ABC	1125,14	2747,46	611,43	565,39	2110,24	615,84
	BP	3266,82	5458,78	889,37	2167,49	4549,89	2445,22
3	ABC	1470,61	3159,66	237,54	1026,18	2367,37	232,31
	BP	3284,60	5565,00	890,15	2408,01	5216,16	2483,32
4	ABC	3205,90	3259,41	7,41	2408,01	2408,01	0,00
	BP	3244,75	5569,84	984,29	2408,01	5296,65	2419,85
5	ABC	3279,52	3279,52	0,00	2408,01	2408,01	0,00
	BP	3218,95	5430,94	797,70	2408,01	5277,08	2399,29

Tablo 3 incelenirse, $m=1$ olduğunda ABC algoritması BP algoritmasına göre daha düşük ortalama HKOKegt ve HKOKtest değerine sahiptir. Ayrıca hem eğitim hem de test kümesi için ABC algoritmasının standart sapma değeri de BP'ye göre oldukça düşüktür. Ancak $m=1$ olduğunda eğitim ve test kümesi için BP algoritması daha düşük minimum HKOK değerini vermiştir. Diğer girdi sayıları için ABC algoritması BP'ye göre eğitim ve test kümeleri için elde edilen HKOK değerlerinden hesaplanan tanımlayıcı istatistiklerine göre daha düşük ortalama, minimum ve standart sapma değerine sahiptir. ABC yöntemi ile eğitim yapıldığında en iyi test sonucu, girdi sayısının 2 olduğu durumda elde edilmiştir. BP algoritmasından ise en iyi test sonucu, girdi sayısının 1 olduğu durumda elde edilmiştir.

Tablo 4. “İMKB 100 Endeksi” zaman serisi için ABC ve BP algoritmalarından elde edilen HMYO değerleri

m	HMYOegt			HMYOtest			
	ABC	min	mean	std	min	mean	std
1	ABC	0,0365	0,0402	0,0062	0,0461	0,0679	0,0140
	BP	0,0245	0,0866	0,0143	0,0232	0,0894	0,0497
2	ABC	0,0164	0,0433	0,0105	0,0096	0,0393	0,0123
	BP	0,0528	0,0894	0,0170	0,0380	0,0861	0,0474
3	ABC	0,0201	0,0509	0,0043	0,0147	0,0445	0,0052
	BP	0,0531	0,0921	0,0173	0,0454	0,0993	0,0481
4	ABC	0,0516	0,0528	0,0002	0,0454	0,0454	0,0000
	BP	0,0527	0,0926	0,0195	0,0454	0,1003	0,0467
5	ABC	0,0532	0,0532	0,0000	0,0454	0,0454	0,0000
	BP	0,0525	0,0894	0,0155	0,0454	0,0997	0,0465

Tablo 4 incelenirse, $m=1$ olduğunda ABC algoritması BP algoritmasına göre daha düşük ortalama HMYOegt ve HMYOtest değerine sahiptir. Ayrıca hem eğitim hem de test kümesi için ABC algoritmasının standart sapma değeri de BP'ye göre oldukça düşüktür. Ancak $m=1$ olduğunda eğitim ve test kümesi için BP algoritması daha düşük minimum HKOK değerini vermiştir. Diğer girdi sayıları için ABC algoritması BP'ye göre eğitim ve test kümeleri için elde edilen HKOK değerlerinden hesaplanan tanımlayıcı istatistiklerine göre daha düşük ortalama, minimum ve standart sapma değerine sahiptir. ABC yöntemi ile eğitim yapıldığında en iyi test sonucu, girdi sayısının 2 olduğu durumda elde edilmiştir. BP algoritmasından ise en iyi test sonucu, girdi sayısının 1 olduğu durumda elde edilmiştir. ABC ve BP yöntemlerinin test kümesi için elde edilen HKOK ölçütı değerlerine göre en iyi durumları için, test kümelerinden elde edilen öngörülerin gerçek değerler ile birlikte grafiği Şekil 6'da verilmiştir.



Şekil 6. “İMKB 100 Endeksi” zaman serisi için ABC ve BP ile eğitilmiş tek çarpımsal sinir hücresi model YSA'dan elde edilen öngörülerin gerçek değerler ile birlikte grafiği

Şekil 6 incelendiğinde; ABC ile eğitilmiş tek çarpımsal sinir hücresi model YSA'dan elde edilen öngörülerin gerçek değerlerle BP algoritmasına göre daha iyi uyum sağladığı görülmektedir.

5. SONUÇ ve TARTIŞMA

Literatürde tek çarpımsal sinir hücresi YSA eğitiminde, BP ve diğer bazı algoritmalar başarıyla uygulanmıştır. Bu çalışmada ilk kez, tek çarpımsal sinir hücresi model eğitiminde ABC algoritması uygulanmıştır. ABC algoritmasının tek çarpımsal sinir hücresi modele uygulanması için kullanılacak algoritma verilmiştir. Ayrıca iki farklı gerçek hayat zaman serisi kullanılarak tek çarpımsal sinir hücresi model YSA'nın eğitimi için ABC ve BP yöntemleri karşılaştırılmıştır. Elde edilen sonuçlardan ABC yönteminin farklı rastgele başlangıç ağırlıkları kullanıldığından girdi sayısı ne olursa olsun BP yöntemine göre daha düşük standart sapmalar ürettiği görülmüştür. Bu durum ABC yönteminin rastgele başlangıç değerinden BP'ye göre daha az etkilendiğini ve yerel minimum tuzağına takılma olasılığının BP'ye göre daha az olduğunu göstermektedir. ABC yönteminde elde edilen ortalama HKOK ve HMYO değerleri ise hem eğitim hem de test kümesi için BP'den daha düşüktür. Bu durum ABC algoritmasının BP'den daha iyi öngörü sonuçları üreteceğini göstermektedir. Girdi sayısının 1 olduğu durum hariç, diğer tüm durumlarda minimum hatalı model de yine ABC'den elde edilmektedir. Ancak, bu çalışmada elde edilen sonuçların kullanılan veriye özel olduğu göz arı edilmemelidir. ABC ve BP algoritmalarının karşılaştırılması için daha fazla zaman serisi kullanılarak Alpaslan vd. (2012) çalışmasına benzer olarak, hipotez testlerine dayalı sonuçlar üretilebilir. Ayrıca ABC algoritmasının diğer yöntemler ile karşılaştırılması ise gelecek çalışmaların konusu olarak seçilebilir.

KAYNAKLAR

- Aladağ, C.H. (2011). *Defining Fuzzy Relations with Multiplicative Neuron Model*. The Second International Fuzzy Systems Symposium (FUZZYSS'11) Proceedings, 29-33.
- Alpaslan, F., Eğrioglu, E., Aladağ, C.H. ve Tiring, E. (2012). A Statistical Research on Feed Forward Neural Networks for Forecasting Time Series. *American Journal of Intelligence Systems* 2(3), 21-25.
- Avcı, G. (2011). Gerçek Zamanlı Uygulamalar için ABC Algoritmasının FPGA üzerinde Gerçeklenmesi. Yüksek Lisans Tezi, Niğde Üniversitesi, Niğde.
- Gunay, S., Eğrioglu, E. ve Aladag, C.H. (2007). *Introduction to Single Variable Time Series Analysis*. Hacettepe University Press.
- İlter, D. (2012). Tek Çarpımsal Sinir Hücresi Modelinin Eğitiminde Yapay Arı Kolonisi Algoritmasının Performansının Değerlendirilmesi. Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi, Samsun, 43-44.
- İ.M.K.B. (2012). Fiyat Endeksi. <http://www.imkb.gov.tr/Data/StocksData.aspx> (18.06.2012).
- İstanbul Altın Borsası, (2012). Altın Verileri. <http://www.iab.gov.tr/veriler.asp> (18.06.2012).
- Karaboğa, D. (2005). An Idea Based on Honey bee Swarm for Numerical Optimization. Technical Report-TR06, Erciyes University, Engineering Faculty, *Computer Engineering Department*.
- Karaboğa, D. (2011). Yapay Zeka Optimizasyon Algoritmaları. Nobel Yayın Dağıtım, Ankara, 231s.
- Karaboğa, D. ve Akay, B. (2007). Yapay Arı Koloni (Artificial Bee Colony, ABC) Algoritması ile Yapay Sinir Ağlarının Eğitilmesi. *Sinyal İşleme ve İletişim Uygulamaları* (SIU 2007). IEEE 15th, 1 – 4.
- Karaboğa, D., Akay B., Öztürk, C. (2007). Artificial Bee Colony (ABC) Optimization Algorithm for Training Feed-Forward Neural Networks, LNCS: Modeling Decisions for Artificial Intelligence, 4617, 318-329.
- Karaboğa, D. ve Öztürk, C. (2009). Neural Networks Training by Artificial Bee Colony Algorithm on Pattern Classification. *Neural Network World* 19(3), 279-292.
- Kumbhar, P.Y. ve Krishnan, S. (2011). Use of Artificial Bee Colony (ABC) Algorithm in Artificial Neural Network Synthesis. *International Journal of Advanced Engineering Sciences And Technologies* 11(1), 162-171.
- Mammadov, M. ve Taş, E. (2006). An Improved Version of Backpropagation Algorithm with Effective Dynamic Learning Rate and Momentum. *WSEAS Transactions on Mathematics* 7(5), 872-877.
- Mammadov, M., Taş, E., Omay, R.E. (2008). Accelerating Backpropagation using Effective Parameters at Each Step and An Experimental Evaluation. *Journal of Statistical Computation and Simulation* 78(11), 1055-1064.
- Öztürk, C. ve Karaboğa, D. (2011). Hybrid Artificial Bee Colony Algorithm for Neural Network Training. *Evolutionary Computation (CEC), 2011 IEEE Congress on*, 5-8 June 2011, 84-88.
- Samanta, B. (2011). Prediction of Chaotic Time Series using Computational Intelligence. *Expert Systems with Applications* 38(9), 11406-11411.

Bilim ve Teknoloji Dergisi - A - Uygulamalı Bilimler ve Mühendislik 14 (3)
Journal of Science and Technology - A - Applied Science and Engineering 14 (3)

Şen, Z. (2004). *Yapay Sinir Ağları İlkeleri*. Su Vakfı Yayınları, İstanbul, 183.

Tsai, P-W., Pan, J-S., Liao, B-Y. ve Chu, S-C. (2009). Enhanced Artificial Bee Colony Optimization. *International Journal of Innovative Computing, Information and Control* 5(12), 5081-5092.

Yadav, R.N., Kalra, P.K. ve John, J. (2007). Time Series Prediction with Single Multiplicative Neuron Model. *Applied Soft Computing* 7, 1157-1163.

Zhang, G., Patuwo, B.E. ve Hy, Y.M. (1998). Forecasting with Artificial Neural Networks: The State of The Art. *International Journal of Forecasting* 14, 35-62.

Zhao, L. ve Yang, Y. (2009). PSO-based Single Multiplicative Neuron Model for Time Series Prediction. *Expert Systems with Applications* 36, 2805-2812.