

## ELMAN AĞININ BENZETİLMİŞ TAVLAMA ALGORİTMASI KULLANARAK EĞİTİLMESİ

Adem KALINLI

Erciyes Üniversitesi, Kayseri Meslek Yüksek Okulu, Elektronik Bölümü, 38039, Kayseri

**Özet:** Yaygın olarak kullanılan geribeslemeli yapay sinir ağlarından birisi Elman ağıdır. Son yıllarda Elman ağı ve geliştirilmiş modelleri sistem kimliklendirme uygulamalarında sıkça kullanılmaktadır. Orijinal Elman ağı ve geliştirilmiş modelleri ileribesleme ve geribesleme bağlantılarına sahiptir. Ancak, bu ağlar temelde ileribeslemeli ağlar gibi standart geri yayılım algoritması ile eğitilmekte, geribesleme bağlantıları ise sabit kalmaktadır. Eğitime başarısı için, geribesleme bağlantılarının doğru değerde seçilmesi önemlidir. Bununla beraber, bu değerler uzunca bir deneme yanılma işlemiyle belirlenmektedir. Bu makalede benzetilmiş tavlama algoritmasının sistem kimliklendirme amacıyla Elman ağını eğitmede kullanılması tanımlanmıştır. Benzetilmiş Tavlama algoritması, ileribesleme ve geribesleme bağlantılarının her ikisi için optimal ağırlık değerlerini sağlayabilecek, etkili bir rasgele araştırma algoritmasıdır.

**Anahtar Kelimeler :** Geribeslemeli sinir ağları, Elman ağı, benzetilmiş tavlama, dinamik sistem kimliklendirme

### TRAINING ELMAN NETWORK USING SIMULATED ANNEALING ALGORITHM

**Abstract:** One of the common used recurrent neural networks is the Elman network. Recently, Elman network and its modified models have been used in applications of system identification. The original Elman network and its modified models have feedforward and feedback connections. However, so that it can be trained essentially as feedforward networks by means of the basic backpropagation algorithm, but their feedback connections have stayed as constant. For training success, it is important to select correct values for the feedback connections. However, finding these values manually can be a lengthy trial-and-error process. This paper investigates the use of simulated annealing (SA) algorithm to train the Elman network for linear and nonlinear dynamic systems identification. The SA algorithm is an efficient random search procedure which can simultaneously obtain the optimal weight values of both the feedforward and feedback connections.

**Key words :** Recurrent neural networks, simulated annealing, Elman network, dynamic system identification

#### 1. Giriş

Sistem kimliklendirme ve modelleme amacıyla yapay sinir ağlarının kullanılması bir çok araştırmanın konusu olmuştur [1-8]. Yapay sinir ağlarının çok detaylı bilgiye ihtiyaç duymadan bir sistemin davranışını öğrenebilmesi bu tür uygulamalarda önemli bir avantaj olarak ortaya çıkmaktadır. Sistem kimliklendirme amacıyla kullanılan yapay sinir ağlarının, ileribeslemeli ve geribeslemeli olmak üzere iki ana türü vardır. İleribeslemeli ağlarda nöronların bağlantısı, sinyal giriş ünitelerinden tek doğrultuda çıkış ünitelerine akacak şekildedir. Geribeslemeli ağlarda ise ileribesleme ve geribesleme bağlantıları ile sinyal zıt doğrultularda yayılabilmektedir. İleribeslemeli ağlar dinamik sistemlerin kimliklendirilmesi amacıyla başarıyla kullanılmıştır [3,4]. Fakat, ileribeslemeli yapay sinir ağlarını kullanmanın ortaya çıkardığı bazı dezavantajlar vardır. Örneğin, bu ağlarda çok sayıda nöron kullanma zorunluluğu eğitime zamanını artırmakta ve ağı gürültüye karşı daha duyarlı olmasına neden olmaktadır. Geribeslemeli yapay sinir ağları ise daha az giriş hattı gerektirir ve gürültüye karşı daha az duyarlıdır. Ayrıca, geribeslemeli ağların sahip olduğu geribesleme bağlantıları dinamik bir hafıza davranışı sağlar ve bu nedenle geribeslemeli ağlar dinamik sistemlerin kimliklendirilmesi için daha doğal modellerdir. Tüm bu nedenlerle dinamik sistem kimliklendirme alanında araştırmacıların ilgisi geribeslemeli yapay sinir ağlarına yönelmiştir [5-8]. Ancak, geribeslemeli yapay sinir ağlarının eğitilmesi daha zordur ve çoğu zaman özel eğitime algoritmalarının kullanılması ve belirli kabullerin yapılması gerekmektedir. Geribeslemeli yapay sinir ağlarının yaygın olarak kullanılan bir türü Elman ağıdır [9]. Bu ağı ve geliştirilmiş modellerinin sistem kimliklendirmedeki performansları araştırmacılar tarafından incelenmiştir [6,8,10,11]. Elman ağı ve geliştirilmiş modelleri temelde standart geri yayılım (backpropagation) öğrenme algoritması ile eğitilmektedir. Bu algoritmanın uygulanmasında, ağı sadece ileribesleme bağlantıları eğitilebilmekte, geribesleme bağlantıları ise, kullanıcının önceden deneme yanılma yoluyla belirlediği değerlerde sabit kalmaktadır. Bu ağlarda eğitime başarısı için, geribesleme bağlantı değerlerinin doğru seçilmesi oldukça önemlidir. Eğitime performansı üzerinde çok etkili olduğu bilinen geribesleme bağlantılarının standart GY algoritması ile eğitilememesi, bazı sistem kimliklendirme uygulamalarında ağı başarısız olmasına neden olmaktadır. Standart GY algoritması kullanılmasının ortaya çıkardığı bu sınırlamaları ortadan kaldırarak ağı daha başarılı bir şekilde eğitilebilmesi için yapılan yaklaşımlardan birisi, ağıdaki her bir ağırlık değerini birer parametre olarak algılayabilen dolayısıyla ileribesleme yada

geribesleme bağlantısı ayırımı yapmayan sezgisel algoritmaların eğitime amacıyla kullanılması olmuştur. Yapılan çeşitli çalışmalarda, bu ağların ileribesleme ve geribesleme bağlantı ağırlıklarının eğitilmesinde tabu araştırma ve genetik algoritma gibi sezgisel algoritmaların başarıyla kullanılabileceği ortaya konmuştur [12-16].

Bu çalışmada, sezgisel bir algoritma olan Benzetilmiş Tavlama (Simulated Annealing) algoritmasının dinamik sistem kimliklendirme amacıyla Elman ağının eğitilmesinde kullanılması tanımlanmıştır. Benzetilmiş Tavlama (BT) problemden bağımsız, olasılık tabanlı bir algoritmadır ve bu algoritmayı geleneksel optimizasyon metodlarından ayıran önemli özelliklerden birisi, uyguladığı stratejiler ile büyük oranda yerel minimumdan kurtulabilme kabiliyetinin olmasıdır. Simülasyon çalışmalarında, BT algoritmasının Elman ağının eğitilmesindeki performansı incelenerek elde edilen neticeler standart geriyayılım (GY) algoritması ile elde edilen sonuçlarla karşılaştırılmıştır.

İkinci bölümde standart BT algoritması hakkında bilgi verilmiştir. Üçüncü bölümde ise, Elman ağının yapısı tanıtılarak, BT algoritmasının bir dinamik sistemin kimliklendirilmesi için verilen ağları eğitmekte nasıl kullanıldığı açıklanmıştır. Dört farklı tek-girişli tek-çıkışlı sistem için sağlanan sonuçlar ise, dördüncü bölümde verilmiştir.

## 2. Benzetilmiş Tavlama Algoritması

Benzetilmiş Tavlama ilk olarak Kirkpatrick, Gelatt ve Vecchi tarafından önerilmiş, olasılık tabanlı sezgisel bir algoritmadır [17]. BT algoritması katıların fiziksel tavlama işlemi ve kombinatoriyal optimizasyon problemlerinin çözümü arasındaki benzerlik üzerine dayalıdır. Tavlama, katının ergime noktasına kadar ısıtılması ve devamında mükemmel kafes yapılı durumda kristalize olana kadar yavaşça soğutulması işlemidir. Malzemelerin atomları yüksek sıcaklıklarda yüksek enerji seviyelerindedir ve düzgün yerleşimler için daha fazla hareket serbestliğine sahiptirler. Düzgün yapılı bir kristal sağlandığında, sistem minimum enerjiye sahiptir. Sıcaklık azaldıkça, atomik enerji düşer. Eğer soğutma işlemi çok hızlı gerçekleşirse, kristal yapıda bozukluklar ve düzensizlikler ortaya çıkacaktır. Bu nedenle soğutma işleminin dikkatle yapılması gerekmektedir [18].

Fiziksel tavlama işlemi, Monte Carlo tekniği üzerine dayalı olarak Metropolis ve arkadaşları tarafından modellenmiştir [19]. Verilen bir T sıcaklığında, sistem enerjilerinin olasılık dağılımı aşağıda verilen termodinamik kanunu ile belirlenir:

$$P(E) = e^{-E/(kT)} \quad (1)$$

Burada,  $E$  sistem enerjisi,  $k$  ise Boltzmann sabitidir.

Küçük bir karışıklıkla sistem durumunda değişiklik yaratılması halinde, Metropolis algoritmasına göre sistemin yeni enerjisi hesaplanır. Eğer enerji azalmış ise, sistem bu yeni duruma geçer. Eğer enerji artmış ise yeni durumun kabul edilip edilmemesine, Eşitlik (1) de verilen olasılık formülü kullanılarak karar verilir: Uniform dağılımdan  $[0,1]$  aralığında rasgele bir  $\delta$  sayısı üretilir ve Eşitlik (2)' de verilen şart sağlanıyorsa yeni çözüm, mevcut çözüm olarak kabul edilir. Aksi takdirde, mevcut çözüm değiştirilmez.

$$\delta \leq e^{-\Delta E/T} \quad (2)$$

Burada,  $\Delta E$ , iki durumun enerji seviyeleri arasındaki farktır. Bu kabul kriteri *Metropolis kriteri* olarak bilinir. Eşitlik (1)' e göre, yüksek sıcaklıklarda tüm enerji durumları için  $P(E)$ , 1'e yakınsar. Düşük sıcaklıklarda bile sistemin yüksek enerji seviyesine sahip olması küçük bir olasılıkla görülebilir. Bu nedenle enerjilerin istatistiksel dağılımı, sistemin bir yerel enerji minimumundan çıkmasına izin verir.

Kombinatoriyal optimizasyon problemi ve tavlama işlemi arasındaki benzerlikte, katının durumları optimizasyon probleminin mümkün olan çözümlerini temsil eder ve bu durumların enerjileri çözümler için hesaplanan amaç fonksiyon değerlerine karşılık gelir. Minimum enerji durumu problem için optimal çözümü ifade eder, hızlı soğutma işlemi ise yerel optimum olarak görülebilir. BT iteratif bir algoritmadır, yani algoritma çözüm uzayında sayıların vektörü formundaki tek bir çözümü sürekli olarak geliştirme şeklinde çalışır. Standart bir BT algoritmasının adımları Şekil 1' de verilmiştir.

Şekil 1. Benzetilmiş Tavlama algoritmasının temel adımları

BT algoritmasının bir probleme uygulanması amacıyla dizaynında karar verilmesi gereken önemli kavramları iki grupta toplamak mümkündür [20]:

a) Probleme özgü seçimler: Problem, mümkün çözümlerin kümesi tanımlanabilecek şekilde formüle edilmelidir. Çözümlerin temsili (kodlama yapısı), minimize edilecek bir amaç fonksiyon değeri ve komşuluk üretim mekanizması belirlenmeli ve bir başlangıç çözümü üretilmelidir.

b) Soğutma planına ait seçimler: Sıcaklık parametresi  $T$  nin başlangıç değeri; soğutma oranı ve güncelleme kuralı; her bir sıcaklıkta icra edilecek iterasyonların sayısı ve algoritmayı durdurmak için sıcaklık parametresinin son değerine karar verilmelidir.

BT algoritmasının performansı büyük oranda seçilen soğutma planına bağlıdır. Günümüze kadar çok çeşitli soğutma planları önerilmiştir. Önerilen en eski plan Kirckpatrick ve arkadaşlarının fiziksel tavlama ile olan benzerliğe dayanarak ileri sürdükleri plandır. Bu tavlama planına göre, maddenin sıvı safhaya ulaştığında tüm parçacıkların rasgele düzenlenmesini taklit etmek için,  $T$  sıcaklık parametresinin başlangıç değeri, denenen tüm hareketler kabul edilecek kadar yüksek seçilmiştir. Sıcaklık parametresinin değerini azaltmak için ise, oransal bir sıcaklık fonksiyonu kullanarak sabit bir  $r$  için,  $T(t+1)=r.T(t)$  dikkate alınmıştır. Burada,  $r$  değeri 1' den küçük fakat 1'e yakın bir sabittir ve genellikle değeri 0.8 ile 0.99 arasında bir değer almaktadır. Bu sıcaklık fonksiyonu ile sıcaklık parametresinin değeri, sıfıra yaklaştıkça daha da yavaş azalmaktadır. Sıcaklık parametresinin her değerinde gerçekleştirilecek yeterli tekrar sayısı sabit bir üst sınıra göre belirlenerek problemin, fiziksel tavlamadaki ısı dengeye karşılık gelen bir denge durumuna ulaşması amaçlanmaktadır. Bu tavlama planı ile, sıcaklık parametresinin her değerinde elde edilen çözüm, belli sayıda ardışık sıcaklık değişimleri boyunca aynı kalırsa BT algoritması durdurulmaktadır. Buna göre elde edilen son durum, fiziksel tavlamadaki *donma durumuna* (*frozen state*) karşılık gelmektedir.

### 3. Elman Ağının Benzetilmiş Tavlama Algoritması Kullanarak Eğitilmesi

Temel yapısı Şekil 2' de verilen Elman ağı üç katmanlıdır. İlk katman nöronların iki farklı gurubundan oluşmuştur. Bunlar, harici giriş nöronlarının gurubu ve dahili giriş nöronları olarak da adlandırılan geciktirme ünitelerinin gurubudur. Giriş katmanı nöronları sadece tampon görevi yapar ve gelen sinyali değiştirmeden geçirir. Geciktirme üniteleri için giriş, saklı katman nöronlarının çıkışlarıdır. Bu ağlarda saklı katmandaki önceki durumlar hafıza olarak saklanarak girişe verilmekte ve bu durumda ağı çıkışı, o anki ve önceki girişe bağlı olarak belirlenmektedir. Bu yapı *dinamik hafıza* olarak görev yapmaktadır.

Elman ağına ileri besleme bağlantıları eğitilebilirdir ve ağı eğitilmesinde standart GY algoritması kullanılmaktadır. Geri besleme bağlantıları ise standart GY algoritması kullanarak

kullanılmaktadır. Geri besleme bağlantıları ise standart GY algoritması kullanarak eğitilememektedir. Bu bağlantı ağırlıklarının değeri keyfi olarak sabit bir değerde seçilebilmekle beraber, çoğunlukla 1 olarak kabul edilmektedir. Eğitim başarısı için, geri besleme bağlantılarının değerinin doğru seçilmesi önemlidir. Öğrenme başlangıcında, ağı saklı katman nöronlarının aktivasyon değerleri bilinmediğinden, bu değer genellikle saklı katman nöronlarının alabileceği maksimum değer yarısı veya sıfır olarak alınmaktadır. Genel olarak bu değeri, saklı katman nöronlarında sigmoid aktivasyon fonksiyonu kullanılması durumunda 0.5, hiperbolik tanjant aktivasyon fonksiyonu kullanılan ağda ise 0 olarak almak mümkündür [11]. Kaynak [21,22]' e göre geribeslemeli bir ağı geciktirme ünitelerinde sağlanacak öz-bağlantılar ile ağı dinamik hafıza yeteneğinde artış sağlanabilmektedir. Bu düşünceden hareketle Pham ve Liu temel Elman ağına düzenleme yapmışlardır [6]. Elman ağı için önerilen bu model Şekil 3'te gösterilmiştir. Şekilde gösterilen  $\alpha$  öz-bağlantı kazanç değeri yada öz-bağlantı oranı olarak adlandırılmaktadır. Elman ağı için önerilen bu model standart GY algoritması ile eğitilmekte, öz-bağlantı oranı değeri de geribesleme bağlantı ağırlıkları gibi daha önceden deneme yanılma yoluyla belirlenen değerlerde sabit kalmaktadır.

Şekil 2. Elman Ağının yapısı

Şekil 3. Geliştirilmiş bir elman ağı

Bu çalışmada, kimliklendirme amacıyla dikkate alınan sistemler tek-giriş tek-çıkışlıdır. Bu nedenle, kullanılan Elman ağlarında harici giriş ve çıkış nöron sayısı 1 olarak alınmıştır. Saklı katman nöron sayısı ise sisteme göre değişik değerlerde seçilmiştir. Burada, BT algoritması, ağ yapısına karar verilmiş bir geribeslemeli yapay sinir ağının eğitilmesinde kullanılmıştır. Ağdaki katmanların sayısı, aktivasyon fonksiyonlarının türü, her bir katmandaki nöron sayıları, eğitilebilir ağırlıkların izin verilen aralığı ve sabit bağlantı ağırlıklarının değerlerinin hepsi bilinmektedir. BT algoritması için, başlangıç çözümü rasgele sayı üretici ile sağlanmaktadır. Kullanılan bu çözüm, geribeslemeli ağ için mümkün olan bir ağırlık setini temsil etmektedir ve BT algoritması uyguladığı çeşitli stratejiler ile, geribeslemeli ağ için en iyi ağırlık setini araştırmaktadır.


Eğitilebilir bağlantıların sayısı  $n$  olmak üzere, bir çözüm her biri sayısal değer olan  $n$  elemanlı bir ağırlıklar dizisidir (Şekil 4). BT algoritması ile belirlenecek parametre sayısı, eğitilebilir bağlantı ağırlıklarının sayısı kadardır. İleri besleme ağırlıkları  $[-1,1]$  aralığında, geribesleme ağırlıkları ise  $[0,1]$  aralığında değerlere sahiptir. Yaygın olarak kullanılan GY algoritmasının aksine, BT algoritması açısından bakıldığında geribesleme ve ileri besleme bağlantıları arasında fark yoktur ve bağlantıların bir türünün eğitilmesi ile diğerlerinin eğitilmesi aynıdır.

Şekil 4. Eğitilebilir ağırlıkların dizi formunda temsili

ağ ve sistem çıkışlarıdır. Elman ağının eğitilmesi, optimizasyon problemi olarak Eşitlik (3)'te verilen amaç fonksiyonu ile formüle edilebilir.

$$J(\mathbf{w}) = \left( \frac{1}{M} \sum_{k=1}^M (y_p(k) - y_m(k))^2 \right)^{1/2} \quad (3)$$

Burada,  $M$  gurup çalışmasında kullanılan veri sayısı ve,  $\mathbf{W} = [w_{11} \ w_{12} \ w_{13} \ \dots \ w_{pq}]^T$  Elman ağının bağlantı ağırlıklarını göstermektedir. Amaç,  $\mathbf{W}$ 'yi ayarlayarak Eşitlik (3) ile verilen etkin hatayı minimize etmektir. Eğitim aşamasında, önce  $u(k)$  ( $k=0,1,\dots$ ) giriş sinyali dizisinin bir elemanı, mevcut çözümden sağlanan ağırlıklarla tasarlanmış geribeslemeli ağ ve sistemin her ikisinin girişlerine uygulanır. Sonra geribeslemeli ağ ve sistem çıkışları arasındaki hata değeri hesaplanır. Giriş sinyali dizisinin tüm elemanları için hesaplanan hata değerleri yardımıyla Eşitlik (3)'te verilen ifade ile belirlenen etkin (rms) hata değeri, ağın mevcut durumunun iyiliğinin ölçüsü olarak kullanılmıştır. Mevcut durumdan sağlanan etkin hata değeri ile, yeni üretilen komşu çözümle sağlanan etkin hata değeri karşılaştırılır. Eğer yeni çözüm ile sağlanan etkin hata değeri daha düşük ise, yeni çözüm mevcut çözüm olarak atanır ve araştırmaya devam edilir. Aksi takdirde, Metropolis kriterine göre seçim yapılır.



Şekil 5. Sistem kimliklendirme için geribeslemeli yapay sinir ağının BT algoritması kullanılarak eğitilmesi planı

#### Sistem 1

Simülasyon için kullanılan birinci örnek, Eşitlik (4) ile verilen iki eşlenik kompleks kutuplu ikinci derece sistemdir.

$$G(s) = \frac{1 - e^{-Ts}}{s} \cdot \frac{w}{(s+a)^2 + w^2} \quad (4)$$

Eşitlik (4)'ün ayrık formu aşağıda verilmiştir:

$$y(k) = A_1 y(k-1) + A_2 y(k-2) + B_1 u(k-1) + B_2 u(k-2) \quad (5)$$

Burada,  $T=0.1$  s,  $a=1.0$  ve  $w=2\pi/2.5$ , parametreler ise  $A_1=1.752821$ ,  $A_2=-0.818731$ ,  $B_1=0.011698$ ,  $B_2=0.010942$  dir. Elman ağını eğitmede kullanılan giriş sinyali,  $u(k)$ ,  $k=0,1,\dots,99$ ,

$|u(k)| \leq (a^2 + w^2) / w$  aralığında rasgele üretilmiştir ( $M=100$ ). Bu sistem için, Elman ağının saklı katmanında 4 nöron kullanılmıştır. Ağda tüm bağlantı ağırlıkları ayarlanabilir olarak alındığından, BT algoritması tarafından belirlenecek parametre sayısı 28 dir. BT algoritması ile eğitilen ağ ve sistem cevapları Şekil 6' da verilmiştir. Şekilden görüldüğü gibi sistem için daha kompleks olan geliştirilmiş Elman ağına ihtiyaç duyulmadan oldukça doğru bir model sağlanabilmiştir.

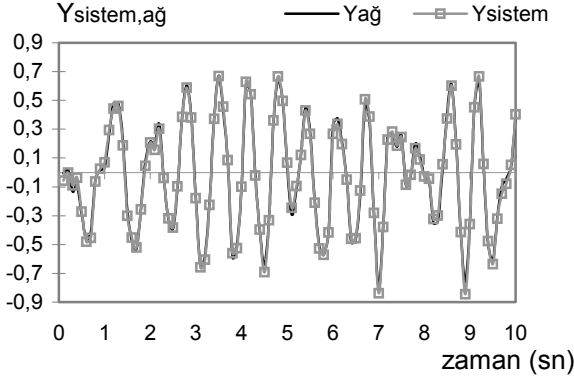
Bir dinamik sistem modeli için, geribeslemeli sinir ağının eğitilmesi amacıyla BT algoritmasının kullanılmasında Şekil 5' de gösterilen kimliklendirme konfigürasyon kullanılmıştır. Burada,  $y_m(k)$  ve  $y_p(k)$  sırasıyla

Eğitimde kullanılacak giriş dizisi elemanları genellikle sinüsoidal v çalışmada gerçekleştirilen simüle sinyal dizileri kullanılmıştır.

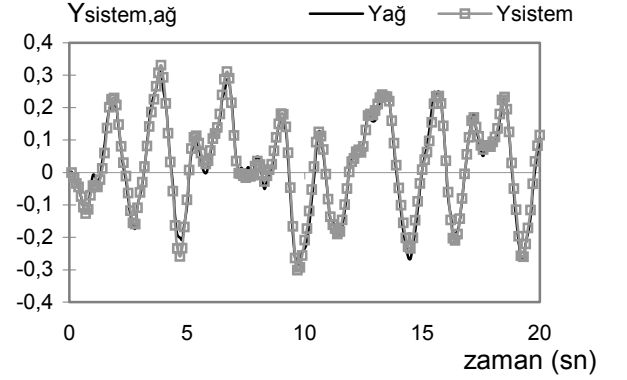
#### 4. Simülasyon Sonuçları

Simülasyon çalışmalarında, Elman sistem kullanılmıştır. Birinci ve ikinci Üçüncü ve dördüncü örnekler ise sistemler için Elman ağının tüm katmanları için Elman ağının saklı katmanında nöronlar kullanılmıştır. Nonlineer aktivasyon fonksiyonu kullanılmıştır edilmiştir.





Şekil 9. Sistem 3 için, sistem ve ağ cevapları (etkin hata = 2.57737E-02)



Şekil 10. Sistem 4 için, sistem ve ağ cevapları (etkin hata = 1.77047E-02)


#### Sistem 4

Bu model, ayrık zaman ifadesi aşağıda verilen nonlinear bir sistemdir.

$$y(k) = \frac{A_1 y(k-1) + A_2 y(k-2) + B_1 u(k-1) + B_2 u(k-2)}{1 + y^2(k-2)} \quad (8)$$

Burada,  $A_1=1.752821$ ,  $A_2=-0.818731$ ,  $B_1=0.011698$ ,  $B_2=0.010942$  dir. Eğitimde kullanılan giriş sinyali,  $u(k)$ ,  $k=0,1,\dots,199$ ,  $[-2,2]$  aralığında rasgele üretilmiştir ( $M=200$ ). Kullanılan Elman ağının yapısı bir önceki sistem için kullanılan ile aynıdır. BT algoritması ile eğitilen ağ ve sistem cevapları Şekil 10'da verilmiştir.

Şekil 3'de verilen geliştirilmiş Elman ağının Sistem 4 için  $\alpha$  nın değişik değerlerindeki standart GY ve BT algoritması ile eğitilmesi durumundaki performans incelemesine ait sonuçlar Şekil 11'de verilmiştir. Bu amaçla kullanılan giriş eğitme dizisi  $u(k)$ ' nın değeri, Sistem 1'deki ile aynı aralıkta rasgele olarak seçilmiştir. Şekilden görüldüğü gibi, bu sistem içinde BT algoritması ile, standart geriyayılım algoritmasına göre daha başarılı neticeler elde edilmiştir.



Şekil 11. Sistem 4 için farklı geribesleme oranlarına ait etkin hata performansları.

kimliklendirilmesi için Elman ağını eğitmek amacıyla kullanılması incelenmiştir. Elde edilen neticelerden görüldüğü gibi, ikinci dereceden lineer bir sistem için standart GY algoritması orijinal Elman ağının eğitilmesinde başarısız olmuştur. Bununla beraber, BT algoritması kullanılarak orijinal Elman ağının tüm bağlantı ağırlıklarının eğitilmesi ile hem ikinci derece hem de üçüncü dereceden lineer sistemler başarılı bir şekilde eğitilebilmiştir. Geliştirilmiş Elman ağının standart GY algoritması ile ikinci derece sistemin kimliklendirilmesi için eğitilmesi ise ancak öz-bağlantı oranının belirli bir değerinde başarılı olmuştur ( $\alpha=0.6$ ). Oysa geliştirilmiş Elman ağının aynı sistemin kimliklendirilmesi için BT algoritması ile eğitilmesi, öz-bağlantı oranının geniş bir aralıkta başarıyla gerçekleştirilebilmiştir.

Nonlinear sistemlerin için elde edilen neticeler, orijinal ve geliştirilmiş Elman ağının eğitilmesinde BT algoritmasının, standart GY algoritmasına göre daha başarılı olduğunu göstermiştir. Şekil 11'

Bu çalışmada, BT algoritması için sıcaklık noktalarının sayısı 15, her bir sıcaklıktaki iterasyon sayısı 15 ve sıcaklık azalma parametresi 0.9 olarak alınmıştır. Her bir eğitim işlemindeki değerlendirme sayısı, Sistem 1 için 28000, diğer sistemler için 54000 dir.

#### 5. Tartışmalar ve Sonuç

Bu çalışmada BT algoritmasının, dinamik sistemlerin

den görülebileceği gibi, Örnek 4 ile verilen nonlinear sistem için geliştirilmiş Elman ağının GY ile eğitilmesi işlemi en düşük hata değeri yaklaşık %6'dır. Orijinal Elman ağının tüm bağlantı ağırlıklarının eğitilebilir yapılarak BT algoritması ile eğitilmesi durumunda elde edilen hata değeri ise yaklaşık %1.77'dir.

Lineer ve nonlinear sistemler için orijinal Elman ağının BT algoritması ile eğitilmesine ait sonuçların tamamı, GY algoritması ile elde edilenlerden daha başarılıdır. Yine elde edilen neticelerden açıkça görülmektedir ki, orijinal Elman ağının BT algoritması ile eğitilmesi durumunda başarı, GY algoritması ile geliştirilmiş Elman ağının eğitilmesi durumundaki sonuçlardan çok daha yüksektir.

Elde edilen neticeler, BT algoritmasının sistem kimliklendirme amacıyla Elman ağının eğitilmesinde başarıyla kullanılabileceğini göstermiştir. Ayrıca BT algoritması gibi etkin algoritmaların kullanılması halinde Elman ağının, daha kompleks geliştirilmiş ağ modellerine ihtiyaç duyulmadan orijinal haliyle de başarılı bir şekilde eğitilebileceği ortaya konmuştur.

#### Kaynaklar

1. Chen, S., Billings, S.A. and Grant, P.M., Nonlinear system identification using neural networks, *Int. J. Control*, **51**, 6, 1191-1214, 1990.
2. Narendra, K.S. and Parthasarathy, K., Identification and control of dynamical systems using neural networks, *IEEE Trans on Neural Networks*, 1 (1), s.4-27, 1990.
3. Pham D.T., Liu X., *Neural networks for identification, prediction and control*, London: Springer-Verlag, 1999 (4th edition).
4. Yun L, Häußler A., Artificial evolution of neural networks and its application to feedback control, *Artificial Intelligence in Engineering*, 10(2), s.143-152, 1996.
5. Pham D.T., Liu X., Dynamic system identification using partially recurrent neural networks, *Journal of Systems Engineering*, 2(2):90-97, 1992.
6. Pham DT, Liu X., Identification of linear and nonlinear dynamic systems using recurrent neural networks. *Artificial Intelligence in Engineering*, 8, s.67-75, 1993.
7. Ku C-C, Lee KY., Diagonal recurrent neural networks for dynamic systems control. *IEEE Trans. on Neural Networks*, 6(1), s.144-156, 1995.
8. Pham D.T., Liu X., Training of Elman networks and dynamic system modelling. *Int. Journal of Systems Science*, 27(2), s.221-226, 1996.
9. Elman, J.L., Finding Structure In Time, *Cognitive Science*, 14, s.179-211, 1990.
10. Pham DT, Oh SJ., A recurrent backpropagation neural network for dynamic system identification, *Journal of Systems Engineering*, 2(4), s.213-223, 1992.
11. Liu, X., *Modelling and Prediction Using Neural Networks*, PhD Thesis, University of Wales College of Cardiff, Cardiff, UK, 1993.
12. Pham, D.T., Karaboga, D., Training Elman and Jordan networks for system identification using genetic algorithms, *Artificial Intelligence in Engineering*, 13, s.107-117, 1999.
13. Karaboga D. and Kalinli A., Training recurrent neural networks using tabu search algorithm, 5th Turkish Symposium on Artificial Intelligence and Neural Networks, s.293-298, Türkiye, 1996.
14. Kalinli, A., Karaboga, D., Geribeslemeli Yapay Sinir Ağlarının Paralel Tabu Araştırma Algoritması Kullanarak Eğitilmesi, 11<sup>th</sup> Turkish Symposium on Artificial Intelligence and Neural Networks (TAINN'2002), s.261-270, İstanbul, June 20-21, 2002.
15. Kalinli, A., Geribeslemeli Yapay Sinir Ağlarının Genetik Operatörlere Dayalı Tabu Araştırma Algoritması Kullanarak Eğitilmesi, Doktora tezi, Fen Bilimleri Enstitüsü, Erciyes Üniversitesi, Kayseri, 1996.
16. Pham D.T. and Karaboga D., *Intelligent Optimisation Techniques: Genetic Algorithms, Tabu Search, Simulated Annealing And Neural Networks*, Advanced Manufacturing Series, Springer-Verlag, London, 2000.
17. Kirkpatrick, S., Gelatt Jr, C.D., Vecchi Jr, M.P., Optimization By Simulated Annealing, *Science*, cilt.220, s.671-680, 1983.
18. Dowsland, K.A., Simulated Annealing. In *Modern Heuristic Techniques for Combinatorial Problems*, (Editor, Reeves, C.R.), McGraw-Hill, 1995.
19. Metropolis, N., Rosenbluth, A., Rosenbluth, M., Teller, A. and Teller, E., Equation Of The State Calculation By Fast Computing Machines, *Journal of Chemical Physics*, cilt.21, s.1087-



1092, 1953.

20. Johnson, S., Aragon, C., McGeoch, L., and Schevon, C., Optimization By Simulated Annealing: An Experimental Evaluation, Part-I, Graph Partitioning, Operations Research, cilt.37, s.865-892, 1989.

21. Hertz, J., Krogh, A. and Palmer, R.G., Recurrent Networks, in introduction to the theory of neural computation, Addison-Wesley, Reading, MA, Chap.7, 1991.

22. Rumelhart D.E., McClelland, J.L., Explorations in the Micro-Structure of Cognition, Parallel Distributed Processing 1, Cambridge, MA: MIT Press, 1986.