

ELMAN AĞININ SIMULATED ANNEALING ALGORİTMASI KULLANARAK SİSTEM KİMLİKLENDİRME İÇİN EĞİTİLMESİ

Adem KALINLI

ÖZET: Elman ağı geribeslemeli yapay sinir ağlarının özel bir türüdür. Elman ağının ileribesleme bağlantıları, ileribeslemeli ağlar gibi yalın geriyayılım algoritması ile eğitilmekte, geribesleme bağlantıları ise sabit kalmaktadır. Geribesleme bağlantılarının uygun değerlerde seçilmesi, eğitmenin başarısı için önemlidir. Ancak, bu değerlerin belirlenmesi uzunca bir deneme yanılma işlemiyle olabilmektedir. Bu çalışmada, Simulated annealing (SA) algoritmasının, dinamik sistemlerin kimliklendirilmesi amacıyla Elman ağının eğitilmesi için kullanılması tanımlanmıştır. SA algoritması, tüm bağlantıların optimal ağırlık değerlerini sağlayabilecek, etkili bir rasgele araştırma algoritmasıdır.

ANAHTAR KELİMELEER : Simulated annealing, Elman ağı, sistem kimliklendirme

TRAINING ELMAN NETWORK FOR SYSTEM IDENTIFICATION USING SIMULATED ANNEALING ALGORITHM

ABSTRACT: A special type of recurrent neural networks is the Elman network. Feedforward connections of the Elman network can be trained essentially as feedforward networks by means of the simple backpropagation algorithm, their feedback connections have to be kept constant. It is important to select correct values for the feedback connections for the training to convergence. However, finding these values can be a lengthy trial-and-error process. This paper describes the use of simulated annealing (SA) algorithm to train the Elman network for dynamic systems identification. The SA algorithm is an efficient random search procedure which can simultaneously obtain the optimal weight values of all connections.

KEYWORDS : Simulated annealing, Elman network, system identification

I. GİRİŞ

Yapay sinir ağıları için yapısal ve öğrenme algoritmaları bakımından önerilmiş pek çok farklı model bulunmaktadır. Yapay sinir ağıları işlemci elemanlarının bağlantı yapıları bakımından, ileribeslemeli ağılar ve geribeslemeli ağılar olarak iki ana guruba ayrılabilir [1]. İleribeslemeli ağılarda işlemci elemanlarının bağlantısı, sinyal giriş ünitelerinden tek doğrultuda çıkış ünitelerine akacak şekildedir. Geribeslemeli ağılarda ise, ileri geçişli ve geribeslemeli bağlantılarla sinyal zıt doğrultularda yayılabilir. Yapay sinir ağılarının eğitilmesinde kullanılan pek çok algoritma Hebbian ve gradyent öğrenme tabanlıdır. Gradyent tabanlı algoritmalarından birisi, Rumelhart tarafından önerilen ve yaygın olarak kullanılan standart geriyayılım algoritmasıdır (Backpropagation, BP). Standart BP algoritması nispeten kolaylıkla kullanılabilmesine rağmen, pratik uygulamalarında çeşitli zorluklar ortaya çıkabilmektedir. Bu dezavantajlardan bazıları, bölgesel minimadan kurtulmasının zorluğu ve geribeslemeli ağılarda geribesleme bağlantılarını eğitememesidir [2].

Sistem kimliklendirme ve modelleme amacıyla yapay sinir ağılarının kullanılması bir çok araştırmanın konusu olmuştur. Yapay sinir ağılarının çok detaylı bilgiye ihtiyaç duymadan bir sistemin davranışını öğrenebilmesi ve sahip olduğu gürültü toleransı özelliği bu tür uygulamalarda önemli bir avantaj olarak ortaya çıkmaktadır.

İleribeslemeli ağılar dinamik sistemlerin kimliklendirilmesi amacıyla başarıyla kullanılmıştır. Fakat ileribeslemeli yapay sinir ağılarını kullanmanın ortaya çıkardığı bazı dezavantajlar vardır. Genel olarak, bu ağılarda çok sayıda işlemci elemanı kullanma zorunluluğu eğitime zamanını artırmakta ve ağı gürültüye karşı daha duyarlı olmasına neden olmaktadır [3-5].

Diğer bir ağ yapısı, daha az giriş hattı gerektiren ve gürültüye karşı daha az duyarlı olan geribeslemeli yapay sinir ağılarıdır. Yukarıda belirtilen dezavantajlardan kaçınmak için, dinamik sistem kimliklendirme alanında araştırmacıların ilgisi geribeslemeli yapay sinir ağılarına yönelmiştir [3-9]. Geribeslemeli yapay sinir ağılarının iyi bilinen ve yaygın olarak kullanılanlarından birisi Elman ağıdır [10]. Bu ağı ve geliştirilmiş versiyonlarının sistem kimliklendirmedeki performansları çeşitli çalışmalarda

incelenmiştir [1,3,4,5,8]. Elman ağı temelde ileribeslemeli ağlar gibi standart BP algoritması ile eğitilmektedir. Bu algoritmanın uygulanmasında, ağın sadece ileribesleme bağlantıları eğitilmekte, geribesleme bağlantıları ise kullanıcının önceden deneysel olarak belirlediği değerlerde sabit kabul edilmektedir. Geribesleme bağlantılarının ağırlık değerleri eğitime başarısı üzerinde oldukça etkili olup, uygun değerlerin seçilmesi büyük önem taşımaktadır [1,3].

Geribeslemeli yapay sinir ağlarının eğitilmesinde BP gibi standart öğrenme algoritmalarının kullanılması ancak bazı kabullerle mümkün olabilmekte veya ağa özgü daha kompleks algoritmaların kullanılması gerekmektedir. Bu ağların kolaylıkla ve başarılı bir şekilde eğitilebilmesi için sezgisel (*heuristic*) optimizasyon algoritmalarının kullanılmasına olan ilgi ise gittikçe artmaktadır [1,11-14].

Simulated annealing algoritması (SA), Tabu araştırma algoritması (TA) ve genetik algoritma (GA) zor mühendislik problemlerinin çözümü için önerilmiş sezgisel algoritmalarından bazılarıdır. GA ve TA algoritması Elman ağının sistem kimliklendirme amacıyla eğitilmesinde kullanılmış olmasına rağmen, literatürde SA algoritmasının bu probleme uygulanmasına ait bir çalışmaya rastlanmamıştır. SA algoritması problemden bağımsız olasılık tabanlı bir algoritmadır. SA algoritmasını geleneksel optimizasyon metotlarından ayıran önemli özelliklerden birisi, uyguladığı stratejiler ile büyük oranda yerel minimadan kurtulabilme kabiliyetinin olmasıdır. Bu çalışmada, SA algoritması Elman ağının ileribesleme ve geribesleme bağlantı ağırlıklarının değerlerini belirlemek amacıyla kullanılmıştır. Simülasyon çalışmalarında SA algoritmasının doğrusal ve doğrusal-olmayan dinamik sistemlerin kimliklendirilmesi amacıyla orijinal Elman ağının eğitilmesindeki performansı incelenmiş, elde edilen neticeler standart BP algoritması ile karşılaştırılmıştır.

İkinci bölümde standart SA algoritması hakkında bilgi verilmiştir. Üçüncü bölümde Elman ağının yapısı tanıtılarak, SA algoritmasının dinamik sistem kimliklendirme amacıyla nasıl kullanıldığı açıklanmıştır. Sonuçlar ise dördüncü bölümde verilmiştir.

II. SIMULATED ANNEALING ALGORİTMASI

Simulated Annealing (SA) ilk olarak Kirkpatrick, Gelatt ve Vecchi tarafından önerilmiş, olasılık tabanlı sezgisel bir algoritmadır [15]. SA algoritması katıların fiziksel tavlama işlemi ile 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 azaltıldıkça atomik enerji düşer. Eğer soğutma işlemi çok hızlı gerçekleşirse kristal yapıda bozukluklar ve düzensizlikler ortaya çıkacaktır. Bu nedenle soğutma işleminin dikkatle yapılması gerekmektedir [16]. Fiziksel tavlama işlemi Monte Carlo tekniği üzerine dayalı olarak Metropolis ve arkadaşları tarafından modellenmiştir [17]. 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 şu şekilde karar verilir: Düzgün (uniform) dağılımdan $[0,1]$ aralığında rasgele bir δ sayısı üretilir ve Eşitlik (2)' de verilen şart sağlanırsa durum, yeni durum olarak kabul edilir. Aksi takdirde, mevcut durum değiştirilmez.

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

Burada, ΔE , iki durumun enerji seviyeleri arasındaki farktır ve 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 bölgesel enerji minimumundan çıkmasına izin verir.

Kombinatoryal optimizasyon problemi ile tavlama işlemi arasındaki benzerlik de, katının durumları optimizasyon probleminin muhtemel çözümlerini temsil eder ve bu durumların enerjileri, çözümler için hesaplanan amaç fonksiyon değerlerine karşılık gelir. Minimum enerji durumu problem için optimal çözümü ifade eder.

SA iteratif bir algoritmadır, yani algoritma çözüm uzayında sayıların vektörü formunda ifade edilen bir çözümü sürekli olarak geliştirmeye çalışır. Standart bir SA algoritmasının adımları Şekil 1' de verilmiştir. SA algoritmasının bir probleme uygulanması aşamasında karar verilmesi gereken önemli kavramları iki grupta toplamak mümkündür [18]:

a) Probleme özgü seçimler: Problem, muhtemel tüm çözümleri içerecek şekilde formüle edilmelidir. Çözümlerin temsili yapılmalı, minimize edilecek bir amaç fonksiyonu ile komşuluk üretim mekanizması tanımlanmalı ve bir başlangıç çözümü üretilmelidir.

b) Soğutma planına ait seçimler: Sıcaklık parametresi T ' nin başlangıç değerine, soğutma oranı ve güncelleme kuralına, her bir sıcaklıkta icra edilecek iterasyon sayısına karar verilmelidir.

SA algoritmasının performansı büyük oranda seçilen soğutma planına bağlıdır. Literatürde 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, $T(t+1)=r.T(t)$ bağıntısı kullanılmıştır. Burada, r değeri 1' den küçük fakat 1'e yakın bir sabittir ve genellikle değeri 0.8 ile 0.99 arasında seçilir. Bu sıcaklık fonksiyonu ile sıcaklık parametresinin değeri sıfıra yaklaştıkça daha da yavaş

azalmaktadır. Sıcaklık parametresinin her değerinde gerçekleştirilecek iterasyon sayısı sabit bir üst sınıra göre belirlenerek problemin fiziksel tavlamadaki ısı dengeye karşılık gelen bir denge durumuna ulaşması amaçlanmaktadır. Bu tavlama planında, sıcaklık parametresinin her değerinde elde edilen çözüm belirli sayıda ardışık sıcaklık değişimleri boyunca aynı kalırsa SA algoritması durdurulmaktadır. Buna göre elde edilen son durum fiziksel tavlamadaki *donma durumuna (frozen state)* karşılık gelmektedir.

Adım 1. Bir başlangıç çözümü üret, S .

Adım 2. Bir $S' \in N(S)$ çözümü seç ve amaç fonksiyon değerlerindeki farkı hesapla.
 $\Delta = C(S) - C(S')$

Adım 3. **Eğer**,

(i) S' , S den daha iyi ($\Delta > 0$), **yada**

(ii) $\delta \leq e^{\Delta E/T}$ **ise**,

S' nü yeni çözüm olarak tayin et ($S \leftarrow S'$)

Aksi takdirde, mevcut çözümü tut.

Adım 4. Sıcaklığı güncelle.

Adım 5. **Eğer** Durdurma kriteri sağlanıyor **ise** dur,
Aksi takdirde Adım 2' ye git.

Şekil 1. Simulated annealing algoritmasının temel adımları.

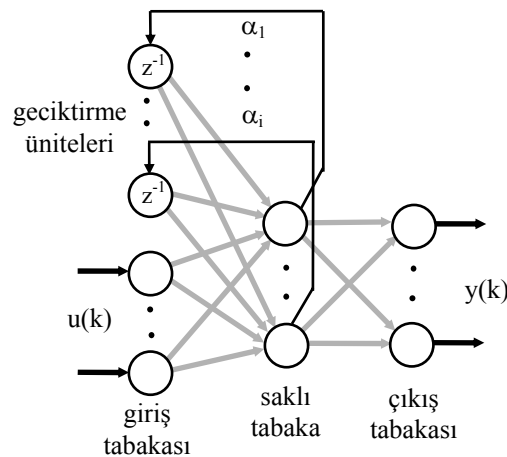
III. ELMAN AĞININ SIMULATED ANNEALING ALGORİTMASI KULLANARAK EĞİTİLMESİ

Yapısı Şekil 2' de verilen Elman ağı üç katmanlı bir sinir ağıdır. 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 (ikinci) nöronlarının çıkışlarıdır. Bu ağlarda saklı katmandaki önceki durumlar hafıza olarak saklanarak girişe verilmekte ve bu durumda ağın çıkışı o anki ve önceki girişe bağlı olarak belirlenmektedir. Bu yapı *dinamik hafıza* olarak görev yapmaktadır.

Bu ağın eğitilmesinde temel olarak BP algoritması kullanılmakta ve ağın sadece ileribesleme bağlantıları eğitilebilmektedir. Geribesleme bağlantıları ise standart BP algoritması kullanarak eğitilememektedir. Bu bağlantı ağırlıklarının değeri keyfi olarak sabit bir değerde seçilebilmekle beraber, çoğunlukla 1.0 olarak kabul edilmektedir. Eğitme başarısı için geribesleme bağlantılarının değerinin doğru seçilmesi önemlidir [1,10].

Öğrenme başlangıcında, ağın saklı katman nöronlarının aktivasyon değerleri bilinmemektedir. Bu değer genellikle saklı tabaka 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 0.0 olarak almak mümkündür [3,14,19].

Bu çalışmada kullanılan ağın yapısı, sonuçların karşılaştırılabilmesi amacıyla Kaynak [3]' deki gibi seçilmiştir. Kimliklendirilecek sistemler tek-giriş tek-çıkışlı olduğundan harici giriş ve çıkış işlemci elemanı sayısı 1' dir. Saklı tabaka işlemci elemanı sayısı ise 6' dır.




Şekil 2. Elman Ağının yapısı.

Bu çalışmada, SA algoritması ağ yapısına karar verilmiş bir geribeslemeli sinir ağının ağırlıklarının eğitilmesinde kullanılmıştır. Ağda katmanların sayısı, aktivasyon fonksiyonlarının türü, her bir katmandaki işlemci elemanı sayıları, eğitilebilir

ağırlıkların izin verilen aralığı ve sabit bağlantı ağırlıklarının değerlerinin hepsi bilinmektedir. SA algoritması için başlangıç çözümü rasgele sayı üretici ile sağlanmaktadır. Kullanılan bu çözüm geribeslemeli ağ için mümkün olan bir ağırlık setini temsil etmektedir ve SA 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 3). SA algoritması ile belirlenecek parametre sayısı, sadece ileribesleme bağlantı ağırlıkları eğitilebilir olduğunda 48, tüm ağırlıklar eğitilebilir olduğunda ise 54' tür. Tüm ağırlıklar eğitilebilir olduğunda ileribesleme ağırlıkları $[-1,1]$ aralığında iken, geribesleme ağırlıkları $[0,1]$ aralığında değerlere sahiptir. Geribesleme bağlantı ağırlıkları sabit olduğunda ise değeri 1.0 olarak ($\alpha_i=1.0$) alınmıştır. Bir komşu çözüm, mevcut çözümden, $[-1,1]$ aralığında rasgele üretilen bir sayının bir ağırlığa eklenmesiyle elde edilir. Yaygın olarak kullanılan BP algoritmasının aksine SA algoritması açısından bakıldığında geribesleme ve ileribesleme bağlantıları arasında fark yoktur ve bağlantıların bir türünün eğitilmesi ile diğerlerinin eğitilmesi aynıdır.



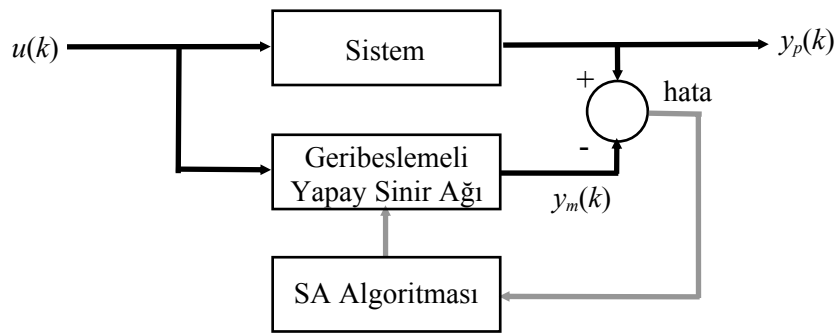
Şekil 3. Eğitilebilir ağırlıkların dizi formunda temsili.

Bir dinamik sistem modeli için geribeslemeli sinir ağının eğitilmesi amacıyla SA algoritmasının kullanılmasında Şekil 4' te gösterilen kimliklendirme konfigürasyon kullanılmıştır. Burada, $y_p(k)$ ve $y_m(k)$ sırasıyla sistem ve ağ 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 grup 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 (rms) 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 etkin 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.

Eğitimde kullanılacak giriş dizisinin seçimi eğitim başarısı üzerinde önemlidir. Giriş dizisinin elemanları genellikle sinüzoidal ve rasgele giriş ardışıklıklarından seçilmektedir [20]. Bu çalışmada gerçekleştirilen simülasyon çalışmalarında düzgün dağılıma sahip rasgele $u(k)$ giriş sinyal dizisi kullanılmıştır.



Şekil 4. Sistem kimliklendirme için geribeslemeli yapay sinir ağının SA algoritması kullanılarak eğitilmesi planı.

IV. SİMÜLASYON SONUÇLARI

Simülasyon çalışmalarında, Elman ağının SA algoritmaları ile eğitilmesinde üç farklı dinamik sistem kullanılmıştır. Birinci örnek 3. dereceden doğrusal bir sistemdir. İkinci ve üçüncü örnekler ise doğrusal-olmayan sistemlerdir. Simülasyon çalışmalarında

kullanılan Elman ağı, giriş tabakasında bir işlemci elemanı, saklı tabakada 6 işlemci elemanı ve çıkış tabakasında bir işlemci elemanı olacak şekilde seçilmiştir (1-6-1). Doğrusal sistem için Elman ağının tüm tabakalarında doğrusal işlemci elemanları kullanılmıştır. Doğrusal-olmayan sistemler için Elman ağının saklı tabakasında doğrusal-olmayan işlemci elemanları, diğer katmanlarında ise yine doğrusal işlemci elemanları kullanılmıştır. Doğrusal-olmayan işlemci elemanlarının aktivasyon fonksiyonu olarak hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır. Üç sistem için de örnekleme periyodu 0.01sn. olarak kabul edilmiştir.


Sistem 1

Simülasyon için kullanılan birinci örnek, aşağıdaki eşitlikle tanımlanan 3. dereceden doğrusal sistemdir.

$$y(k) = A_1y(k-1) + A_2y(k-2) + A_3y(k-3) + B_1u(k-1) + B_2u(k-2) + B_3u(k-3) \quad (4)$$

Burada, $A_1=2.627771$, $A_2=-2.333261$, $A_3=0.697676$, $B_1=0.017203$, $B_2=-0.030862$, $B_3=0.014086$ 'dır.

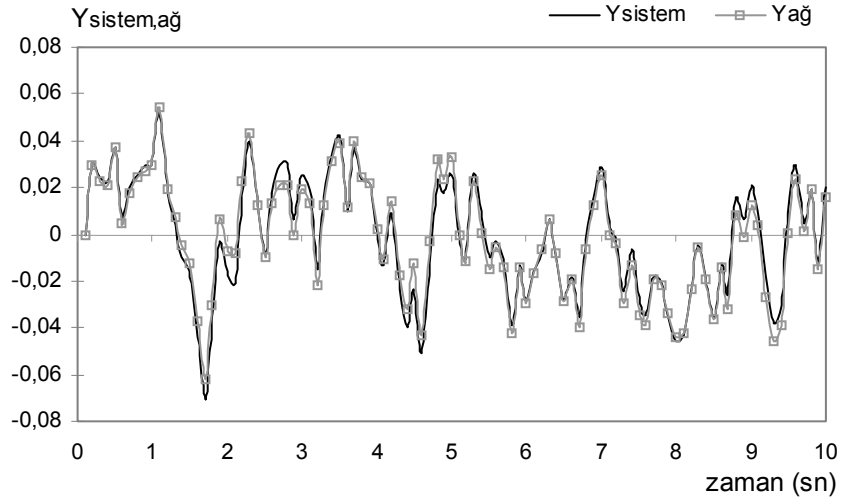
Elman ağını eğitmede kullanılan giriş sinyali, $u(k)$, $k=0,1,...99$, $[-1,1]$ aralığında rasgele üretilmiştir ($M=100$). Önce, sadece ileribesleme bağlantı ağırlıkları ayarlanabilir olarak kabul edilerek BP ve SA algoritmaları ile Elman ağının eğitilmesine ait sonuçlar elde edilmiştir. Sonra Elman ağının tüm bağlantı ağırlıklarının ayarlanabilir olması durumu için SA algoritması ile sonuçlar elde edilmiştir. Her bir durum için denemeler farklı başlangıç çözümleri ile 6 kez tekrarlanmıştır. Standart BP ve SA algoritmaları kullanılarak elde edilen sonuçlar Şekil 5' de verilmiştir. Bu algoritmalar için yapılan denemelerde elde edilen ortalama etkin hata değerleri ve gelişme yüzdeleri Tablo 1' de, $5.22282E-03$ etkin hata değerinin elde edildiği denemeye ait SA algoritması ile eğitilen ağ ve sistem cevapları ise Şekil 6'da verilmiştir.



Şekil 5. Doğrusal sistem için elde edilen neticeler.

Tablo 1. Doğrusal sistem için sonuçların karşılaştırılması

Kullanılan model	Ortalama etkin hata	Gelişme (%)
Geriyayılım (BP)	7.67536E-02	-
SA ($\alpha=1$)	6.51350E-03	91.51
SA (tüm ağırlıklar eğitilebilir)	4.96526E-03	93.53



Şekil 6. Doğrusal sistem için sistem ve ağ çıkışları (rms hata = 5.22282E-03).

Sistem 2


İkinci model aşağıda ayrık zaman ifadesi verilen ve Kaynak [8]' den alınan doğrusal-olmayan sistemdir.

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


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 ($M=200$). Sistem 1' de olduğu gibi farklı başlangıç çözümleri ile yapılan 6 deneme için sonuçlar elde edilmiştir. Standart BP algoritması ve SA algoritması ile elde edilen hata değerleri Şekil 7'de, ortalama etkin hata değerleri ve gelişme yüzdeleri ise Tablo 2' de verilmiştir. Denemelerden birine ait olan, $1.77047E-02$ etkin hata değeri için SA algoritması ile eğitilen ağ ve sistem cevapları ise Şekil 8'de verilmiştir.

Tablo 2. Sistem 2 için sonuçların karşılaştırılması

Kullanılan model	Ortalama etkin hata	Gelişme (%)
Geriyayılım	0.12863E00	-
SA ($\alpha=1$)	0.04637E00	63.95
SA (tüm ağırlıklar eğitilebilir)	0.02176E00	83.08



Şekil 7. Sistem 2 için elde edilen neticeler.



Şekil 8. Sistem 2 için, sistem ve ağ cevapları (rms hata = 1.77047E-02).

Sistem 3

Simülasyonlar için kullanılan üçüncü model, küçük açılarla salınan basit bir sarkaçtır. Sistemin ayrık zaman tanımı aşağıdaki gibidir:


$$y(k) = A_1y(k-1) + A_2y(k-2) + A_3y^3(k-2) + B_1u(k-2) \quad (6)$$

Burada, $A_1=1.04$, $A_2=-0.824$, $A_3=0.130667$, $B_1=-0.16$ 'dır.


Elman ağını eğitmede kullanılan giriş sinyali, $u(k)$, $k=0,1,\dots,99$, $[-1,1]$ aralığında rasgele üretilmiştir ($M=100$). Standart BP ve SA algoritmaları için elde edilen etkin hata değerleri Şekil 9' da gösterilmiştir. Bu algoritmalar için yapılan denemelerdeki ortalama etkin hata değerleri ve gelişme yüzdeleri Tablo 3' de, $2.57737E-02$ etkin hata değerinin elde edildiği denemeye ait, SA algoritması ile eğitilen ağ ve sistem cevapları ise Şekil 10' da verilmiştir.

Tablo 3. Sistem 3 için sonuçların karşılaştırılması

Kullanılan model	Ortalama etkin hata	Gelişme (%)
Geri yayılım	0.26182E00	-
SA ($\alpha=1$)	0.09131E00	65.12
SA (tüm ağırlıklar eğitilebilir)	0.02943E00	88.76



Şekil 9. Doğrusal-olmayan sistem için elde edilen neticeler.



Şekil 10. Doğrusal-olmayan sistemde sistem ve ağ cevapları (rms hata = 2.57737E-02).

Çalışmada, SA algoritması için gerekli olan çeşitli parametre değerlerine karar vermek için bir çok deneme gerçekleştirilmiştir. Bu denemeler sonucunda SA algoritması için sıcaklık noktalarının sayısı 15, her bir sıcaklık noktasında gerçekleştirilen iterasyon sayısı 15 ve sıcaklık azalma parametresi 0.9 olarak alınmıştır. Her bir denemedeki amaç fonksiyonu değerlendirme sayısı, sadece ileribesleme ağırlıklarının eğitilebilir olduğu durumda 48000, tüm ağırlıklar eğitilebilir olduğu durumda ise 54000'dir. SA algoritmasının daha büyük boyutlu ağ yapılarının eğitilmesinde kullanılması

durumunda, optimize edilecek parametre sayısındaki artışın göz önünde bulundurularak parametrelerin yeniden belirlenmesi gerekli olabilecektir.

TA algoritması ve GA, Elman ağının sistem kimliklendirme amacıyla eğitilmesinde kullanılmıştır. TA algoritması, üçüncü dereceden doğrusal bir sistemin kimliklendirilmesi amacıyla Elman ağının eğitilmesinde başarıyla kullanılmıştır [12-14]. Halbuki bu çalışmada kullanılan yapıya sahip bir Elman ağının, standart BP algoritması kullanarak ikinci dereceden doğrusal bir sistemin kimliklendirilmesinde bile başarısız olduğu belirtilmiştir [10]. Ayrıca, Elman ağı standart GA ile eğitildiğinde ikinci derece sistem başarılı bir şekilde kimliklendirilebilmesine rağmen, üçüncü dereceden sistemin kimliklendirilmesinde başarısız olunmuştur [1]. Şekil 5, Şekil 7 ve Şekil 9' dan açıkça görüldüğü gibi ağ yapılarının üçü (tüm ağırlıklar eğitilebilir ve ileribesleme bağlantı ağırlıkları eğitilebilir) de SA algoritması ile, standart BP algoritmasından daha iyi eğitilebilmiştir. Doğrusal ve doğrusal-olmayan sistem kimliklendirme için de geribesleme ağırlıklarının uygun şekilde belirlenmesinin eğitime başarısını büyük oranda etkilediği de açıkça görülmektedir.

V. SONUÇ VE TARTIŞMALAR

Bu çalışmada, SA algoritmasının dinamik sistemlerin kimliklendirilmesi amacıyla Elman ağının eğitilmesi için kullanılması tanımlanmıştır. Simülasyon çalışmalarında doğrusal ve doğrusal olmayan sistemler için sonuçlar elde edilmiştir. Elman ağının geribesleme bağlantı ağırlıklarının değeri sabit alındığında bile (standart BP algoritması ile eğitilmesi durumunda olduğu gibi), SA algoritması hem doğrusal hem de doğrusal-olmayan sistemler için ağı eğitmede büyük performans göstermiştir. SA algoritmasının yapısı gereği sağladığı avantajla, ağdaki tüm bağlantı ağırlıkları eğitilebilir yapıldığında ise eğitime performansında ilave artışlar sağlandığı da görülmüştür. SA algoritması ile doğrusal-olmayan sistemler için elde edilen sonuçlar, BP algoritması ile doğrusal sistem için sağlanan sonuçlardan bile çok daha az hata içermektedir.

Elde edilen simülasyon sonuçları, SA algoritmasının Elman ağının dinamik sistem kimliklendirme amacıyla eğitilmesinde başarılı bir şekilde kullanılabileceğini

göstermesi bakımından önemlidir. SA algoritmasının bu uygulamadaki başarısı, diğer geribeslemeli yapay sinir ağlarının eğitilmesinde de ümit verici bir yaklaşım olarak görülebilir.

Literatürde, sistem kimliklendirme uygulamalarındaki başarımı artırmak için bir çok ağ yapısı önerilmiş olmakla beraber, bu yaklaşımların hemen hepsinde standart yapılara göre daha kompleks yaklaşımlar sergilemektedir. Bu çalışmada, SA algoritması ile elde edilen neticeler, aynı yapıya sahip bir yapay sinir ağının etkili bir eğitime algoritması ile oldukça yüksek bir başarımla eğitilebileceğini göstermesi bakımından da anlamlıdır.

Elde edilen neticeler, belirli bir devre modeline veya probleme bağımlı olmayan ve zeki yaklaşımlarla küresel optimumu bulma kabiliyetine sahip sezgisel algoritmaların yapay sinir ağlarının diğer türlerinin eğitilmesinde de başarı ile kullanılabilceğini düşündürmektedir. Bu nedenle, literatürde yer alan en yeni sezgisel algoritmalar olan, karınca koloni algoritması, diferansiyel gelişim ve memetic algoritma gibi sezgisel algoritmaların yapay sinir ağlarının eğitilmesindeki performanslarının incelenmesine yönelik çalışmalar da devam etmekte olup, elde edilecek neticeler gelecek çalışmalarda ortaya konacaktır. SA algoritmasının, diğer geribeslemeli yapay sinir ağlarının dinamik sistem kimliklendirme uygulamaları ve farklı problemler için eğitilmesindeki performansı ise gelecek çalışmalarda incelenecektir.

VI. KAYNAKLAR

- [1] D.T. Pham and D. Karaboga, “*Intelligent Optimisation Techniques: Genetic Algorithms, Tabu Search, Simulated Annealing and Neural Networks*”, Advanced Manufacturing Series, Springer-Verlag, London, 2000.
- [2] L.R. Medsker, L.C. Jain, “*Recurrent Neural Networks, Design and Applications*”, CRC Press, London, 2001.
- [3] X. Liu, “*Modelling and Prediction Using Neural Networks*”, PhD Thesis, University of Wales College of Cardiff, Cardiff, UK, 1993.
- [4] D.T. Pham, X. Liu, “*Neural networks for identification, prediction and control*”, London, Springer-Verlag, 1995.

- [5] D.T. Pham, X. Liu, "Training of Elman networks and dynamic system modelling", *Int. Journal of Systems Science*, Vol.27, No.2, pp.221–226, 1996.
- [6] L. Yun, A. Häußler., "Artificial evolution of neural networks and its application to feedback control", *Artificial Intelligence in Engineering*, Vol.10, No.2, pp.143–152, 1996.
- [7] C.C. Ku, K.Y. Lee, "Diagonal recurrent neural networks for dynamic systems control", *IEEE Trans. on Neural Networks*, Vol.6, No.1, pp.144–156, 1995.
- [8] D.T. Pham, X. Liu, "Dynamic system identification using partially recurrent neural networks", *Journal of Systems Engineering*, Vol.2, No.2, pp.90–97, 1992.
- [9] D.T. Pham, S.J. Oh, "A recurrent backpropagation neural network for dynamic system identification", *Journal of Systems Engineering*, Vol.2, No.4, pp.213–223, 1992.
- [10] J.L. Elman, "Finding Structure in Time", *Cognitive Science*, Vol.14, pp.179-211, 1990.
- [11] D.T. Pham., D. Karaboga, "Training Elman and Jordan networks for system identification using genetic algorithms", *Artificial Intelligence in Engineering*, Vol.13, pp.107-117, 1999.
- [12] D. Karaboga and A. Kalınlı, "Training Recurrent Neural Networks Using Tabu Search Algorithm", 5th Turkish Symposium on Artificial Intelligence and Neural Networks, pp.293-298, Türkiye, 1996.
- [13] A. Kalınlı, D. Karaboga, "Geribeslemeli Yapay Sinir Ağlarının Paralel Tabu Araştırma Algoritması Kullanarak Eğitilmesi", 11th Turkish Symposium on Artificial Intelligence and Neural Networks (TAINN'2002), ss.261-270, İstanbul, Haziran 20-21, 2002.
- [14] A. Kalınlı, " Geribeslemeli Yapay Sinir Ağlarının Genetik Operatörlere Dayalı Tabu Araştırma Algoritması Kullanarak Eğitilmesi", Doktora tezi, Fen Bilimleri Enstitüsü, Erciyes Üniversitesi, Kayseri, 1996.
- [15] S. Kirkpatrick, C.D. Gelatt, M.P. Vecchi, "Optimization by Simulated Annealing", *Science*, Vol.220, pp.671-680, 1983.
- [16] K.A. Dowsland, "*Simulated Annealing. In Modern Heuristic Techniques for Combinatorial Problems*", (Editor, Reeves, C.R.), McGraw-Hill, 1995.

- [17] N. Metropolis, A. Rosenbluth, M. Rosenbluth, A. Teller and E. Teller, "Equation of The State Calculation by Fast Computing Machines", *Journal of Chemical Physics*, Vol.21, pp.1087-1092, 1953.
- [18] S. Jhonson, C. Aragon, L. Mccgeoch and C. Schevon, "Optimization By Simulated Annealing: An Experimental Evaluation, Part-I, Graph Partitioning", *Operations Research*, Vol.37, pp.865-892, 1989.
- [19] D.T. Pham, X. Liu, "Identification of linear and nonlinear dynamic systems using recurrent neural networks", *Artificial Intelligence in Engineering*, Vol.8, pp.90–97, 1993.
- [20] D.E. Rumelhart, J.L. McClelland, "*Explorations in the Micro-Structure of Cognition, Parallel Distrubuted Processing I*", Cambridge, MA: MIT Press, 1986.