

HIZLI EVRİMSEL ENİYİLEME İÇİN YAPAY SİNİR AĞI KULLANILMASI

Abdurrahman HACIOĞLU

HHO Dekanlığı Havacılık Mühendisliği Bölümü,
34149, Yeşilyurt, İstanbul
hacioglu@hho.edu.tr

ÖZET

Bu çalışmada, daha önce tersten tasarım problemleri için önerilmiş olan Yapay Sinir Ağı ile Güçlendirilmiş Genetik Algoritmanın (YGGA), eniyileme problemlerine uyarlaması yapılmıştır. YGGA eniyileme problemlerine uygulanabilecek şekilde güncellenmiş ve genel anlamda bir eniyileme problemine nasıl uygulanacağı gösterilmiştir. YGGA'da, reel kodlu bir Genetik Algoritma (GA) ile uygun bir Yapay Sinir Ağı (YSA) mimarisi melez bir yapı içerisinde kullanılmıştır. Bu yapı içerisinde YSA, popülasyonun güçlendirilmesini sağlamıştır. Bu amaçla GA'nın her adımında, o adımda kullanılan popülasyondaki bireyler ve bunlara ait uygunluk değerleri kullanarak YSA eğitilmiştir. Eğitim sırasında, bireyleri ifade eden parametreler YSA'nın girdisi, bireylerin uygunluk değerleri de çıktısı olarak değerlendirilmiştir. Eğitilen bu YSA'ya, Benzetimli Tavlama (BT) yardımıyla bir eniyileme süreci uygulanarak, mevcut popülasyondaki bireylerden daha iyi uygunluk değerine sahip bir birey üretilmeye çalışılmıştır. Elde edilen uygun birey GA tarafından üretilen yeni popülasyona ilave edilmiştir. GA'nın her adımında tekrar edilen bu işlemlerin sonucunda popülasyonun gelişimi daha çabuk sağlandığından, daha az amaç fonksiyonu hesabı ile daha iyi uygunluk değerlerine ulaşılmıştır. Yönteminin etkinliği, model deneme fonksiyonlarına uygulaması yapılarak gösterilmiştir.

Anahtar Kelimeler: Eniyileme, Genetik Algoritma, Yapay Sinir Ağ, Benzetimli Tavlama.

FAST EVOLUTIONARY OPTIMIZATION USING ARTIFICIAL NEURAL NETWORKS

ABSTRACT

In this paper, the Augmented Genetic Algorithm with Artificial Neural Network (AGANN) is expanded for optimization works, and its implementations to model problems are demonstrated. With the purpose of getting a faster algorithm, a neural network and a real coded genetic algorithm are hybridized in a new way. In this way, instead of predicting objective function calculation of a candidate, a properly trained neural network is used for predicting the candidate itself. At each step of the genetic process, using a simulated annealing based optimization procedure, the trained neural network produces an individual, which is a candidate solution of the optimization problem. Adding this candidate to the population at each step improves the exploration power of the genetic process. The proposed algorithm is tested for some test function problems. The results indicate that the computational efficiency of the implemented algorithm is tremendously high. Due to still being a genetic algorithm based technique, this method is also as robust as the pure genetic algorithms.

Keywords: Optimization, Genetic Algorithms, Neural Networks; Simulated Annealing.

1. GİRİŞ

Evrimsel Algoritmaların yaygın olarak en çok kullanılanlarından olan Genetik Algoritmalar (GA) ile hızlı bir şekilde eniyileme yapmayı sağlayan melez tekniklerden bir tanesi, vekil (surrogate) bir model içerisinde Yapay Sinir Ağı (YSA) kullanmaktır. Vekil modellerde, işlem süreleri çok uzun olabilen gerçek hesaplamalı mühendislik programlarının yerine, daha

kısa sürede işlem yapan (örnek olarak uygun bir şekilde eğitilmiş YSA'dan elde edilen) yaklaşıkları (vekilleri) kullanılır. Böylece, GA içerisinde amaç fonksiyonlarının hesabı için harcanan işlem süreleri azaltılarak, eniyileme çalışmasının toplam süresi kısaltılmış olur. Bu nedenle, GA ile yapılan eniyileme ve tasarım çalışmalarında YSA kullanan vekil modeller sıkça tercih edilir [1,2]. Ancak bununla birlikte, YSA kullanan bir vekil model ile yapılan GA

çalışmasının başarısı, YSA'nın yaklaşık hesaptaki başarısına bağlıdır. Diğer taraftan, çözüm uzayının araştırılmasında sadece mutasyon ve çaprazlama gibi GA işlemcileri kullanıldığından, hedeflenen sonuca ulaşabilmede YSA'nın bir etkisi yoktur ve tek başına GA belirleyicidir.

Mühendislik eniyileme ve tasarım çalışmalarında GA ve YSA, yukarıda açıklanan vekil yöntemden farklı olarak bir başka teknikle de melez bir yapı içerisinde kullanılabilir. Bu yeni teknik Yapay Sinir Ağı ile Güçlendirilmiş Genetik Algoritma (YGGA) olarak isimlendirilmiş ve tersten aerodinamik tasarım için kullanılmıştır [3,4,5]. YGGA'da, vekil modelden farklı bir şekilde YSA, amaç fonksiyonunun yaklaşık hesabı için kullanılmaz. Bunun yerine, problemin doğrudan çözümüne yönelik olarak GA'nın her adımında bir birey (aday çözüm) tahmin etmesi için kullanılır. Bu amaçla, GA'nın her bir adımında mevcut popülasyondaki bireyler ve bunlara ait amaç fonksiyonu çözümleri kullanılarak YSA eğitilir. Eğitilmiş olan YSA'dan, mevcut popülasyondaki bireylerden daha uygun bir birey elde edilmeye çalışılır ve bu birey yeni popülasyona eklenir. GA'nın her adımında tekrar eden bu yöntemle popülasyonun daha çabuk gelişmesi sağlanarak arzu edilen çözüme daha az işlemle (amaç fonksiyonu hesabı) ulaşılmaktadır. YGGA'da, bütün amaç fonksiyonu hesapları gerçek hesaplama yöntemi ile yapılmakta ve YSA'da, GA ile birlikte çözüme ulaşmada belirleyici olmaktadır.

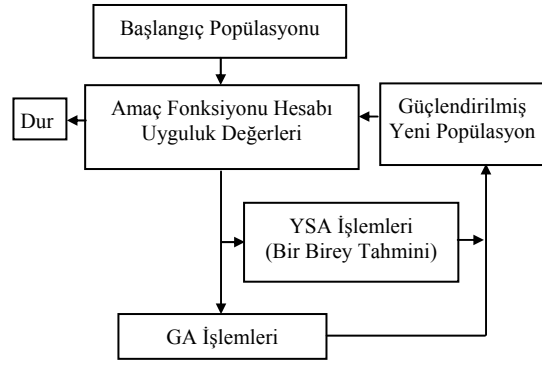
YGGA [3,4,5] çalışmalarında tersten tasarım problemlerine uygulanırken, eğitilmiş YSA'na tersten tasarım probleminin hedefi girilerek, bu hedefi sağlayan birey elde edilmeye çalışılmıştır. Ancak bir eniyileme problemi söz konusu olduğunda, hedef çözüm belli olmadığından, eğitilmiş YSA'dan uygun bireyin elde edilmesi işlemi farklı bir şekilde yapılmak zorundadır. Bu çalışmanın amacı, YGGA'nın mühendislik eniyileme çalışmalarına uygulanışı ile ilgili genel esasların açıklanıp uygulamasının gösterilmesidir. Ayrıca yöntemin, eniyileme algoritmalarının test edilmesinde kullanılan değişik model fonksiyonlar üzerindeki etkinliği araştırılmıştır. YSA tekniği olarak Radyal Tabanlı Fonksiyon Ağları (RTFA) kullanılacaktır.

2. ENİYİLEME İÇİN YGGA ALGORİTMASI

YGGA'da amaç, YSA'nın tahmin gücünden faydalanarak GA'nın arama/bulma kabiliyetini güçlendirmektir. Bunu başarmak için, GA'nın her adımında, popülasyondaki bireyler ve amaç fonksiyonu (ya da uygunluk) değerleri kullanılarak YSA eğitilir. Eğitimden sonra YSA'dan eniyileme problemi için bir aday çözüm (tahmin) üretilir. Bu aday çözümün, eğitimde kullanılan popülasyondaki bireylerden daha iyi bir uygunluk değerine sahip olacak şekilde üretilmesi gerekir. Bu nedenle eğitilen YSA'dan aday çözüm elde etmek için bu YSA'ya da

bir eniyileme yapmak gerekir. Eğitilen YSA'nın eniyilemesi için değişik yöntemler kullanmak mümkün olmakla birlikte burada Benzetimli Tavlama (BT) kullanılacaktır. Blok diyagramı Şekil 1'de görülen YGGA'nın bir eniyileme problemine uygulanmasındaki ana adımlar aşağıdaki gibi olacaktır:

- İlk olarak popülasyondaki bireylerin amaç fonksiyonları ile ilgili hesaplar yapılarak uygunluk değerleri bulunur ve GA işlemleri (seçim, çaprazlama, mutasyon vb.) ile yeni popülasyon üretilir.
- İkinci olarak popülasyondaki bireyler ve uygunluk değerleri kullanılarak YSA eğitilir. Eğitim sırasında birey parametreleri girdileri, uygunluk değerleri çıktıları oluşturur.
- Son olarak, BT kullanılarak eğitilmiş YSA'ya bir eniyileme süreci uygulanır ve mevcut popülasyondaki bireylerden daha iyi uygunluk değerine sahip bir birey üretilir. Üretilen bu birey, GA tarafından oluşturulan yeni popülasyona ilave edilir ve bütün bu işlemler GA'nın bütün adımlarında tekrarlanır.




Şekil 1. YGGA blok diyagramı.

YSA'dan elde edilecek daha yüksek uygunluk değerli aday çözüm de aslında bir tahmindir. Bu tahmin de her zaman başarılı olmayabilir. Düşük uygunluk değerli bireyler GA'nın seçim safhasında elenebildiği için, YSA'nın yapacağı başarısız tahminler, eniyileme süreci ile ilgili bir olumsuzluğa neden olmayacaktır. Diğer taraftan, GA işlemleri dışında, YSA tarafından farklı bir şekilde üretilen birey popülasyonun çeşitliliğini arttıracak ve mutasyon etkisi yapacaktır.

3. RADYAL TABANLI FONKSİYON AĞLARI

RTFA çok boyutlu problemler için en uyumlu sonuç veren YSA tekniklerinden biridir [6]. RTFA mimarisinde, girdi katmanından gizli katmana (radyal tabanlı katman) doğrusal olmayan ve gizli katmandan çıktı katmanına doğrusal bir dönüşüm uygulanır. İnterpolasyon özelliği çok iyi olması nedeniyle RTFA'lar, eğitim için kullanılan verilerin arasında ve yakın civarında arama yapmak için uygundur. Bu nedenle eniyileme çalışması için YGGA içerisinde RTFA tercih edilmiştir.



Girdi Katmanı Gizli Katman Çıktı Katmanı

Şekil 2. RTFA mimarisi.

Mimarisi Şekil 2’de gösterilen RTFA’da, m adet örnek içeren eğitim seti ve her örnekteki n adet parametreden oluşan girdi verilerine (x) bağlı olarak,

$$u_i^k = \sum_{j=1}^n (x_j^k - x_j^i)^2 \quad (i=1,m \text{ ve } k=1,m) \quad (1.a)$$

$$h_i^k = \phi(u_i^k) \quad (1.b)$$

$$[h]\{w\} = \{f\} \quad (1.c)$$

denklemleriyle, her bir girdi grubu için önce m adet radyal taban (h) ve sonra çıktı değerlerine (f) bağlı olarak, gizli katman ile çıktı katmanı arasındaki ağırlıklar w_j hesaplanır. Eğitim setindeki m adet örneğin tamamı radyal merkez olarak kullanıldığında, $[h]$ matrisi $m \times m$ boyutunda kare matris olur. Burada (1) denklemlerindeki ϕ radyal fonksiyondur ve değişik şekillerde tanımlanmaktadır. Bu çalışmada yapılacak uygulamalarda Gauss formunda

$$\phi(u) = e^{-\frac{u}{rs}} \quad (2.a)$$

ve kuadratik formda

$$\phi(u) = \frac{1}{\sqrt{rk^2 + u}} \quad (2.b)$$

bağıntıları kullanılmaktadır (rs ve rk kullanıcının belirlediği reel sayılardır). Eğitim sonunda (1.c) denklemiyle w_j ağırlıkları belirlendikten sonra,

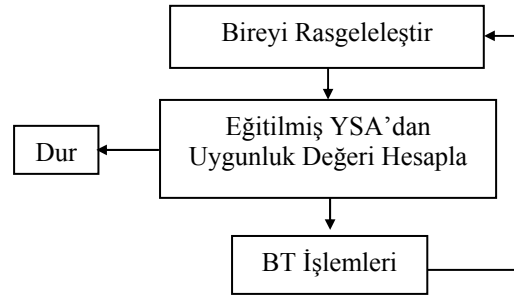
$$f(x) = \sum_{j=1}^m w_j h_j \quad (2.c)$$

bağıntısı ile herhangi bir x girdisi için, (1.a) ve (1.b) denklemleriyle u ve h değerleri hesaplandıktan sonra, $f(x)$ çıktısı tahmin edilebilir.

Yukarıda bahsedildiği gibi RTFA’nın eğitimi, GA içerisinde kullanılan popülasyondaki m adet birey kullanılarak yapılacaktır. Kolayca tahmin edilebileceği gibi, girdi katmanındaki x parametreleri, bir bireyi tanımlayan n adet parametreden (kromozomu oluşturan genler) oluşacak ve çıktı katmanındaki f değeri ise o bireye ait uygunluk değeri olacaktır. RTFA’nın eğitimi sonucu (1) denklemlerindeki w_j katsayıları belirlendikten sonra, uygulanacak bir eniyileme süreci ile f değerini geliştirecek x girdi takımı araştırılabilecektir.

4. BENZETİMLİ TAVLAMA İLE ENİYİLEME

BT algoritması, erimiş metalin soğutma sürecinin fiziksel işleyişini taklit eder. Yönteminin özü, metalin ısıtılıp soğutulmasıyla daha düşük enerji seviyelerine geçme fırsatı yakalamaya çalışmasından ibarettir. YGGA içerisinde BT ile RTFA’ya uygulanacak olan eniyileme süreci ile ilgili blok diyagram Şekil 3’de verilmiştir.



Şekil 3. BT işlemleri ile eniyileme süreci.

BT ile eğitilmiş RTFA’ya uygulanacak eniyileme sürecine, eğitim setindeki (popülasyon ve uygunluk değerleri) mevcut en yüksek uygunluk değerli bireye ait parametrelerin (genler) rasgeleleştirilmesiyle başlanır. Rasgeleleştirilen parametreler eğitilmiş RTFA’ya girdi yapılarak uygunluk değeri tahmin edilir. Elde edilen uygunluk değerinin başlangıç uygunluk değerinden büyük ya da küçük olmasına göre BT işlemleri yapılır. Elde edilen birey tekrar rasgeleleştirilerek aynı işlemler tekrar edilir. Bu eniyileme sırasında, gerçekçi olmayan aşırı büyük uygunluk değerlerinden sakınmak ve eldeki mevcut bireylerin çevrelediği çözüm uzayından çok uzaklaşmamak için, uygunluk değerinde belli bir

oranda gelişme sağlandığında eniyileme durdurulmalıdır. BT ile yapılacak eniyileme sürecine ait sözde program (pseudo code) aşağıdaki gibidir:

x0 (başlangıç bireyi) tanımla
t0 ve α (başlangıç sıcaklığı, azaltım fonksiyonu) tanımla
Tekrarla (belirtilen koşullar gerçekleşinceye kadar)
Tekrarla (izin verilen iterasyon sayısı kadar)
x0'dan rasgeleleştirmeye x oluştur
RTFA ile x'in uygunluk değerini, f(x), bul
Farkı hesapla δ=f(x0)-f(x)
Eğer δ<0 ise x0=x ve xS=x
Değilse
u[0,1] aralığında rasgele sayı üret
Eğer u<exp(-δ/t) ise x0=x
Sıcaklığı azalt t=α(t)

Buradaki işlemler, bize daha iyi uygunluk değerine sahip olan bireyi (xS) verecektir. BT işlemleri ile bulunmuş olan bu birey, uygunluk değeri tahmini RTFA ile yapıldığından, aslında RTFA tarafından tahmin edilmiş birey olacaktır.

Popülasyondaki en iyi bireyin kromozomu, x0,

$$\Delta x = \sum_i \frac{|x0_i|}{100n} \quad (3.a)$$

$$x_i = x0_i + 2\Delta x(0.5 - u(0,1)) \quad (3.b)$$

denklemleriyle rasgeleleştirilir. Burada n, kromozomdaki toplam gen sayısı ve u(0,1), [0,1] aralığında rasgele sayı üreticidir. Sıcaklık azaltım fonksiyonu

$$\alpha(t) = t0 / (\text{mod}(itr, 100) + 1) \quad (4.a)$$

şeklinde kullanılmıştır. BT için müsaade edilen en büyük iterasyon sayısı 1000 olup, itr iterasyon adımını göstermektedir. Başlangıç sıcaklık değeri t0=0.0001 alınmıştır. Uygunluk değeri artım oranı,

$$AO = f(x)/f(x0) \quad (4.b)$$

AO>1 olacak şekilde kullanıcı tarafından tanımlanacaktır.

5. KULLANILACAK GA TEKNİKLERİ

İki farklı teknik kullanılacaktır:

- i. Reel kodlu bir GA (RGA)
- ii. YGGA (RGA+RTFA)

GA işlemlerinde değişik popülasyon büyüklükleri kullanılmıştır. Çaprazlama metodu olarak BLX-α [8]

metodu kullanılacak ve α = 0.5 alınacaktır. Çaprazlama oranı, Pc =(n-2)/n, (n popülasyon büyüklüğü) mutasyon oranı, Pm=1/2n olacaktır. Mutasyon için, uniform olmayan mutasyon metodu [9] ve seçim işlemi için Stokastik Tümel Örnekleme (Stochastic Universal Sampling, SUS) [10] yöntemi kullanılacaktır.

YGGA kullanıldığında, RTFA eğitiminde kullanılacak eğitim setinin büyüklüğü popülasyon büyüklüğü ile aynı olacaktır.

6. UYGULAMALAR

Mühendislik eniyileme çalışmalarında yaygın olarak kullanılan bazı test problemleri üzerinde yapılan uygulamalar takip eden bölümlerde verilmiştir. Uygulamalarda yukarıda belirtilen GA teknikleri kullanılmıştır. GA uygulamaları ile ilgili sonuçların hepsi 10 ayrı denemenin ortalaması olarak verilecektir.

6.1 Tepe Çıkma Problemi

Tek amaçlı, çok modlu bir tepe çıkma problemi Holst ve Pulliam tarafından [7] aşağıdaki gibi tanımlanmıştır:

$$z = \max(b_1, \dots, b_{N_m}) \quad (m = 1, \dots, N_m)$$

$$b_m = h_m e^{-\frac{a_m}{N_G}} \quad (5)$$

$$a_m = \sum_{i=1}^{N_G} (x_i - c_{i,m})^2$$

Burada z tepe yüksekliğini (amaç fonksiyonu), x'ler genleri (amaç fonksiyonu parametreleri), c'ler problemin girdisi olarak kullanılan serbest parametreleri, h'ler tepelerin en yüksek değerlerini, a ve b ise ara değerleri ifade etmektedir. Mod sayısı m alt indisi ile gösterilmiştir. Nm toplam mod sayısını ifade etmektedir. Bu problemde hedef z değerini en büyük yapacak x değerlerini bulmaktır.

Tek modlu hesap için (Nm=1) denklem (5)'deki h değeri 100.0 alınacak ve c değerleri rasgele sayı üretici u(0,1) kullanılarak

$$c_{i,m} = 5[u(0,1) - 0.5] \quad (6)$$

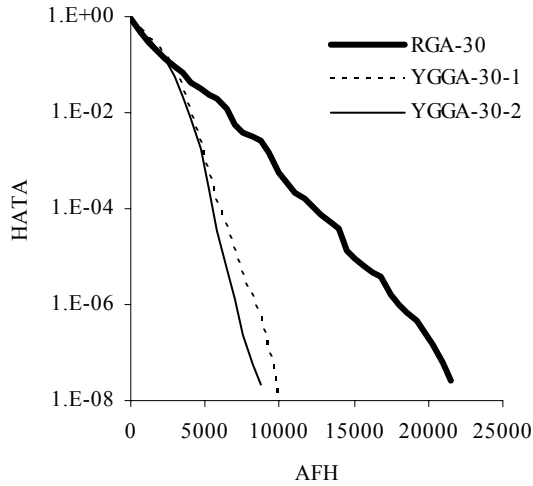
şeklinde belirlenecektir. Çözüm sırasında c ve h parametrelerinin değerleri değişmeyecektir. Yapılacak uygulamada denklem (5)'deki NG=32 alınacaktır. GA'nın n nci adımındaki en büyük uygunluk değerindeki hata (E^n), n nci adımındaki en iyi uygunluk değeri f^n ve problemin gerçek en iyi uygunluk değeri f_max ile

$$E^n = \frac{|f^n - f_{\max}|}{f_{\max}} \quad (7)$$

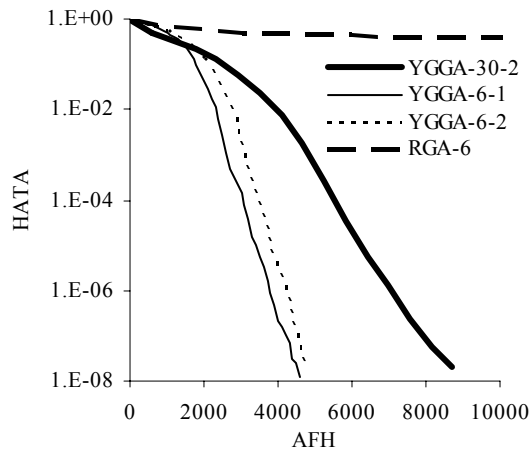
ifadesiyle hesaplanır. İki farklı GA tekniği ile yapılan uygulamaların sonuçları E^n üzerinden verilecektir. Eniyileme için, GA içerisinde a_m değeri en küçük yapılmaya çalışılacak ve uygunluk değerleri $1/a_m$ ile belirlenecektir.

Denklem (5)'deki $N_G=32$ olduğundan, bireylerin gen sayısı ve dolayısıyla RTFA'nın girdi katmanındaki veri sayısı 32 olacaktır. Çıktı katmanında ise bireyin uygunluk değeri bulunacaktır.

Yukarıda tanımlanan model tepe çıkma problemi için RGA ve YGGA ile yapılan eniyileme çalışması Şekil 4.a ve 4.b'de gösterilmiştir. Verilen her bir sonuç 10 denemenin ortalamasıdır. Şekil üzerinde, kullanılan GA tekniğinin devamında verilen sayılar kullanılan popülasyon büyüklüğünü göstermektedir. Ayrıca,



Şekil 4.a. Tepe çıkma problemi için GA tekniklerinin verdikleri sonuçlar.



Şekil 4.b. Tepe çıkma problemi için küçük popülasyonlu YGGA sonuçları.

YGGA teknikleriyle verilen sonuçlarda, popülasyon büyüklüğünden sonra verilen 1 ve 2 rakamları, RTFA'da kullanılan radyal fonksiyona işaret etmektedir. Denklem (2.a)'nın kullanıldığı durum için 1; (2.b)'nin kullanıldığı durum için 2 rakamı kullanılmıştır. Buna göre Şekil 4.a'daki YGGA-30-1, kullanılan GA tekniğinin YGGA (RGA+RTFA); popülasyon büyüklüğünün 30 ve kullanılan radyal fonksiyonun (2.a) denklemiyle tanımlanan fonksiyon olduğunu göstermektedir.

Şekil 4.a'daki sonuçlar, aynı popülasyon büyüklükleriyle (popülasyon büyüklüğü 30) yapılmış uygulamaları göstermektedir. Yatay ekseninde Amaç Fonksiyonu Hesabı (AFH) sayısı belirtilmiştir. Düşey eksen (7) denklemiyle ifade edilen "hata" değerini göstermektedir. Sonuçlar incelendiğinde YGGA tekniğinin RGA'ya göre daha az AFH ile yakınsadığı görülecektir. Sayısal olarak belirtmek gerekirse AFH sayısının azalması %60 mertebesinde. İki farklı radyal fonksiyon kullanarak yapılan YGGA uygulamaları ise yaklaşık olarak aynı sonucu vermiştir.

YGGA-30 ile yapılan uygulamalarda, denklem (2.a)'daki $rs=1$ ve (2.b)'deki $rk=0.75$ ($rk [0.5,0.8]$ aralığında birbirine yakın sonuçlar vermiştir) alınmıştır. BT için işlemleri için denklem (4.c)'deki AO değeri 1.5 olarak kullanılmıştır. Şekil 4.a ve 4.b'de gösterilen YGGA uygulamalarında kullanılan parametre değerleri Tablo 1'de özetlenmiştir.

Tablo 1. Tepe çıkma problemi için YGGA'da kullanılan parametreler

Teknik	AO	rs	rk
YGGA-30-1	1.5	1.0	-
YGGA-30-2	1.5	-	0.75
YGGA-6-1	1.25	1.0	-
YGGA-6-2	1.25	-	0.5

Diğer taraftan Şekil 4.b incelenirse, YGGA'nın daha küçük popülasyon büyüklükleriyle daha da iyi sonuç verdiği görülecektir. RGA'nın 6 birey kullanarak (RGA-6) bir sonuca ulaşması çok zor olmasına rağmen, YGGA önceki popülasyon büyüklüğü (YGGA-30) ile olan sonuca göre performansını %40 civarında arttırmıştır. Bu son durumda RGA-30 ile karşılaştırılırsa, YGGA'nın %80 daha az AFH ile sonuca ulaştığı ortaya çıkmaktadır.

Tepe çıkma problemi için Tablo 1'de dikkat çeken önemli bir husus ise, popülasyon (RTFA için eğitim seti büyüklüğü) küçüldüğünde AO değerinin de küçülmüş olmasıdır. RTFA daha az sayıda eğitim verisiyle eğitildiğinde, muhtemelen daha küçük bir cevap uzayı inşa edeceğinden, AO değerinin de

küçültülmesi gerekeceği beklenen bir durumdur. Çünkü AO değerinin 1'e yaklaşması, RTFA'nın daha yakındaki noktalar için tahmin yapmasını gerektirecektir.

Burada akla şu soru gelebilir: AFH sayısı azalmakla birlikte, YGGA'da yapılan YSA işlemleri toplam işlem sayısını arttırmayacak mıdır? Aslında AFH süresi, YSA işlemleri süresinden kısa olan problemler için böyle bir tehlike söz konusu olabilir. Ancak gerçek mühendislik eniyileme problemlerindeki (aerodinamik eniyileme ve tasarım problemlerinde olduğu gibi) AFH süreleri, genellikle YSA işlemleri için harcanan sürelerle kıyaslanmayacak kadar fazladır ve problemin çözüm süresini tamamen AFH için harcanan zaman belirler. Bu nedenle, gerçek uygulamalarda AFH sayısındaki azalmaya kıyasla, YSA işlemleri için harcanan zaman ihmal edilebilir seviyede olacak ve AFH sayısındaki azalma kadar problemin toplam çözüm süresi azalacaktır.


6.2 Rastrigin Fonksiyonu

Bu fonksiyon, eniyileme algoritmalarının denenmesinde yaygın olarak kullanılan fonksiyonlardan biridir. Rastrigin fonksiyonu $-5.12 \leq x_i \leq 5.12$ ve $i=1,2,...,n$ olmak üzere, aşağıdaki gibi tanımlanır:


$$f_{Rastrigin} = 10n + \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i)] \quad (8)$$

İki değişken için ($n=2$) fonksiyonun grafiği Şekil 5'de verilmiştir. Bu fonksiyon, $x_i=0$ için en küçük, $f_{Rastrigin}=0$ olur. Fonksiyonla ilgili yapılacak deneme bir enküçükleme çalışması olacaktır. Uygulamada $n=20$ alınacaktır. Bu takdirde RTFA'nın girdi katmanında her bir veri grubu (birey ve uygunluk değeri) için 20 adet parametre (x_i 'ler) kullanılacaktır. Çıktı katmanına ise $1/f_{Rastrigin}$ ile tanımlanan uygunluk değeri gelecektir.

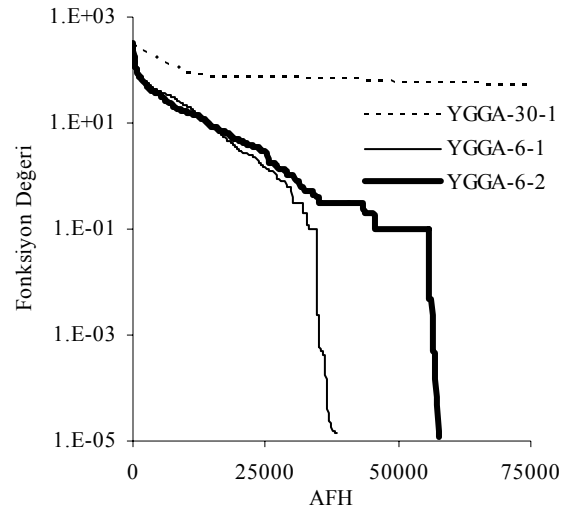
İki farklı GA tekniği ile yapılan enküçükleme çalışmasının sonuçları Şekil 6.a ve 6.b'de verilmiştir. Rastrigin fonksiyonu, Şekil 5'ten de tahmin edilebileceği gibi, birbirine yakın ve aynı düzeylerde çok sayıda tepe ve çukur noktaları içermektedir. Bu nedenle yerel optimum noktalardan sıyrılıp genel optimuma ulaşılması zor bir fonksiyondur. Genelde $f_{Rastrigin}=1$ olacak şekilde yakınsama sağlamak mümkün olmakla beraber $f_{Rastrigin}=0$ 'daki genel optimuma ulaşılması zordur. Şekil 6.a'da da bu durum görülmektedir. RGA genel optimuma yaklaşmazken, YGGA'nın bunun başardığı görülmektedir. Ancak işlem sayıları milyon mertebesindedir. Diğer taraftan Şekil 6.b ise, küçük popülasyon büyüklüğüyle YGGA'nın, belirgin bir şekilde az AFH ile genel optimuma ulaştığını göstermektedir.



Şekil 5. İki değişkenli Rastrigin fonksiyonu.



Şekil 6.a. Rastrigin fonksiyonu için sonuçlar.



Şekil 6.b. Rastrigin fonksiyonu için küçük popülasyonlu YGGA sonuçları.

YGGA uygulamalarında kullanılan parametrelerin değerleri Tablo 2’de gösterilmiştir. Bu kez AO değerinin 1.05 olduğu görülmektedir. Bunun sebebi, Rastrigin fonksiyonunun, birbiriyle yakın seviyelerde oldukça fazla tepe ve çukurlardan oluşmasından dolayı RTFA’nın ancak cevap uzayına yakın bölgelerdeki tahminlerinde başarılı olmasıdır. Eğitim setinin (popülasyonun) büyüklüğü de bu bakımdan fazla etkili olmamıştır. Ancak buna rağmen, AO=1.05 değeri de YGGA’nın RGA’ya göre başarılı olmasını sağlamıştır.

Tablo 2. Rastrigin fonksiyonu için YGGA’da kullanılan parametreler

Teknik	AO	rs	rk
YGGA-30-1	1.05	1.0	-
YGGA-30-2	1.05	-	0.75
YGGA-6-1	1.05	1.0	-
YGGA-6-2	1.05	-	0.75

6.3 Bump Fonksiyonu

Bump fonksiyonu enbüyükleme çalışması gerektiren bir fonksiyondur ve

$$\prod_{i=1}^n x_i > 0.75, \quad \sum_{i=1}^n x_i < \frac{15n}{2}$$

$$0 \leq x_i \leq 10, \quad i = 1, 2, \dots, n$$

koşullarını sağlamak şartıyla

$$f_{Bump} = \frac{\left| \sum_{i=1}^n \cos^4(x_i) - 2 \prod_{i=1}^n \cos^2(x_i) \right|}{\sqrt{\sum_{i=1}^n ix_i^2}} \quad (9)$$

şeklinde tanımlanır. Bump fonksiyonu, pek çok eniyileme yöntemi için çalışılması oldukça zorlu bir deneme fonksiyonudur [11]. İki değişkenli durum için ($n=2$) fonksiyonun grafiği Şekil 7’de gösterilmiştir. Buradan da görüleceği gibi, oldukça düzgün olmasına rağmen, fonksiyonun birbiri ile aynı seviyede pek çok tepe noktası vardır. Ayrıca bu uygulamayla, mühendislik problemlerinde genelde karşılaşılan, sınır kısıtları civarındaki en yüksek noktanın bulunması için de yöntem denenmiş olacaktır [1].


Uygulama için $n=20$ alınmıştır. Rastrigin fonksiyonu için yapılan çalışmada olduğu gibi burada da RTFA’nın girdi katmanında 20 parametre olacak ve çıktı katmanında fonksiyonun değeri ile ifade edilecek uygunluk değeri olacaktır. Bump fonksiyonunun $n=20$ için genel optimum değeri tam olarak belli değildir [1]. Ancak yapılan uygulamalarda, [1]’de olduğu gibi,

en fazla [0.8,0.81] aralığında değerlere ulaşmak mümkün olmaktadır.


Şekil 8, yapılan eniyileme çalışmasının sonucunu göstermektedir. Buradaki sonuçlara göre, YGGA, RGA’ya göre daha yüksek değere ulaşmakla birlikte, RGA’nın ulaştığı $f_{Bump}=0.745$ değerine yaklaşık %90 daha AFH yaparak ulaşmıştır. Bu fonksiyon için YGGA’nın küçük popülasyon büyüklükleriyle yapılan denemeleri YGGA-30 kadar iyi sonuç vermemişlerdir. Bu durumun, Bump fonksiyonunun karakterinden kaynaklandığı; bu nedenle RTFA’nın bu fonksiyon için küçük popülasyonlara yeterli bir cevap uzayı oluşturamadığı değerlendirilmektedir. YGGA işlemlerinde kullanılan parametreler ise Tablo 3’de sunulmuştur. Buradaki rs ve rk değerleri, elde edilen eniyi sonuçlara ait olan değerlerdir. Önceki iki uygulama için kullanılan rs ve rk değerleri de bunlara yakın sonuçlar vermektedir.

Tablo 3. Bump fonksiyonu için YGGA’da kullanılan parametreler

Teknik	AO	rs	rk
YGGA-30-1	1.25	10.0	-
YGGA-30-2	1.25	-	0.8



Şekil 7. İki değişkenli Bump fonksiyonu.



Şekil 8. Bump fonksiyonu için sonuçlar.

7. ANALİZ VE SONUÇ

Model bir tepe çıkma problemi, Rastrigin ve Bump fonksiyonları için yapılmış olan uygulamalar, YGGA tekniğinin eniyileme problemlerinde etkin bir şekilde kullanılabilceğini göstermektedir. Yukarıda verilmiş olan uygulama sonuçlarına göre, standart bir GA (RGA) ile elde edilen sonuçlarla karşılaştırıldığında YGGA metodunun aşağıda belirtilen üstünlükleri olduğu söylenebilir:

- AFH sayısını önemli ölçüde azaltmaktadır.
- Daha yüksek uygunluk değerlerine ulaşmak mümkündür.
- GA ile birlikte YSA'nın da arama gücünü kullandığından, RGA'nın bulamayacağı genel optimumları bulma şansı daha yüksektir. Ayrıca, RGA'ya göre yerel optimumlardan daha çabuk kurtulur ya da bunlara hiç takılmaz.
- Küçük popülasyon büyüklükleriyle çalışmaya imkan vermektedir.
- GA esaslı olduğu için, saf GA'lar kadar gürbüzdür.
- Farklı mühendislik problemlerine uygulanabilir.

Bu üstünlükleriyle beraber, AFH süresi çok kısa süren (YSA işlemleri mertebesinde) eniyileme problemlerinde, eğer genel optimuma ulaşmada sorun yoksa, bu yöntemi kullanmaya gerek yoktur. Çünkü bu takdirde, AFH sayısı azalsa da, YSA işlemleri nedeniyle toplam işlem (süre) miktarı artabilecektir.

8. KAYNAKLAR

- [1] Ong, Y. S., Nair, P. B. and Keane, A. J., "Evolutionary Optimization of Computationally Expensive Problems via Surrogate Modeling," *AIAA Journal*, 41 (4): 687-696, 2003.
- [2] Jin, Y., Olhofer, M., and Sendhoff, B., "A Framework for Evolutionary Optimization with Approximate Fitness Function," *IEEE Transactions on Evolutionary Computation*, 6 (5): 481-494, 2002.
- [3] Hacıoğlu, A., "Yapay Sinir Ağı İle Güçlendirilmiş Genetik Algoritma Ve Tersten Kanat Profili Dizaynı", *HUTEN Havacılık ve Uzay Teknolojileri Dergisi*, 1 (3), 2004.
- [4] Hacıoğlu, A., "Augmented Genetic Algorithm with Neural Network and Implementation to Airfoil Design," *AIAA* 2004-4633, 2004.
- [5] Hacıoğlu, A., "A Novel Usage of Neural Network in Optimization and Implementation to the Internal Flow Systems," *Aircraft Engineering and Aerospace Technology*, 77 (5): 369-376, 2005.
- [6] Haykin, S., "Neural Network; A Comprehensive Foundation," Prentice Hall, 1999.

- [7] Holst, T. L., and Pulliam, T. H., "Evaluation of Genetic Algorithm Concepts Using Model Problems Part I: Single-Objective Optimization," NASA/TM-2003-212812, 2003.
- [8] Eshelman, L.J. and Schaffer, J. D., "Real Coded Genetic Algorithms and Interval Schemata," 187-202, *Foundations of Genetic Algorithms 2*, Morgan Kaufmann Publishers, 1993.
- [9] Wright, A., "Genetic Algorithm for Real Parameter Optimization," 205-218, *Foundations of Genetic Algorithm 1*, Morgan Kaufmann Publishers, 1990.
- [10] Baker, J. E., "Reducing Bias and Inefficiency in the Selection Algorithm," 14-21, *Proceedings of the Second International Conference on Genetic Algorithms*, Morgan Kaufmann Publishers, 1987.
- [11] Keane, A. J., "Genetic Algorithm Optimization of Multi-Peak Problems: Studies in Convergence and Robustness," *Artificial Intelligence in Engineering*, 9 (2), 75-83, 1995.

ÖZGEÇMİŞ

Hv.Yrd.Doç.Dr.Müh.Bnb. Abdurrahman HACIOĞLU

İTÜ Uçak ve Uzay Bilimleri Fakültesi Uçak Mühendisliği Bölümü'nden 1991 yılında mezun oldu. 1991-1995 yılları arasında Kayseri 2.HİBM K.lığında görev yaptı. 1995-1997 yılları arasında ODTÜ Havacılık Mühendisliği Bölümü'nde yüksek lisans eğitimini; 1998-2003 yılları arasında İTÜ Uçak Mühendisliği Bölümü'ndeki doktora eğitimini tamamladı. Akışkanlar Mekaniği, Hesaplamalı Akışkanlar Dinamiği, Genetik Algoritmalar ve Aerodinamik Optimizasyon konuları ile ilgilenmektedir. Halen Binbaşı rütbesinde olup Hava Harp Okulu Dekanlığı, Havacılık Mühendisliği Bölümü'nde yardımcı doçent olarak öğretim üyeliği yapmaktadır.