

BASKIN GEN SEÇİMİ OPERATÖRÜNE DAYALI GENETİK ALGORİTMA MODELİ

Adem KALINLI, Özgür AKSU

Erciyes Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü, Kayseri
kalinlia@erciyes.edu.tr, oaksu@erciyes.edu.tr

(Geliş/Received: 06.01.2009; Kabul/Accepted: 21.07.2011)

ÖZET

Bu çalışmada genetik algoritma için baskın gen seçimi operatörüne dayalı yeni bir model önerilmiştir. Önerilen modelin performansı iyi bilinen sürekli test fonksiyonları üzerinde incelenerek sonuçlar standart genetik algoritmaya ait sonuçlarla karşılaştırılmıştır. Elde edilen sonuçlardan önerilen yaklaşımın standart genetik algoritmanın performansını artırdığı görülmüştür.

Anahtar kelimeler: Genetik algoritma, baskın gen seçimi, sürekli optimizasyon.

GENETIC ALGORITHM MODEL BASED ON DOMINANT GENE SELECTION OPERATOR

ABSTRACT

In this work, a new model based on dominant gene selection operator is proposed for the genetic algorithm. The performance of the proposed model is evaluated for the well-known continuous test problems and then its performance is compared to that of standard genetic algorithm. From the results, it was seen that the proposed approach improves the performance of the standard genetic algorithm.

Keywords: Genetic algorithm, dominant gene selection, continuous optimization.

1. GİRİŞ (INTRODUCTION)

Geleneksel algoritmalar genellikle küçük boyutlu problemlerin çözümünde iyi sonuçlar vermektedir. Bu nedenle, tasarım, üretim, kontrol, haberleşme ve taşıma gibi pratik alanlardaki optimizasyon problemlerinin büyük zorluğu, araştırmacıları yeni ve güçlü algoritmalar geliştirmeye teşvik etmiştir. Bu amaçla araştırmacıların ilgisi yapay zeka ve tabii bilimler üzerine yoğunlaşmış ve geliştirilen çeşitli algoritmalar birçok zor problemin çözümünde başarılı sonuçlar sağlamıştır. Araştırmacılar tarafından yaygın olarak kullanılan bu tür algoritmalarından birisi Holland tarafından önerilen Genetik Algoritma (GA)'dır [1]. GA yapay zekanın önemli bir dalı olan ve Darwin'in evrim teorisinden esinlenerek oluşturulan evrimsel hesaplama (evolutionary computing) tekniklerinden biridir.

Yönlendirilmiş rasgele araştırmanın bir formu olan GA, doğal seçim mekanizması ve genetik biliminde dayalıdır. GA çözüm uzayında mümkün olan

çözümlerden oluşturulan başlangıç yoğunluğunu, nesil olarak adlandırılan her çevrimde (generation) doğal seçme, mutasyon ve çaprazlama gibi genetik operatörlerle geliştirmeye çalışır. Bu süreçte GA'nın iki temel itici gücü vardır: Yeniden üreme ve mutasyon gibi değiştirme operatörleri gerekli farklılaşmayı ve bu yolla yeniliği sağlarken, seçme işlemi kaliteye doğru itici güç olarak rol oynar. Temel bir GA, paralel yapısı nedeniyle araştırma uzayının ümit verici bölgelerini oldukça çabuk bulabilmesine rağmen, olasılık tabalı yaklaşımlar gösterdiği için birçok durumda bölgesel yakınsama problemine sahip olmakta veya küresel optimuma yakınsaması kabul edilebilir zamanın ötesinde bir süre gerektirebilmektedir.

Standart bir GA (S-GA) küçük boyutlu bazı problemlerde başarılı sonuçlar üretebilmesine rağmen, genel olarak yüksek performansa sahip değildir. Başlangıç popülasyonunun oluşturulma yöntemi, bir sonraki nesil için bireylerin seçilme yöntemi, popülasyon büyüklüğü, mutasyon oranı ve

çaprazlama oranı gibi kontrol parametreleri bir GA'nın performansı üzerinde son derece etkilidir [2]. Bu nedenle genetik algoritmaların başarımının artırılmasına yönelik literatürde çok sayıda çalışma bulunmaktadır. Genel olarak bu çalışmalar, yeni ve değiştirilmiş operatörlerin önerilmesi, uygun kontrol parametrelerinin belirlenmesi, hibrid ve paralel yapılar içeren yeni genetik algoritma modellerinin ortaya konması gibi konular üzerine yoğunlaşmıştır.

Bu çalışmada, standart bir GA'nın performansını artırmak amacıyla genetik biliminden esinlenerek ortaya konan baskın gen seçim operatörü üzerine dayalı bir model önerilmiştir (BGS-GA). Önerilen modelin performansı değişik zorluk derecelerine sahip sürekli test fonksiyonları üzerinde incelenmiş ve sonuçlar S-GA'nın performansı ile karşılaştırılmıştır. İkinci bölümde genetik algoritma ve erken yakınsama problemi hakkında bilgi verilerek literatürdeki bazı çalışmalar kısaca özetlenmiştir. Üçüncü bölümde önerilen model tanıtılmış, dördüncü bölümde ise simülasyon sonuçları verilmiştir. Beşinci bölümde elde edilen sonuçlar tartışılmıştır.

2. GENETİK ALGORİTMA ve ERKEN YAKINSAMA PROBLEMİ (GENETIC ALGORITHM and PREMATURE CONVERGENCE PROBLEM)

Çaprazlama (*crossover*) ve mutasyon (*mutation*) genetik algoritmada mevcut bireylerden yeni bireyler oluşturmak amacıyla kullanılan iki temel operatördür. Çaprazlama operatörü, mevcut popülasyondaki iki bireyden (ebeveyn) bilgi değişimi (gen takası) yoluyla iki yeni birey (çocuk) meydana getirmek için kullanılır. Çaprazlamadaki amaç, eski kromozomların iyi parçalarını birleştirerek daha iyi olması beklenen yeni bireylerin ortaya çıkarılmasıdır. Çaprazlama işleminin hangi sıklıkla yapılacağı ise çaprazlama olasılığı olarak adlandırılan bir parametre ile kontrol edilmektedir. Yüksek bir çaprazlama oranı araştırma uzayının çok hızlı bir şekilde araştırılmasına sebep olacak ve diğerlerine göre daha iyi olan bireyler yeni üreme işlemlerinden sonra çok hızlı bir şekilde bozulacaktır. Düşük bir çaprazlama oranı ise üreme sonucu oluşan yeni nesile çok az sayıda yeni ve farklı bireylerin girmesine sebep olacak, araştırma uzayı yeterince taranamayacaktır. Dolayısıyla, çaprazlama oranı için makul bir olasılık değerinin belirlenmesi algoritmanın başarımı için önemlidir.

Mutasyon operatörü ise tabiatta bulunan genetik mutasyon olayını simüle eder ve GA'nın başarısında önemli rol oynar. Bu operatör, var olan bir çözüme ait kromozomların bazı genlerinin değerini değiştirilerek yeni bir çözüm üretir. Mutasyon operatörü mevcut popülasyona yeni bilgilerin girerek çözüm uzayının farklı bölgelerinin taranmasını sağlar. Bu yolla erken yakınsama probleminin aşılmasına yardım eder. Mutasyon operatörü bulunmayan genetik algoritmada optimal çözüm, ancak gerekli bilginin başlangıç popülasyonunda bulunması halinde elde edilebilecektir. Dolayısıyla, mutasyon operatörü bulunmayan genetik algoritmanın popülasyon

büyükliğünün çok büyük tutulması gerekecektir. Bu durum ise algoritmanın hızını düşürecektir. Mutasyon işlemi uygulanacak olan genler oldukça küçük tutulan bir mutasyon oranına göre rasgele olarak belirlenir. Yüksek bir mutasyon oranı, araştırmaya aşırı bir rasgelelik kazandıracak ve iraksamayı hızlandıracaktır. Tersine düşük bir mutasyon oranı ise iraksamayı yavaşlatacak ve araştırma uzayının tamamen araştırılmasını engelleyecektir. Dolayısıyla erken yakınsama problemi ortaya çıkacaktır.

Algoritmanın başarımı için bu operatörlere ait kontrol parametrelerinin uygun şekilde belirlenmesi son derece önemlidir ve literatürde bu konuyla ilgili pek çok çalışma bulunmaktadır [2-4]. Genetik algoritmanın kontrol parametreleri birbiriyle doğrusal olmayan bir şekilde etkileşim içindedir. Bu yüzden herhangi bir anda kontrol parametrelerinden birisinin optimize edilmesi mümkün değildir. Bu nedenle, kontrol parametrelerinin algoritmanın performansı üzerindeki bireysel etkilerinin çoğunlukla tahmin edilemez olması genetik algoritmaların temel sorunlardan birisidir [5]. Ayrıca optimal parametre değerlerinin probleme göre değişmesi de konuyla ilgili diğer bir zorluktur. Evrimsel algoritmalarda parametre ayarları ve parametre adaptasyonu üzerinde çok çalışılan bir konudur. Hangi yaklaşımın en iyi olduğu veya en uygun parametre değerleri konusunda varılmış ortak bir yargı bulunmamaktadır [6]. De Jong, Schaffer ve Grefenstette kontrol parametrelerinin genetik algoritmanın performansı üzerindeki etkisini incelemek için bazı test problemleri üzerinde çeşitli deneysel çalışmalar yapmışlardır [7-9]. Bunlardan De Jong'un önerisi hala yaygın olarak kullanılmaktadır.

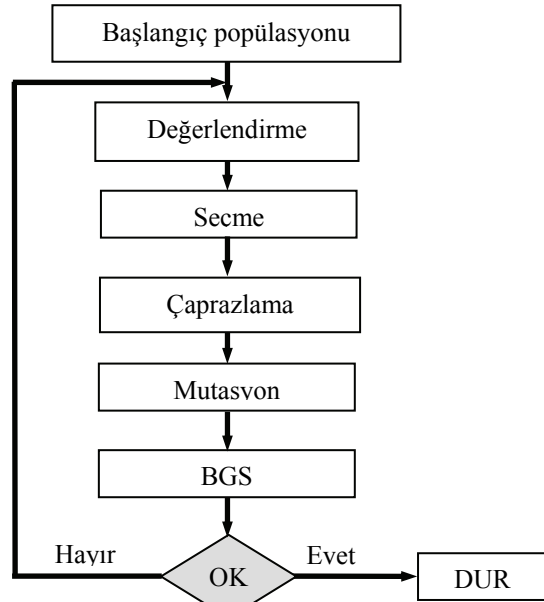
Genetik algoritmalar parametre optimizasyonu, desen tanıma, sinyal işleme, özellik çıkarma, sistem kimliklendirme ve üretim planlama gibi birçok mühendislik probleminin çözümü amacıyla başarıyla uygulanmıştır. Ancak, erken yakınsama gibi bazı zorlukların aşılması için GA'nın geliştirilmesine duyulan ihtiyaç halen devam etmektedir. Bazı araştırmacılar erken yakınsama probleminden kaçınmak için, iyileştirilmiş seçme stratejisi [10,11], yeni çaprazlama ve mutasyon operatörü modelleri [12-18] ve kontrol parametrelerinin optimizasyonu üzerine çalışmalar yapmışlardır [10,19-21].

3. ÖNERİLEN MODEL (PROPOSED MODEL)

John Holland iyi bir genetik algoritma tasarlamının temelini farklılaşmanın sürdürülebilmesi olduğunu söylemiştir [1]. Genetik algoritmada çaprazlama ve mutasyon operatörleri ile araştırmada sağlanan farklılaşma çoğu kez sınırlı kalmaktadır. Çaprazlama operatörü, yalnızca eşleştirilen iki birey arasında gen takası yapılabilmesine olanak sağlamakta, mutasyon operatörü ise yalnızca bazı kromozomların sınırlı sayıdaki genlerinin değerini değiştirmektedir. Ayrıca bu operatörler için uygun parametre değerlerinin belirlenmesinin her zaman mümkün olamaması nedeniyle, her iki operatöründe araştırma uzayının

yeterince taramasına olan katkısı sınırlı kalabilmektedir.

Bu çalışmada popülasyondaki bireylerin araştırmanın sürdürüldüğü farklı bölgelere ilişkin sahip oldukları bilgileri birleştirerek araştırmayı yönlendirmek amacıyla standart bir GA'ya Baskın Gen Seçimi (BGS) operatörü eklenmiştir. Önerilen baskın gen seçimli genetik algoritma (BGS-GA) modelinin blok diyagramı Şekil 1' de gösterilmiştir [22,23].



Şekil 1. Önerilen GA modeli (Proposed GA Model).

Genetikte, bir karakteri temsil eden ve bu karakterin çocuklara aktarılmasını sağlayan DNA parçasına *gen* adı verilir ve her karakterin geni kromozom üzerinde *lokus* denen belirli bir yerde bulunur. Yavru bireyde karakteri oluşturan genlerden biri anneden diğeri ise babadan gelir ve karakteri oluşturan bu gen çiftine *alel gen* adı verilir. Alel genler, aynı karakter üzerine zıt etki yaparlar (örneğin, A, a gibi). Karşılıklı lokuslarında aynı karakteri temsil eden ve biri anadan diğeri babadan gelen iki gen bulunduran kromozomlara *homolog kromozom* denir. Eğer, bu iki alel gen aynı özellikte ise buna *homolog karakter* (arı döl) denir ve bu genler karakter oluşumunda aynı yönde etki ederler. Bunlar anne ve babadan aynı karakteri almış bireylerdir (örneğin; AA, bb, cc). Bir kromozomun karşılıklı lokuslarında farklı özellikte iki alel gen bulunması olayına ise *heterozigot karakter* (melez döl) denir ve bu iki alel gen karakter oluşumunda zıt yönde etki ederler. Bunlar anne ve babadan farklı karakterleri almış bireylerdir (örneğin; Aa, Bb, Cc gibi). Bir karakterin oluşumunda etkisini her zaman gösteren gene baskın gen (*dominant*); etkisini ancak homozigot ise gösterebilen gene ise çekinik gen (*resesif*) denir.

Bu çalışmada, genetik bilimindeki baskın gen kavramından hareketle geliştirilen baskın gen seçimi operatörü ikili çalışan bir GA' ya uygulanmıştır. BGS

fikri, popülasyondaki aday çözümlerin kalitesi ve bu çözümlerin aynı pozisyonlarında bulunan gen değerlerinin farklı bireylerde tekrarlanma sayısına (0 veya 1' lerin sayısı) dayalıdır. Bu yaklaşımda daha düşük kaliteye sahip çözümlerin aynı gen için ortaya koyacağı kalitelerin toplamının daha yüksek kaliteli çözüm adaylarının ortaya koyacağı kaliteye göre üstünlük sağlaması durumunda daha düşük kaliteli bireylerin belirleyici olması sağlanmıştır. Bu sayede, kalitesi yüksek olan genlerin her zaman belirleyici olmaları ve bu durumda ortaya çıkabilecek erken yakınsama problemlerine engel olunması amaçlanmıştır. Baskın gen seçiminin uygulanmasında önce popülasyondaki her bir bireye amaç değere uygunluğuna göre bir kalite değeri atanır. Örneğin, amaç fonksiyon değerinin sıfır olması gerektiği ve her bir çözüme 0 ile 10 arasında bir kalite değeri atandığı kabul edilirse, minimize edilen amaç fonksiyonu için bulunan çözüm değeri f olmak üzere kalite değeri aşağıda verildiği gibi belirlenebilir:

$$K = \frac{1}{0,1 + f} \quad (1)$$

Her bir bireyin kalite değerinin belirlenmesinden sonra baskın gen seçimi gerçekleştirilir. Bu amaçla önce tüm çözümlerin birinci gen değeri 1 ve 0 olanların kalite değerleri ayrı ayrı toplanır. Sonra birinci gen değeri 1 olan çözümlerin ve 0 olan çözümlerin kalite değerleri karşılaştırılır. Eğer 1'lerin kalite toplamları daha yüksek ise baskın gen seçimi ile belirlenen çözümün birinci geni 1, aksi takdirde 0 yapılır. Bu işlem bütün genler için yapılarak, baskın çözümün tüm gen değerleri belirlenir. Tablo 1' de örnek bir baskın gen seçim işlemi gösterilmiştir. BGS popülasyondaki tüm bireyler üzerine uygulanarak bir tek yeni çözüm adayı üretebileceği gibi, popülasyondan oluşturulacak değişik büyüklüklerdeki alt popülasyonlara uygulanarak birden çok yeni çözüm adayı da oluşturabilmektedir.

Tablo 1. Baskın gen seçimi işlemi (Dominant gene selection process)

1.Ç. K=4	2.Ç. K=6	3. Ç. K=4	4.Ç. K=3	5.Ç. K=8	$\Sigma K(0)$	$\Sigma K(1)$	BÇ
1	0	1	1	0	14	11	0
0	1	1	0	1	7	18	1
1	1	0	0	0	15	10	0
0	0	0	1	1	14	11	0
1	0	1	1	1	6	19	1
...

Ç:Çözüm, K: Kalite, BÇ: Baskın Çözüm

Uygulamada alternatif çözüm adaylarının kalite değerlerinin belirlenmesinde kullanılacak kalite fonksiyonunun probleme özgü olarak tasarlanması gereklidir. Örneğin yukarıda verilen kalite ifadesinde amaç fonksiyonunun bir minimizasyon problemi olduğu varsayılmıştır. Oysa bir maksimizasyon probleminde bu tür bir fonksiyon kullanılması uygun olmayacaktır. Bu durumda amaç fonksiyonunun değeri yükseldikçe daha yüksek kalite değeri sağlayacak bir

amaç fonksiyonunun kullanılması uygun olacaktır. Ancak, bir maksimizasyon problemini yukarıda verilen kalite fonksiyonunda mevcut hata değerini dikkate almak suretiyle bir minimizasyon problemi gibi dikkate almakta mümkündür. Dolayısıyla kalite fonksiyonun nasıl belirleneceği uygulayıcılar tarafından probleme göre belirlenmesi gereken bir husustur.

Mutasyon operatörü herhangi bir çözümün bazı genlerini değiştirerek, çaprazlama işlemi ise, ikili eşleştirilen çözümlerin bazı gen parçalarını değiştirerek yeni çözümlerin üretilmesini sağlamaktadır. Bununla beraber, BGS mevcut popülasyondaki çeşitli büyüklüklerde oluşturulacak bireylerden oluşan alt popülasyonların ortak katkısı ile yeni çözüm adayları üretmekte ve araştırmayı daha ümit verici bölgelere doğru yönlendirebilmektedir [24].

4. SİMÜLASYON SONUÇLARI (SIMULATION RESULTS)

Önerilen modelin performansının belirlenmesi amacıyla iyi bilinen yedi adet sürekli test fonksiyonu kullanılmıştır. Tablo 2’ de verilen bu fonksiyonlardan

ilk dördü De Jong tarafından önerilmiştir. Tüm test fonksiyonları değişik zorluk derecelerine sahiptirler. Sphere (F1), düz, tek modlu, konveks ve simetriktr.

Rosenbrock (F2) çözüm uzayında çok dar bir yamaca sahip olduğundan zor bir fonksiyon olarak kabul edilmektedir. Step (F3) düz yüzeylerin problemini temsil eder. Düz yüzeyler hangi doğrultunun seçileceği hususunda herhangi bir bilgi vermediklerinden optimizasyon algoritmaları için zor problemlerdir. Foxholes (F4) birçok yerel optimuma sahip fonksiyonlara örnektir ve bu problem için birçok klasik optimizasyon algoritması genellikle bulunduğu ilk yerel optima takılmaktadır. F5 Fonksiyonu $x_1, x_2 \in [-10,10]$ aralığında seçildiğinde 4000 yerel optima sahip zor bir fonksiyondur. Griewangk (F6), doğrusal olmayan çok modlu bir fonksiyondur. Rastrigin (F7), geniş araştırma uzayında bulunan çok sayıda bölgesel minimum noktası nedeniyle oldukça zor bir fonksiyondur. Tablo 3’ te dikkate alınan parametre sayıları, çözümler, parametre sınırları ve çözüm uzunlukları verilmiştir.

Önerilen modelin performansının S-GA’ya ait sonuçlarla karşılaştırılabilmesi amacıyla her bir fonksiyon için değerlendirme sayısı F1-F5

Tablo 2. Nümerik test fonksiyonları (Numeric test functions)


Gösterim	İsim	Fonksiyonlar
F1	Sphere	$f_1 = \sum_{i=1}^4 x_i^2$
F2	Rosenbrock	$f_2 = 100(x_1^2 - x_2)^2 + (1 - x_1)^2$
F3	Step	$f_3 = \sum_{i=1}^5 [x_i], [x_i], x_i$ ‘ye eşit veya daha küçük en büyük tam sayıyı gösterir.
F4	Foxholes	$f_4 = [0.002 + \sum_{j=1}^{25} (j + \sum_{i=1}^2 (x_i - a_{ij})^6)^{-1}]^{-1}$ $\{a_{1j}, a_{2j}\}_{j=1}^{25} = \{(-32,-32), (-16,-32), (0,-32), (16,-32), (32,-32), (-32,-16), (-16,-16), (0,-16), (16,-16), (32,-16), \dots, (-32,32), (-16,32), (0,32), (16,32), (32,32)\}$
F5		$f_5 = (x_1^2 + x_2^2) / 2 - \cos(20\pi x_1) \cos(20\pi x_2) + 2$
F6	Griewangk	$f_6 = 1 + \sum_{i=1}^{10} (x_i^2 / 4000) - \prod_{i=1}^{10} (\cos(x_i / \sqrt{i}))$
F7	Rastrigin	$f_7 = 20A + \sum_{i=1}^{20} (x_i^2 - 10 \cos(2\pi x_i))$, $A = 10$

Tablo 3. Fonksiyonlara için tanımlamalar (Descriptions of the functions)

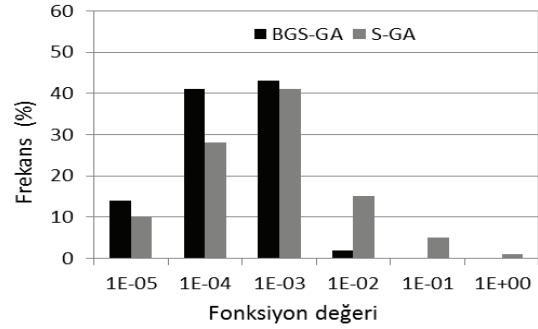
Fonksiyon	Parametre sayısı	Çözümler		Parametre Sınırları		Çözümün bit sayısı
		x_i	$F(x)$	En küçük	En büyük	
F1	4	0,0	0,0	-5,12	5,12	40
F2	2	1,0	0,0	-2,048	2,048	32
F3	5	-5,12	-30,0	-5,12	5,12	50
F4	2	-32,0	1,0	-65536	65536	40
F5	2	0,0	1,0	-10	10	36
F6	10	0,0	0,0	-600	600	200
F7	20	0,0	0,0	-5,12	5,12	400

fonksiyonları için 50000, F6 ve F7 fonksiyonları için 70000 olarak alınmıştır. GA için popülasyon büyüklüğü 50, çaprazlama oranı 0,2 ve mutasyon oranı 0,3 olarak seçilmiştir. Popülasyondan rastgele eşleştirilerek belirlenen her bir 10 bireye BGS operatörü uygulanmış, dolayısıyla her bir jenerasyonda popülasyona 5 yeni birey eklenmiştir. Önerilen model ve S-GA ile her bir fonksiyon için


100' er farklı deneme gerçekleştirilmiştir. Denemelerden elde edilen sonuçlara ait histogramlar Şekil 2-8' de, ortalama hata değerleri ve önerilen model ile sağlanan gelişme yüzdeleri Tablo 4' te verilmiştir.



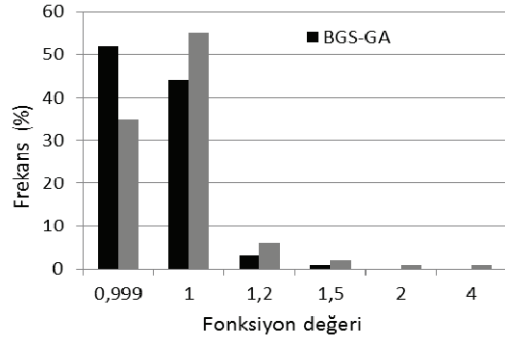
Şekil 2. F1 fonksiyonu için S-GA ve BGS-GA ile elde edilen sonuçlara ait histogramlar (Histograms drawn from the results obtained for the function F1 by S-GA and BGS-GA)




Şekil 3. F2 fonksiyonu için S-GA ve BGS-GA için elde edilen sonuçlara ait histogramlar (Histograms drawn from the results obtained for the function F2 by S-GA and BGS-GA)



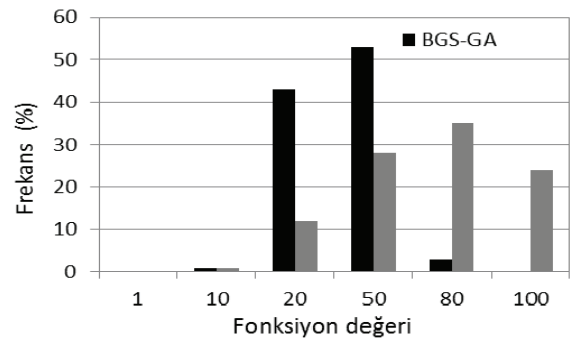
Şekil 4. F3 fonksiyonu için S-GA ve BGS-GA için elde edilen sonuçlara ait histogramlar (Histograms drawn from the results obtained for the function F3 by S-GA and BGS-GA)




Şekil 5. F4 fonksiyonu için S-GA ve BGS-GA için elde edilen sonuçlara ait histogramlar (Histograms drawn from the results obtained for the function F4 by S-GA and BGS-GA)



Şekil 6. F5 fonksiyonu için S-GA ve BGS-GA için elde edilen sonuçlara ait histogramlar (Histograms drawn from the results obtained for the function F5 by S-GA and BGS-GA)



Şekil 7. F6 fonksiyonu için S-GA ve BGS-GA için elde edilen sonuçlara ait histogramlar (Histograms drawn from the results obtained for the function F6 by S-GA and BGS-GA)



Şekil 8. F7 fonksiyonu için S-GA ve BGS-GA için elde edilen sonuçlara ait histogramlar (Histograms drawn from the results obtained for the function F7 by S-GA and BGS-GA)

Tablo 4. Standart ve önerilen GA için ortalama hata değerleri ve gelişme yüzdeleri (Average error values and improvement percentages for standard and proposed GA)

Fonksiyon	Ortalama Hata Değerleri		Gelişme (%)
	BGS-GA	S-GA	
F1	0,1460	0,2604	43,93
F2	6,72E-04	1,69E-02	96,02
F3	3,8000	4,4900	15,36
F4	0,0115	0,0823	86,02
F5	0,0660	0,0670	01,49
F6	37,600	68,500	45,11
F7	194,50	218,20	10,86
Ortalama Gelişim			42,68

Şekil 2-8'den görüldüğü gibi önerilen model dikkate alınan tüm test fonksiyonları için S-GA'ya göre daha başarılı sonuçlar sağlamıştır. Ancak Tablo 4'e verilen gelişme yüzdeleri incelendiğinde farklı problemler için sağlanan gelişimlerin de farklı oranda olduğu görülmektedir. Örneğin beşinci test fonksiyonu için sağlanan gelişme %1,49 gibi düşük bir oranda kalırken, ikinci fonksiyon için bu oranın %96 civarında gerçekleştiği görülmektedir. Farklı problemlerde önerilen modelin performansının farklı olması kontrol parametrelerinin probleme göre değişmesi ve problemlerin zorluk derecelerinin farklı olması gibi etkenlere bağlıdır. Bu tür algoritmalar için kontrol parametrelerinin algoritmanın performansı üzerinde son derece etkili olduğu bilinen bir husustur. Bu nedenle önerilen modelin kontrol parametrelerinin probleme göre optimal değerlerinin ne olması gerektiği hususu da ayrı bir çalışma konusu teşkil etmektedir. Bu çalışmada, dikkate alınan test problemleri için önerilen model ile standart bir genetik algoritmaya göre sağlanan gelişimin ortalaması %42,68 olarak gerçekleşmiştir. Dolayısıyla elde edilen sonuçlardan önerilen operatörün algoritmanın performansını önemli ölçüde artırdığı açıkça görülmektedir.

5. SONUÇ VE TARTIŞMALAR (RESULTS and CONCLUSIONS)

Erken yakınsama problemi, yapay zeka optimizasyon algoritmalarından birisi olan standart genetik algoritmanın başarımını olumsuz etkileyen faktörlerin başında gelmektedir. Bu problemin aşılması amacıyla literatürde yapılmış bir çok çalışma bulunmaktadır.

Bu çalışmada, standart GA'nın performansını artırmak amacıyla genetik biliminden esinlenerek geliştirilen baskın gen seçimi operatörü üzerine dayalı yeni bir model önerilmiştir. Önerilen modelin performansı değişik zorluk derecelerine sahip test fonksiyonları üzerinde incelenmiştir. Elde edilen sonuçlardan önerilen modelin standart genetik algoritmaya göre daha başarılı sonuçlar sağladığı görülmüştür.

Önerilen modelin başarımındaki temel etken baskın gen seçimi operatörünün topluluktaki bireylerin sahip olduğu farklı bölgelere ait bilgileri birleştirerek araştırmayı daha ümit verici bölgelere yönlendirmesidir. Ancak, baskın gen seçimi operatörünün uygulanmasının gerekli hesaplama zamanını artırdığı da bir gerçektir. Algoritmaların hesaplama zamanı özellikle gerçek zamanlı problemler için oldukça önemlidir. Bu nedenle, operatörün uygulanacağı alt popülasyonların sayısının hesaplama zamanını aşırı artırmaktan kaçınacak; ancak araştırmaya yeterli iraksamayı sağlayacak oranlarda belirlenmesi önemlidir. Alt popülasyon boyutunun performans ve hesaplama zamanı üzerindeki etkilerinin incelenmesi ise ayrı bir çalışma konusu olarak planlanmaktadır.

KAYNAKLAR (REFERENCES)

- Holland, J.H., Adaption in natural and artificial systems, University of Michigan Press, Ann Arbor, 1975.
- De Jong, K.A., Spears, W.M., "An analysis of the interacting roles of population size and crossover in genetic algorithms", **Parallel Problem Solving from Nature**, Springer, Berlin, Cilt LNCS 496, 38-47, 1991.
- Schaffer, J.D., Caruana, R.A., Eshelman, L.J., Das, R., "A study of control parameters affecting online performance of genetic algorithms for function optimization", The 3rd Int. Conf. GAs, 51-60, 1989.
- Grefenstette, J.J., "Optimisation of control parameters for genetic algorithms", **IEEE Trans. SMC**, Cilt 16, No 1, 122-128, 1986.
- Reeves C.R., Rowe J.E., **Genetic algorithms principles and perspectives: A Guide to GA Theory**, ISBN 978-1402072406, Springer, 2002.
- Michalewicz, Z., Schoenauer, M., "Evolutionary algorithms for constrained parameter

- optimization problems”, **Evolutionary Computation**, Cilt 4, 1-32, 1996.
7. De Jong, K. A., **An analysis of the behavior of a class of genetic adaptive systems**, Doctoral Thesis, Department of Computer and Communication Sciences. University of Michigan, Ann Arbor, 1975.
 8. Grefenstette, J.J., “Optimization of control parameters for genetic algorithms”, **IEEE Trans on Systems, Man and Cybernetics**, Cilt SMC-16, 122-128, 1986.
 9. Schaffer, J.D., et al, “A study of control parameters affecting online performance of genetic algorithms for function optimization”, **3rd International Conference on Genetic Algorithms**, Morgan Kaufmann, San Mateo, CA, 51-60, 1989.
 10. Eshelmn, L.J., Shaffer, J.D., “Preventing premature convergence in genetic algorithms by preventing incest”, **Proc. 4 th Int. Conf Genetic Algorithms**, 115-122, 1991.
 11. Andris, P., Frollo, I., “Optimisation of NMR coils by genetic algorithms”, **Measurement Science Review**, Cilt 2, No 2, 13-22, 2002.
 12. Davidor, Y., “Analogous crossover operator”, **Proc 3rd Int. Conf Genetic Algorithms**, George Mason Univ., Arlington, VA., 98-103, 1989.
 13. Fagarty, T.C., “Varying the probability of mutation in the genetic algorithm”, **Proc. 3rd Int. Conf Genetic Algorithms**, 104-109, 1989.
 14. Watanabe, M., Ida, K., Gen, M., “A genetic algorithm with modified crossover operator and search area adaptation for the job-shop scheduling problem”, **Computers and Industrial Engineering**, Cilt 48, No 4, 743-752, 2005.
 15. Jiri, K., Jiri, L., “A new genetic operator maintaining population diversity”, In Dubois Daniel M., editor(s), **Computing Anticipatory Systems**, Liege, Belgium, American Institute of Physics, ISBN 0-7354-0012-1, 338-348, 2001.
 16. Yang, W.X., “An improved genetic algorithm adopting immigration operator”, **Intelligent Data Analysis**, Cilt 8, No 4, 385-401, 2004.
 17. Silva, R.R., Lopes, H.S., Erig Lima, C.R., “A new mutation operator for the elitism-based compact genetic algorithm”, **LNCS**, Cilt 4431, Springer Berlin/Heidelberg, 159-166, 2007.
 18. Mitchell, G.G., O'Donoghue, D., Barnes, D., McCarville, M., “GeneRepair - A repair operator for genetic algorithms”, late-breaking paper, **GECCO**, Chicago IL, July 2003.
 19. Srinwa, M., Patnaik, L.M., “Adaptive probabilities of crossover and mutation in genetic algorithms”, **IEEE Trans. SMC**, Cilt SMC-24, No 4, 656-666, 1994.
 20. Grefenstette, J.J., “Optimization of control parameters for genetic algorithms”, **IEEE Trans. SMC**, Cilt SMC-16, No 1, 122-128, 1986.
 21. Samples, M.E., Byom, M.J., Diada, J.M., “Parameter sweeps for exploring parameter spaces of genetic and evolutionary algorithms”, in **Parameter Setting in Evolutionary Algorithms**, Fernando G. Lobo, Cl'audio F. Lima, Zbigniew Michalewicz (Editors), Springer, 161-184, 2007.
 22. Holland J.H., “Building blocks, cohort genetic algorithms, and hyperplane-defined functions”, **Evolutionary Computation**, Cilt 8, 373-391, 2000.
 23. Aksu, O., **Yeni bir paralel genetik algoritma modeli ve analog devre tasarımına uygulanması**, Yüksek Lisans Tezi, Erciyes Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı, Kayseri, Temmuz 2008.
 24. Kalınlı, A., **Geribeslemeli yapay sinir ağlarının genetik operatörlere dayalı tabu araştırma algoritması kullanarak eğitilmesi**, Doktora Tezi, Erciyes Üniversitesi, Elektronik Mühendisliği Anabilim Dalı, 1996.
 25. Kalınlı, A., Karaboga, D., “Training recurrent neural networks by using parallel tabu search algorithm based on crossover operation”, **Engineering Applications of Artificial Intelligence**, Cilt 17, No 5, 529-542, 2004.

