

ÇOK AMAÇLI GENETİK ALGORİTMA YÖNTEMLERİNİN BAŞARIMININ BELİRLENMESİ İÇİN İKİ YENİ ÖLÇÜT ÖNERİSİ

* Engin Ufuk ERGÜL

* Amasya Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü,
05100, Amasya, TÜRKİYE

Özet- Genetik algoritmalar, çok amaçlı optimizasyon problemlerinin çözümünde kullanılan etkili yöntemlerdir. Çok amaçlı optimizasyon problemlerinin doğası gereği, bu problemleri çözebilecek birçok çok amaçlı genetik algoritma (ÇAGA) yöntemi önerilmiştir. Bu yöntemlerin, optimizasyon problemlerini ne kadar iyi çözdüğünün belirlenmesi için literatürde birçok başarıml ölçütü önerilmiştir. Bu çalışmada, ÇAGA yöntemlerinin sıralama (puan atama) yeteneklerinin ölçülmesi için Ceza ve Ödül başarıml ölçütleri önerilmektedir. Bu iki ölçüt ile bir ÇAGA yöntemi tarafından seçme mekanizmasına ne kadar nitelikli bilgi aktarıldığı sezgisel ve istatistiksel olarak tespit edilebilmektedir. Literatürde çok kullanılan SPEA yöntemi ile yeni önerilmiş DOPGA yöntemi, 4 farklı test fonksiyonu üzerinde çalıştırılmış ve sonuçlar Ceza ve Ödül ölçütleri kullanılarak değerlendirilmiştir.

Anahtar Kelimeler- Genetik Algoritma, Optimizasyon, Başarıml Ölçütü, Ceza, Ödül

PROPOSAL OF TWO NEW METRICS TO DETERMINE THE PERFORMANCE OF MULTI-OBJECTIVE EVOLUTIONARY ALGORITHMS

Abstract- Genetic algorithms are effective methods to solve the multi-objective optimization problems. Due to the nature of multi-objective optimization problems, a lot of multi-objective evolutionary algorithms (MOEAs) are proposed to solve these problems. In literature, a lot of performance metrics are proposed for determining the performance of MOEAs. In this paper, Punishment and Reward metrics are proposed to measure fitness assignment capabilities of MOEAs. With the help of two proposed metrics, how much useful information can be generated and passed into the selection mechanism by MOEA methods can now be determined heuristically and statistically. The state of the art SPEA and newly proposed DOPGA methods are tested on four test functions and the results are evaluated by using Punishment and Reward metrics.

Key Words- Genetic Algorithms, Optimization, Performance Metric, Punishment, Reward

* euergul@gmail.com

1. GİRİŞ (INTRODUCTION)

Genetik algoritmalar en iyileme (optimizasyon) problemlerinin çözümünde kullanılan çok etkili arama yöntemleridir. Bir problemin en iyi çözüm ya da çözümlerinin bulunmasında, genetik algoritmalar, çaprazlama, mutasyon ve seçme gibi mekanizmaları kullanırlar. Ayrıca, genetik algoritmalar, algoritmalarının ilk adımlarında bireylere ya da çözüm önerilerine bir puan (fitness) değeri atarlar. Genetik algoritmalar hakkındaki daha ayrıntılı bilgilere [1, 2] numaralı makalelerden ulaşılabilir. Eğer bir optimizasyon probleminde birden fazla amaç değerlendiriliyorsa, o zaman buna çok amaçlı problem adı verilir ve bu problemlerin çözümünde ÇAGA yöntemleri kullanılır. Literatürde birçok ÇAGA yöntemi önerilmiştir ve önerilmeye de devam etmektedir. Bu yöntemler hakkındaki ayrıntılı incelemelere [1, 2, 3, 4] numaralı kaynaklarından ulaşılabilir.

Bir optimizasyon problemini çözmek için yeni bir yöntem önerildiğinde, önerilen yöntemin çalıştığını gösteren görsel bir tanımlama yeterlidir. Bu tür yöntemlerin işleyişinin okuyucunun zihninde, bir resminin çizilebilmesi önemlidir. Bununla birlikte, yöntem popüler olduğunda ve birçok farklı uygulaması yapıldığında, başarımının karşılaştırılabilmesi için çeşitli test fonksiyonlarına verdiği tepkiler belirlenmeli ve ölçülebilmelidir.

ÇAGA' ların popüler olmaya başladığı yıllarda, yöntemlerin karşılaştırılması yapılırken yöntemler tarafından bulunan Pareto bireyler ile test fonksiyonlarında yer alan gerçek Pareto-optimal bireyler birlikte gösterilerek karşılaştırma yapılmaktaydı. Bu çalışmalarda, bulunan sonuçların gerçek Pareto-optimal sonuçlara ne kadar yaklaştığı vurgulanırdı. İlerleyen yıllarda farklı ÇAGA yöntemlerinin önerilmesiyle birlikte, bu yöntemlerin çeşitli test fonksiyonları üzerinde başarımlarının karşılaştırılması gerekli olmuştur. Bir karşılaştırma çalışması yapmadan önce, uygun bir test fonksiyonunun seçilmesine ihtiyaç vardır. Daha doğrusu, Pareto-optimal cepheleri bilinen test fonksiyonlarının seçilmesi gereklidir.

Çok amaçlı optimizasyonun iki temel amacı vardır: (i) Pareto-optimal cepheye (önceden biliniyorsa) mümkün olduğunca yakın çözümler bulmak (*yakınsama*), (ii) bulunan bastırılmayan(Pareto) bireylerin Pareto cephesinde mümkün olduğunca düzgün dağılması (*dağılım veya çeşitlilik*). İlk amaç, Pareto-optimal bölgeye doğru bir aramaya ihtiyaç duyarken; ikinci amaç, Pareto-optimal cephe boyunca bir aramaya ihtiyaç duyar. İyi bir ÇAGA yönteminin, gerçek Pareto-optimal cepheye yakın ve bu cephede düzgün olarak dağılmış çözümler bulması gerekmektedir. ÇAGA yöntemlerinin yakınsama ve çeşitlilik değerlerinin ölçülmesi için ve aynı zamanda ÇAGA yöntemlerini karşılaştırılması için literatürde birçok başarımlar ölçütü önerilmiştir. Bunlardan bazıları aşağıdaki gibidir:

- Aralık (Spacing, S) [5]
- Hata Oranı (Error Ratio, ER) [6]
- C-metriği (C-measure) [7, 8]
- Maksimum Pareto Cephe Hatası (Maximum Pareto Front Error, ME) [5]
- Ters Nesilsel Mesafe (Inverted Generational Distance, IGD) [9]
- Hypervolume (HV) [8]
- Epsilon (ϵ) Indicator [9]
- Nesilsel Mesafe (Generational Distance, GD) [2, 10]
- Yayılım (Spread, Δ) [2, 10]

Yukarıda sıralanan ölçütlerin dışında literatürde birçok ölçüt önerilmiştir ve önerilmeye devam edilmektedir. Bu ölçütler hakkında daha fazla bilgiye [1, 9, 11, 12, 13] kaynaklarından ulaşılabilir.

Bu çalışmada, ÇAGA yöntemlerinin sıralama yeteneklerinin dolayısıyla başarımının tespit edilmesinde kullanılabilir iki yeni başarımlar ölçütü (ceza ve ödül) önerilmektedir. Bu ölçütler iki ÇAGA yönteminin başarımının ölçülmesinde kullanılmış ve sonuçlar değerlendirilmiştir.

Çalışmanın bundan sonraki bölümleri şu şekilde oluşturulmuştur: 2. Bölümde çalışmada kullanılan ÇAGA yöntemlerinden kısaca bahsedilmiş, 3. Bölümde önerilen Ceza ve Ödül ölçütleri verilmiş, 4. Bölümde elde edilen bulgulara yer verilmiş ve son bölümde çalışmadan elde edilen sonuçlar değerlendirilmiştir.

2. ÇOK AMAÇLI GENETİK ALGORİTMA YÖNTEMLERİ (MULTI-OBJECTIVE EVOLUTIONARY ALGORITHMS)

Bu çalışmada, ceza ve ödül ölçütlerinin değerlendirilmesi için SPEA ve DOPGA yöntemleri kullanılmıştır. Bu bölümde, bu yöntemler kısaca açıklanmaktadır.

2.1. SPEA (Pareto Gücü Evrimsel Algoritma, Strength Pareto Evolutionary Algorithm)

SPEA, Pareto tanımına dayalı elitist bir ÇAGA yöntemidir [7, 8]. Farklı bir kümede (arşiv veya ikinci topluluk) saklanan elit bireylerin sayısını, çözüm kümesinin karakteristiğini bozmadan kümeleme yöntemi kullanarak azaltır. Arşivdeki tüm bireyler seçme işleminde kullanılır. SPEA yönteminde, birey puanları iki aşamada atanır: *i*) Pareto bireylerin puanlanması, *ii*) Pareto olmayan bireylerin puanlanması.

Bir Pareto bireyin puanı, baskın olduğu bireylerin sayısı ile orantılıdır. n bir Pareto bireyin baskın olduğu bireylerin sayısı ve N de Pareto olmayan bireylerin (birinci Pareto cephesi dışındaki tüm bireylerin) toplam sayısı olsun. Buna göre, bir Pareto bireyin puanı (ya da gücü, strength) şu şekilde hesaplanır:

$$f_i = \frac{n}{N+1} \quad (1)$$

Pareto bireylerin puanları aynı zamanda güçlerine de eşittir ($f_i = s_i$). Bu durumda, eğer iki Pareto birey aynı sayıda bireye baskın oluyorsa puanları aynı olacaktır, bu durumda bu iki bireyi seçme mekanizmasının ayırt etmesi zor olacaktır.

Pareto olmayan bir bireyin puanı; ona baskın olan tüm Pareto bireylerin puanları toplamına **1** eklenmesiyle bulunur ($f_j = 1 + \sum s_i$). Bu puanlama yöntemi, en düşük puan değerini en çok istenilen bireye, en yüksek puan değerini ise en az istenilen bireye atar.

SPEA yönteminde, her bir adımda bulunan elit (ya da Pareto) bireyler arşiv olarak adlandırılan ikinci bir toplulukta saklanır. Arşiv boyutu sabittir. Daha sonra, her adımda, yeni bulunan elit bireyler arşiv ile karşılaştırılır ve baskın olanlar arşivde saklanmaya devam eder, baskın olmayanlar ise silinirler. İlerleyen adımlarda elit bireylerin sayısında artış olabilir. Bu durumda, yalnız arşiv boyut kadar birey arşivde saklanır. Eğer arşiv boyutu aşılsa, bir çeşit kümeleme yöntemi kullanılarak kalabalık bölgede olan elit bireyler arşiv boyutuna ulaşıncaya kadar silinir, böylece çeşitlilik de sağlanmış olur.

2.2. DOPGA (Bireyin Baskınlık Gücü Genetik Algoritma, Domination Power of an Individual Genetic Algorithm)

DOPGA, ÇAGA' lar için yeni önerilmiş bir puan ölçekleme yöntemidir [14]. DOPGA' da bir bireyin puanı (rank veya fitness) iki aşamada atanır. İlk aşamada, çözüm önerilerinin yer aldığı bireylerden oluşan topluluk birkaç adet alt topluluğa bölünür ve MOGA [15] yöntemi kullanılarak bu alt topluluklar sıralanır. MOGA' da bir bireyin puanı, o toplulukta ona baskın olan (domine eden) bireylerin sayısı ile belirlenir. Bastırılmayan (non-dominated) tüm bireylere "1" puanı atanır. Bu ilk puanlama ile "1" puanına sahip bireylerden oluşan ilk Pareto cephesi elde edilir ve diğer cephelere ait bireylere artan şekilde puan ataması yapılır.

İkinci aşamada her alt topluluk baskınlık gücü kavramı kullanılarak yeniden puanlanır. Baskınlık gücü, bireylerin konumuna yani Pareto olup olmadığına bakılmaksızın her bir bireye uygulanır. Ek olarak, arşivdeki birey sayısı daha önce kullanıcı tarafından belirlenmiş boyutu aşarsa, azaltımsal kümelemenin (subtractive clustering) [16] değiştirilmiş bir biçimi uygulanır ve azaltılmış topluluk (kullanıcı tarafından belirlenen boyuta düşürülmüş) elde edilir. Eğer arşivin boyutu kullanıcı tarafından belirlenmiş boyuta ulaşmazsa, arşivdeki tüm bireyler ana toplulukla birleştirilir. DOPGA' da, kümeleme yöntemi puanlama mekanizmasında kullanılmaz ve yalnızca arşiv yönetimi için kullanılır.

DOPGA' da, puan ölçekleme bireylerin komşuluklarının dikkate alınmasıyla yapılır. Örneğin, bir birey kendi alt topluluğundaki diğer bireylerden daha yüksek bir baskınlık gücüne (domination power) sahipse, o zaman kendi alt topluluğundaki en az istenen birey olacaktır. Eğer bir birey yüksek bir baskınlık gücüne sahipse, bu onun kalabalık bir bölgede olduğu anlamına gelir ve bu yüzden, çevresinde kendisine benzer birçok çözüm olacaktır. Bu durumda, DOPGA bu bireyi cezalandırır ve kendi alt topluluğunda en az istenilen birey yapar. DOPGA bireyleri birbirinden ayırt ederek, seçme mekanizmasının çalışmasına önemli ölçüde katkıda bulunur. Ayrıca, DOPGA çeşitliliğin sağlanması için herhangi bir ekstra parametre kullanmaz.

DOPGA puanlama algoritması aşağıda verilmektedir [14]:

Adım 1: Her bireye alt topluluk (*alt_top*) numarası ile ters orantılı olan bir yapay *p* puan atanır (MOGA algoritması kullanılarak).

$$yp(birey_i) = \frac{1}{alt_top(j)} \quad (2)$$

$i=1 \dots n$, burada n bireylerin toplam sayısı ve $j=1 \dots m$, m ise toplam alt topluluk sayısıdır.

Adım 2: Bireyin *bağlı baskınlık gücü* hesaplanır. Bunun için, kaç tane bireyin bu birey tarafından bastırıldığı belirlenir ve baskın olan bireylerin yapay puanları toplanır.

$$bbg(birey_i) = \sum_{k=1}^r yp(birey_k) \quad (3)$$

Burada $k \dots r$, i bireyinin baskın olduğu tüm bireyleri göstermektedir ve $k \dots r \neq i$.

Adım 3: Aynı alt topluluktaki tüm bireyler için Adım 2 tekrar edilir. Aynı alt topluluktaki tüm bireylerin *bbg()* leri toplanır ve her alt topluluk için toplam *baskınlık gücü* aşağıdaki gibi hesaplanır:

$$tbg (alt_top(j)) = \sum_i^p bbg (birey_i) \quad (4)$$

Burada $i \dots p$, $Alt_top(j)$ ' de yer alan tüm bireylerdir.

Adım 4: i bireyinin gerçek puanı aşağıdaki formül kullanılarak hesaplanır (paydaya sıfıra bölme durumunda kurtulmak için 1 eklenmiştir):

$$gp (i) = alt_top (j) + \frac{bbg (i)}{tbg (alt_top (j)) + 1} \quad (5)$$

Adım 5: Topluluktaki tüm bireyler puanlanana kadar Adım 2- Adım 4 arası tekrarlanır.

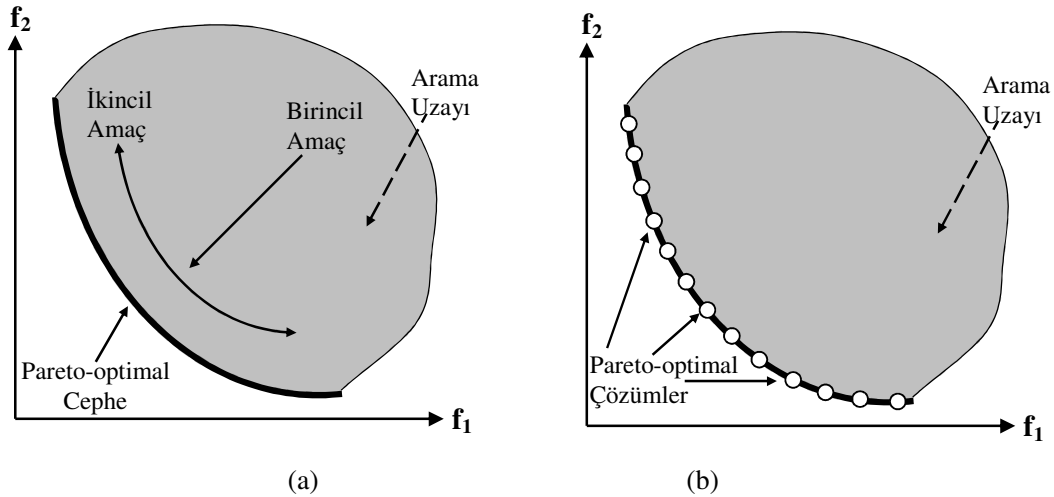
DOPGA yöntemi hakkındaki ayrıntılı bilgiye [14] numaralı makaleden ulaşılabilir.

3. CEZA VE ÖDÜL ÖLÇÜTLERİ (PUNISHMENT AND REWARD METRICS)

Çok amaçlı optimizasyonun iki temel amacı vardır:

- (i) Pareto-optimal cepheye (önceden biliniyorsa) mümkün olduğunca yakın çözümler bulmak (*yakınsama*),
- (ii) Bulunan bastırılmayan(Pareto) bireylerin Pareto cephesinde mümkün olduğunca düzgün dağılması (*dağılım veya çeşitlilik*).

İlk amaç, Pareto-optimal bölgeye doğru bir aramaya ihtiyaç duyarken; ikinci amaç, Pareto-optimal cephe boyunca bir aramaya ihtiyaç duyar. İyi bir ÇAGA yönteminin, gerçek Pareto-optimal cepheye yakın ve bu cephede düzgün olarak dağılmış çözümler bulması gerekmektedir (Bkz. Şekil 1).



Şekil 1. (a) Çok amaçlı optimizasyonda ulaşılmaması istenen iki amaç
(b) İdeal bir Pareto-optimal çözüm kümesi

Literatürde ÇAGA yöntemlerinin karşılaştırılmasında kullanılmak üzere birçok ölçüt önerilmiştir. Bu çalışmada ise ÇAGA yöntemlerinin puanlama yeteneğinin belirlenmesi için iki

..:Çok Amaçlı Genetik Algoritma Yöntemlerinin Başarımının Belirlenmesi İçin İki Yeni Ölçüt Önerisi:..

yeni ölçüt önerisi yapılmaktadır. Bu yeni ölçütlere geçmeden önce, ÇAGA yöntemlerinin nasıl karşılaştırılabileceğine bakmak yararlı olabilir. Literatürde yer alan tipik bir karşılaştırma senaryosu aşağıda verilmektedir [17]:

- Karşılaştırılacak ÇAGA yöntemleri belirlenir,
- Varolan test fonksiyonlarından birkaçı seçilir veya yenileri oluşturulur,
- ÇAGA yöntemi tarafından elde edilen sonuçları karşılaştırmak için birtakım başarımlı ölçütleri seçilir,
- Her bir test fonksiyonunda tüm ÇAGA yöntemlerinin sonuçları bulunur,
- Sonuçlar kullanılarak ölçümler yapılır ve elde edilen veriler karşılaştırılır,
- Sonuçlar grafiksel olarak çizdirilir.

Ceza ve ödül ölçütleri, bir ÇAGA yönteminin puanlama mekanizmasının görevini ne kadar iyi yaptığı belirlemek için kullanılırlar. Puanlama (sıralama) yeteneğinin ölçülmesi için belirli bir ölçüt yoktur. Diğer bir deyişle, puanlamanın ne kadar iyi yapıldığını doğrudan ölçen bir ölçüt yoktur. Burada önerilen ölçütler, problem tipinden bağımsızdır ve Pareto-optimal cephenin önceden bilinmesine de ihtiyaç duymamaktadırlar. ÇAGA yöntemleri tarafından bir topluluktaki bireylere atanan puanların bilinmesiyle karşılaştırma yapılabilir. Buradaki fikir, "Bireylerin puanlarına bakılarak topluluk hakkında ne kadar bilgi edinilebilir?" sorusundan gelmektedir. Ayrıca, *bu puan değerleri kullanılarak karar vericiye ya da seçme mekanizmasına ne kadar bilgi gönderilebilir?* Bir topluluktaki bireylere puan atanması, aslında bireylerin en çok istenilenden en az istenilene doğru sıralanması işlemidir. Bu sorulara yanıt bulabilmek için ceza ve ödül ölçütleri önerilmektedir.

Prensip olarak, farklı bireyler aynı puana sahipse, bu durumda bir ceza değeri oluşturacaklardır. Örneğin, en çok istenilen iki birey (iki Pareto birey gibi) aynı puana sahipse, daha az istenilen iki bireye (iki Pareto olmayan birey gibi) göre daha fazla ceza değeri üreteceklerdir. Yani daha önemli bireylerin aynı puana sahip olması daha fazla ceza değeri üretir, bu nedenle ceza eğrisi üstel bir biçimde azalan bir işlev olmalıdır. Aşağıda bu duruma uygun bir ceza işlevi verilmektedir. Bu işlev, her bireyin konumu veya önemi ile ilişkilidir.

$$\text{Ceza}(i) = \exp\left(-\frac{i}{\text{top_boyut}}\right) \quad i=1,2,\dots,\text{top_boyut} \quad (6)$$

Ceza değeri aşağıdaki algoritma kullanılarak hesaplanır:

- 1- ÇAGA yöntemini çalıştır ve bireylerin puan değerlerini al,
- 2- Puan değerlerini en önemliden en az önemliye (ÇAGA yöntemine göre değişebilir) doğru sırala,
- 3- Aynı puan değerlerine sahip olan bireyleri belirle,
- 4- Ceza işlevine (denklem 6) git ve Adım-3' teki bireylerin ceza değerlerini belirle, daha sonra bu ceza değerlerini topla,

$$\text{Toplam_Ceza} = \sum \text{Ceza}(m) \quad (m: \text{aynı puana sahip birey indisleri}) \quad (7)$$

Hesaplamaların daha iyi anlaşılması için aşağıda sayısal bir örnek verilmektedir. Sekiz bireylik bir topluluğa ait puan değerleri aşağıdaki gibi verilsin. Buna göre toplam ceza şöyle hesaplanır:

- 1- Birey puanları : [1 2 1 6 4 8 5 8]
- 2- Puanlar sıralanır : [1 1 2 4 5 6 8 8]
- 3- İlk iki ve son iki birey aynı puanlara sahip,

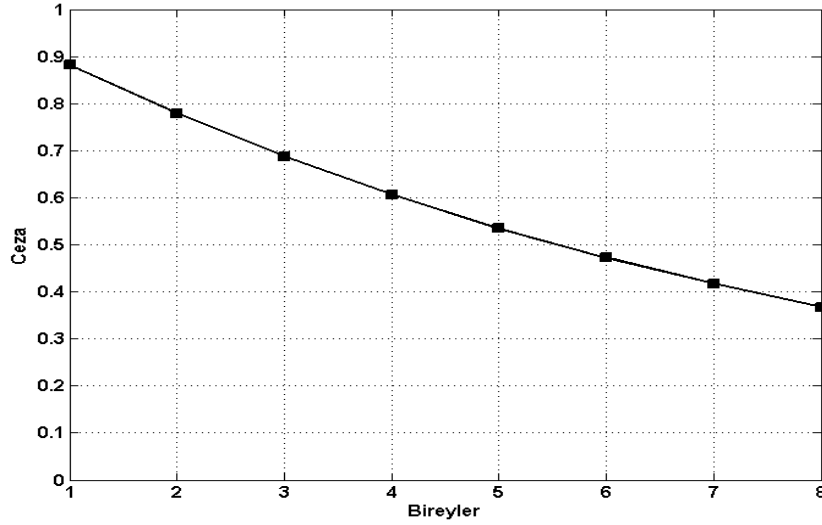
- 4- (6) numaralı denkleme göre 8 bireylik bir ceza eğrisi oluşturulur (Bkz. Şekil 2) ve aynı puana sahip bireylerin ayrı ayrı ceza değeri hesaplanır:

$$\text{ceza}(1) = p(1) = \exp\left(\frac{-1}{8}\right) = 0.8825 \quad \text{ceza}(2) = p(2) = \exp\left(\frac{-2}{8}\right) = 0.7788 \quad (8)$$

$$\text{ceza}(7) = p(7) = \exp\left(\frac{-7}{8}\right) = 0.4169 \quad \text{ceza}(8) = p(8) = \exp\left(\frac{-8}{8}\right) = 0.3679 \quad (9)$$

$$\text{Toplam_Ceza} = \sum \text{Ceza}(m) = \sum p(m) = p(1) + p(2) + p(7) + p(8) \quad (10)$$

$$\text{Toplam_Ceza} = 0.8825 + 0.7788 + 0.4169 + 0.3679 = 2.4461 \quad (11)$$



Şekil 2. Sekiz bireylik bir topluluk için ceza işlevi

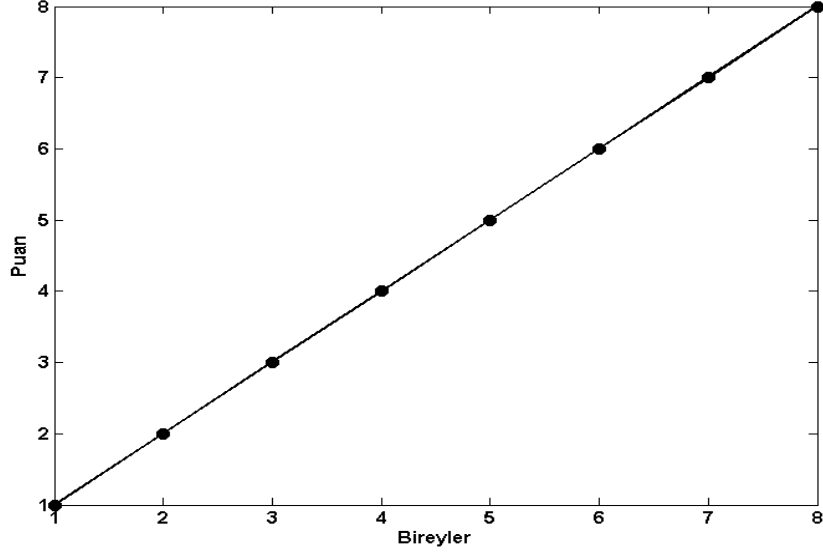
Ödül ölçütü ise, tüm bireyler birbirinden farklı olsa veya topluluk sıfır ceza değerine sahip olsa bile, bireylerin puan dağılımının ne kadar düzgün olduğunun belirlenmesinde kullanılır. Ödül ölçütü şöyle hesaplanır:

- 1- Puan değerleri 0 ile 1 arasına normalize edilir,
- 2- Normalize puan değerleri en önemliden en az önemliye doğru sıralanır,
- 3- Tüm toplulukta ardışıl bireyler arasındaki normalize puan farkları (NPF) hesaplanır,
- 4- Ardışıl bireyler arasındaki normalize puan farklarının standart sapması ve ortalama değeri bulunur ve buna göre Ödül ölçütü aşağıdaki gibi hesaplanır:

$$\text{Ödül} = \frac{\text{Standart Sapma(NPF)}}{\text{Ortalama Deger(NPF)}} \quad (12)$$

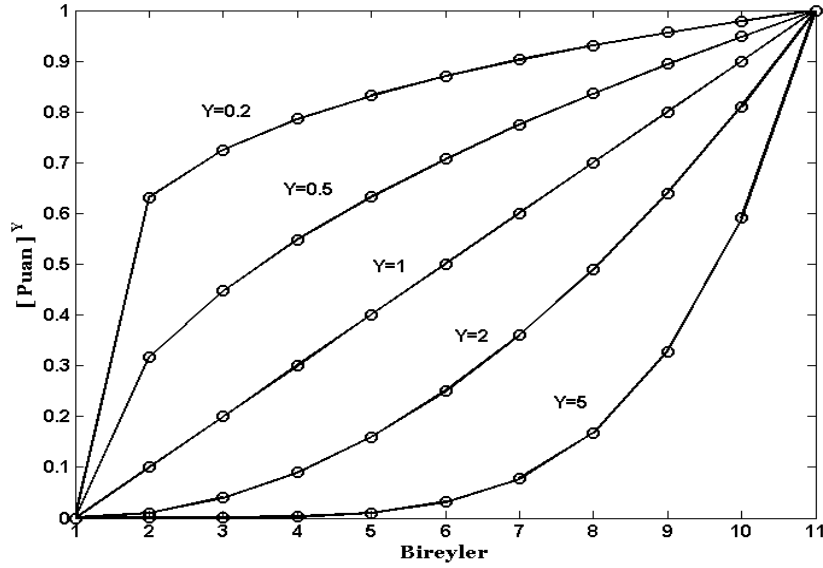
...:Çok Amaçlı Genetik Algoritma Yöntemlerinin Başarımının Belirlenmesi İçin İki Yeni Ölçüt Önerisi:..

Eğer Şekil 3' te gösterildiği gibi ödül değeri sıfır olursa, puan dağılımı kesinlikle düzgündür. Burada 1 nolu birey en iyi birey, 8 nolu birey ise en kötü bireydir. Bu ideal puan dağılımında, bireyler eşit aralıklarla sıralanmış ve puan değerleri arasındaki farklar sabit olduğundan standart sapma sıfır olacaktır.



Şekil 3. İdeal puan dağılımı

ÇAGA yöntemleri karşılaştırıldığında, en düşük ceza ve ödül (birlikte düşünülmelidir) değerine sahip olan yöntem sıralama yeteneği açısından en iyi yöntem olacaktır. Puan değerleri seçme mekanizmasının giriş kümesidir ve seçme mekanizması giriş kümesinin içeriğine bağlı olarak bir çıkış kümesi oluşturur. Şekil 4, birbirinden farklı puan dağılımları olan ancak hepsi de sıfır ceza değerine sahip beş farklı topluluğu göstermektedir. Çünkü tüm bu farklı puan dağılımları seçme mekanizması üzerinde farklı seviyelerde seçilme baskısı oluşturacaklardır. Bir başka deyişle, bu beş farklı küme ile beslendiğinde, seçme mekanizmasının çıkışları (bir sonraki ebeveynler) aynı olmayacaktır. Tüm bu dağılımlar sıfır ceza değerine sahip olmalarına rağmen, ödül tanımından dolayı ödül değerleri birbirinin aynısı değildir. Şekil 4' ten görüleceği üzere, puan değerinin $\gamma=1$ ile üssü alınır, bu durumda puan dağılımı düzgün olur. Eğer γ değeri 1' den büyük olursa, puan dağılımının grafiği içbükey olur ve ilk birkaç bireyin puanı birbirine çok yakın olurken, tersine son birkaç bireyin puanı birbirinden uzak olur. Benzer olarak, eğer γ değeri 1' den küçük ise, puan dağılımı dışbükey bir işlev olur. İlk birkaç bireyin puan değerleri birbirinden uzak yerleşirken, tersine son birkaç bireyin puanı çok yakın olur. Puan dağılımının kısmi seyreklikleri ve kısmi kalabalıkları, sıfırdan farklı bir ödül değeri olmasına neden olur ve bu da dağılımın düzgün olup olmadığını gösterir. Tüm bu beş farklı puan dağılımı ve bunlara ilişkin ödül değerleri Şekil 4. ve Tablo 1' de verilmektedir.



Şekil 4. Beş farklı topluluğun puan dağılımları

Tablo 1. Şekil 4' teki puan dağılımlarının ödül değerleri

Puan Dağılımının Üs Değeri	Ödül (R) Değeri
$\gamma=1$	0
$\gamma=2$	0.6055
$\gamma=5$	1.3867
$\gamma=0.5$	0.7981
$\gamma=0.2$	1.8788

4. BULGULAR (FINDINGS)

Literatürde sık kullanılan SPEA yöntemi ile yakın zamanda önerilmiş DOPGA yöntemlerinin sıralama yeteneklerinin ölçülmesi için, sık kullanılan dört test fonksiyonu (ZDT1, ZDT2, ZDT3, ZDT6) üzerinde bu yöntemler çalıştırılmış ve her bir GA adımında bireylere atadıkları puan değerleri, ceza ve ödül ölçüt değerlerinin hesaplanmasında kullanılmıştır. Tüm ÇAGA yöntemleri 20' şer kez 100 adım çalıştırılmıştır. Her bir adımda bireylere atanan puan değerleri kullanılarak, ceza ve ödül ölçütleri ($20 \times 100 = 2000$ değer) hesaplanmıştır. Daha sonra bu ceza ve ödül değerlerinin ortalamaları sıralama yeteneklerinin karşılaştırılmasında kullanılmıştır. Ceza ve ödül ölçütlerinin yanı sıra, yakınsama (GD) ve yayılım (Δ) ölçütleri de hesaplanarak ortalama değerleri alınmıştır. Test fonksiyonlarına ilişkin bilgiler Tablo 2' de verilmektedir.

Tablo 2. Test Fonksiyonları (m parametre sayısı)

Test Fonksiyonu	m	Parametre Sınırları	Amaç Fonksiyonları	Pareto Cephesi
ZDT1	30	[0,1]	$f_1(X) = x_1$ $f_2(X) = g(X)[1 - \sqrt{x_1 / g(X)}]$ $g(X) = 1 + 9 \left(\sum_{i=2}^m x_i \right) / (m - 1)$	Dışbükey
ZDT2	30	[0,1]	$f_1(X) = x_1$ $f_2(X) = g(X)[1 - (x_1 / g(X))^2]$ $g(X) = 1 + 9 \left(\sum_{i=2}^m x_i \right) / (m - 1)$	İçbükey
ZDT3	30	[0,1]	$f_1(X) = x_1$ $f_2(X) = g(X)[1 - \sqrt{x_1 / g(X)} - \frac{x_1}{g(X)} \sin(10\pi x_1)]$ $g(X) = 1 + 9 \left(\sum_{i=2}^m x_i \right) / (m - 1)$	Dışbükey ve Süreksiz
ZDT6	10	[0,1]	$f_1(X) = 1 - \exp(-4x_1) \sin^6(6\pi x_1)$ $f_2(X) = g(X)[1 - (f_1(X) / g(X))^2]$ $g(X) = 1 + 9 \left[\left(\sum_{i=2}^m x_i \right) / (m - 1) \right]^{0.25}$	İçbükey ve Düzgün Dağıılmamış

Benzetimlerde kullanılan parametrelerin değerleri Tablo 3' te verilmektedir. Karar değişkenleri 30 bit olarak kodlanmıştır.

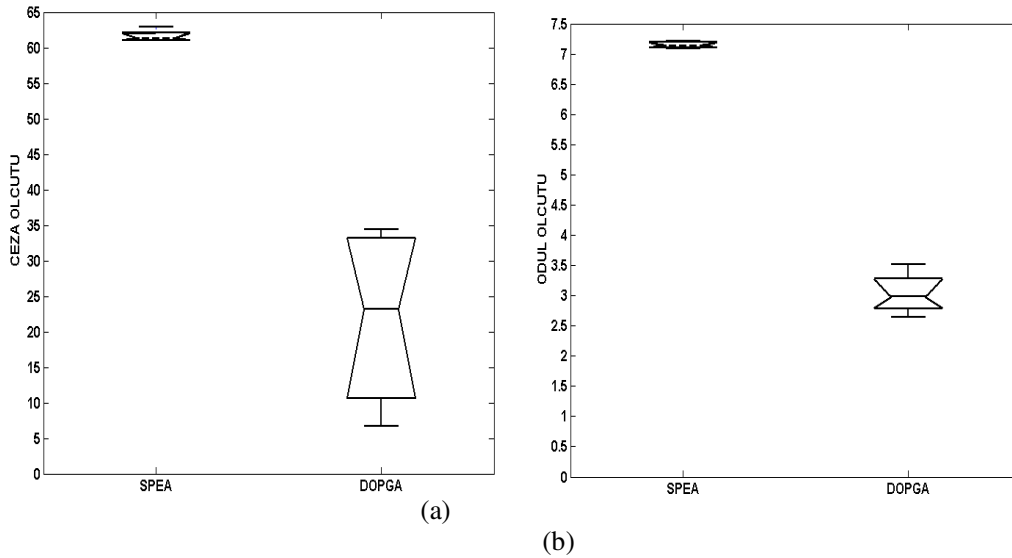
Tablo 3. Benzetimlerde kullanılan parametreler

	SPEA	DOPGA
Karar değişkenlerinin (parametrelerin) sayısı (n)	ZDT6 için 10, Diğer test fonksiyonları için 30	ZDT6 için 10, Diğer test fonksiyonları için 30
Mutasyon olasılığı (p_m)	1/l (burada l diz boyutudur)	1/l (burada l diz boyutudur)
Çaprazlama olasılığı (p_c)	0.9	0.9
Topluluk boyutu (N)	100	100
Arşiv veya ikinci topluluk boyutu (\bar{N})	25	100
Maksimum nesil sayısı	100	100
Çalıştırılma sayısı	20	20

Tablo 4, SPEA ve DOPGA yöntemleri için elde edilen ölçüt değerlerini göstermektedir. Şekil 5'te ise SPEA ve DOPGA yöntemlerinin ceza ve ödül değerlerine göre elde edilen boxplot gösterimler verilmektedir. Ceza ve ödül ölçütlerine göre daha iyi olan yani hem ceza hem de ödül ölçütü daha düşük olan DOPGA yöntemi, SPEA yöntemine göre daha iyi sıralama yeteneğine sahiptir. Bu sonuçlara göre DOPGA yönteminin Pareto-optimal cepheye yakınsama ve bu cephe üzerinde dağılım açısından da SPEA yönteminde daha iyi olması beklenmektedir. Yakınsama ve dağılım ölçütlerinin sonuçlarına göre de DOPGA yöntemi başarımlı açılarından SPEA yönteminden daha iyidir.

Tablo 4. SPEA ve DOPGA yöntemleri için ölçüt değerleri

		CEZA (P)	ÖDÜL (R)	GD	Δ
SPEA	ZDT1	60.9579	7.1189	0.1277	0.6184
	ZDT2	61.2675	7.1624	0.3046	0.7556
	ZDT3	62.9278	7.2240	0.0977	0.6228
	ZDT6	61.1981	7.0937	2.0635	0.9112
DOPGA	ZDT1	31.9688	3.0415	0.0156	0.5797
	ZDT2	14.4255	2.9271	0.0223	0.5922
	ZDT3	34.4204	3.5166	0.0097	0.6111
	ZDT6	6.6732	2.6472	0.8116	0.8334



Şekil 5. Boxplot gösterim: (a) Ceza ölçütü, (b) Ödül ölçütü

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, ÇAGA yöntemlerinin sıralama yeteneklerinin ölçülmesi için iki yeni başarımlı ölçütü önerilmiştir. Bu ölçütler kullanılarak, ÇAGA yöntemlerinin bir topluluktaki bireyleri en çok istenilenden en az istenilene doğru sıralama yetenekleri tespit edilmiştir. Ceza ve ödül ölçütleri en az olan yöntem sıralama yeteneği açısından daha iyidir. Böylece seçme mekanizmasına veya karar vericiye en fazla / nitelikli bilgiyi iletmektedir. Bu ölçütler, test

...:Çok Amaçlı Genetik Algoritma Yöntemlerinin Başarımının Belirlenmesi İçin İki Yeni Ölçüt Önerisi::

fonksiyonlarından bağımsızdırlar ve daha önceden bilinse dahi Pareto cephesini kullanmamaktadırlar.

Ölçütlerin değerlendirilmesinde SPEA ve DOPGA yöntemleri kullanılmıştır. Sonuç olarak, DOPGA yönteminin SPEA yöntemine göre bireyleri en çok istenilenden en az istenilene doğru daha iyi sıraladığı belirlenmiştir. Yakınsama ve dağılım açısından da beklendiği üzere DOPGA yöntemi daha iyidir. Ceza ve ödül ölçütleri ile yakınsama ölçütü arasında bir bağ bulunmamaktadır. Ancak, dağılım ile ceza-ödül arasında doğrusal bir ilişki vardır, yani ceza ve ödülü düşük olan yöntem dağılım açısından daha iyi olmaktadır. Ayrıca seçme mekanizmasının olasılıksal olarak davranması nedeniyle, sıralama bilgileri nitelikli bir biçimde kullanılmamaktadır. Yani hangi birey çiftlerinin çaprazlamaya tabi tutulacağı kesin olarak bilinmediğinden dolayı olasılıksal bir seçim yapılmaktadır. Bu da seçme mekanizmasının puanlama mekanizmasından gelen bilgileri kullanmadığı anlamına gelir. Bu durumda, olasılıksal olarak çalışan seçme mekanizması yerine uzman sistem veya kural tabanlı bir seçme mekanizması kullanıldığında ceza ve ödül ölçütleri daha anlamlı olacaktır.

Gelecek çalışmalarda, önerilen ölçütler diğer ÇAGA yöntemlerine ve diğer test fonksiyonlarına uygulanacaktır. Ayrıca kural tabanlı bir seçme mekanizması geliştirilmeye çalışılacaktır.

6. KAYNAKLAR (REFERENCES)

- [1]. Coello, C. A. C., Lamont, G. B., Veldhuizen, D. A., (2007). Evolutionary Algorithms For Solving Multi-Objective Problems, Second Edition. *Springer, New York, U.S.A.*
- [2]. Deb, K., (2001). Multiobjective Optimization Using Evolutionary Algorithms, *Wiley, Chichester, U.K.*
- [3]. Coello Coello, C. A., (1999). A Comprehensive Survey of Evolutionary-Based Multiobjective Optimization Techniques, *Knowledge and Information Systems*, 1(3), pp.269-308.
- [4]. Ghosh A., Dehuri S., (2004). Evolutionary Algorithms for Multi-Criterion Optimization: A Survey, *International Journal of Computing & Information Sciences*, 2(1).
- [5]. Schott, J. R., (1995). *Fault Tolerant Design Using Single and Multi-Criteria Genetic Algorithms*, Master Thesis, Department of Aeronautics and Astronautics, Massachusetts Institute of Technology, Boston, USA.
- [6]. Van Veldhuizen, D.A., (1999). *Multiobjective Evolutionary Algorithms: Classifications, Analyses, and New Innovations*, PhD. Thesis, Air Force Institute of Technology, Dayton.
- [7]. Zitzler, E., (1999). *Evolutionary Algorithms for Multiobjective Optimization: Methods and Applications*, Ph.D Thesis, Swiss Federal Institute of Technology, Switzerland.
- [8]. Zitzler, E., Thiele, L., (1999). Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach, *IEEE Transactions on Evolutionary Computation*, 3(4), 257-271.
- [9]. Zitzler, E., Thiele, L., Laumans, M., Fonseca, C. M., Fonseca, V. G., (2003). Performance Assesments of Multiobjective Optimizers: An Analysis and Review, *IEEE Transactions on Evolutionary Computation*, 7(2), 117-132.
- [10]. Deb, K., Pratap, A., Agarwal, S., Meyarivan, T., (2002). A Fast and Elitist Multi-objective Genetic Algorithm: NSGA-II, *IEEE Transactions on Evolutionary Computation*, 6,182-197.
- [11]. Van Veldhuizen, D.A., and Lamont G.B., (2000). Multiobjective Evolutionary Algorithms: Analyzing the State-of-the Art, *Evolutionary Computation* 7(3), 1-26.

- [12]. Knowles J., Thiele L., and Zitzler E., (2006). A Tutorial on the Performance Assessment of Stochastic Multiobjective Optimizers, 214, Computer Engineering and Networks Laboratory (TIK), ETH Zurich, Switzerland, Revised Version.
- [13]. Knowles, J.D., Corne, D.W., (2002). On Metrics for Comparing Nondominated Sets, *Proceedings of the 2002 Congress on Evolutionary Computation, CEC '02*, 1, 711-716.
- [14]. Ergul, E.U., Eminoglu, I., (2014). DOPGA: A New Fitness Assignment Scheme for Multi-objective Evolutionary Algorithms, *International Journal of Systems Science*, 45(3), 407-426.
- [15]. Fonseca, C.M., Fleming, P.J., (1993). Genetic Algorithms for Multi-objective Optimization: Formulation, Discussion and Generalization, *In Proceedings of the Fifth International Conference on Genetic Algorithms*, 416-423.
- [16]. Chiu, S., (1994). Fuzzy Model Identification Based on Cluster Estimation, *Journal of Intelligent & Fuzzy Systems*, 2(3).
- [17]. Huband, S., Hingston, P., Barone, L., While, L., (2006). A Review of Multiobjective Test Problems and A Scalable Test Problem Toolkit, *IEEE Transactions on Evolutionary Computation*, 10(5), 1-30.