Klonal Seçme Algoritması kullanarak Uyarlanır Süzgeçler ile Doğrusal Kestirim

Linear Prediction with Adaptive Filters by using Clonal Selection Algorithm

Tuba Çağlıkantar[1], Rifat Kurban[2]

[1]Jeodezi ve Fotogrametri Mühendisliği Bölümü
[2]Bilgisayar Mühendisliği Bölümü
Erciyes Üniversitesi, Mühendislik Fakültesi, 38039, Kayseri
{tubac, rkurban}@erciyes.edu.tr

Özetçe

Bu çalışmada, klonal seçme algoritması (CLONALG) kullanan bir uyarlanır süzgeç yapısı ile işaretlerin doğrusal kestirimi gerçekleştirilmiştir. Gradyent tabanlı en küçük ortalama kareler algoritması ile klonal seçme algoritmasının başarımı karşılaştırılmıştır. Diğer yandan, önerilen yaklaşımda uyarlanır süzgeç derecesinin başarıma etkisi incelenmiştir ve yüksek dereceli süzgeçler ile daha küçük kestirim hataları elde edilmiştir. Ayrıca, klonal seçme algoritmasının tasarım parametrelerine bağımlılığının geleneksel yöntemlere göre daha az olduğu görülmüştür.

Abstract

In this paper, linear prediction of signals is realized with an adaptive filter structure using a clonal selection algorithm (CLONALG). The performances of gradient based least mean squares method and the clonal selection algorithm are compared. Furthermore, the effect of the adaptive filter order for proposed approach on the performance is examined and with higher order filters smaller prediction errors are obtained. Also, it is seen that the dependence of the clonal selection algorithm to the design parameters is less than the conventional methods.

1. Giriş

Uyarlanır süzgeçler, işlenilecek olan işaretlerin istatistiksel özellikleri bilinmediğinde, giriş verisinden arzu edilen bilginin elde edilmesini sağlayabilirler ve işaret istatistiklerinde meydana gelen geçici değişikleri takip edebilirler [1].

Günümüzde uyarlanır süzgeç tekniklerinin uyarlanır diziler, gürültü giderimi, sinyal kestirimi, sistem modelleme, kanal dengeleme ve yankı giderimi gibi çok geniş bir uygulama alanı vardır [2].

Doğrusal kestirim, bir ayrık zamanlı işaretin, daha önceki örneklerinin doğrusal bir birleşimi olarak ifade edilmesidir. Doğrusal kestirimden türetilen doğrusal kestirim kodlaması (LPC), konuşma tanıma ve konuşma kodlama gibi uygulamalarda sıklıkla kullanılır. Diğer yandan, sistem analizinde bir matematiksel modelleme tekniği olarak görülmektedir. Nörofizikte ve jeofizikte de pek çok uygulamaları mevcuttur [3].

Uyarlanır süzgeçlerde kullanılabilecek pek çok uyarlama algoritması geliştirilmiştir [4]. Hata yüzeyi tek modlu ve kuadratik olan problemler için türeve dayalı yaklaşımlar oldukça başarılı olmaktadırlar. Ancak bu algoritmaların en önemli dezavantajları yakınsama hızlarının düşük olması ve adım büyüklüğü parametresine hassas olmalarıdır [5].

Bu problemlerin üstesinden gelebilmek için gelişime dayalı evrimsel optimizasyon algoritmaları kullanılabilir. Bu algoritmalardan birisi de, insanın bağışıklık sisteminden esinlenerek modellenen klonal seçme algoritmasıdır (KSA). Basit yapısı, her türlü probleme kolaylıkla uygulanabilirliği, parametrelere çok fazla bağımlı olmaması ve yüksek yakınsama hızı sayesinde süzgeç tasarımı gibi pek çok mühendislik probleminin çözümünde kullanılmaktadır [6,7].

2. Uyarlanır Süzgeçler ile Doğrusal Kestirim

Doğrusal kestirim modelinin en genel gösterim şekli aşağıdaki gibidir:

$$\hat{x}(n) = -\sum_{i=1}^{p} a_i x(n-i) \tag{1}$$

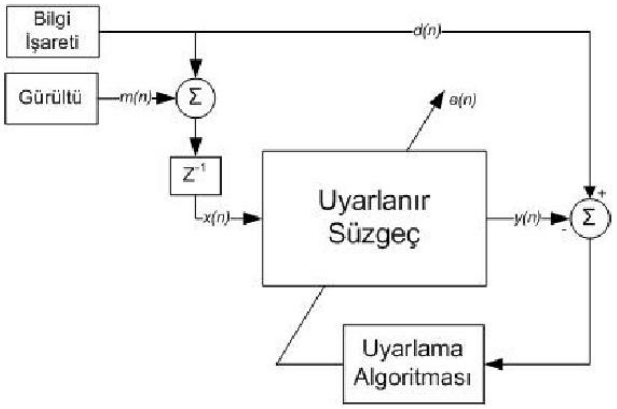
burada, $\hat{x}(n)$ kestirilen işaretin değeri, $x(n-i)$ bilgi işaretinin önceki gözlenen değerleri ve a_i kestirim katsayılarıdır. Bu tahmin sonucu elde edilen hata değeri; $e(n) = x(n) - \hat{x}(n)$ şeklinde bulunur. Burada $x(n)$ işaretin gerçek değeridir [3].

Doğrusal kestirim modeli, bir sonlu darbe cevaplı (FIR) sistemi temsil etmektedir. Tek modlu hata yüzeyine sahip olmaları ve sürekli kararlı olmalarından dolayı FIR uyarlanır süzgeçler, uygulamalarda sıkça tercih edilmektedirler. Bu yüzden doğrusal kestirim modelinde herhangi bir FIR tipi uyarlama algoritması kullanılabilir. FIR süzgeçlerin genel ifadesi şu şekildedir:

$$y(n) = \sum_{k=1}^{M} w_k x(n-k) \tag{2}$$

burada; $x(n)$ ve $y(n)$ sırasıyla süzgecin giriş ve çıkış işaretleridir. Uyarlanır süzgeç ile doğrusal kestirim modeli Şekil 1'de gösterilmiştir.

Authorized licensed use limited to: Kayseri University. Downloaded on November 24,2020 at 13:59:23 UTC from IEEE Xplore. Restrictions apply.



Şekil 1: Uyarlanır süzgeç ile doğrusal kestirim.

Bu süzgecin tasarımı, aşağıda verilen *J*(w) maliyet fonksiyonunun minimize edilmesi problemi olarak düşünülebilir:

$$J(w)=E[\,|e(n)|^2\,] \quad (3)$$

burada; $w=[w_1 w_2 ... w_p]^T$ süzgeç katsayı vektörünü, E beklenen değeri ve *e*(*n*) arzu edilen işaret ile süzgeç çıkışının farkı olan hata işaretini belirtmektedir.

Ortalama karesel hatayı (Mean Squared Error-MSE) minimize edecek şekilde, her bir iterasyonda süzgeç ağırlıklarını güncellemek için kullanılacak olan adaptasyon algoritmasının seçimi, uygulamanın performansı açısından son derece önemlidir. En küçük ortalama kareler (EKOK-LMS), Normalize EKOK (NLMS) ve özyinelemeli ortalama kareler (RLS) gibi türev tabanlı algoritmalar uyarlanır süzgeçlerde yaygın şekilde kullanılmaktadır [4].

Doğrusal kestirim probleminin uyarlanır süzgeç yapısı ile çözümünde, arzu edilen işaret olarak mevcut bilgi işareti süzgece verilmekte ve giriş işareti olarak da arzu edilen işaretin gecikmiş hali verilmektedir. Burada daha gerçekçi bir modelleme yapabilmek için gecikmiş işaretin üzerine beyaz Gauss gürültüsü de eklenir. Uyarlanır süzgeç, uyarlama algoritması ile süzgeç katsayılarının en uygun değerlerini bularak işaretin gecikmiş ve gürültülü halinden işaretin kendisini kestirir.

3. En Küçük Ortalama Kareler Yöntemi

En küçük ortalama kareler algoritması, süzgecin sadece ilgili andaki hataya göre uyarlanmasıyla elde edilen stokastik gradyent azaltım tabanlı bir yöntemdir. Basitliği ve donanımsal olarak kolay uygulanabilirliği sayesinde halen pek çok uygulamada tercih edilmektedir.

Çalışmada kullanılan EKOK algoritmasının temel adımları şu şekildedir:

1. $\hat{w}(0)=0$
2. n=0,1,2,… için;
   a. $u(n)=[x(n),x(n-1),...,x(n-p)]^T$
   b. $e(n)=d(n)-\hat{w}^T(n)u(n)$
   c. $\hat{w}(n+1)=\hat{w}(n)+\mu e(n)u(n)$
   d. $\breve{e}(n)=d(n)-\hat{w}^T(n+1)x(n)$
   e. $MSE(n)=E[\breve{e}(n)^2]$

burada; *p* süzgeç katsayı sayısını, μ adım büyüklüğünü, *x(n)* giriş işaretini ve *d(n)* arzu edilen işareti belirtmektedir. EKOK algoritmasının başarımı büyük ölçüde seçilen adım büyüklüğününe bağlıdır. Öğrenme eğrisini oluşturmak amacıyla MSE her bir iterasyonda elde edilen katsayıların kullanılması ile elde edilen hata işaretinden hesaplanmıştır.

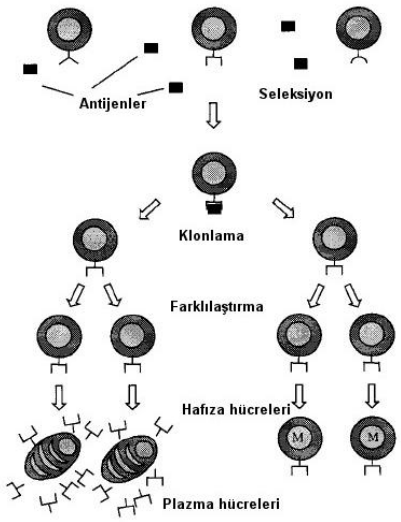
4. Klonal Seçme Algoritması

Klonal seçme prensibi [8], antijen uyarılarına karşı bağışıklık cevabının temel özelliklerini açıklamak için kullanılır. Bu prensibe göre sadece antijenleri tanıyan hücreler çoğalmak üzere seçilir. Seçilen bu hücreler, seçici antijenlere olan benzerliklerini artırmak için benzerlik olgunlaşması işlemine (affinity maturation process) tabi tutulur.

Vücutta bir antijen tespit edildiği zaman, bu antijenler kemik iliğinden üretilen antikorlarla (*Ab*) karşılanırlar. Her bir hücrede antijene özel olan bir antikor türü gizlidir. Antijen, antikorlara bağlanır ve *T* yardımcı hücrelerinden aldığı sinyalle *B* hücrelerini, bölünmeleri ve plazma hücreleri denilen antikor salgılayan hücrelere dönüşmesi için uyarır. Hücre bölünmesi süreci bir klon oluşturur, tek bir hücreden bir hücre veya hücreler kümesi oluşturulabilir. Plazma hücreleri antikor salgılama işleminde aktif iken, çok hızlı bölünen *B* lenfositleri de daha düşük bir hızla antikor salgılar. Diğer taraftan *T* hücreleri, *B* hücre cevabının yönetilmesinde merkezi bir rol oynar ve hücre dolaylı bağışıklık cevabında üstündürler.

Lenfositler, çoğalma ve plazma hücrelerine dönüşmeleri dışında, uzun ömürlü *B* hafıza hücrelerine de dönüşebilirler. Hafıza hücreleri kan, lenf ve dokular boyunca yayılır ve ikinci kez bir antijene maruz kaldığında, ilk cevap sırasında uyarılmış ve antijene özel olarak önceden seçilmiş yüksek benzerlikli antikor üretme kabiliyeti olan büyük lenfositlere dönüşmeye başlarlar.

Klonal seçim mekanizması, negatif seçimin rolünü tamamlayıcı olarak, bir "nonself" hücre, bir "*B*" hücresi tarafından tanındığı zaman nasıl bir bağışıklık tepkisi verileceğini açıklamak için kullanılmaktadır. Şekil 2. klonal seçim mekanizmasını göstermektedir [9].



Şekil 2: Klonal seçme prensibi.

Authorized licensed use limited to: Kayseri University. Downloaded on November 24,2020 at 13:59:23 UTC from IEEE Xplore. Restrictions apply.

Algoritmanın (CLONALG) temel adımları şu şekildedir:

1. Rastgele bir başlangıç popülasyonu üret (Ab).
2. Popülasyondaki tüm bireyleri amaç fonksiyonunda yerine koy ve uygunluk değerlerini hesapla.
3. Amaç fonksiyon değerlerine göre en iyi n adet bireyi seç (Ab_n).
4. Seçilen n adet bireyi klonla (C).
5. Klonların popülasyonuna hiper-mutasyon işlemi uygula ve olgunşamış popülasyonu oluştur (C^*).
6. Klonların popülasyonu için amaç fonksiyon değerlerini bul ve en iyi n adet bireyi seç ve popülasyonun düşük benzerlikli bireyleriyle yer değiştir.
7. Farklılaşmayı sağlamak için popülasyonun düşük benzerlikli d adet bireyini yeni üretilmiş bireylerle değiştir.

Öncelikle rastgele üretilen hücrelerden bir başlangıç popülasyonu oluşturumaktadır. Her bir hücre muhtemel bir çözümü, antijen de problemi temsil etmektedir. Hücreler ikili bit dizilerinden oluşurlar ve bit dizilerinin uzunluğu istenen hassasiyete göre seçilmektedir. Ardından, popülasyondaki her hücreye ait hata fonksiyonu değeri (uygunluk) hesaplanır ve hücreler uygunluk değerlerine göre sıralanır. En düşük uygunluk değerine sahip n tane hücre seçilir ve sonra uygunluk değerleri ile orantılı olarak klonlanır. Seçilen n tane hücrenin her biri için oluşturulan klon sayısı,

$$N_c = \sum_{i=1}^{n} round\left(\frac{\beta N}{i}\right) \qquad (4)$$

ile verilmektedir. Burada, N_c her bir birey için oluşturulacak klon büyüklüğü, N popülasyon büyüklüğü ve β ise çarpım faktörüdür. Oluşturulan klonlar, uygunluk değerleri ile ters orantılı olarak mutasyona uğrarlar. Daha sonra mutasyona uğratılmış (olgunlaşmış) klonların uygunluk değerleri hesaplanır. Seçilen her bir hücre ve klonları bir alt popülasyon oluşturur. Her bir alt popülasyonun en düşük uygunluk değerine sahip hücresi seçilir ve yaşamasına izin verilir. Popülasyonun en yüksek uygunluk değerlerine sahip d tane hücresi rastgele üretilen hücrelerle değiştirilir. Böylelikle popülasyondaki farklılaşma sağlanmış olur. Bu işlemler durdurma ölçütü sağlanana kadar devam eder [9].

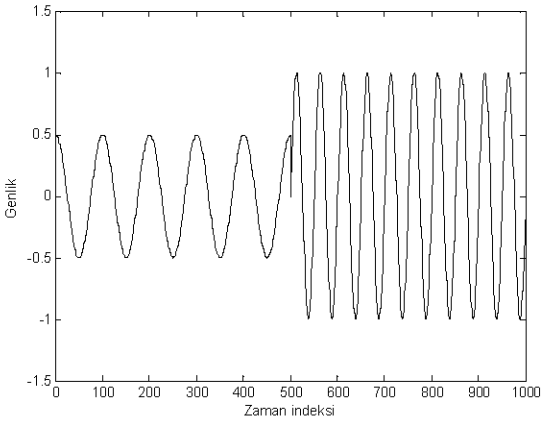
5. Benzetim Sonuçları

Çalışmada iki farklı benzetim yapılmıştır. İlk benzetimde, EKOK ve KSA'nın doğrusal kestirim uygulamasındaki başarım karşılaştırmaları, ikinci benzetimde ise KSA'nın parametrelerinin sonuca etkileri irdelenmiştir. Yapılan çalışmalarda, gürültü eklenmiş sinusodial bir bilgi işaretinin o anki değeri, geçmiş p adet değeri kullanılarak, p-1. dereceden bir uyarlanır süzgeç ile kestirilmiştir. Arzu edilen işaret 0.01 çevrim/örnek kosinüs işareti ve 0.02 çevrim/örnek sinüs işaretinin birleşiminden oluşan 1000 örneklik bir veridir. Uyarlanır süzgecin girişi, arzu edilen işaretin geciktirilmiş ve 0.5 varyanslı beyaz Gauss gürültüsü eklenmiş halidir.

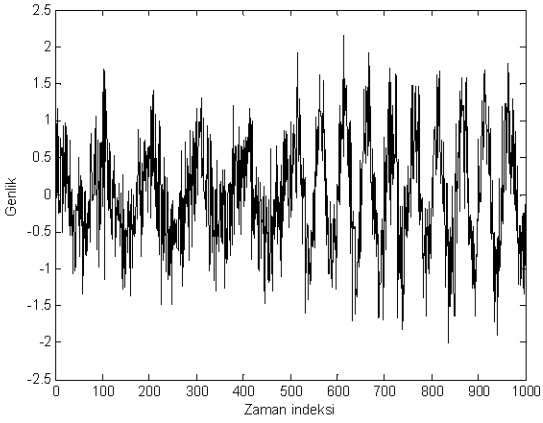
5.1. Benzetim #1

Bu benzetim uygulamasında, 31. dereceden bir uyarlanır FIR süzgeç ile doğrusal kestirim yapılmıştır. Benzetimlerde iterasyon sayısı 1000 olarak alınmıştır. EKOK yöntemi için adım büyüklüğü μ=0.01, KSA için popülasyon büyüklüğü N=50, β=0.1 ve hiper-mutasyon oranı 0.01 olarak alınmıştır.

Çalışmalarda kullanılan bilgi işareti (arzu edilen işaret) Şekil 3'de ve bilgi işaretinin bir birim geciktirilmiş ve gürültü eklenmiş hali Şekil 4'de verilmiştir.

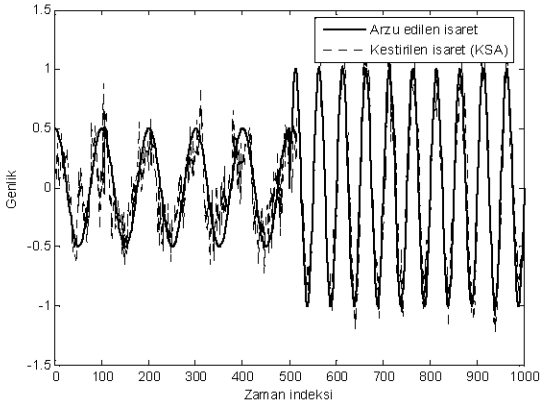


Şekil 3: Bilgi işareti *d(n)*.



Şekil 4: Uyarlanır süzgeç için giriş işareti *x(n)*.

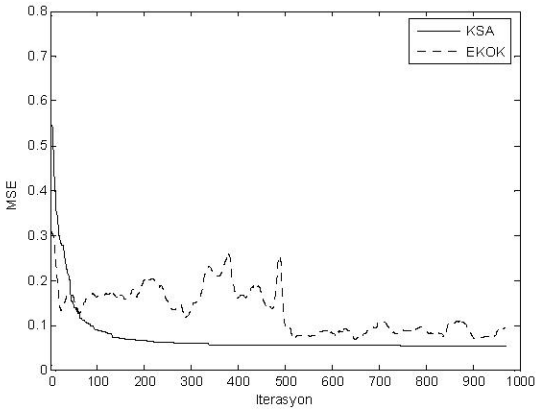
KSA tabanlı uyarlanır süzgeç tarafından, en son iterasyonda elde edilen optimum süzgeç katsayıları kullanılarak elde edilen sonuçlar Şekil 5 ile verilmiştir.



Şekil 5: Arzu edilen işaret *d(n)* ve KS tabanlı uyarlanır süzgecin çıkışı *y(n)* (kestirilen işaret).

Authorized licensed use limited to: Kayseri University. Downloaded on November 24,2020 at 13:59:23 UTC from IEEE Xplore. Restrictions apply.

Şekil 6'da ise EKOK ve KSA tabanlı yöntemlerin MSE performans karşılaştırmaları verilmiştir.



Şekil 6: MSE başarım eğrileri.

Görüldüğü gibi KSA, minimum hata değerine daha hızlı bir şekilde yakınsamıştır.

5.2. Benzetim #2

KSA'nın parametrelerinin çözüm üzerine etkisini incelemek amacıyla çeşitli hiper-mutasyon oranlarına karşılık farklı derecelerden uyarlanır FIR süzgeçler kullanılarak aynı problem için doğrusal kestirim yapılmıştır. Sonuçların istatistiksel olarak anlamlı olabilmesi için algoritma 30 kez koşulmuştur. Her bir koşmada, bilgi işaretine 0.5 varyanslı rastgele bir beyaz Gauss gürültüsü eklenmiştir. Yapılan benzetimlerde KSA için popülasyon büyüklüğü N=50 ve iterasyon sayısı 500 olarak alınmıştır. Koşmalar sonucunda elde edilen MSE değerlerinin ortalaması "Koşma Ortalaması" olarak standart sapmaları ile verilmiştir.

Tablo 1: Süzgeç derecesinin ve hiper-mutasyon oranının KSA tabanlı uyarlanır süzgeç yapısının başarımına etkisi.

			Süzgeç katsayı sayısı (p)			
			4	8	16	32
Hiper-mutasyon Oranı	0.005	Koşma Ort.	0,076202	0,076	0,065133	0,060212
		Std. Sapma	0,008609	0,009200	0,007660	0,008069
	0.01	Koşma Ort.	0,076137	0,074419	0,061018	0,055337
		Std. Sapma	0,007582	0,006585	0,005438	0,005573
	0.02	Koşma Ort.	0,07377	0,072089	0,059505	0,058732
		Std. Sapma	0,006919	0,006224	0,005969	0,006855
	0.05	Koşma Ort.	0,071344	0,070238	0,059996	0,15207
		Std. Sapma	0,005964	0,005324	0,005538	0,019576

KSA tabanlı uyarlanır FIR süzgecin katsayı sayısı arttıkça başarımının arttığı gözlemlenmiştir. Ayrıca katsayı sayısı p=32, hiper-mutasyon oranı 0.01 olduğu durumda da en düşük MSE değerine erişildiği görülmektedir. Koşmalardaki erişilen MSE değerlerinin standart sapmalarının düşük olması, önerilen KSA tabanlı yaklaşımın her koşmada tutarlı bir sonuç elde ettiğini göstermektedir.

6. Sonuç

Bu çalışmada, KSA tabanlı uyarlanır süzgeç ile işaretlerin doğrusal kestirimi gerçekleştirilmiştir ve önerilen yapının başarımı EKOK yöntemi ile karşılaştırılmıştır. Gerçekleştirilen çalışmada, gelişime dayalı, evrimsel bir küresel optimizasyon algoritması olan KSA'nın uyarlanır süzgeçler ile doğrusal kestirimde EKOK yöntemine göre yakınsama hızının daha iyi olduğu ve daha küçük MSE değerlerine ulaştığı görülmüştür. Ayrıca, önerilen yaklaşımın kararlı bir yapıya sahip olduğu da gözlemlenmiştir.

7. Kaynakça

[1] Neubauer, A., "Non-linear adaptive filters based on genetic algorithms with applications to digital signal processing", *IEEE International Conference on Evolutionary Computation,* Vol. 2, 527 – 532, 1995.

[2] Morgan, D.R., Thi, J.C.; "A delayless subband adaptive filter architecture", *IEEE Transactions on Signal Processing*, Vol. 43 (8), 1819 – 1830, 1995.

[3] Makhoul, J., "Linear prediction: A tutorial review" *Proceedings of the IEEE*, Vol. 63 (4), 561 – 580, 1975.

[4] Prandoni, P., Vetterli, M.;"An FIR cascade structure for adaptive linear prediction", *IEEE Transactions on Signal Processing*, Vol. 46 (9), 2566 – 2571, 1998.

[5] Ng, S.C., Leung, S.H., Chung, C.Y., Luk, A., Lau, W.H., "The Genetic Search Approach", *IEEE Signal Processing Magazine*, 38-46, 1996.

[6] Kalinli A, Karaboga N, "Artificial immune algorithm for IIR filter design", *Engineering Applications of Artificial Intelligence,* Vol. 18 (8), 919–929 2005.

[7] Tsai, J.-T., Chou, J.-H.,Design of Optimal Digital IIR Filters by Using an Improved Immune Algorithm, *IEEE Transactions on Signal Processing*, Vol. 54 (12), 4582 – 4596, 2006.

[8] Ada, G. L., and Nossal, G., "The clonal selection theory", *Scientific American*, Vol. 257, 50–57, 1987.

[9] De Castro, L. N., and Von Zuben, F. J., "Learning and optimization using the clonal selection principle", *IEEE Transactions on Evolutionary Computation,* Vol. 6, 239–251, 2002.

Authorized licensed use limited to: Kayseri University. Downloaded on November 24,2020 at 13:59:23 UTC from IEEE Xplore. Restrictions apply.