

UMA ABORDAGEM EVOLUTIVA BASEADA EM MODELOS CAÓTICOS DE BUSCA ASSOCIADO AO ALGORITMO DE EVOLUÇÃO DIFERENCIAL

Fran Sérgio Lobato

franpi22@yahoo.com.br

Faculdade de Engenharia Mecânica

Valder Steffen Jr

vsteffen@mecanica.ufu.br

Faculdade de Engenharia Mecânica

Luís Cláudio Oliveira-Lopes

lcol@ufu.br

Faculdade de Engenharia Química

Universidade Federal de Uberlândia

Campus Santa Mônica - 38.400-902

Resumo: Os parâmetros de entrada de quaisquer métodos evolutivos são valores constantes durante todo o processo de otimização e afetam a convergência na resolução dos problemas. Esta característica pode fazer com que os métodos evolutivos rapidamente encontrem uma região associada ao ótimo, o que não necessariamente garante que outras regiões do espaço de busca sejam exploradas. Neste sentido, este trabalho propõe uma abordagem evolutiva resultante da associação do Algoritmo de Evolução Diferencial com Modelos Caóticos de Busca para obter parâmetros auto-adaptativos, com a finalidade de introduzir diversidade na população e prevenir convergência prematura. Os resultados obtidos com o algoritmo proposto são comparados com outras abordagens.

Palavras-chave: Evolução Diferencial, Parâmetros Auto-Adaptativos, Modelos Caóticos de Busca.

1. INTRODUÇÃO

O comportamento de sistemas caóticos pode ser observado em diferentes campos da ciência tais como a engenharia, a medicina, a ecologia, a biologia e economia. Matematicamente o caos pode ser entendido como um gerador randômico obtido através de sistemas determinísticos (Tavazoei e Haeri, 2007). No contexto de otimização estocástica, consegue-se escapar de um ótimo local por aceitar uma solução não tão boa de acordo com certa probabilidade de mutação. Nos algoritmos de otimização com busca caótica a convergência prematura é prevenida através do movimento caótico incorporado pelos modelos (Li e Jiang, 1998).

Segundo Yang *et al.* (2007), a idéia básica de um algoritmo de otimização baseado em um modelo caótico de busca é a de primeiramente definir um gerador de caos baseado em alguma relação matemática (conhecida como mapa caótico). De posse desse gerador, uma sequência de pontos caóticos é gerada dentro do espaço de projeto e estes são avaliados segundo a função objetivo. O melhor ponto é tomado como sendo o ótimo. Durante esse processo são realizadas pequenas perturbações nesse ponto com o intuito de melhorá-lo.

O uso de modelos baseados em caos acoplados a abordagens determinísticas e não-determinísticas vem ganhando espaço devido à incorporação de diversidade e a capacidade de prevenção de convergência prematura que esses acrescentam aos métodos evolutivos (Coelho e Mariani, 2006). Dentre os trabalhos mais recentes, pode-se citar o trabalho de Coelho e Mariani (2006), que faz uso de modelos caóticos associados a um algoritmo híbrido que usa Evolução Diferencial e Programação Quadrática Sucessiva. Já em Tavazoei e Haeri (2007) é realizado um estudo sobre o desempenho de diferentes modelos caóticos de busca quando estes são incorporados a abordagens clássicas de otimização. Yang *et al.* (2007) propõem combinações entre o Método de Monte Carlo, o Algoritmo Clássico BFGS (Broyden-Fletcher-Goldfarb-Shanno) (Vanderplaats, 1999) e alguns modelos caóticos para formar algoritmos híbridos que são aplicados a um conjunto de funções matemáticas teste. Uma versão híbrida do Algoritmo de Enxame de Partículas com a incorporação de Mapas Logísticos pode ser encontrada em Alatas *et al.* (2007). Nesta linha de atuação, Coelho e Mariani (2007) aplicaram o Algoritmo de Colônia de Formigas com Mapas Logísticos em dois problemas de projeto de engenharia.

O objetivo deste trabalho é o uso de modelos com dinâmica caótica para introduzir diversidade na população e prevenir convergência prematura do Algoritmo de Evolução Diferencial. Este trabalho está estruturado como segue: na Seção 2 são apresentados alguns modelos caóticos de busca. A Seção 3 apresenta a concepção do Algoritmo de Evolução Diferencial. Já nas Seções 4 e 5 é descrita a metodologia proposta e mostrado um estudo de caso, respectivamente. Finalmente, as conclusões e sugestões para trabalhos futuros são apresentadas na Seção 6.

2. MODELOS CAÓTICOS DE BUSCA

Dentro do contexto dos modelos caóticos de busca, os mapas de busca uni-dimensionais são sistemas simples que tem a capacidade de geração de movimento caótico (Ott, 2002). A seguir são apresentados alguns desses modelos.

2.1 Mapa Logístico

Esse é um dos modelos mais utilizados para ilustrar comportamentos caóticos que surgem em equações dinâmicas não lineares. O Mapa Logístico é definido pela relação (Ott, 2002):

$$x_{n+1} = \mu x_n (1 - x_n) \text{ para } 3,57 \leq \mu \leq 4 \quad (1)$$

2.2. Mapa Seno

Esse mapa tem qualitativamente a mesma forma do Mapa Logístico (Devaney, 1987):

$$x_{n+1} = \frac{\mu}{4} \sin(\pi x_n) \text{ para } 0 \leq \mu \leq 4 \quad (2)$$

2.3. Mapa de Zaslavskii

O Mapa de Zaslavskii é um modelo de dinâmica caótico que mapeia o ponto (x_n, y_n) no plano para um novo ponto. Este é descrito conforme a equação a seguir:

$$\begin{aligned} x_{n+1} &= (x_n + v + a y_{n+1}) \bmod(1) \\ y_{n+1} &= \cos(2\pi x_n) + e^{-r} y_n \end{aligned} \quad \text{para } v = 400, r = 3 \text{ e } a = 12 \quad (3)$$

O operador $z_1 \bmod z_2$ é o resto da divisão de z_1 por z_2 . Além disso, é importante destacar que $y_{n+1} \in [-1,0512 \ 1,0512]$, e dessa forma, esses valores devem ser normalizados para a faixa de interesse.

3. O ALGORITMO DE EVOLUÇÃO DIFERENCIAL

O Algoritmo de Evolução Diferencial (ED) foi proposto por Storn e Price (1995) para problemas de otimização. Aplicações em várias áreas podem ser encontradas, tais como: a solução de Problemas de Controle Ótimo (Chiou e Wang, 1999); o projeto de sistemas mecânicos (Oliveira, 2006), a otimização de estruturas veiculares (Oliveira *et al.*, 2007). No contexto da otimização multi-objetivo, podem-se citar: otimização de um reator adiabático industrial (Babu *et al.*, 2005), aplicação em um problema de controle ótimo (Lobato *et al.*, 2007), projeto de sistemas mecânicos (Lobato e Steffen, 2007) entre outras aplicações (Storn *et al.*, 2005).

De maneira resumida, nessa abordagem estrutural o valor de cada variável é representado por um valor real (ponto flutuante) e a geração de candidatos é feita através do uso de operações vetoriais como apresentado e detalhado a seguir:

Algoritmo de Evolução Diferencial

```

Inicializar e avaliar a população  $P$ 
enquanto nenhum critério de parada for satisfeito faça {
  para ( $i = 0$  ;  $i < N$  ;  $i++$ ) {
    Rotina Candidato  $C[i]$ 
    Avalie o candidato  $C[i]$ 
    se ( $C[i]$  é melhor que  $P[i]$ )
       $P'[i] = C[i]$ 
    senão
       $P'[i] = P[i]$ 
  }
   $P = P'$ 
}

```

em que N é o tamanho da população, P é a população da geração atual, e P' é a população da próxima geração. O procedimento para a criação do candidato (Candidato $C[i]$) é mostrado a seguir:

Candidato $C[i]$

```

Randomicamente selecione os pais  $P[i_1]$ ,  $P[i_2]$  e  $P[i_3]$ , onde  $i$ ,  $i_1$ ,  $i_2$  e  $i_3$  são diferentes.
Geração do candidato:  $C_1[i] = P[i_1] + F \times (P[i_2] - P[i_3])$ .
 $C[i]$  por cruzamento dos genes de  $P[i]$  e  $C_1[i]$  como segue:
para ( $j = 0$  ;  $j < N$  ;  $j++$ ) {
  se ( $r < CR$ )
     $C[i][j] = C_1[i][j]$ 
  senão
     $C[i][j] = P[i][j]$ 
}

```

onde $C[i]$ é a solução candidata i da população, $C[i][j]$ é o j -th entrada no vetor solução de $C[i]$, r é um número randômico entre 0 e 1, CR é a probabilidade de cruzamento e F a taxa de perturbação.

O algoritmo implementado por Storn e Price (Storn e Price, 1995) possibilita ao usuário a escolha do tipo de estratégia que será utilizada durante o processo evolutivo. A Tabela 1 mostra as possíveis estratégias que podem ser adotadas.

Tabela 1: Estratégias propostas por Storn e Price (1995).

1 - DE/best/1/exp	6 - DE/best/1/bin
2 - DE/rand/1/exp	7 - DE/rand/1/bin
3 - DE/rand-to-best/1/exp	8 - DE/rand-to-best/1/bin
4 - DE/best/2/exp	9 - DE/best/2/bin
5 - DE/rand/2/exp	10 - DE/rand/2/bin

A convenção geral usada é DE/x/y/z. DE para Evolução Diferencial (*Differential Evolution*), x representa o vetor que será perturbado, y é o número de vetores que são utilizados para a perturbação de x, e z representa o tipo de cruzamento que será utilizada (exp=exponencial; bin=binomial).

A escolha dos valores dos parâmetros NP , F , CR não é uma tarefa trivial e depende de cada problema. Storn e Price (Storn e Price, 1995) normalmente aconselham o uso de NP em torno de 5 a 10 vezes o número de variáveis do problema, F como sendo um valor entre 0,4 a 1,0 e CR igual a 0,1, mas em geral CR poderá ser tão grande quanto possível. Recentemente, Oliveira (2006) mostrou que, para os estudos de casos apresentados em seu trabalho, F e CR devem estar compreendidos entre 0,4 e 0,8.

4. A METODOLOGIA PROPOSTA

Como destacado anteriormente, uma das principais dificuldades encontradas na utilização de Métodos Determinísticos ou Não-Determinísticos, é a definição do valor dos parâmetros que serão usados no processo de otimização. Por exemplo, na abordagem clássica, a definição do valor do parâmetro de penalidade é uma das principais questões, pois um valor muito baixo desse parâmetro pode fazer com que as restrições não sejam satisfeitas e, em contrapartida, um fator de penalidade muito alto pode provocar problemas numéricos como rigidez (Vanderplaats, 1999). No contexto evolutivo, apesar de existirem inúmeros trabalhos que usam valores padronizados (*default*) na literatura para uma grande variedade de aplicações, a utilização de parâmetros constantes ao longo do processo evolutivo pode não garantir a diversidade da população ou prevenir convergência prematura (Coelho e Mariani (2006), Tavazoei e Haeri (2007), Yang *et al.* (2007)).

Neste sentido, este trabalho propõe a utilização de modelos de busca caóticos apresentados na Seção 2 para atualizar os valores da taxa de perturbação F e da probabilidade de cruzamento CR . Isto é realizado, por exemplo, usando o Mapa Logístico descrito na Seção 2.1:

$$\begin{aligned} F_{n+1} &= \mu F_n (1 - F_n) \\ CR_{n+1} &= \mu CR_n (1 - CR_n) \end{aligned} \quad (4)$$

onde F_{n+1} e CR_{n+1} são os valores atualizados desses parâmetros na geração $n+1$ a partir do valor *padrão* da literatura. Dessa forma, esses parâmetros são atualizados a cada geração segundo um modelo que introduz diversidade a esses parâmetros e por consequência ao processo evolutivo.

Foram propostos 3 versões do Algoritmo de Evolução Diferencial com o acoplamento de modelos caóticos: o **EDMC(1)**, o **EDMC(2)** e o **EDMC(3)**, que usam o Mapa Logístico, o Mapa Seno e o Mapa de Zaslavskii, respectivamente. Com o intuito de comparar a abordagem proposta, foi utilizado o **EDrand**, que simplesmente atualiza os valores de F e de CR de forma randômica e o **ED** que é o Algoritmo de Evolução Diferencial original.

5. ESTUDO DE CASO

Considere o problema da viga engastada como apresentado na Figura 1 (Vanderplaats, 1999). Deseja-se obter a espessura (b_i) e a altura (h_i) da viga em cada um de seus N ($N=5$) segmentos de tal forma a minimizar o seu volume.




Figura 1: Viga Engastada.

A deflexão y_i , no final do lado direito de cada segmento i , é calculado pela seguinte fórmula recursiva:

$$y_0 = y'_0 = 0 \quad (5)$$

$$y'_i = \frac{Pl_i}{EI_i} \left[L + \frac{l_i}{2} - \sum_{j=1}^i l_j \right] + y'_{i-1} \quad (6)$$

$$y_i = \frac{Pl_i^2}{2EI_i} \left[L - \sum_{j=1}^i l_j + \frac{2l_i}{3} \right] + y'_{i-1}l_i + y_{i-1} \quad (7)$$

onde y'_i é a derivada de y com relação a inclinação x , e l_i é o comprimento do segmento i . O módulo de Young E é o mesmo para todos os segmentos e o momento de inércia para o segmento i é dado por:

$$I_i = \frac{b_i h_i^3}{12} \quad (8)$$

A tensão máxima permitida para essa estrutura é dada por:

$$\sigma_i = \frac{h_i}{2l_i} \left[P \left[L + l_i - \sum_{j=1}^i l_j \right] \right] \quad (9)$$

Dessa forma o problema de otimização pode ser resumido como descrito a seguir:

$$\min V = \sum_{i=1}^N b_i h_i l_i \quad (10)$$

sujeito a:

$$\frac{\sigma_i}{\sigma_{\max}} - 1 \leq 0 \quad i = 1, \dots, N \quad (11)$$

$$h_i - 20b_i \leq 0 \quad i = 1, \dots, N \quad (12)$$

$$\frac{y_N}{y_{\max}} - 1 \leq 0 \quad (13)$$

$$1 - b_i \leq 0 \quad i = 1, \dots, N \quad (14)$$

$$5 - h_i \leq 0 \quad i = 1, \dots, N \quad (15)$$

Neste estudo de caso, existem $N+1$ restrições não-lineares, N restrições lineares e $2N$ restrições de canto para as variáveis de projeto.

Os parâmetros do problema são (Vanderplaats, 1999): $\sigma_{\max}$ é tensão máxima permitida (14000 N/cm²), $y_{\max}$ é o deslocamento máximo permitido (2,5 cm), o módulo de *Young* E é $2,0 \times 10^7$ N/cm², a carga P é 50,000 N, o comprimento L é 500 cm ($l_i = L/N$).

Vanderplaats (1999) resolveu esse problema usando o Método do Multiplicador de Lagrange Aumentado com 7 iterações e com 582 avaliações da função objetivo. Já em cada um dos algoritmos evolutivos foram necessárias 9030 avaliações da função objetivo usando 30 indivíduos, 300 gerações, F igual a 0,6 e CR igual a 0,8. Para os métodos **EDMC(1)** ($\mu=3,57$), **EDMC(2)** ($\mu=4$) e **EDMC(3)** ($v=400$, $r=3$ e $a=12$) esses valores de F e CR são as condições iniciais para a atualização desses parâmetros. No **EDrand**, F e CR são números randômicos pertencentes ao intervalo (0,1).

Nesse trabalho definiu-se o parâmetro de comparação *Sucesso* como a quantidade de vezes que o algoritmo evolutivo consegue, no mínimo, melhorar o resultado tomado como sendo referência, neste caso o trabalho de Vanderplaats (1999). Deve ser destacado que cada um dos métodos evolutivos foi resolvido 20 vezes utilizando o Método de Penalidade Interior (Vanderplaats, 1999) com fator de penalidade igual a 10^{10} para o tratamento das restrições de desigualdade.

Os resultados obtidos pelas abordagens propostas e os respectivos atendimentos das restrições de desigualdade são apresentados nas Tabelas 2 e 3.

Tabela 2: Comparação entre as melhores soluções obtidas por cada abordagem.

Variável	Vanderplaats (1999)	ED	EDrand	EDMC(1)	EDMC(2)	EDMC(3)
h_1	62,23	62,522736	62,681494	62,681092	62,595270	62,479577
h_2	57,88	57,618901	57,637254	57,925503	57,677451	57,809943
h_3	51,79	51,675809	51,609363	51,248345	51,651264	51,618033
h_4	44,17	44,232734	44,098774	44,139805	44,098103	44,123046
h_5	34,97	34,990692	34,995465	34,989173	34,994618	35,022872
b_1	3,11	3,126818	3,134099	3,134078	3,130658	3,126904
b_2	2,91	2,881777	2,881879	2,896506	2,883992	2,890513
b_3	2,59	2,587360	2,580492	2,564782	2,585820	2,581087
b_4	2,21	2,215480	2,204962	2,207418	2,205431	2,206936
b_5	1,75	1,750888	1,749838	1,751860	1,750421	1,751211
f	65465	65450,7521	65420,3679	65440,0982	65437,7169	65440,7846
<i>Sucesso (%)</i>	-	65	87	100	100	100

Tabela 3: Atendimento das restrições de desigualdade.

Variável	Vanderplaats (1999)	ED	EDrand	EDMC(1)	EDMC(2)	EDMC(3)
g_1	-0,111000	-0,123434	-0,129895	-0,129878	-0,126537	-0,122247
g_2	-0,119000	-0,104093	-0,104695	-0,118060	-0,106598	-0,112695
g_3	-0,075000	-0,069572	-0,064691	-0,045657	-0,068132	-0,065221
g_4	-0,005000	-0,011293	-0,000532	-0,003499	-0,000714	-0,002524
g_5	0,001000	-0,000392	-0,000065	-0,000860	-0,000350	-0,002412
g_6	0,000000	-0,013619	-0,000492	-0,000469	-0,017883	-0,058505
g_7	-0,022000	-0,016645	-0,000334	-0,004626	-0,002388	-0,000325
g_8	0,000000	-0,071400	-0,000471	-0,047297	-0,065138	-0,003701
g_9	0,002000	-0,076873	-0,000465	-0,008552	-0,010510	-0,015669
g_{10}	-0,003000	-0,027070	-0,001291	-0,048023	-0,013805	-0,001351
g_{11}	0,000000	-0,000020	-0,000001	-0,000021	-0,000101	-0,000083

É possível observar na Tabela 2 que apesar do elevado número de avaliações da função objetivo via métodos evolutivos, quando comparado com o Método dos Multiplicadores de Lagrange, conseguiu-se melhorar o valor da função objetivo em relação aquele obtido pelo método clássico utilizado. Além disso, observa-se na Tabela 3 o perfeito atendimento das restrições de desigualdade em todas as abordagens evolutivas.

O Método de Evolução Diferencial original (**ED**) consegue uma probabilidade de *Sucesso* de 65%, ou seja, quando se executa o algoritmo **ED** 20 vezes, em 13 das execuções conseguiu-se superar o ótimo obtido pela referência. Isto faz conjecturar que a utilização de F e CR constantes pode ser interessante, mas não garante que a solução seja alcançada toda vez que esse algoritmo é executado. Desta forma, foi utilizado o Método Evolução Diferencial Randômico (**EDrand**), que considera F e CR randômicos durante o processo evolutivo. Com isso, consegue-se aumentar a porcentagem de *Sucesso* (87%). Entretanto, com o uso do acoplamento entre o Método de Evolução Diferencial com modelos baseados em busca caóticos (**EDMC(1)**, **EDMC(2)** e **EDMC(3)**), conseguiu-se aumentar drasticamente, em comparação com o **ED**, a probabilidade de *Sucesso* (=100%).

6. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho objetivou a comparação entre o Algoritmo de Evolução Diferencial com e sem o acoplamento de modelos caóticos de busca.

A partir da análise dos resultados obtidos usando um estudo de caso clássico, podem-se destacar alguns pontos: a variação da taxa de perturbação e da probabilidade de cruzamento durante o processo evolutivo, independentemente da forma com que isso é feito, faz com a porcentagem de *Sucesso* durante o processo evolutivo aumente; o uso de modelos baseados em busca caóticas introduz ao algoritmo original de Evolução Diferencial uma maior diversidade na população, fazendo com que uma maior região de busca seja explorada, e que pode ser observado quando se analisa a probabilidade de *Sucesso* obtida por esses métodos. O mesmo não pode ser garantido quando se faz uso apenas de sua geração randômica.

Como sequência deste trabalho, pretende-se propor a utilização de outros modelos caóticos de busca caóticos ao algoritmo de Evolução Diferencial e a outras estratégias evolutivas. Além disso, pretende-se avaliar a incorporação desses modelos no contexto de otimização multi-objetivo. Considera-se que o problema de convergência prematura pode ser ainda mais dramático em aplicações complexas de engenharia, justificando plenamente o estudo empreendido.

7. AGRADECIMENTOS

Os autores agradecem o apoio da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo suporte financeiro deste trabalho através da bolsa de doutorado para o primeiro autor. O segundo autor agradece também ao CNPq por sua bolsa de produtividade em pesquisa.

8. REFERÊNCIAS

- Alatas, B., Akin, E. and Ozer, A. B., 2007, "Chaos Embedded Particle Swarm Optimization Algorithms". Chaos, Solutions and Fractals, *article in press*.
- Babu, B. V., Chakole, P. G. and Mubeen, J. H. S., 2005, "Multi-objective Differential Evolution (MODE) for Optimization of Adiabatic Styrene Reactor". Chemical Engineering Science, Vol. 60, pp 4822-4837.
- Chiou, Ji-Pyng and Wang, F. S., 1999, "Hybrid Method of Evolutionary Algorithms for Static and Dynamic Optimization Problems with Application to a Fed-Batch Fermentation Process". Computers and Chemical Engineering, v. 23, 1277-1291.
- Coelho, L. S. and Mariani, V. C., 2006, "Combining of Chaotic Differential Evolution and Quadratic Programming for Economic Dispatch Optimization with Valve-Point Effect". IEEE Transactions on Power Systems, Vol. 21, N 2, pp 989-996.
- Coelho, L. S. and Mariani, V. C., 2007, "Use of Chaotic Sequence in a Biologically Inspired Algorithm for Engineering Design Optimization". Expert Systems with Applications, *article in press*.
- Devanei, R. L., 1987, "An Introduction to Chaotic Dynamical Systems". Addison-Wesley.
- Li, B. and Jiang, W., 1998, "Optimization of Complex Functions by Chaos Search". International Journal of Cybernetics and Systems, Vol. 29 (4), pp 409-419.
- Lobato, F. S. and Steffen, V., 2007, "Engineering System Design with Multi-Objective Differential Evolution". 19th COBEM – International Congress of Mechanical Engineering.
- Lobato, F. S., Oliveira-Lopes, L. C., Murata, V. V. and Steffen, V., 2007, "Solution of Multi-Objective Optimal Control Problems with Fluctuation Index Using Differential Evolution". 6th DINCON – Brazilian Conference on Dynamics, Control and Their Applications.
- Oliveira, G. T. S., 2006, "Estudo e Aplicações da Evolução Diferencial". Dissertação de Mestrado, Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia.
- Oliveira, F. C. G., Viana, F. A. C., Borges, J. A. F. and Steffen, V., 2007, "Three-Dimensional Vehicular Structure Design Combining Finite Element Modeling and Numerical Optimization". 19th COBEM – International Congress of Mechanical Engineering.
- Ott, E., 2002, "Chaos in Dynamical Systems". Cambridge University Press, Cambridge, UK.
- Storn, R. and Price, K., 1995, "Differential Evolution: A Simple and Efficient Adaptive Scheme for Global Optimization over Continuous Spaces". Technical Report TR 95-012, International Computer Science Institute, Berkeley.
- Storn, R., Price, K. and Lampinen, J. A., 2005, "Differential Evolution - A Practical Approach to Global Optimization". Springer - Natural Computing Series.
- Tavazoei, M. S. and Haeri, M., 2007, "Comparison of Different One-Dimensional Maps as Chaotic Search Pattern in Chaos Optimization Algorithms". Applied Mathematics and Computation, Vol. 187, pp 1076-1085.
- Vanderplaats, G. N., 1999, "Numerical Optimization Techniques for Engineering Design". Colorado Springs, CO, Third Edition.
- Yang, D., Li, G. and Cheng, G., 2007, "On the Efficiency of Chaos Optimization Algorithms for Global Optimization". Chaos, Solutions and Fractals, Vol. 34, pp 1366-1375.

AN EVOLUTIONARY APPROACH BASED ON SEARCH CHAOTIC PATTERN ASSOCIATED TO DIFFERENTIAL EVOLUTION ALGORITHM

Fran Sérgio Lobato

franpi22@yahoo.com.br

School of Mechanical Engineering

Valder Steffen Jr

vsteffen@mecanica.ufu.br

School of Mechanical Engineering

Luís Cláudio Oliveira-Lopes

lcol@ufu.br

School of Chemical Engineering

Federal University of Uberlândia

Campus Santa Mônica - 38.400-902

Abstract: *The input parameters of any evolutionary methods are taken as constant values during the optimization process and affect the convergence of the problems. This characteristic, found in those methods, lead to fast convergence, which does not necessarily guarantee that other regions of the design space have been explored. In this sense, this work proposes an evolutionary approach resulting from the association of the Differential Evolution Algorithm with Search Chaotic Pattern to obtain self-adaptative parameters, aiming at introducing diversity in the population and to prevent premature convergence. The results obtained with the proposed algorithm are compared with those from other approaches.*

Keywords: *Differential Evolution, Self-Adpatative Parameters, Search Chaotic Pattern.*