



## PROBLEMA DE ALOCAÇÃO DE CONFIABILIDADE-REDUNDÂNCIA USANDO EVOLUÇÃO DIFERENCIAL AUTO-ADAPTATIVA

**Hellen Cristina Spengler**

**Gustavo Valentim Loch**

hspengler.mat@gmail.com

gustavo.gvalentim@gmail.com

Universidade Federal do Paraná

Campus III - Centro Politécnico - Av. Cel. Francisco H. dos Santos - 210 - Jardim das Américas  
- Curitiba, 81531-970, Paraná, Brasil

**Resumo.** *Esse trabalho considera a otimização não-linear inteira-mista do problema de alocação de confiabilidade-redundância, determinando simultaneamente a confiabilidade e redundância dos componentes de um sistema em série. Grande número de métodos (exatos e meta-heurísticos) já abordaram esse problema, apresentando soluções satisfatórias. Nesse trabalho é utilizado um algoritmo de evolução diferencial auto-adaptativa (SaMDE) junto a um algoritmo de busca local. O exemplo numérico resolvido indica que o método proposto possui boa performance, embora ainda instável, comparado aos resultados anteriormente conhecidos.*

**Palavras-chave:** *Otimização de confiabilidade, Redundância, Evolução diferencial, Auto-ada-patação.*

## 1 INTRODUÇÃO

Com a evolução da tecnologia e a atenção contra falhas, o problema de aumento da confiabilidade de sistemas (série, série-paralelo p.ex.) torna-se importante. O design de tais sistemas influencia diretamente em sua confiabilidade, tornando-os mais competitivos. Existem diversas abordagens para o problema, porém será tratado pela alocação de confiabilidade-redundância, em que se procura aumentar a confiabilidade dos componentes e usar componentes redundantes (Valian et al., 2013).

Nesse trabalho o problema será formulado pela maximização da confiabilidade do sistema, dada por uma função objetivo, e sujeito a múltiplas restrições não-lineares. Assim, pode-se entendê-lo por um problema de programação não-linear inteiro-misto (Hikita, 1992). Segue a sua forma:

$$\begin{aligned} & \text{Maximize } R_s = f(\mathbf{r}, \mathbf{n}), \\ & \text{sujeito a } g(\mathbf{r}, \mathbf{n}) \leq l \\ & 0 \leq r_i \leq 1, \quad r_i \in \mathbb{R}, \quad n_i \in \mathbb{Z}^+, \quad 1 \leq i \leq m. \end{aligned}$$

Em que  $R_s$  é a confiabilidade do sistema,  $g$  representa o conjunto de restrições (usualmente interpretadas como peso, volume e custo),  $\mathbf{r} = (r_1, r_2, \dots, r_m)$  o vetor da confiabilidade dos componentes do sistema e  $\mathbf{n} = (n_1, n_2, \dots, n_m)$  o vetor dos componentes redundantes do sistema. Logo,  $r_i$  e  $n_i$  são a confiabilidade e a redundância de cada  $i$ -ésimo subsistema, respectivamente. O vetor  $l$  representa os recursos do problema e  $m$  o número de subsistemas do sistema.

A seguir, será apresentada uma metaheurística de evolução diferencial com auto-adaptação (SaMDE) junto a um algoritmo simples de busca local, para resolução do exemplo de um sistema em série. Também será comparado com resultados anteriores na literatura.

## 2 EVOLUÇÃO DIFERENCIAL COM AUTO-ADAPTAÇÃO

O Algoritmo de Evolução Diferencial (DE), proposto em (Storn and Price, 1995), é baseado no processo de evolução natural. Embora traga tal estrutura, seus operadores não são baseados neste processo, tornando-se um simples e eficiente método de busca.

Porém, ainda que eficaz possui deficiências. Seja pelo número limitado de combinações do espaço de busca ou pelos parâmetros fixos, que levam a desperdiçar a convergência no processo final. Além disso, a escolha de seus parâmetros influencia diretamente no resultado obtido (Eiben et al, 1999). Portanto, a auto-adaptação dos parâmetros traz uma solução a estas deficiências. Diversos métodos já foram desenvolvidos utilizando estes conceitos, tais como o jDE, SaDE, DESAP e SaMDE (Prado, 2010).

### 2.1 Algoritmo SaMDE e busca local

O algoritmo SaMDE baseia-se na auto-adaptação dos parâmetros para múltiplas estratégias de mutação. Apresentando rápida convergência comparado ao algoritmo DE. Porém, por vezes torna-se prematura tal convergência, diminuindo sua capacidade de diversificação e estacionando em ótimos locais (Prado, 2010).

**Algorithm 1** Algoritmo SaMDE

---

```

1:  $t \leftarrow 1$ 
2: Inicializar população  $X_t = (x_{t,i}; i = 1, 2, \dots, NP)$ 
3: Avaliar  $X_t$ 
4: while condição de parada do
5:   for  $i = 1 : NP$  do
6:     Selecione aleatoriamente  $r_1, \dots, r_5 \in 1, \dots, NP$ 
7:     Selecione aleatoriamente  $\delta_i \in 1, \dots, n$ 
8:     Selecione aleatoriamente  $F' \in [0.8, 1]$ 
9:     for  $k=1$ :Número de estratégias do
10:       $V_i^k = V_{r_1}^k + F' (V_{r_2}^k - V_{r_3}^k)$ 
11:    end for
12:     $w \leftarrow$  Estratégia escolhida pela roleta
13:     $F_i^w = F_{r_1}^w + F' (F_{r_2}^w - F_{r_3}^w)$ 
14:     $CR_i^w = CR_{r_1}^w + F' (CR_{r_2}^w - CR_{r_3}^w)$ 
15:    for  $j = 1 : n$  do
16:      if  $U_{[0,1]} \leq CR_i^w \vee j = \delta_i$  then
17:        if  $w = 1$  then
18:           $u_{t,i,j} \leftarrow x_{t,r_1,j} + F_i^w (x_{t,r_2,j} - x_{t,r_3,j})$ 
19:        else if  $w = 2$  then
20:           $u_{t,i,j} \leftarrow x_{t,best,j} + F_i^w (x_{t,r_1,j} - x_{t,r_2,j})$ 
21:        else if  $w = 3$  then
22:           $u_{t,i,j} \leftarrow x_{t,r_1,j} + F_i^w (x_{t,r_2,j} - x_{t,r_3,j}) + F_i^w (x_{t,r_4,j} - x_{t,r_5,j})$ 
23:        else if  $w = 4$  then
24:           $u_{t,i,j} \leftarrow x_{t,i,j} + F_i^w (x_{t,r_1,j} - x_{t,i,j}) + F_i^w (x_{t,r_2,j} - x_{t,r_3,j})$ 
25:        end if
26:      else
27:         $u_{t,i,j} \leftarrow x_{t,i,j}$ 
28:      end if
29:    end for
30:    for  $i = 1 : NP$  do
31:      if  $f(u_{t,i}) \leq f(x_{t,i})$  then
32:         $x_{t+1,i} \leftarrow u_{t,i}$ 
33:      else
34:         $x_{t+1,i} \leftarrow x_{t,i}$ 
35:      end if
36:    end for
37:  end for
38:   $t \leftarrow t + 1$ 
39: end while

```

---

Em um segundo momento, é aplicado um pós-processamento utilizando uma busca local. Promovendo pequenas alterações nas posições reais da solução encontrada pela metaheurística. Caso seja factível, é aceita a nova solução e retorna-se a incrementar a confiabilidade dos componentes.

### 3 EXEMPLOS NUMÉRICOS

Alguns exemplos já são costumeiramente adotados na área (Chen, 2005). Portanto, traz-se uma breve aplicação ao sistema em série, que está descrito logo abaixo.

$$\begin{aligned} \text{Maximize } R_s &= \prod_1^m R_i(n_i) \\ \text{sujeito a} \\ g_1(\mathbf{r}, \mathbf{n}) &= \sum_{i=1}^m w_i v_i^2 n_i^2 \leq V, \\ g_2(\mathbf{r}, \mathbf{n}) &= \sum_{i=1}^m \alpha_i \left( -\frac{1000}{\ln r_i} \right)^{\beta_i} \left[ n_i + \exp\left(\frac{n_i}{4}\right) \right] \leq C, \\ g_3(\mathbf{r}, \mathbf{n}) &= \sum_{i=1}^m w_i n_i \exp\left(\frac{n_i}{4}\right) \leq W, \\ 0 \leq r_i \leq 1, r_i &\in \mathbb{R}, n_i \in \mathbb{Z}^+, 1 \leq i \leq m. \end{aligned}$$

A seguir, é apresentada a melhor solução encontrada pelo método proposto. Nota-se que em diversas vezes não se obteve tão bom desempenho. Tornou-se um método satisfatório mas instável.

**Table 1: Dados usados no sistema em série.**

Estado	$10^5 \alpha_i$	$\beta_i$	$w_i v_i^2$	$w_i$	V	C	W
1	2.330	1.5	1	7	110	175	200
2	1.450	1.5	2	8			
3	0.541	1.5	2	8			
4	8.050	1.5	4	6			
5	1.950	1.5	2	9			

Comparando com as soluções apresentadas na literatura, nota-se também que a abordagem traz uma solução tão quanto eficiente as anteriores.

**Table 2: Comparação do melhor resultado para o sistema em série com outros resultados apresentados na literatura.**

Parâmetros	Hikita et al.	Chen	Valian et al.	Spengler et al.
$R_s$	0.931451	0.931678	0.931682387	0.9316823845
$n$	(3, 2, 2, 3, 3)	(3, 2, 2, 3, 3)	(3, 2, 2, 3, 3)	(3, 2, 2, 3, 3)
$r$	0.774887	0.779266	0.779416938	0.7793899301
	0.870065	0.872513	0.871833278	0.8718308464
	0.898549	0.902634	0.902885082	0.9028872228
	0.716524	0.710648	0.711393868	0.7113899926
	0.791368	0.788406	0.787803712	0.7878417664

## 4 CONCLUSÕES

A metaheurística apresentada, associada ao pós-processamento por uma busca local, possibilitou um bom desempenho, porém por muitas vezes instável. De forma que apenas o melhor resultado é apresentado. Devendo-se tal instabilidade a convergência ainda pré-matura da metaheurística. Desse modo, demonstrando um trabalho ainda a ser estudado e melhorado, seja pela de hibridação com outras heurísticas ou métodos exatos, que abranjam tais deficiências.

Além disso, ainda se faz necessária a validação para outros exemplos já considerados na literatura. Permitindo uma melhor comparação de desempenho.

## AGRADECIMENTOS

Agradecimentos ao apoio financeiro do Cnpq e paciência do prof. Gustavo V. Loch.

## REFERÊNCIAS

- Chen, T., & You, P., 2005. Immune algorithms-based approach for redundant reliability problems with multiple component choices. *Computers in Industry*, n. 56, pp. 195–205.
- Eiben, A. E., Michalewicz, Z., Schoenauer, M., & Smith, J. E., 1999. Parameter control in evolutionary algorithms. *IEEE Transactions on Evolutionary Computation*, vol. 3, pp. 124–141.
- Hikita, M., Nakagawa, Y., & Harihisa, H., 1992. Reliability optimization of systems by a surrogate constraints algorithm. *IEEE Trans. Reliab*, n. 41, pp. 473–480.
- Prado, R. S., 2010. *Um estudo sobre a autoadaptação de parâmetros na evolução diferencial*. PhD thesis, Universidade Federal de Ouro Preto/Minas Gerais.
- Storn, R., & Price, K., 1995. Differential evolution - a simple and efficient adaptive scheme for global optimization over continuous spaces. *Technical report.*, vol. 17, n. 1, pp. 200–212.
- Valian, E., Tavakoli, S., Mohanna, S. & Haghi, A., 2013. Improved cuckoo search for reliability optimization problems. *Comput. Ind. Eng*, n. 64, pp. 459–468.