

APLICAÇÃO DA COMPUTAÇÃO EVOLUCIONÁRIA NA OTIMIZAÇÃO DE CONFIABILIDADE DE SISTEMAS

MARCIA F. P. SALGADO*, ADRIANO C. LISBOA†, RODNEY R. SALDANHA†, WALMIR M. CAMINHAS*,
BENJAMIM R. DE MENEZES*

**Laboratório de Inteligência Computacional e Engenharia de Confiabilidade,
Departamento de Eletrônica, UFMG
Av. Antônio Carlos, 6627 - Pampulha - 31270-901 Belo Horizonte, MG, Brasil*

*†Laboratório de Otimização e Projeto Assistido por Computador, Departamento de Elétrica, UFMG
Av. Antônio Carlos, 6627 - Pampulha - 31270-901 Belo Horizonte, MG, Brasil*

Emails: marcia.platilha@cpdee.ufmg.br, adriano@cpdee.ufmg.br, rodney@cpdee.ufmg.br,
caminhas@cpdee.ufmg.br, brm@cpdee.ufmg.br

Abstract— In this paper stochastic methods for solving redundancy-reliability allocation problems are employed. In order to understand the major issues on solving those problems, three different designs are considered and redundancy allocation problems are formulated for each of them. The problems are solved in two stages, one stochastic and another deterministic. Genetic and the immune algorithms are implemented.

Keywords— reliability engineering, system reliability, immune algorithm, genetic algorithm

Resumo— No presente trabalho métodos de otimização estocástica são utilizados para resolver problemas de alocação de redundância-confiabilidade. A fim de exemplificar as questões principais acerca da solução de tais problemas, três arquiteturas de sistemas distintas têm suas formulações apresentadas. Os problemas formulados são resolvidos em dois estágios, um estocástico e um determinístico. Os algoritmos imune e genético são implementados.

Keywords— engenharia de confiabilidade, confiabilidade de sistemas, algoritmo imune, algoritmo genético

1 Introdução

A complexidade dos sistemas vem aumentando continuamente nos últimos anos, e com isso vem também crescendo ainda mais a atenção dada a problemas relacionados com a confiabilidade dos mesmos. Isso se deve especialmente ao fato de que as perdas geradas pelas falhas de sistemas complexos podem ser significativas ou até mesmo irreparáveis. Aspectos como custos diretos e indiretos, qualidade dos produtos e serviços, integridade física dos sistemas e estruturas, e mais importante, a segurança, ganharam nos últimos anos atenção redobrada. Assim, o estudo da confiabilidade no âmbito da engenharia de sistemas é um fator crucial ao projeto de sistemas seguros, a custos compatíveis e com desempenhos desejáveis.

O termo Confiabilidade refere-se à probabilidade de um sistema não falhar dentro de um intervalo de tempo e condições operacionais específicas (Kececioğlu, 2002).

A Engenharia de Confiabilidade é um ramo da Engenharia de Sistemas que tem como objetivos (O'Connor, 2002):

- Aplicar o conhecimento de engenharia e técnicas específicas para prevenir ou reduzir frequência de falhas;
- Identificar e solucionar as causas das falhas que ocorrem, mesmo com todo o esforço para preveni-las;

- Estabelecer formas de atuar sobre as falhas cujas causas não foram solucionadas;
- Aplicar métodos para a estimação da confiabilidade de novas arquiteturas e para a análise de dados de confiabilidade.

Tais objetivos podem ser trabalhados no contexto da Inteligência Computacional abordando-se três problemas típicos de interesse e complementares entre si, a citar:

- O problema da modelagem, ou seja, a identificação de um modelo que descreva a confiabilidade de um sistema;
- O problema da predição de confiabilidade, ou seja, o uso dos modelos em técnicas para o diagnóstico e prognóstico de falhas com foco em atingir níveis de confiabilidade desejados;
- O problema da otimização de um sistema para melhoria de confiabilidade.

No campo da modelagem de confiabilidade, há diversas técnicas analíticas e/ou gráficas conhecidas e amplamente utilizadas as quais são fundamentadas em conceitos da Probabilidade e Estatística assim como na teoria de sistemas, como por exemplo, diagramas de bloco, árvores de falha, cadeias de Markov, entre outras. Confiabilidade de sistemas tem natureza estocástica, sendo razoável que se considere a existência de incerteza associada aos parâmetros que descrevem o comportamento de um sistema ou componente. O

tratamento de incertezas utilizando técnicas tradicionais baseadas em conceitos da Probabilidade e Estatística pressupõem a existência de dados em quantidade e qualidade suficientes para que inferências possam ser realizadas e decisões possam ser tomadas, e que, além disso, modelos que representem de forma adequada o sistema em análise possam ser obtidos. Na prática, dados são “contaminados” por todo tipo de “ruído” e, muito frequentemente, não estão disponíveis. Assim, a análise de dados de falha de sistemas reais utilizando técnicas tradicionais nos fornece informações questionáveis e que podem levar a decisões equivocadas. Obviamente, tais observações não invalidam a utilização de técnicas tradicionais, mas exigem que o analista/engenheiro conheça as limitações dos métodos frente aos dados disponíveis.

No campo da predição de confiabilidade, o foco principal está direcionado para o diagnóstico e prognóstico de falhas, que representam um importante campo de pesquisa devido à crescente necessidade por segurança, manutenibilidade e confiabilidade de plantas industriais. Com o aumento da complexidade de sistemas industriais, a tarefa de diagnóstico de falhas tem sua dificuldade e complexidade aumentadas de forma não gerenciável quando se tenta aplicar técnicas convencionais. Assim, na última década pesquisas intensas foram dedicadas para que soluções alternativas com características adaptativas para lidar com as mudanças inerentes que ocorrem no processo de diagnóstico. Tais pesquisas se concentraram especialmente no estudo de métodos inspirados no raciocínio humano e na natureza. Um diagnóstico automático eficiente é aquele que possui habilidades na identificação automática de ‘síntomas’ bem como no mapeamento de suas causas e, eventualmente, que possa ser capaz de prescrever as ações necessárias para o reparo/restauração da função do sistema (Palade et al., 2006).

No campo da otimização de confiabilidade, o interesse está voltado para a escolha de arquitetura e componentes de sistemas de forma a atender requisitos tecnológicos, assim como mercadológicos. Tais estudos requerem necessariamente que o sistema seja modelado e que funções-objetivo e/ou restrições sejam especificadas para que algoritmos sejam projetados. O estudo de técnicas de otimização é extremamente importante para o engenheiro de confiabilidade, uma vez que a busca por soluções factíveis com foco na maximização da confiabilidade e minimização dos custos associados a um sistema são metas intrínsecas ao papel por ele desempenhado. A maximização da confiabilidade não se dá de forma irrestrita, pois os recursos são finitos e não há como não levar em consideração aspectos cruciais como peso, volume, e principalmente, o custo decorrente das escolhas de engenharia. Assim, na prática, buscam-se soluções para problemas com restrição mono ou

multiobjetivo (Levitin, 2007).

Tanto para os problemas de modelagem e predição, como para o de otimização, a Inteligência Computacional oferece técnicas, que aliadas às técnicas convencionais, propiciam o desenvolvimento de metodologias eficientes para a análise e melhoria de confiabilidade de processos industriais. Avanços no campo de aplicação da Inteligência Computacional na Engenharia de Confiabilidade apresentam importância significativa no que diz respeito à maximização do desempenho de sistemas e a decorrente maximização dos resultados operacionais de plantas industriais.

O presente trabalho foca o problema de otimização de confiabilidade. Este tem sido um tema de interesse desde a década de 60. Muitas publicações têm abordado o assunto usando estruturas de sistemas e métodos de solução diferentes. Em (Levitin, 2007) as aplicações mais recentes da Inteligência Computacional em Engenharia de Confiabilidade são apresentadas. Uma introdução detalhada à confiabilidade de sistemas e otimização de confiabilidade pode ser obtida em (Kuo et al., 2001). Uma revisão geral dos métodos empregados na solução de vários problemas de otimização de confiabilidade desde década de 70 é apresentada em (Kuo and Prasad, 2000), com excelente revisão bibliográfica do assunto.

O texto está dividido como segue: no item 2, denominado Problemas de Otimização os modelos para os sistemas a serem otimizados com foco em confiabilidade são apresentados; no item 3, denominado Métodos de Otimização, os algoritmos utilizados para a solução dos problemas de otimização são brevemente apresentados; no item 4, denominado Resultados, as soluções obtidas através dos algoritmos são apresentadas e analisadas. E, finalmente, no item 5, algumas conclusões são fornecidas.

2 Problemas de Otimização

A otimização de sistemas com foco na confiabilidade está associada à escolha de soluções que atendam a requisitos tecnológicos estabelecidos. Em (Levitin, 2007) cinco formulações para o problema de otimização de confiabilidade são citadas. No presente trabalho adotou-se o que foi denominado formulação tradicional a qual foi também adotada por (Chen, 2006). Tal formulação é apresentada a seguir.

Seja m o número de subsistemas, $\mathbf{r} \in [0, 1]^m$ o vetor de confiabilidades dos componentes dos subsistemas e $\mathbf{n} \in \mathbb{N}^{*m}$ o vetor de número de redundâncias de cada subsistema. A confiabilidade de cada subsistema pode então ser escrita como

$$R_i(r_i, n_i) = 1 - (1 - r_i)^{n_i}, \quad i = 1, \dots, m \quad (1)$$

Definem-se as funções

$$g_1(\mathbf{r}, \mathbf{n}) = V - \sum_{i=1}^m w_i v_i^2 n_i^2 \quad (2)$$

$$g_2(\mathbf{r}, \mathbf{n}) = C - \sum_{i=1}^m \alpha_i \left(-\frac{1000}{\ln r_i} \right)^{\beta_i} (n_i + e^{n_i/4}) \quad (3)$$

$$g_3(\mathbf{r}, \mathbf{n}) = W - \sum_{i=1}^m w_i n_i e^{n_i/4} \quad (4)$$

relativas às restrições em volume, custo e peso, respectivamente. Os valores α e β são parâmetros que representam características físicas dos componentes dos subsistemas, \mathbf{r} é o vetor de confiabilidade dos componentes de cada subsistema, \mathbf{n} é o vetor contendo o número de redundâncias em cada sub-sistema, e V , C e W são as metas para o volume, o custo e o peso do sistema sendo otimizado.

A confiabilidade de um sistema série, como ilustrado na Figura 1, é dada por

$$R_{s1}(\mathbf{r}, \mathbf{n}) = \prod_{i=1}^m R_i(r_i, n_i) \quad (5)$$



Figura 1: Sistema série.

A confiabilidade do sistema série-paralelo ilustrado na Figura 2 é dada por

$$R_{s2}(\mathbf{r}, \mathbf{n}) = 1 - (1 - R_1 R_2) \{1 - [1 - (1 - R_3)(1 - R_4)] R_5\} \quad (6)$$

A confiabilidade do sistema complexo ilustrado na Figura 3 é dada por

$$\begin{aligned} R_{s3}(\mathbf{r}, \mathbf{n}) = & R_1 R_2 + R_3 R_4 + R_1 R_4 R_5 + R_2 R_3 R_5 \\ & - R_1 R_2 R_3 R_4 - R_1 R_2 R_3 R_5 \\ & - R_1 R_2 R_4 R_5 - R_1 R_3 R_4 R_5 \\ & - R_2 R_3 R_4 R_5 + 2R_1 R_2 R_3 R_4 R_5 \end{aligned} \quad (7)$$

Problemas de alocação de redundância-confiabilidade são tipicamente definidos na forma de programação não-linear mista-inteira (Gen and

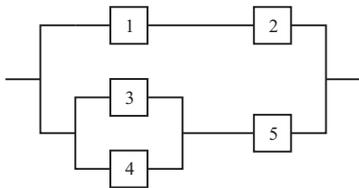


Figura 2: Sistema série-paralelo.

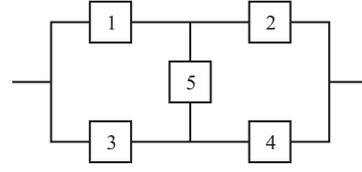


Figura 3: Sistema complexo (ponte).

Yun, 2006). Os problemas tratados neste artigo são formulados como segue:

$$\begin{aligned} & \text{maximize } R_s(\mathbf{r}, \mathbf{n}) \\ & \text{sujeito a } \mathbf{g}(\mathbf{r}, \mathbf{n}) \geq 0 \end{aligned} \quad (8)$$

A solução dessa classe de problemas por algoritmos determinísticos é tipicamente feita com a estratégia branch-and-bound aplicada a um algoritmo não-linear. Entretanto, ela cria uma árvore de sub-problemas que onera a busca pela solução, além de herdar a característica de aprisionamento em ótimos locais. Essas limitações são fortes no problema (8), o que motiva o estudo de técnicas estocásticas.

Neste trabalho, o algoritmo genético e o algoritmo imune são avaliados na otimização de confiabilidade de sistemas. Foram implementados os operadores fundamentais destes algoritmos evolucionários com codificação real, e adicionado um tratamento diferenciado das restrições.

2.1 Algoritmo genético

O algoritmo genético (GA) se baseia na teoria da evolução de Darwin, onde uma população de indivíduos sujeitos a mutações são selecionados através de gerações de acordo com o grau de adaptação ao ambiente. Espera-se obter uma população com indivíduos cada vez mais adaptados ao ambiente onde vivem com operadores de cruzamento, mutação e seleção. Este algoritmo proporciona uma boa exploração dos locais entre os melhores indivíduos.

2.2 Algoritmo imune

O algoritmo imune (IA) se baseia no sistema imunológico, onde anticorpos são clonados e maturados de acordo com o grau de casamento ao antígeno. Espera-se que os anticorpos combatam cada vez melhor o organismo invasor com operadores de clonagem, maturação e seleção. Este algoritmo promove uma boa exploração de vários locais ao mesmo tempo (de Castro and Zuben, 2002).

2.3 Algoritmo elipsoidal

O método elipsoidal (EM) é um algoritmo baseado na exclusão de semi-espacos. Esta estratégia trata restrições de modo transparente, *i.e.* o corte

baseia-se na função objetivo caso não haja restrições ativas ou nas restrições, caso contrário. Sua convergência para o mínimo global é garantida caso as funções envolvidas forem contínuas quasi-convexas (note que as funções podem não ser continuamente diferenciáveis). Sua convergência foi acelerada com o uso de múltiplos cortes, provindos de cortes passados ou de várias restrições ativas (Vieira et al., 2007).

2.4 Tratamento de restrições

O tratamento de restrições dos algoritmos evolucionários implementados usa a equivalência (Vieira et al., 2002) entre o problema mono-objetivo restrito original 8, com o problema multi-objetivo irrestrito

$$\begin{aligned} & \text{maximize } R_s(\mathbf{r}, \mathbf{n}) \\ & \text{min}\{\mathbf{g}(\mathbf{r}, \mathbf{n}), 0\} \end{aligned} \quad (9)$$

onde as funções objetivo adicionais são dadas por cada função de restrição limitada superiormente em zero. Dessa maneira o ponto ótimo do problema (8) pertence ao conjunto Pareto ótimo de (9). Além disso, ela permite uma melhor exploração de locais onde a função objetivo é menor em regiões inactíveis ou mesmo atravessar regiões inactíveis. Pelo teorema do valor extremo, fronteiras de tais regiões são grandes candidatas a conter pontos ótimos.

O primeiro objetivo dos algoritmos é localizar uma solução factível. Para tanto, os objetivos são colocados em zero até o primeiro deles ser encontrado. Para garantir que o vértice da solução factível esteja no conjunto Pareto final, o melhor ponto factível é mantido na população de cada iteração.

3 Resultados

Os problemas de teste usados são dados pelas instâncias de (8) nas configurações série, série-paralelo e complexa de 5 subsistemas assim como apresentado em (Chen, 2006). Os valores dos parâmetros dos modelos adotados são dados nas Tabelas 1 e 2.

i	1	2	3	4	5
$10^5 \alpha_i$	2,330	1,450	0,541	8,050	1,950
β_i	1,5	1,5	1,5	1,5	1,5
$w_i v_i^2$	1	2	3	4	2
w_i	7	8	8	6	9
V	110				
C	175				
W	200				

Tabela 1: Parâmetros para as instâncias de configuração série e complexa.

i	1	2	3	4	5
$10^5 \alpha_i$	2,500	1,450	0,541	0,541	2,100
β_i	1,5	1,5	1,5	1,5	1,5
$w_i v_i^2$	2	4	5	8	4
w_i	3,5	4,0	4,0	3,5	4,5
V	180				
C	175				
W	100				

Tabela 2: Parâmetros para a instância de configuração série-paralela.

Foi feita uma análise estatística para 200 resultados, ilustrada nas Figuras 4, 5 e 6. Os melhores resultados da otimização são mostrados nas Tabelas 3, 4 e 5. O problema foi avaliado 25.000 vezes em cada simulação do GA e do IA. O GA utilizado foi ajustado para 50 indivíduos evoluídos durante 500 gerações com cruzamento polarizado com probabilidade de 80%, com mutação de 5% e seleção por rank aplicados em toda a população. Já o IA foi ajustado para uma taxa de clonagem de 50%, um fator de clonagem de $\beta = 0.6$, um decaimento no raio de maturação de $\rho = 1$ aplicados a uma população inicial de 50 anticorpos maturados durante 500 gerações.

Para refinar a solução nas variáveis contínuas do ótimo local (possivelmente global) obtido pelo GA e pelo IA, foi lançado o algoritmo elipsoidal (EM) (Vieira et al., 2007) com as variáveis inteiras fixadas.

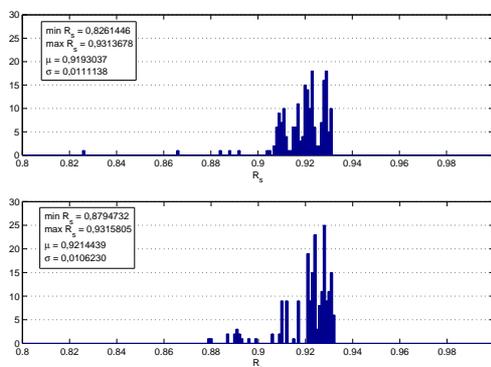


Figura 4: Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema série.

Os problemas implementados são bem sensíveis às variáveis de otimização. Isso pode ser exemplificado no problema do sistema complexo, onde observa-se que a parte inteira (parâmetro \mathbf{n}) resultante dos algoritmos implementados apresentou variação em relação ao resultado obtido por (Chen, 2006) para o mesmo sistema (ver Tabela 6), mesmo representando um pequeno ganho na confiabilidade do sistema. Contudo, obter confiabilidades próximas da melhor encontrada não é improvável para os algoritmos utilizados.

	GA	IA	EM
n	(3,2,2,3,3)	(3,2,2,3,3)	(3,2,2,3,3)
r	0,7764205	0,7848284	0,7793982
	0,8714998	0,8701397	0,8718371
	0,8945247	0,9023847	0,9028857
	0,7172746	0,7111458	0,7114024
	0,7910414	0,7857573	0,7877999
$R_s(\mathbf{r}, \mathbf{n})$	0,9313678	0,9315805	0,9316824
g(r, n)	27	27	27
	0,004118 7,518918	0,073122 7,518918	0,000000 7,518918

Tabela 3: Melhores resultados da otimização do sistema série.

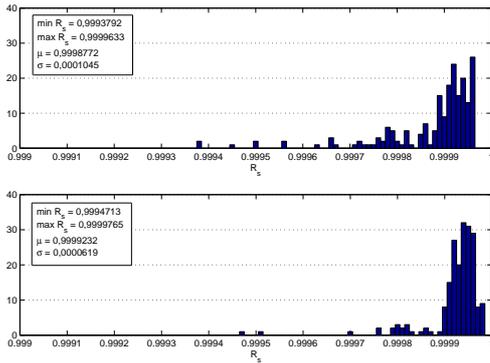


Figura 5: Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema série-paralelo.

	GA	IA	EM
n	(3,2,2,3,3)	(2,2,2,2,4)	(2,2,2,2,4)
r	0,7763730	0,8182806	0,8197290
	0,8687575	0,8516073	0,8450074
	0,7787454	0,9010889	0,8954876
	0,8418725	0,8930029	0,8954872
	0,8965929	0,8661254	0,8684305
$R_s(\mathbf{r}, \mathbf{n})$	0,9999633	0,9999765	0,9999766
g(r, n)	18	40	40
	0,0525863 0,5839591	0,0462522 1,6092890	0,000000 1,6092890

Tabela 4: Melhores resultados da otimização do sistema série-paralelo.

Os resultados devem ser utilizados para decisão sobre qual arquitetura implementar, considerando os fatores custo, volume, peso e a confiabilidade ótima de cada solução disponibilizada pelos algoritmos. Por exemplo, para o sistema série os algoritmos apontaram que para a maximização de confiabilidade a arquitetura do sistema deve ser alterada para a apresentada na Figura 7. O algoritmo immune tende a apresentar resultados significativamente mais perto do melhor valor devido à sua característica de busca local quando comparado ao algoritmo genético. Ressalta-se a importância de se utilizar métodos de otimiza-

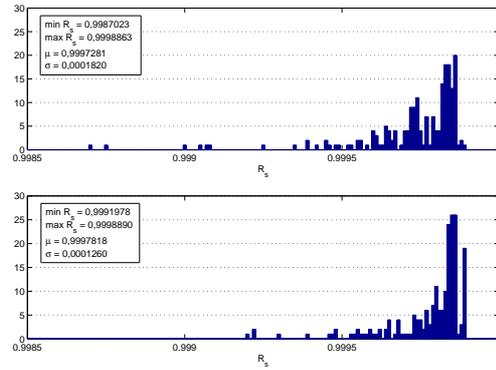


Figura 6: Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema complexo.

	GA	IS	EM
n	(3,3,3,3,1)	(3,3,2,4,1)	(3,3,2,4,1)
r	0,8070836	0,8257889	0,8280856
	0,8779927	0,8626022	0,8578044
	0,8628981	0,9127624	0,9142408
	0,6965346	0,6430090	0,6481465
	0,7823552	0,7251948	0,7041713
$R_s(\mathbf{r}, \mathbf{n})$	0,9998863	0,9998890	0,9998896
g(r, n)	18	5	5
	0,0740375 4,2647698	0,0411987 1,5604663	0,0000000 1,5604663

Tabela 5: Melhores resultados da otimização do sistema complexo.

	S1	S2	S3
n	(3,2,2,3,3)	(2,2,2,2,4)	(3,3,3,3,1)
r	0,779266	0,812485	0,812485
	0,872513	0,843155	0,867661
	0,902634	0,897385	0,861221
	0,710648	0,894516	0,713852
	0,788406	0,870590	0,756699
	$R_s(\mathbf{r}, \mathbf{n})$	0,931678	0,99997658
g(r, n)	27	40	18
	0,001559 7,518918	0,02627 1,6092890	0,001494 4,264770

Tabela 6: Melhores resultados da otimização apresentados por (Chen,2006) para os problemas série (S1), série-paralelo (S2) e complexo (S3).

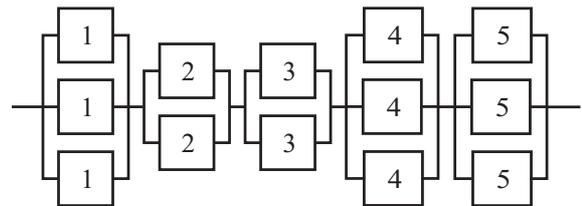


Figura 7: Nova arquitetura para o sistema série.

ção para a melhoria de confiabilidade, pois com o

aumento da complexidade qualquer pequena variação na confiabilidade dos componentes empregados pode afetar significativamente a confiabilidade do sistema.

4 Conclusões

O desenvolvimento do presente trabalho auxiliou na identificação de trabalhos voltados à aplicação da Inteligência Computacional à Engenharia de Confiabilidade. Os resultados apresentados na solução do problema de otimização formulado mostraram-se consistentes. Percebe-se claramente a importância prática do emprego da computação evolucionária na otimização de confiabilidade de sistema. A estratégia em dois estágios para a solução dos problemas formulados garantiu um resultado superior ao apresentado na literatura.

Referências

- Chen, T.-C. (2006). Ias based approach for reliability redundancy allocation problems, *Elsevier Applied Mathematics and Computation* **182**: 1556–1567.
- de Castro, L. N. and Zuben, F. J. V. (2002). Learning and optimization using the clonal selection principle, *IEEE Transactions on Evolutionary Computation*, N.3 **6**: 239–251.
- Gen, M. and Yun, Y. (2006). Soft computing approach for reliability optimization: State-of-the-art survey, *Reliability Engineering and System Safety* **91**: 1008–1026.
- Kececioglu, D. (2002). *Reliability Engineering Handbook*, Vol. 1-2, DEStech publications.
- Kuo, W. and Prasad, V. R. (2000). An annotated overview of system-reliability optimization, *IEEE Transactions on Reliability* N.2 **49**: 176–187.
- Kuo, W., Prasad, V. R., Tillman, F. A. and Hwang, C.-L. (2001). *Optimal Reliability Design: Fundamentals and Applications*, 1 edn, Cambridge University Press.
- Levitin, G. (2007). *Computational Intelligence in Reliability Engineering: Evolutionary Techniques in Reliability Analysis and Optimization and New Metaheuristics, Neural and Fuzzy Techniques in Reliability*, Vol. 39-40, Springer-Verlag.
- O'Connor, P. (2002). *Practical Reliability Engineering*, 4th edn, John Wiley.
- Palade, V., Bocaniala, C. D. and Jain, L. (2006). *Computational Intelligence in Fault Diagnosis*, Springer-Verlag.
- Vieira, D. A. G., da Silva Adriano, R. L., Vasconcelos, J. A. and Krahenbuhl, L. (2002). Handling constraints as objectives in a multiobjective genetic based algorithm, *Journal of Microwaves and Optoelectronics* **2**(6): 59–69.
- Vieira, D. A. G., Júnior, A. S. M., Lisboa, A. C., Sadanha, R. R. and Takahashi, R. H. C. (2007). A multi-cut fast ellipsoid optimization method for non-smooth problems, *Submetido ao Mathematical Programming*.