

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, Departamento de Engenharia Eletrônica, UFMG
Avenida Antônio Carlos, 6627 - Pampulha - 31270-901 Belo Horizonte, MG, Brasil

† Laboratório de Otimização e Projeto Assistido por Computador, Departamento de Engenharia Elétrica, UFMG
Avenida 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, computational intelligence

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 são consideradas e seus respectivos problemas de alocação de redundância-confiabilidade têm suas formulações apresentadas. Os problemas formulados são resolvidos em dois estágios, um estocástico e um determinístico. Os algoritmos imune e genético são implementados.

Palavras-chave: engenharia de confiabilidade, confiabilidade de sistemas, algoritmo imune, algoritmo genético, inteligência computacional.

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 (Kececioglu, 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 é avaliar e prever a confiabilidade de um sistema dado o seu perfil de falhas ao longo do seu ciclo de vida. Técnicas convencionais de predição de confiabilidade baseiam-se na utilização de modelos probabilísticos obtidos em uma fase de modelagem. Nesse sentido falhas precisam ser diagnosticadas uma vez que análises de confiabilidade para modos de falha específicos são em geral necessárias, do contrário, sob a perspectiva da manutenção de sistemas, não seria vantajoso desenvolvê-las. Entretanto, conhecer a confiabilidade do sistema pode ser útil sob certos aspectos. O diagnóstico de falhas representa um campo de pesquisa importante devido à crescente necessidade por segurança, manutenibilidade e confiabilidade de plantas industriais. Esta tarefa ainda vem sendo desempenhada na indústria por operadores e/ou mantenedores com base em inspeção (medições de alguns parâmetros, visual, etc.), e é essencial à engenharia de confiabilidade. Se modos de falha (funcionais e físicos) são diagnosticados e descritos de maneira apropriada, é possível o desenvolvimento de um banco de dados e, assim, técnicas convencionais podem ser empregadas facilmente. 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 a obtenção de soluções alternativas com caracte-

terísticas 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 “sintomas” bem como no mapeamento de suas causas e, eventualmente, que possa ser capaz de prever 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. Sob a perspectiva da engenharia de confiabilidade, o desempenho de sistemas pode ser medido em termos do tempo médio até a falha (*MTTF* ou *Mean Time To Failure*) no caso de sistema não-reparáveis, ou em termos do disponibilidade (*Availability*) do sistema que pode ser estimada por uma relação entre o tempo médio entre falhas (*MTBF* ou *Mean Time Between Failures*) e do tempo médio de reparo (*MTTR – Mean Time to Repair*) no caso de sistema reparáveis. Um vez que a medida de confiabilidade e/ou disponibilidade do sistema tenha sido escolhida, um modelo e outras medidas de desempenho podem ser consideradas, e.g., investimento ou custos de manutenção associados com o projeto e componentes do sistema. Estas variáveis são então utilizadas na formulação do problemas de otimização, i.e., objetivos e restrições são formulados matematicamente. 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. Na prática, problemas de otimização de confiabilidade de sistemas são em geral formulados como problemas restritos multi-objetivo (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 et al. (2007) uma revisão bibliográfica completa com 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 (2000), com excelente revisão bibliográfica do assunto.

O texto está dividido como segue: na seção 2, denominada Problemas de Otimização – Formulação Mono-objetivo, os modelos para os sistemas a serem otimizados com foco em confiabilidade assim como os algoritmos utilizados para a solução dos problemas de otimização são brevemente apresentados; na seção 3, denominada Resultados – Formulação Mono-objetivo, as soluções obtidas através dos algoritmos são apresentadas e analisadas. Na seção 4, os problemas da seção 2 são reformulados como problemas multi-objetivo. Na seção 5, as curvas de Pareto obtidas para os problemas multi-objetivo são apresentadas. E, finalmente, na seção 6, algumas conclusões são fornecidas.

2 Problemas de Otimização – Formulação Mono-objetivo

A otimização de confiabilidade de sistemas está associada à escolha da arquitetura/projeto e componentes a serem utilizados de forma a atender requisitos ou metas de desempenho específicas. Em Levitin (2007), cinco formulações para problemas de otimização de confiabilidade são apresentadas. No pre-

sente trabalho a formulação denominada tradicional foi adotada, a qual também foi utilizada por Chen (2006). A formulação dos problemas é apresentada a seguir.

Seja m o número de subsistemas, \mathbf{r} o vetor de confiabilidades dos componentes de cada subsistema e $\mathbf{n} \in \mathbb{N}^m$ um vetor contendo o número de redundâncias em cada subsistema. A confiabilidade de cada subsistema e as restrições em volume, custo and peso são definidas pelas equações (1) a (4), respectivamente:

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

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

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

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

Os termos α e β são parâmetros representando características físicas dos componentes, e V , C e W são as metas (limites) para o volume, custo e peso para o sistema que se pretende otimizar sob a perspectiva da confiabilidade.

A confiabilidade do sistema em série genérico apresentado na Figura 1 é dada por (5):

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




Figura 1: Sistema série genérico.

A confiabilidade do sistema em série-paralelo apresentado na Figura 2 é dada por (6):

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




Figura 2: Sistema série-paralelo genérico.

A confiabilidade do sistema complexo (ponte) apresentado na Figura 3 é dada por (7):

$$\begin{aligned}
 R_{S3}(\mathbf{r}, \mathbf{n}) = & R_1 R_2 + R_3 R_4 + R_1 R_4 R_5 + R_2 R_3 R_5 \\
 & - R_1 R_2 R_3 R_4 - R_1 R_2 R_3 R_5 \\
 & - R_1 R_2 R_4 R_5 - R_1 R_3 R_4 R_5 \\
 & - R_2 R_3 R_4 R_5 + 2R_1 R_2 R_3 R_4 R_5 \quad (7)
 \end{aligned}$$




Figura 3: Sistema complexo genérico.

Problemas de alocação de confiabilidade-redundância são tipicamente definidos como problemas de programação inteira mista não-linear (Gen, 2006). Estes problemas são tratados no presente artigo por meio da formulação apresentada em (8):

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

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 (Castro, 2002).

2.3 Algoritmo elipsoidal

O método elipsoidal (EM) é um algoritmo baseado na exclusão de semi-espacos por meio de elipsóides. 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 e pode ser acelerada com o uso de múltiplos cortes, provindos de cortes passados ou de várias restrições ativas (Vieira et al., 2007).

Na figura 4 apresenta-se a atualização iterativa de uma elipse a qual define o corte de um semi-plano e as curvas de nível da função que se pretende otimizar (Note pelas quinas nas curvas de nível que as funções-objetivo podem não ser continuamente diferenciáveis). São consideradas somente as curvas de nível que se encontram dentro da região delimitada pela faixa cinza. Mais informações sobre o algoritmo elipsoidal podem ser obtidas em Lisboa et al. (2007).

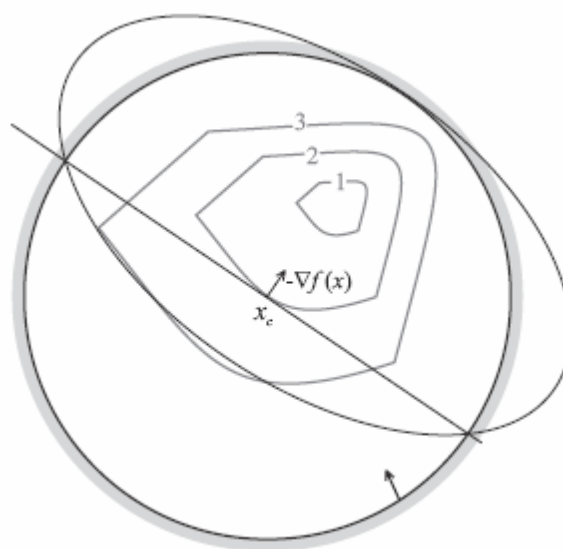


Figura 4: Atualização iterativa de uma elipse com o corte de um semi-plano.

2.4 Tratamento das restrições

O tratamento das restrições nos algoritmos evolucionários foi implementado usando a equivalência (Vieira et al., 2002) entre o problema original formulador em (8) e o problema multi-objetivo irrestrito descrito por (9), onde as funções objetivo adicionais são dadas pelas restrições de (8) limitadas superiormente por zero.

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

Desta forma, o ótimo do problema (8) pretence ao conjunto Pareto-ótimo de (9). Além disso, esta abordagem 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. Para lidar com a parte multi-objetivo, os indivíduos da população que fazem parte do conjunto Pareto são colocados em primeiro, depois uma ordenação baseada na distância entre os valores dos objetivos é empregada.

3 Resultados – Formulação Mono-objetivo

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>i</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
$\omega_i v_i^2$	1	2	3	4	2
ω_i	7,0	8,0	8,0	6,0	9,0
V	110				
C	175				
W	200				

Tabela 1: Parâmetros para instâncias dos sistemas série e complexo.

<i>i</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
$\omega_i v_i^2$	2	4	5	8	4
ω_i	3,5	4,0	4,0	3,5	4,5
V	180				
C	175				
W	100				

Tabela 2: Parâmetros para instâncias do série-paralelo

Os algoritmos foram simulados e análises estatísticas para 200 resultados são apresentadas nas Figuras 5, 6 e 7. Os melhores resultados da otimização são mostrados nas Tabelas 3, 4 e 5, e comparados aos resultados obtidos por Chen (2006). 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 evoluídos 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. O número máximo de redundâncias que podem ser alocadas para cada subsistema foi definido como 9. Os resultados apresentados mostram a robustez dos algoritmos implementados, especialmente para os sistemas série-paralelo e complexo, em que observou-se um desvio padrão nas soluções desprezível. No caso do sistema série, as soluções obtidas apresentaram um desvio padrão de aproximadamente 1%.




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

	GA	IA	EM	(Chen,
--	----	----	----	--------

	2006)			
n	(3,2,2,3,3)	(3,2,2,3,3)	(3,2,2,3,3)	(3,2,2,3,3)
r	0,7764205	0,7848284	0,7793982	0,779266
	0,8714998	0,8701397	0,8718371	0,872513
	0,8945247	0,9023847	0,9028857	0,902634
	0,7172746	0,7111458	0,7114024	0,710648
	0,7910414	0,7857573	0,7877999	0,788406
$R_s(\mathbf{r},\mathbf{n})$	0,9313678	0,9315805	0,9316824	0,9316780
$g(\mathbf{r},\mathbf{n})$	27	27	27	27
	0,004118 7,518918	0,073122 7,518918	0,000000 7,518918	0,001559 7,518918

Tabela 3: Melhores resultados da otimização do sistema série.




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

	GA	IA	EM	(Chen, 2006)
n	(3,2,2,3,3)	(2,2,2,2,4)	(2,2,2,2,4)	(2,2,2,2,4)
r	0,7763730	0,8182806	0,8197290	0,812485

	0,8687575	0,8516073	0,8450074	0,843155
	0,7787454	0,9010889	0,8954876	0,897385
	0,8418725	0,8930029	0,8954872	0,894516
	0,8965929	0,8661254	0,8684305	0,870590
$R_s(\mathbf{r}, \mathbf{n})$	0,99996330	0,99997650	0,99997660	0,99997658
$g(\mathbf{r}, \mathbf{n})$	18	40	40	40
	0,0525863	0,0462522	0,0000000	0,0262700
	0,5839591	1,6092890	1,6092890	1,6092890

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




Figura 7: Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema complexo.

	GA	IA	EM	(Chen, 2006)
\mathbf{n}	(3,3,3,3,1)	(3,3,2,4,1)	(3,3,2,4,1)	(3,3,3,3,1)
\mathbf{r}	0,8070836	0,8257889	0,8280856	0,812485
	0,8779927	0,8626022	0,8578044	0,867661
	0,8628981	0,9127624	0,9142408	0,861221
	0,6965346	0,6430090	0,6481465	0,713852
	0,7823552	0,7251948	0,7041713	0,756699
$R_s(\mathbf{r}, \mathbf{n})$	0,9998863	0,9998890	0,9998896	0,99988921
$g(\mathbf{r}, \mathbf{n})$	18	5	5	18
	0,0740375	0,0411987	0,000000	0,001494

	4,2647698	1,5604663	1,5604663	4,264770
--	-----------	-----------	-----------	----------

Tabela 5: *Melhores resultados da otimização do sistema complexo.*

Os problemas implementados são bem sensíveis às variáveis de otimização. Isso pode ser exemplificado no problema do sistema complexo na Tabela 5, onde observa-se que a parte inteira (parâmetro n) resultante dos algoritmos implementados apresentou uma variação em relação ao resultado obtido por Chen (2006), o que resultou em um pequeno ganho na confiabilidade. Contudo, obter confiabilidades próximas da melhor encontrada não é improvável para os algoritmos utilizados, como pode ser observado nas Figuras 5, 6 e 7. 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 8. O algoritmo imune tende a apresentar resultados significativamente mais perto do melhor valor devido à sua característica de busca local quando comparado ao algoritmo genético, como pode ser observado nas Figuras 5, 6 e 7. Ressalta-se a importância de se utilizar métodos de otimização 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.

Chen (2006) adota como medida de desempenho (Máxima Melhoria Possível - MMP) do seu algoritmo imune a comparação percentual de quão próximas as soluções apresentadas na literatura ficam das soluções por ele obtidas. A MMP é dada por (10), onde R_S é a confiabilidade do sistema obtida no presente trabalho e R_C a confiabilidade do sistema obtida por Chen (2006).

$$MMP (\%) = \frac{R_S - R_C}{1 - R_C} \quad (10)$$

Aplicando-se o mesmo critério de avaliação de desempenho, observou-se pequena melhoria na confiabilidade do sistema série em relação ao obtido por Chen (2006) (MMP = 0,006 %) por meio da metodologia proposta no presente trabalho. É possível perceber que as variações na confiabilidade são muito pequenas. Embora possa parecer não ser muito relevante, essas pequenas variações são importantes quando se avalia sistemas complexos compostos de muitos sub-sistemas.




Figura 8: *Nova arquitetura para o sistema série*

4 Problemas de Otimização – Formulação Multi-objetivo

Na seção 3, problemas de otimização de confiabilidade mono-objetivo foram formulados para os sistemas série (Figura 1), série-paralelo (Figura 2) e complexo (Figura 3). Formulações multi-objetivo são mais adequadas à prática, pois a obtenção de alternativas são em geral requeridas pelo engenheiro de confiabilidade. Assim, o problema (8) foi alterado para formulação onde se considera também como objetivo o custo decorrente das escolhas dos componentes e número de redundâncias em cada subsistema. As restrições para os problemas multi-objetivo são as mesmas dos problemas mono-objetivo com uma restrição adicional de se ter uma confiabilidade mínima aceitável para o sistema.

5 Resultados – Formulação Multi-objetivo

A seguir apresentam-se as curvas Pareto-ótimas para os problemas multi-objetivo formulados para os sistemas série (Figura 9), série-paralelo (Figura 10) e complexo (Figura 11). As curvas podem ser utilizadas em um processo de tomada de decisão no qual as decisões do engenheiro de confiabilidade garantam um nível desejável de compromisso entre a confiabilidade e custos dos sistemas.

Note que no sistema série-paralelo e no sistema complexo (Figuras 10 e 11, respectivamente) o custo chega a cair perto de quatro vezes o valor onde a confiabilidade é máxima.

O algoritmo imune na versão multi-objetivo foi utilizado, e o tratamento de restrições seguiu a mesma abordagem adotada para o problema mono-objetivo. As soluções obtidas foram ordenadas segundo o princípio da não-dominância (Deb, 1999; Deb, 2000) e assim, obtidas as curvas pareto-ótimas para os três problemas.

As curvas pareto-ótimo obtidas fornecem a informação balanceada entre o esforço de melhoria de confiabilidade versus os custos associados a essa melhoria. É possível então verificar por meio das figuras 9 a 10, que para o caso do sistema série, qualquer pequena melhoria de confiabilidade apresenta um incremento nos custos bem superior ao observado para os sistemas série-paralelo e complexo. Para os últimos, os custos apresentam-se praticamente constantes para níveis de confiabilidade relativamente altos.




Figura 9: Curva Pareto ótimo para confiabilidade e custo do sistema série.




Figura 10: Curva Pareto ótimo para confiabilidade e custo do sistema série-paralelo.

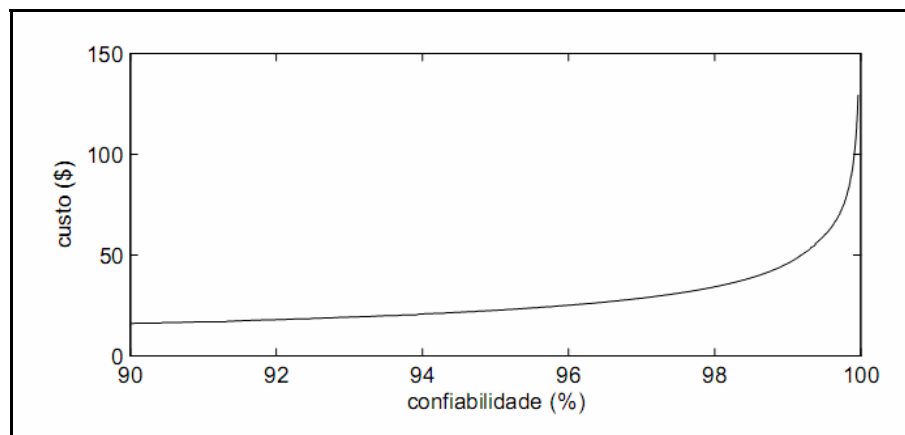


Figura 11: Curva Pareto ótimo para confiabilidade e custo do sistema complexo.

6 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 dos problemas de otimização formulados 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.

7 Referências Bibliográficas

Chen, T.-C. (2006). Ia 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.

Deb, K. (1999). Evolutionary Algorithms for Multi-Criterion Optimization in Engineering Design. In: Evolutionary Algorithms in Engineering and Computer Science. Wiley, pp. 135-161.

Deb, K., Agarwal, S., Pratap, A., Meyarivan, T. (2000). A Fast Elitist Non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. Proceedings of the Parallel Problem Solving from Nature VI Conference, pp. 849-858.

Deb, K., Mathur, A.P., Agarwal, S., Meyrivan, T. (2002). A Fast and Elitist Multi-objective Genetic Algorithm: NSGA-II. IEEE Transactions on Evolutionary Computation, 6(2):182-197.

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 Meta-heuristics, 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 multi-objective genetic based algorithm, Journal of Microwaves and Optoelectronics 2(6): 59-69.

Vieira, D. A. G., Júnior, A. S. M., Lisboa, A. C., Saldanha, R. R. and Takahashi, R. H. C.(2007). A multi-cut fast ellipsoid optimization method for non-smooth problems, Submitted to Mathematical Programming.

Lisboa, A.C, Vieira, D. A. G., Takahashi, R. H. C., Saldanha, R. R. (2007). Algoritmos de Otimização, disponível em <http://www.cpdee.ufmg.br/~adriano/optimization.pdf>.