

Aplicação de Técnicas de Otimização à Engenharia de Confiabilidade

Este exemplar corresponde à redação final da Dissertação devidamente corrigida e defendida por Marcia de Fatima Platilha Salgado e aprovada pela Banca Examinadora.

Belo Horizonte, 28 de março de 2008.

Prof. Benjamim Rodrigues de Menezes
(Orientador)

Prof. Walmir Matos Caminhas (Co-orientador)

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), UFMG, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica.

Substitua pela ficha catalográfica

(Esta página deve ser o verso da página anterior mesmo no caso em que não se imprime frente e verso, i.é., até 100 páginas.)

Substitua pela folha com as assinaturas da banca

Universidade Federal de Minas Gerais
Escola de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica

Aplicação de Técnicas de Otimização à Engenharia de Confiabilidade

Marcia de Fatima Plátilha Salgado

Março de 2008

Banca Examinadora:

- Prof. Benjamim Rodrigues de Menezes (Orientador)
- Prof. Walmir Matos Caminhas (Co-orientador)
- Prof. Rodney Rezende Saldanha
- Carlos Henrique de Moraes Bomfim

Resumo

O presente trabalho busca apresentar de forma sucinta as técnicas tradicionais de modelagem e análise de confiabilidade e manutenibilidade para sistemas reparáveis e não-reparáveis. Técnicas de Inteligência Computacional são também sucintamente analisadas e suas aplicações mais recentes à engenharia de confiabilidade são relacionadas. Em termos de aplicação, buscou-se exemplificar a utilização de uma técnica de inteligência computacional ao problema de Otimização de Confiabilidade. Esta última refere-se a uma área do conhecimento cujo interesse está voltado para a escolha da arquitetura e dos componentes de um sistema 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 - *Mean Time To Failure*) no caso de sistemas não-reparáveis, ou em termos do Tempo Médio entre Falhas (MTBF - *Mean Time Between Failures*), no caso de sistemas reparáveis. Sob a perspectiva da manutenibilidade, uma medida de interesse é o Tempo Médio para Reparar (MTTR - *Mean Time to Repair*), aplicável somente a sistemas reparáveis. A Disponibilidade (*Availability*) é outra medida utilizada para avaliar o desempenho de sistemas reparáveis e que pode ser estimada a partir do MTBF e do MTTR. Uma vez que a medida de confiabilidade, manutenibilidade e disponibilidade do sistema tenham sido especificadas, outras variáveis de interesse podem também ser consideradas, *e.g.*, o investimento necessário e os custos associados ao projeto e à manutenção do sistema. Tais medidas são obtidas por meio de um processo de modelagem e análise de confiabilidade e manutenibilidade e do custo do ciclo de vida. Uma vez que o sistema tenha sido modelado e as variáveis de interesse tenham sido definidas, um problema de otimização pode ser formulado, *i.e.*, objetivos e restrições são representados matematicamente. As características do problema formulado e das funções-objetivo e restrições

são estudadas para que técnicas de otimização mais adequadas sejam empregadas. Na prática, formulações multi-objetivo (multi-critério ou multi-atributo) são mais indicadas pois permitem a avaliação de aspectos que devem ser considerados simultaneamente em um processo decisório, *e.g.*, o nível de desempenho do sistema deve ser balanceado frente aos custos envolvidos para obtê-lo (análise custo-benefício). O estudo de técnicas de otimização é extremamente importante às engenharias de confiabilidade e manutenibilidade, uma vez que a busca por soluções factíveis com foco na maximização do desempenho e minimização dos custos associados a um sistema são metas intrínsecas às funções desempenhadas pelas engenharias de confiabilidade e manutenibilidade. Os problemas de Otimização de Confiabilidade são, em geral, definidos na forma de programação não-linear mista-inteira. Técnicas determinísticas não são eficientes na solução dessa classe de problemas por estes serem de natureza combinatória e, portanto, não podem ser resolvidos de maneira eficiente em tempo polinomial por nenhum método exato. Esse tipo de problema é conhecido na literatura como NP-difícil (*NP-Hard*). Técnicas estocásticas são mais indicadas nesses casos, o que motiva a aplicação de técnicas da Inteligência Computacional.

Abstract

This thesis aims to present Traditional as well as Computational Intelligence Based techniques for reliability modeling and analysis of repairable and non-repairable systems. The more recent applications of Computational Intelligence techniques to reliability engineering are briefly presented. In order to demonstrate the applicability of Computational Intelligence to reliability optimization problems, evolutionary and immune algorithms are employed on the optimization of generic systems focusing on decision variables such as system design, components reliability and redundancy level besides the costs involved on those decisions. From the reliability engineering perspective systems performance can be measured in terms of Mean Time To Failure (MTTF) in case of non-repairable systems, or in terms of Mean Time Between Failures (MTBF) in case of repairable systems. From the maintainability engineering perspective, a measure of interest is the Mean Time To Repair (MTTR) which is applicable only to repairable systems. All of them are the mean values of probability distributions when stochastic models are employed. The Availability is another measure often used to evaluate repairable systems performance which can be estimated from the MTBF and the MTTR. Once system reliability, maintainability and availability measures have been specified, other variables of interest can also be considered such as investment or costs associated to the design and the maintenance strategies, or from a risk perspective, the failure losses. Such measures might be deduced through a reliability modeling and analysis process and from life cycle cost studies. Once one system has been modeled and the variables of interest have been defined, an optimization problem can be formulated, *i.e.*, objectives and constraints are represented mathematically. The characteristics of the objective and constraints functions are studied so that more suitable optimization techniques can be chosen. In practice, multi-objective formulations (multi-criteria or multi-attribute) are preferred

since they make possible to turn the decision-making process more accurate once simultaneous contradictory objectives are involved, *e.g.*, the system performance level must be maximized while the involved costs must be minimized (cost-benefit analysis). The study of optimization techniques is extremely important once the search for feasible solutions which maximize the performance and minimize the costs associated to a system are intrinsic goals of the reliability and maintainability engineering. Optimization problems are generally defined in the form non-linear mixed-integer programming. Deterministic techniques are not efficient on solving this class of problems since they are combinatorial what make difficult to effectively solve them in polynomial-time by none of exact methods. This type of problem is known in the literature as NP-hard (nondeterministic polynomial-time hard). Stochastic techniques are more suitable in these cases, what motivates the use of Computational Intelligence techniques.

Dedicatória

Para meu esposo Marconi, por todo seu amor.

Agradecimentos

Agradeço a Deus por me guiar em todos os momentos e ter me dado a oportunidade de realizar um sonho há muito sonhado. Meus agradecimentos ao Prof. José Martins de Godoy por sua compreensão e apoio à minha dedicação parcial às atividades de consultoria no Instituto de Desenvolvimento Gerencial (INDG). Ao amigo Carlos Alberto Scapin pela motivação aos meus primeiros passos na Engenharia de Confiabilidade e por seus exemplos, sempre muito esclarecedores, fruto de sua vasta experiência prática. Aos amigos e orientadores Prof. Benjamim Rodrigues de Menezes e Prof. Walmir Matos Caminhas pela orientação e por acreditarem no potencial de contribuição desse trabalho. Aos amigos Adriano Chaves Lisboa e Prof. Rodney Rezende Saldanha pela ótima parceria no desenvolvimento da aplicação de conceitos e técnicas da Otimização de Confiabilidade. Meus agradecimentos aos demais professores do PPGEE e amigos do Laboratório de Inteligência Computacional. Obrigada.

Sumário

Resumo	vii
Abstract	ix
Dedicatória	xi
Agradecimentos	xiii
1 Introdução	1
2 Conceitos Básicos	13
2.1 Sistemas, Modelos e Incerteza	13
2.2 Falhas, Modos e Mecanismos de Falha	16
2.3 Manutenção	17
2.4 Confiabilidade	18
2.5 Manutenibilidade	19
2.6 Disponibilidade	20
2.7 Sistemas Reparáveis e Não-Reparáveis	22
3 Modelagem de Confiabilidade	25
3.1 Modelagem de Sistemas Não-Reparáveis	28
3.1.1 Técnicas Não-Paramétricas	28
3.1.2 Técnicas Paramétricas	29
3.2 Modelagem de Sistemas Reparáveis	32

3.2.1	Técnicas Não-Paramétricas	35
3.2.2	Técnicas Paramétricas	35
3.3	Estimação de Parâmetros	36
3.3.1	Estimador de Máxima Verossimilhança – MLE	37
3.3.2	Estimador de Mínimos Quadrados – LSE	38
3.4	Validação de Modelos - Testes de Adequação	38
3.4.1	Técnicas Gráficas	38
3.4.1.1	Para Sistemas Não-Reparáveis	38
3.4.1.2	Para Sistemas Reparáveis	39
3.4.2	Testes Estatísticos	40
4	Técnicas de Modelagem baseadas em Inteligência Computacional	41
4.1	Redes Neurais Artificiais	41
4.2	Computação Evolucionária	42
4.3	Inteligência de População (<i>Swarm Intelligence</i>)	44
4.4	Sistemas Nebulosos (<i>Fuzzy Systems</i>)	45
4.5	Sistemas Imunológicos Artificiais (<i>Artificial Immune Systems</i>)	46
5	Otimização de Confiabilidade	47
5.1	Problemas de Otimização - Formulação Mono-objetivo	51
5.1.1	Algoritmo genético	55
5.1.2	Algoritmo imune	55
5.1.3	Algoritmo elipsoidal	57
5.1.4	Tratamento de restrições	59
5.2	Resultados - Formulação Mono-objetivo	59
5.3	Problemas de Otimização - Formulação Multi-objetivo	65
5.4	Resultados - Formulação Multi-objetivo	66
6	Conclusões e Propostas de Continuidade	69
A	Probabilidade e Processos Estocásticos	71

A.0.1	Definições	71
A.0.2	Funções de Distribuição de Probabilidade	72
B	Modelagem e Análise de Confiabilidade Sistemica	75
B.1	Diagramas de Bloco de Confiabilidade - RBD (<i>Reliability Block Diagram</i>)	75
B.1.1	Configuração Série	76
B.1.2	Configuração Paralela	76
B.1.3	Configuração Série-Paralela	78
B.1.4	Configuração Paralelo-série	79
B.1.5	Configuração k-de-n	80
B.1.6	Sistemas Redundantes	80
B.1.7	Configuração Complexa	82
B.1.7.1	Método de Redução	82
B.1.7.2	Método da Decomposição	84
B.1.7.3	Método de Conjunto de Cortes Mínimos	87
B.2	Análise dos Modos e Efeitos de Falha - FMEA (<i>Failure Mode and Effect Analysis</i>)	88
B.3	Análise de Árvore de Falhas - FTA (<i>Fault Tree Analysis</i>)	89
B.4	Cadeias de Markov	91
B.5	Redes Petri	91
B.6	Redes Bayesianas	91
B.7	Simulação de Monte Carlo	92
	Referências Bibliográficas	6

Lista de Tabelas

5.1	Parâmetros para as instâncias de configuração série e complexa.	60
5.2	Parâmetros para a instância de configuração série-paralela.	60
5.3	Melhores resultados da otimização do sistema série.	61
5.4	Melhores resultados da otimização do sistema série-paralelo.	62
5.5	Melhores resultados da otimização do sistema complexo.	63

Lista de Figuras

1.1	Visão geral da engenharia de sistemas.	2
1.2	Problemas de interesse na Engenharia de Confiabilidade e Manutenibilidade.	6
2.1	Modelos de representação da incerteza.	15
3.1	Fluxograma genérico para modelagem e análise matemática de sistemas	27
3.2	Estimativa de Confiabilidade utilizando estimador de Kaplan-Meier para dados de falha gerados aleatoriamente segundo uma distribuição exponencial. Para a estimativa, utilizou-se a função <code>ecdf(.)</code> do <i>Statistical Toolbox</i> do Matlab®	29
3.3	Exemplo de MCF para dados de falha de um sistema reparável. A MCF foi obtida utilizando-se o pacote estatístico Minitab® 15.1.1.0.	36
5.1	Sistema série genérico com cinco sub-sistemas.	51
5.2	Sistema série-paralelo genérico com cinco sub-sistemas.	51
5.3	Sistema complexo (ponte) com cinco sub-sistemas.	52
5.4	Sistema equivalente para o sistema série quando um componente redundante é alocado em cada um de seus sub-sistemas e possui confiabilidade r_i igual ao componente original do sub-sistema.	53
5.5	Estrutura básica do algoritmo genético (Ashlock, 2005).	56
5.6	Estrutura básica do algoritmo imune (de Castro and Zuben, 2002).	56
5.7	Atualização iterativa de uma elipse com o corte de um semiplano.	58
5.8	Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema série.	61

5.9	Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema série-paralelo.	62
5.10	Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema complexo.	63
5.11	Impacto da confiabilidade de componentes na confiabilidade de sistemas série. . .	64
5.12	Nova arquitetura para o sistema série.	65
5.13	Curva Pareto-ótimo para confiabilidade e custo do sistema série	67
5.14	Curva Pareto-ótimo para confiabilidade e custo do sistema série-paralelo	67
5.15	Curva Pareto-ótimo para confiabilidade e custo do sistema complexo	68
A.1	Modelos probabilísticos e parâmetros usualmente empregados em estudos de Confiabilidade	73
B.1	Sistema série genérico com m componentes	76
B.2	Sistema paralelo genérico com n sub-sistemas ou componentes	77
B.3	Sistema série-paralelo genérico com m sub-sistemas em série consistindo em m_i ($i = 1, 2, \dots, n$) componentes em paralelo.	78
B.4	Sistema paralelo-série genérico com m sub-sistemas em paralelo consistindo em n_i ($i = 1, 2, \dots, m$) componentes em série.	79
B.5	Sistema redundante com n componentes e sub-sistema de chaveamento S - <i>Cold Standby</i>	81
B.6	Sistema complexo genérico com 7 sub-sistemas	83
B.7	Sistema equivalente para B.6, sendo $R_A = 1 - (1 - R_4)(1 - R_5)$ e $R_B = R_2R_3$. . .	83
B.8	Sistema equivalente para B.7, sendo $R_C = R_A R_6$	84
B.9	Sistema equivalente para B.8, sendo $R_D = 1 - (1 - R_B)(1 - R_C)$	84
B.10	Sistema equivalente para B.9, sendo $R_S = R_1 R_D R_7$	85
B.11	Sistema ponte genérico com 5 sub-sistemas	85
B.12	Sistema ponte equivalente com componente 5 assumido como livre de falhas. . .	85
B.13	Sistema ponte equivalente com componente 5 em estado de falha.	86
B.14	Exemplo de tabela utilizada na aplicação de FMEA.	90

Capítulo 1

Introdução

”Systems involving interactions between man, nature and technology are subject to disturbance which may be unlike anything which has been experienced in the past. In particular, the technological revolution increases uncertainty as each new stage perturbs existing structures, limitations and constraints.” (Najim et al., 2004)

A complexidade dos sistemas reais vem aumentando continuamente nos últimos anos, e com isso vem crescendo ainda mais a atenção dada a problemas relacionados à confiabilidade, manutenibilidade e segurança. Isso se deve especialmente ao fato de que as perdas geradas pelas falhas de sistemas complexos podem ser significativas, ou mesmo irreversíveis. 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, a aplicação de conceitos e técnicas da engenharia de confiabilidade, manutenibilidade e segurança, aliados a outras áreas do conhecimento não menos importantes, são essenciais ao projeto, à operação e à manutenção de sistemas a custos compatíveis, riscos mais baixos e com desempenho desejado.

As engenharias de confiabilidade e de manutenibilidade configuram-se como importantes áreas do conhecimento e se inserem no contexto da engenharia de sistemas, a qual é responsável pela integração das duas primeiras a outras disciplinas como Suporte Logístico Integrado, Segurança, Produção/Operação, Testes/Verificação e Garantia da Qualidade, conforme apresentado na Figura 1.1. A seguir são relacionadas as funções de cada uma das disciplinas que integram a

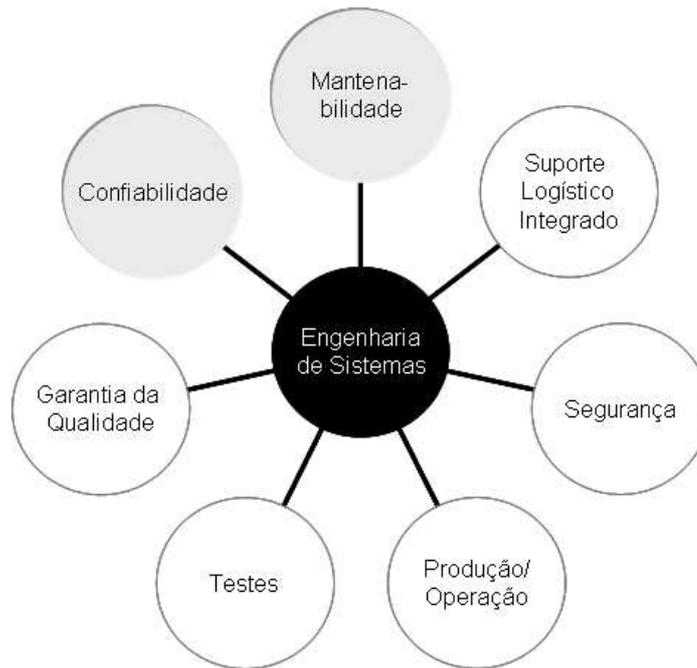


Figura 1.1: Visão geral da engenharia de sistemas.

engenharia de sistemas (NASA, 1995; U.S.F.A.A, 2000):

Confiabilidade: A engenharia de confiabilidade desenvolve e executa programas com foco na modelagem e análise, predição e otimização de confiabilidade, considerando aspectos ambientais e operacionais (*e.g.*, condições de vibração, acústica, térmica, interferência eletromagnética (*Electromagnetic Interference* - EMI) e compatibilidade eletromagnética (*Electromagnetic Compatibility* - EMC)). Define e aloca metas de confiabilidade, estabelece as condições operacionais, auxilia na avaliação de arquiteturas / alternativas de projeto avaliando questões como grau de redundâncias e impacto na confiabilidade versus a manutenibilidade de sistemas. Presta suporte a programas de gestão de riscos, identificando atributos de projeto que apresentam maiores chances de resultarem em problemas de confiabilidade e recomendando ações para mitigar tais riscos. Gera informações de confiabilidade a serem utilizadas em programas de manutenibilidade e logística integrada. Estabelece os requisitos e especificações para testes de qualificação de projetos, sendo responsável por prover análises técnicas e justificativas para eliminar ou flexibilizar tais requisitos. Analisa dados dos testes de qualificação para validar os modelos e predições de confiabilidade, buscando

entender e resolver quaisquer anomalias identificadas. Coleta e analisa dados de confiabilidade de sistemas já em operação como parte da validação do projeto e atendimento às metas estabelecidas;

Mantenabilidade: A engenharia de manutenibilidade desenvolve e executa o plano para o programa de manutenibilidade de sistemas, o qual deve ser estabelecido concomitantemente ao plano de logística integrada. Desenvolve e refina o conceito de manutenção de sistemas alinhado ao conceito de logística integrada. Estabelece e aloca requisitos de manutenibilidade consistentes com o conceito de manutenção e coerente com a disponibilidade (vide seção 2.6) requerida para o sistema. Participa e contribui com a avaliação dos projetos de engenharia para identificar deficiências associadas à manutenibilidade. Realiza e documenta análises para quantificar os recursos necessários à manutenção. Coleta e analisa dados de manutenção de sistemas em operação e verifica se as metas de manutenibilidade e de logística integrada são atendidas;

Suporte logístico integrado: O suporte logístico integrado é responsável por todas as atividades de suporte para o alcance das metas de desempenho projetadas. Engloba a especificação das ações de manutenção, projeto de interfaces nos processos com foco em minimizar o custo do ciclo de vida, registrar dados e informações de engenharia, de técnicas e de custos utilizados nos estudos e avaliações do sistema ao longo do seu ciclo de vida. Especifica os recursos humanos mapeando suas habilidades e competências e necessidade de treinamentos considerando os custos atuais e futuros nas funções operação, manutenção, engenharia e administrativas que dão suporte aos sistemas. Especifica as ferramentas e instrumentos necessários ao desenvolvimento, produção e operação dos sistemas assim como a estrutura física/instalações. É também responsável pela especificação dos recursos e métodos de transporte, manuseio e estocagem de peças e materiais com foco em garantir que as metas de suportabilidade e usabilidade dos sistemas sejam atingidas;

Segurança: A engenharia de segurança é responsável por garantir o projeto seguro de sistemas críticos com o foco de prevenção contra acidentes (impacto em vidas humanas e ambientais). Para isso, avalia projetos objetivando identificar deficiências (riscos de segurança)

e propor modificações e procedimentos que garantam a operação e manutenção seguras. A perspectiva da engenharia de segurança difere um pouco da perspectiva da engenharia de confiabilidade. A primeira busca introduzir soluções ou conceitos tecnológicos com o intuito de eliminar ou controlar os riscos de ocorrência de eventos que possam causar acidentes ou outros efeitos indesejáveis, enquanto a segunda é responsável por introduzir funcionalidades que garantam o cumprimento da missão do sistema. Eventualmente a introdução de certas funcionalidades é válida no contexto da engenharia de confiabilidade, ou seja, aumenta as chances do sistema cumprir sua missão, no entanto aumenta também as chances de um acidente acontecer;

Produção/Operação: A engenharia de produção é responsável pela gestão de riscos no processo de manufatura/fabricação por meio da condução de avaliação de riscos e planejamento das ações para mitigá-los. É também responsável pela identificação de funcionalidades de projeto com foco no aumento de produtividade. Seus esforços são direcionados a simplificação de projetos, especificação das tolerâncias de fabricação e seleção de materiais. Conduz estudos de produtividade para determinar processos de manufatura/fabricação custo-efetivos. É responsável por avaliar relações custo-benefício considerando as restrições de projeto, o que pode incluir a avaliação de fornecedores (experiência e capacidade), a avaliação de tecnologias de fabricação, avaliação de ferramentas especiais e necessidade de treinamentos de operadores de produção, assim como a avaliação de materiais críticos. Também estima custos de produção como parte do processo de gestão do custo do ciclo de vida, desenvolve plano de produção assim como abordagens e planos para validar os processos de manufatura/fabricação;

Testes/Verificação: Teste e verificação é o processo de avaliar a adequação dos resultados de um sistema aos requisitos do ponto de vista funcional, desempenho e de projeto. O processo compreende o planejamento, definição de requisitos e atividades de adequação o qual se desenvolve ao longo de todo o ciclo de vida de um dado sistema. Em cada estágio do processo, o engenheiro de sistemas busca compreender e avaliar os resultados do processo de verificação e propõe as soluções aplicáveis;

Garantia da Qualidade: A garantia da qualidade é responsável por garantir que as especificações de projeto sejam atendidas. Para isso, desenvolve e executa planos de garantia da qualidade por meio do qual verifica o cumprimento de todas as especificações previamente estabelecidas. Estabelece inspeções e auditorias para verificar a adequação dos processos às especificações e registra todos os dados para análises futuras.

O desenvolvimento dos conceitos das engenharias de confiabilidade e de manutenibilidade teve início há pouco mais de sessenta anos, mais especificamente e com maior intensidade, durante a II Guerra Mundial com sua aplicação a sistemas de comunicação e projeto de armas de guerra¹

De maneira mais formal, as engenharias de confiabilidade e de manutenibilidade são áreas da engenharia de sistemas que têm como objetivos (O'Connor, 2002; Dhillon, 2006):

- aplicar o conhecimento de engenharia e técnicas específicas para prevenir ou reduzir a frequência de falhas;
- identificar e solucionar as causas das falhas que ocorrem, mesmo com todo o esforço realizado em projeto para evitá-las;
- estabelecer formas de atuar sobre as falhas cujas causas não foram solucionadas em projeto;
- aplicar métodos para a estimação da confiabilidade e manutenibilidade de novas arquiteturas, e para a análise de dados de confiabilidade e manutenibilidade.

Tais objetivos podem ser trabalhados no contexto da Inteligência Computacional abordando-se três problemas típicos de interesse na Engenharia de Confiabilidade e que são complementares, a citar (Figura 1.2):

1. O problema da modelagem, ou seja, a identificação de um modelo que descreva a confiabilidade de um sistema dado um perfil de falhas e/ou conhecimento de especialistas;

¹Mais detalhes sobre o início do desenvolvimento e sobre aplicações das engenharias de confiabilidade e de manutenibilidade podem ser obtidos em Kececioğlu, 2002 e Dhillon, 2006, respectivamente.

2. O problema da predição de confiabilidade, ou seja, o uso dos modelos em técnicas para o diagnóstico e prognóstico de falhas com o objetivo de se estimar em algum instante futuro a confiabilidade do sistema em estudo;
3. O problema da otimização de confiabilidade com foco em melhorar o desempenho de sistemas frente às limitações tecnológicas e financeiras.

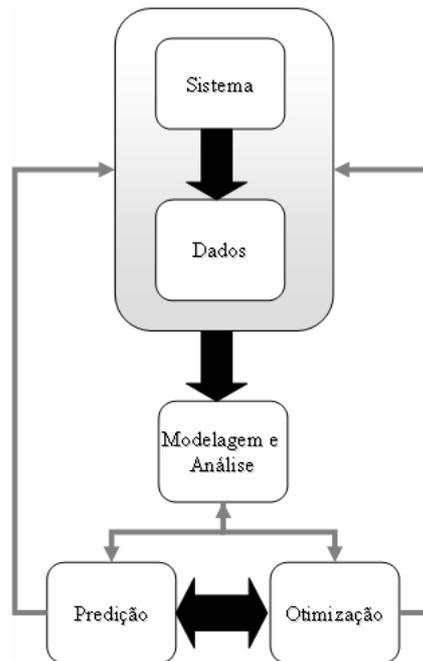


Figura 1.2: Problemas de interesse na Engenharia de Confiabilidade e Manutenibilidade.

A modelagem e análise de sistemas sob o ponto de vista da confiabilidade e da manutenibilidade podem ser realizadas por meio de técnicas qualitativas e quantitativas. 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 freqüentemente, não estão disponíveis. Assim, a análise de dados de falha de sistemas reais utilizando técnicas tradicionais pode gerar informações questionáveis que conduzem 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. Técnicas qualitativas são utilizadas quando não há disponibilidade de dados ou o custo de obtenção de modelos matemáticos é muito alto. Modelos qualitativos podem ser utilizados nesses casos com o objetivo de se obter maior conhecimento sobre um problema ou sistema em estudo, o que pode eventualmente gerar bons resultados em um primeiro momento.

Como em outras áreas do conhecimento, para que estudos quantitativos de confiabilidade e de manutenibilidade de sistemas reais possam ser realizados é, em geral, necessária a obtenção de uma representação matemática do sistema em estudo. Ao processo de construção e implementação de modelos matemáticos de sistemas reais dá-se o nome de modelagem matemática (Aguirre, 2007). A fundamentação matemática das técnicas tradicionais utilizadas na modelagem de confiabilidade e de manutenibilidade de sistemas baseia-se na teoria de conjuntos clássica, probabilidade e de processos estocásticos (Papoulis, 1991).

Embora as técnicas tradicionais de modelagem e análise de confiabilidade (e de manutenibilidade) estejam bastante desenvolvidas, na última década houve um avanço significativo na sua aplicação devido, em especial, à evolução dos recursos computacionais (*hardware* e *software*), que até então representavam forte limitação à realização de estudos quantitativos de sistemas complexos.

Mais recentemente, técnicas alternativas de modelagem e análise de sistemas complexos têm sido empregadas em várias áreas do conhecimento, inclusive em estudos de confiabilidade e de manutenibilidade. Tais técnicas são denominadas técnicas de Inteligência Computacional (IC), e são parte do campo de pesquisa denominado Inteligência Artificial (IA). O termo Inteligência Computacional (IC) é utilizado pois estas novas técnicas são inspiradas nos mecanismos de adaptação presentes na natureza, os quais permitem ou facilitam o comportamento inteligente

de sistemas em ambientes complexos e dinâmicos. Estes mecanismos incluem os paradigmas advindos da IA, que apresentam, em um certo sentido, a capacidade de aprender e de se adaptar a novas situações, de generalizar, de abstrair, de descobrir e de associar. Algumas destas novas técnicas são as redes neurais artificiais, a computação evolucionária, a inteligência de população, sistemas nebulosos e sistemas imunológicos artificiais).

Najim *et al.* (2004) e de B. Pereira and Rao (2005) demonstram a aplicação de redes neurais no problema de modelagem de confiabilidade utilizadas para aproximar funções densidade de probabilidade e nas análises de dados de falha. Mais detalhes sobre o projeto e aplicações de redes neurais artificiais podem ser obtidos em Haykin (1999). Engelbrecht (2003) fornece uma visão geral das técnicas redes neurais artificiais e sistemas nebulosos, assim como da computação evolucionária, inteligência de população. Estas duas últimas têm sido empregadas para resolver problemas de otimização global, por se tratarem de técnicas estocásticas que permitem uma melhor exploração do espaço de busca.

Sistemas nebulosos (*fuzzy systems*) baseiam-se na teoria da lógica nebulosa (*fuzzy logic*), na qual a incerteza devido à imprecisão ou informação vaga é modelada por meio de funções de pertinência (Jang, 1997). A idéia principal no uso da lógica nebulosa é a de modelar o raciocínio humano por meio de variáveis linguísticas e as regras pelas quais as mesmas se relacionam. Constitui-se em uma ferramenta poderosa, pois na prática a informação necessária à modelagem ou análise de um problema ou sistema de interesse somente pode ser obtida por meio de um processo de elicitación, no qual especialistas são consultados. Muitas vezes os especialistas não são capazes de expressar o seu conhecimento de forma numérica. Na engenharia de confiabilidade esse é um problema bastante comum e que restringe o uso de técnicas tradicionais baseadas em modelos estocásticos. As técnicas nebulosas são então alternativas interessantes que podem viabilizar o desenvolvimento de técnicas de modelagem e análise que incorporem o conhecimento tácito dos especialistas, e que sejam menos dependentes da disponibilidade de dados históricos.

Confiabilidade nebulosa (*fuzzy reliability*) é o termo empregado na comunidade científica para se referir às técnicas de modelagem e análise de confiabilidade baseadas em modelos nebulosos. Como comentado na seção 2.1, em confiabilidade nebulosa, ao invés de se empregar distribuições de probabilidade, utiliza-se distribuições de possibilidades, e a maioria das técnicas

de modelagem gráficas como RBD e FTA (Vide anexos B.1 e B.3) podem ser quantificadas por meio de modelos nebulosos, ao invés de modelos estocásticos. Em Sandri *et al.* (1990) o processo de elicitação para o desenvolvimento de modelos possibilísticos é investigado. Dubois *et al.* (1993) investiga a transformação de modelos estocásticos em modelos possibilísticos. Em Levitin (2007) exemplos de aplicação da confiabilidade nebulosa são apresentados.

Mais recentemente uma classe de algoritmos inspirada em mecanismos de sistemas imunológicos têm sido aplicadas a diversos problemas de diagnóstico de falhas e reconhecimento de padrões (de Castro and Zuben, 2002; de Castro e Silva, 2008).

No presente trabalho, um algoritmo imune baseado no princípio da seleção clonal, o qual é bem explicado por de Castro Silva (2003), é utilizado para solução de um problema de Otimização de Confiabilidade e comparado a um algoritmo genético (vide 5). Há vários outros princípios dos Sistemas Imunológicos que podem ser aplicados a diversos problemas complexos de engenharia.

As técnicas de computação evolucionária têm como objetivo modelar o processo de evolução natural, onde o principal conceito associado é o de sobrevivência dos mais adaptados ao ambiente. Na evolução natural, a capacidade de sobrevivência é atingida por meio de um processo de reprodução, cujos filhos que são gerados de dois ou mais pais, contêm material genético de ambos ou todos, e com as melhores características de todos. Os indivíduos que herdaram características ruins, são fracos e perdem a batalha pela sobrevivência.

Em computação evolucionária uma população de indivíduos é gerada para evoluir. Um indivíduo é denominado cromossomo. Um cromossomo define as características de indivíduos em uma população. Cada característica é denominada gene. O valor de um gene é denominado alelo. Para cada geração, indivíduos competem para reproduzir e gerarem filhos. Os indivíduos com melhor capacidade de sobrevivência têm maiores chances de se reproduzirem. Um filho é gerado pela combinação de partes dos pais por um processo denominado cruzamento (*crossover*). Cada indivíduo na população pode sofrer mutações que alteram alguns dos alelos do cromossomo.

A força de sobrevivência de um indivíduo é medida usando uma função de adequação (*fitness*), a qual reflete os objetivos e as restrições do problema a ser resolvido. Após cada geração, os melhores indivíduos podem ser selecionados para a próxima geração (elitismo). Além disso

características comportamentais podem ser usadas para influenciar o processo evolucionário de duas formas: fenótipos podem ser influenciados por meio de mudanças genéticas, e/ou características comportamentais separadamente, promovendo um desenvolvimento gradual e natural dos indivíduos de uma população.

Mais detalhes sobre o projeto e aplicações da computação evolucionária podem ser obtidos em Ashlock (2005), Menon (2004) e Jong (1997). Levitin (2007) apresenta diversos exemplos de aplicação de técnicas de computação evolucionária a problemas de engenharia de confiabilidade.

Inteligência de população é um conceito relativamente novo, com muito potencial de desenvolvimento e ainda com poucas aplicações a problemas reais. O conceito originou-se do estudo de colônias ou populações de indivíduos sociais. Estudos de comportamento social de organismos em colônias são empregados no projeto de algoritmos de otimização e clusterização muito eficientes (Kennedy and Eberhart, 2001).

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, *e.g.*, em avaliações da capacidade produtiva de um processo (*Throughput Analysis*). 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 sistêmico e, assim, técnicas convencionais de modelagem podem ser facilmente empregadas. 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 têm sido desenvolvidas com o objetivo de propor soluções alternativas que possuam características adaptativas e sejam capazes de 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 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. 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 da disponibilidade (*Availability*) do sistema que é uma relação entre o tempo médio entre falhas (**MTBF** ou *Mean Time Between Failures*) e do Tempo Médio para Reparar (**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/perdas associadas 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).

Tendências atuais apontam para o aumento da utilização de técnicas da Inteligência Computacional, aliadas às técnicas tradicionais, com o objetivo de desenvolver metodologias mais eficientes para a modelagem e análise (identificação), predição de desempenho e otimização de sistemas complexos, com foco em confiabilidade e manutenibilidade, o que motivou o

desenvolvimento do presente trabalho (Figura 1.2). As técnicas tradicionais e de inteligência computacional aplicáveis aos três problemas anteriormente citados são pesquisadas.

O problema de otimização de confiabilidade é o foco do presente trabalho por se tratar de uma tema de interesse prático, o qual responde a alguns dos questionamentos mais frequentes no dia-a-dia de engenheiros de manutenção, confiabilidade e manutenibilidade, quais sejam: Como projetar sistemas otimizados sob a perspectiva custos e desempenho? Como estabelecer políticas e práticas de manutenção que produzam uma melhor relação custo-benefício (custos x desempenho em termos de confiabilidade, manutenibilidade e disponibilidade)? Como balancear o atendimento a requisitos de confiabilidade e manutenibilidade aos recursos disponíveis? Com o objetivo de exemplificar a aplicabilidade de técnicas de Otimização baseadas em Inteligência Computacional ao problema de otimização de confiabilidade, foram resolvidos três problemas de alocação de redundâncias e confiabilidade a sistemas genéricos com arquiteturas em série, série-paralelo e ponte (Salgado *et al.*, 2007).

O texto está organizado como segue: Nos capítulos 2 e 3, os conceitos básicos de engenharia de confiabilidade e os problemas de modelagem e análise de confiabilidade e manutenibilidade de sistemas reparáveis e não-reparáveis por meio de técnicas tradicionais são revisados. No Capítulo 5, o problema de otimização de confiabilidade é introduzido de forma mais detalhada seguido de um exemplo de aplicação de uma técnica de Inteligência Computacional. Finalmente, no capítulo 6, apresentam-se algumas conclusões e propostas de continuidade.

Capítulo 2

Conceitos Básicos

”No industry in any country can progress effectively without the knowledge and implementation of reliability engineering. Today it has developed to a high degree of refinement and quantification. All countries should seize upon the opportunity to enlighten their scientists, engineers and industrial and government personnel in this field. Such personnel should enhance their technical and industrial progress by learning the principles of reliability engineering and by applying these principles in their daily efforts.” (Kececioglu, 2002)

2.1 Sistemas, Modelos e Incerteza

Um sistema é um conjunto integrado de “componentes” projetado para cumprir um objetivo (INCOSE, 2002). Um modelo para um sistema real é uma representação utilizada para que algumas características de interesse possam ser estudadas. A complexidade aumenta à medida que mais características são introduzidas no modelo de forma aproximá-lo cada vez mais do sistema real. Assim, a escolha da técnica de modelagem depende da aplicação pretendida para o modelo e há várias considerações que devem ser feitas antes de se iniciar a modelagem de um sistema, as quais fornecem indicativos sobre a natureza dos modelos a serem adotados, como: O sistema é linear ou não-linear? É invariante com o tempo? É um sistema a parâmetros concentrados ou distribuídos? O sistema é reparável ou não-reparável? Que características do sistema precisam ser representadas?, entre outras questões.

Em modelagem matemática há diferentes abordagens que podem ser adotadas para o de-

envolvimento de modelos. Uma das abordagens é a modelagem caixa branca, em que é possível descrever o sistema por meio de relações matemáticas para os fenômenos de interesse. É também conhecida por modelagem pela física ou conceitual. Esse tipo de abordagem é demorada e requer muito conhecimento técnico sobre o sistema em estudo. No campo de confiabilidade e manutenibilidade, por exemplo, pode ser interessante o desenvolvimento de modelos que associam características físicas do sistema em estudo com variáveis de stress ou condições de operação de forma que a frequência de falhas do sistema possa ser estimada. Em NSWC (2007) são apresentados modelos matemáticos para a taxa de falha (vide capítulo 3) como função de parâmetros físicos de componentes de sistemas mecânicos.

Outra abordagem é a modelagem caixa preta ou empírica. A modelagem empírica é pouco, ou mesmo independente, do conhecimento prévio do sistema em estudo, o que em muitos casos práticos apresenta-se como uma melhor alternativa. A modelagem cinzenta é uma abordagem intermediária empregada quando algum conhecimento a priori ou auxiliar, além dos dados disponíveis (*e.g.*, conhecimento de especialistas), é considerado para a modelagem do sistema. Há vários tipos de modelos matemáticos, por exemplo: estáticos e dinâmicos, discretos e contínuos, monovariáveis e multivariáveis, determinísticos e não-determinísticos (estocásticos, nebulosos, possibilistas, etc.), paramétricos e não-paramétricos, entre outros (Aguirre, 2007).

Em engenharia de confiabilidade e manutenibilidade os modelos matemáticos mais empregados são, em geral, não-determinísticos, mais especificamente, modelos estocásticos por estes serem adequados à representação de fenômenos de natureza aleatória. A entrada para um modelo estocástico é uma série de eventos de interesse, e a saída do modelo é uma variável aleatória (Papoulis, 1991). Em engenharia de confiabilidade os eventos de interesse são as falhas (ou sucessos) do sistema, e na engenharia de manutenibilidade os eventos de interesse são os reparos do sistema (em sistemas reparáveis).

Um conceito muito importante associado à confiabilidade é o de incerteza. O termo incerteza é usualmente entendido e empregado quando se fala em fenômenos de natureza aleatória, embora a aleatoriedade não seja a única fonte de incerteza¹.

¹É também utilizado o termo informação imperfeita como forma a se referir a outras fontes de incerteza além da aleatoriedade, o qual está associado à natureza da informação disponível sobre um fenômeno/evento. A informação pode variar de perfeita a imperfeita podendo ser imprecisa, vaga, possibilista, incompleta, inconsistente,

<p style="text-align: center;">Modelo Nebuloso</p> <ul style="list-style-type: none"> • Baseado na Teoria de Conjuntos Nebulosos; • Uso de funções de pertinência para variáveis nebulosas; • Conceito de grau de pertinência e classes 	<p style="text-align: center;">Modelo Estocástico</p> <ul style="list-style-type: none"> • Baseado na Teoria de Conjuntos Clássica e de Probabilidade; • Caso particular de modelo de evidência; • Uso de funções de distribuição de probabilidade para variáveis aleatórias.
<p style="text-align: center;">Modelo Possibilista</p> <ul style="list-style-type: none"> • Baseado na Teoria de Possibilidade; • Uso de funções de distribuição de possibilidades para as funções de pertinência com os valores possíveis de variáveis nebulosas. 	<p style="text-align: center;">Modelo da Evidência</p> <ul style="list-style-type: none"> • Função de credibilidade • Função de plausibilidade

Figura 2.1: Modelos de representação da incerteza.

Há vários modelos de representação da incerteza dependendo da sua natureza. Em Bittencourt (2008) uma revisão da literatura no assunto está disponível, e outros três modelos, além dos estocásticos, são apresentados: nebuloso, possibilista e da evidência (Figura 2.1).

A motivação para o emprego de outras formas de representação da incerteza que não os modelos estocásticos é justificada pela prática, pois informações sobre o que é falha ou não é falha, quando e quantas vezes tal falha ocorreu, em que circunstâncias, quais suas causas, e assim por diante, muitas vezes não estão registradas. Nessas situações, conhecimento de especialistas/técnicos (conhecimento baseado em experiência e/ou impressões), sejam elas quantitativas ou qualitativas, precisam ser utilizadas.

É, em geral, muito difícil obter informações probabilistas de especialistas, os quais, em geral, não são capazes de expressar seu conhecimento em variáveis numéricas, sendo as variáveis linguísticas mais apropriadas. Ao processo de obtenção de informações de especialistas dá-se o nome de *elicitação*. Em Dubois and Kalfsbeek (1990) e O'Hagan *et al.* 2006 são apresentadas metodologias de elicitação para obtenção de modelos possibilistas e estocásticos (probabilistas),

conflitante, etc. Para cada tipo de informação há um tratamento mais adequado

respectivamente.

Técnicas de inteligência computacional são ferramentas que têm sido aplicadas com sucesso para os estudos de confiabilidade e manutenibilidade de sistemas por meio de técnicas não-determinísticas alternativas. Os modelos matemáticos utilizados em técnicas tradicionais de engenharia de confiabilidade (e de manutenibilidade) são apresentados no Capítulo 3. Uma introdução às técnicas de inteligência computacional aplicáveis aos problemas de modelagem e análise, predição e otimização de sistemas com foco em confiabilidade e manutenibilidade são apresentadas no Capítulo 5.

2.2 Falhas, Modos e Mecanismos de Falha

O conceito de falha está associado ao não-atendimento a uma missão/função. Há diversas descrições possíveis para falhas dependendo de um contexto. Falha (*failure*) refere-se a um evento que representa o *término da capacidade de um item desempenhar a função requerida*. O conceito de falha difere do conceito de defeito (*fault*) o qual se refere a *qualquer desvio de uma característica de um item em relação aos seus requisitos*. Um defeito nem sempre afeta a capacidade de um item desempenhar sua função requerida (NBR-5462, 1994). Por outro lado, falhas estão sempre relacionadas a um ou mais defeitos. Quando sistemas/produtos são projetados, sua missão e funções são especificadas. A missão e funções podem ser mensuradas por meio de parâmetros para os quais são especificados os valores e faixas de variação e de segurança. Quando em operação/produção, um sistema ou produto, que não apresente o desempenho dentro das faixas especificadas é dito estar em estado de falha. Algumas vezes, não é possível a definição de um parâmetro mensurável, e a detecção da falha depende da experiência ou da percepção do técnico ou usuário do sistema (especialistas).

O termo modo de falha refere-se à forma como uma falha se manifesta. O modo de falha funcional refere-se à forma como o sistema/ componente deixa de cumprir sua missão/função. O modo de falha físico refere-se a uma característica observável, mensurável ou não, relacionada a um fenômeno físico de deterioração e/ou degradação. Mecanismos de falhas referem-se a processos de falha com um ou mais modos de falha (conjunto de fatores causais que geram uma

falha).

Falhas podem ser classificadas de várias maneiras. Com relação ao seu desenvolvimento, as falhas podem ser incipientes, abruptas, catastróficas (Palade *et al.*, 2006). Com relação às fases do ciclo de vida de um sistema, as falhas podem ser classificadas como precoces, aleatórias, e por desgaste (Moubrey, 2001). Falhas sob o ponto de vista funcional, podem ser primárias, secundárias e de comando (Scapin, 1999).

O conceito de falha nem sempre é utilizado adequadamente e, muitas vezes, os modos de falha funcionais e físicos de sistemas não estão devidamente registrados. Por exemplo, é comum encontrar bases de dados que indicam somente as falhas catastróficas, e nem mesmo apontam os modos de falha e suas causas. Esse é um dos principais problemas práticos enfrentado por engenheiros de confiabilidade no seu dia-a-dia, pois modelos estocásticos não produzem bons resultados dependendo da qualidade dos dados utilizados na sua construção.

2.3 Manutenção

O termo manutenção refere-se a todas as atividades/ações necessárias para restaurar e/ou prevenir a ocorrência ou reincidência de falhas em sistemas/componentes. Políticas de manutenção são estabelecidas de acordo com o perfil de falhas observado ou potencial. As políticas orientam as práticas de manutenção, as quais podem ser reativas ou pró-ativas. Uma prática será classificada como reativa quando for motivada pela ocorrência de uma falha funcional, e pró-ativa, se a decisão pela sua realização não depende da ocorrência efetiva da falha, mas do seu potencial (possibilidade ou probabilidade) de ocorrência (Mobley, 2004; Higgins *et al.*, 2002). Práticas reativas são indicadas desde que sejam estabelecidas de forma consciente, em razão de uma análise comparativa entre o risco de ocorrência de uma falha e os custos/impacto envolvidos, ou seja, manutenção corretiva sem planejamento deve ser evitada. Práticas pró-ativas incluem a aplicação dos princípios da engenharia de confiabilidade, análises de falhas, e reprojeto de sistemas, entre outras, para que as causas de falhas sejam eliminadas permanentemente (Dhillon, 2002).

Processos industriais utilizam em geral duas abordagens de manutenção: (1) corretiva

e (2) preventiva. Na primeira abordagem a ocorrência de uma falha, em geral catastrófica, é “aguardada” para que uma ação de manutenção seja executada (troca ou reparo). Na segunda abordagem, as ações de manutenção são pré-estabelecidas conforme o perfil de falhas típico (modos de falha predominantes), podendo se basear no tempo ou na condição. No último caso, a manutenção é denominada preditiva (Mobley, 2004).

Um aspecto relevante na definição de manutenção é seu escopo de atuação que, de acordo com conceitos mais atuais, refere-se ao seu papel de restabelecer/restaurar a função dos sistemas sobre o qual executa algum tipo de ação. Muito embora a abordagem corretiva seja adotada em algumas circunstâncias, o foco da manutenção deveria ser predominantemente voltado à prevenção.

A execução da manutenção para restaurar a função se dá através de reparos ou trocas de componentes que falharam. A ação de reparo pode ser perfeita ou imperfeita. Reparo perfeito refere-se à troca de um ou mais componentes (o componente que apresentou falha mais outros na iminência ou com potencial de falha) restaurando as funcionalidades originais do sistema, ou seja, o sistema/componente estará em uma condição de tão-bom-quanto-novo (*as-good-as-new*). Reparo imperfeito refere-se à troca/reparo do componente que falhou levando o sistema à condição em que se encontrava antes da falha ou tão-bom-quanto-velho (*as-good-as-old*), também conhecido como reparo mínimo. Estas classificações referem-se à medição do potencial de falha do sistema, que é usualmente conhecido como taxa de falha em sistemas não-reparáveis e intensidade de falha em sistemas reparáveis. Tais conceitos são muito importantes, pois a partir deles os modelos estocásticos tradicionais a serem utilizados, sejam eles paramétricos ou não-paramétricos, podem ser construídos e interpretados.

2.4 Confiabilidade

A definição tradicional de confiabilidade assume que modelos estocásticos são adequados para modelar dados de falha, e é a definição encontrada na maior parte da literatura disponível sobre o assunto. No entanto, como decorrência de outros modelos para representação de incerteza apresentados na seção 2.1 do presente trabalho, outras definições de confiabilidade podem

ser formuladas, substituindo-se probabilidades por outras formas de representação, como por exemplo, possibilidades (Sandri *et al.*, 1990).

Kececioglu (2002) apresenta uma definição tradicional de confiabilidade como: a probabilidade condicional, a um dado nível de confiança, de que um sistema irá executar suas funções de maneira satisfatória ou sem falhas, *i.e.*, dentro dos limites de desempenho especificados, em uma certa idade, por um período de tempo especificado, ou pelo tempo de missão, quando utilizado da maneira e com o objetivo para o qual foi projetado, e operando sob as condições ambientais de aplicação e contexto operacionais com um certo nível de stress associado.

A definição de confiabilidade apresentada é bastante restritiva e preconiza o uso de técnicas tradicionais de probabilidade e estatística para o cálculo de confiabilidade. A definição é restritiva uma vez que há a necessidade de se determinar o que é “falha” além de se especificar, ou isolar, de forma objetiva todos fatores causais ou relevantes que propiciam o seu desenvolvimento ou ocorrência (conhecimento dos mecanismos de falha). Tais considerações podem tornar a modelagem matemática de confiabilidade num grande desafio, caso não sejam assumidas condições simplificadoras como, por exemplo, considerar que as condições operacionais e outros fatores ambientais sejam constantes, que as falhas sejam independentes, etc.

Uma medida de confiabilidade é o tempo médio até a falha (**MTTF** - *Mean Time To Failure*), ou tempo médio entre falhas (**MTBF** - *Mean Time Between Failures*) no caso de sistemas reparáveis (vide seção 2.7 para conceito de sistema reparável). As duas medidas são as médias das distribuições de probabilidade que se ajustam aos dados de falha, caso modelos estocásticos sejam utilizados (vide capítulo 3 para conhecer as técnicas tradicionais de modelagem e análise de confiabilidade de sistemas reparáveis e não-reparáveis).

2.5 **Mantenabilidade**

Muito embora haja uma relação muito forte entre manutenabilidade e manutenção, é importante se fazer uma distinção entre os dois conceitos. O conceito de manutenabilidade refere-se às medidas e ações executadas durante a fase de projeto de um sistema com o objetivo de incluir funcionalidades que facilitem a manutenção, que garantam mínima indisponibilidade

(tempo em que um sistema não está disponível para operar) caso um reparo precise ser executado e mínimo custo do ciclo de vida (*life cycle cost* - LCC), quando o sistema estiver sujeito às condições operacionais para o qual foi projetado; O conceito de manutenção está associado à execução de ações/serviços de manutenção propriamente ditos de forma a manter o sistema em estado operacional (prevenir) ou restaurar o estado operacional em caso de falha. De forma mais simples: manutenibilidade é um parâmetro de projeto com foco em minimizar o tempo de reparo de um sistema, enquanto manutenção é a efetiva execução de ações para manter ou restaurar a operação de um sistema (Dhillon, 2006).

Assim como na engenharia de confiabilidade, em que os tempos entre falhas são medidos e modelados segundo distribuições de probabilidade, é também possível na engenharia de manutenibilidade a medição e modelagem dos tempos de reparo segundo modelos estocásticos. A média da distribuição utilizada nesse caso é denominada Tempo Médio para Reparar ou **MTTR** (*Mean Time to Repair*). Enquanto na engenharia de confiabilidade o interesse é de se obter um **MTBF** maior possível (baixa frequência de falhas), na engenharia de manutenibilidade o interesse é o de se obter um **MTTR** mínimo.

Práticas de manutenção podem afetar tanto a confiabilidade como a manutenibilidade. No caso da confiabilidade, se as práticas adotadas não são capazes de detectar um falha ou potencial de falha de forma eficiente, é evidente que a frequência de falhas pode aumentar, e o **MTBF** tende a diminuir. Além disso, se o processo de manutenção estabelecido não é otimizado, ou seja, se os aspectos logísticos e procedurais não estão efetivamente implementados, o tempo de reparo pode aumentar, e portanto o **MTTR** apresenta tendência de crescimento (vide capítulo 3, seção 3.2 para conhecer as técnicas tradicionais de modelagem de sistemas reparáveis).

2.6 Disponibilidade

A disponibilidade é definida como a probabilidade de um sistema estar disponível para operar, ou em estado operativo, quando requerido em um instante de tempo t . Pode também ser definida como a habilidade de um item estar em um estado que o possibilite operar ou cumprir sua função requerida em um instante ou intervalo estabelecidos, sob certas condições operacionais.

A disponibilidade sob estas condições é denominada *disponibilidade operacional* (no aspecto quantitativo), ou *dependabilidade* (no aspecto qualitativo). Se fatores humanos (cumprimento de padrões, habilidade/experiência para o diagnóstico de falhas, etc.) e o suporte logístico (ferramental, disponibilidade de sobressalentes, etc.) são considerados ideais, a disponibilidade é denominada *disponibilidade intrínseca* (Birolini, 2004).

O tempo total disponível para operar de um sistema é denominado *uptime* ($u(t)$), o tempo total indisponível para operar é denominado *downtime* ($d(t)$). A função disponibilidade é dada pela relação entre o tempo total disponível para operar (*uptime*) e o tempo total útil para operar ($uptime + downtime$). A *disponibilidade instantânea* é matematicamente representada como segue:

$$A(t) = \frac{u(t)}{u(t) + d(t)} \quad (2.1)$$

,onde $u(t)$ é o tempo disponível ou *uptime*, e $d(t)$ é o tempo indisponível ou *downtime*.

A *disponibilidade média* pode ser obtida integrando-se (2.1) em um período de tempo T de interesse, obtendo-se:

$$A(T) = \frac{1}{T} \int_0^T A(t) dt \quad (2.2)$$

É em geral difícil derivar a equação para a disponibilidade instantânea $A(t)$ de um sistema e na maioria das vezes a disponibilidade em regime estacionário ou *steady-state* é de maior interesse, e pode ser obtida por:

$$\lim_{t \rightarrow \infty} A(t) = A(\infty) = \frac{u(\infty)}{u(\infty) + d(\infty)} \quad (2.3)$$

É também possível estimar a disponibilidade em regime estacionário como uma relação entre o tempo médio disponível para operar (*mean uptime*) e o tempo médio útil (*mean uptime + mean downtime*). A disponibilidade em regime estacionário pode então ser obtida como segue:

$$\lim_{t \rightarrow \infty} A(t) = A(\infty) = \frac{m_u}{m_u + m_d} \quad (2.4)$$

Decorre da definição de disponibilidade que um sistema que apresente poucas falhas (seja mais confiável) e que seja reparável com um menor tempo possível (manutenção eficiente) também estará mais disponível para operar, ou seja, há uma relação entre a função disponibilidade e as funções confiabilidade e manutenibilidade. Considere-se que um sistema demore a falhar, ou melhor dizendo, apresente um tempo médio entre falhas grande, isso pode significar que o tempo disponível para operar será maior, ou seja, a disponibilidade é diretamente proporcional à confiabilidade. Por outro lado, considere-se que um sistema esteja em estado falho e o tempo para voltar ao seu estado operativo seja grande, ou melhor, o tempo médio para reparar seja elevado (baixa manutenibilidade). Neste caso, a disponibilidade para operar será menor. Assim a disponibilidade é inversamente proporcional ao tempo médio para reparar. A disponibilidade é em geral preferida para medir o desempenho de sistemas reparáveis pois considera tanto a confiabilidade como a manutenibilidade em sua formulação. A modelagem de sistemas reparáveis será apresentada no capítulo 3, seção 3.2.

A definição de disponibilidade decorre da especificação de estados possíveis para o sistema. Estados binários têm sido empregados em engenharia de confiabilidade com sucesso, no entanto, quando outros estados representando níveis de desempenho intermediários precisam ser considerados, modelos mais complexos devem ser derivados. Em Kuo and Zuo (2003), modelos multi-estado são discutidos.

2.7 Sistemas Reparáveis e Não-Reparáveis

Uma classificação importante de sistemas provém de suas características em termos de reparabilidade. Sistemas podem ser reparáveis e não-reparáveis. Sistemas reparáveis são passíveis de manutenção, ou seja, uma vez detectada uma falha, sua condição operacional pode ser restaurada através de algum tipo de intervenção, diferente do que simplesmente sua substituição. Sistemas não-reparáveis não são passíveis de manutenção, ou seja, uma vez que apresentaram

falha, não podem ter sua função restabelecida, não havendo outro tipo de ação de manutenção possível que não a sua substituição/descarte (Rigdon and Basu, 2000). Os conceitos de manutenção apresentados anteriormente são extremamente importantes à modelagem de sistemas reparáveis.

Muitos dos sistemas reais são sistemas reparáveis como carros, aviões, computadores, etc. No entanto, a grande maioria da literatura de engenharia de confiabilidade disponível discute os modelos estocásticos para sistemas não-reparáveis, em geral aplicáveis a componentes. A razão para isso é que a formalização da teoria de sistemas reparáveis é relativamente nova e decorrente do trabalho de Ascher and Feingold (1984).

As técnicas para a modelagem e análise de confiabilidade serão apresentadas tanto para os sistemas reparáveis como para sistemas não-reparáveis, e as devidas distinções serão feitas quando necessárias. A manutenibilidade é em geral modelada utilizando modelos estocásticos similares aos da confiabilidade, e somente faz sentido no contexto de sistemas reparáveis.

Capítulo 3

Modelagem de Confiabilidade

As técnicas tradicionais de modelagem e análise de sistemas sob a perspectiva da confiabilidade e manutenibilidade decorrem da teoria de processos estocásticos e são, portanto, dependentes da disponibilidade de dados acerca do sistema em estudo. Existem diversas abordagens de modelagem e análise de confiabilidade que podem ser adotadas dependendo de fatores como quantidade e qualidade dos dados de falha e reparo de um sistema, natureza do sistema (reparável ou não-reparável), se a análise é sistêmica (*top-down*) ou a partir dos componentes (*bottom-up*), etc. Cada técnica tem sua aplicação e apresenta um nível de complexidade para o seu desenvolvimento.

Do ponto de vista de gerenciar confiabilidade, as análises devem ser feitas em níveis mais desdobrados com a identificação dos perfis de falha de componentes, e a partir dos componentes, estimar a confiabilidade do sistema. Esse modelo de análise é mais apropriado, pois o modelo para o sistema é uma composição do comportamento de cada componente, os quais podem estar em estágios distintos dos seus ciclos de vida.

Fazer análises sistêmicas de confiabilidade sem o entendimento das falhas funcionais e dos modos de falha não geram muito conhecimento quando a sua utilização tem o foco de auxiliar na definição de planos de melhoria específicos, seja em uma área de Engenharia, seja na Produção ou Manutenção. A melhoria de confiabilidade em projeto se dá em nível de componente e por meio do entendimento do conceito do sistema e sua arquitetura. Sem essa análise, melhorar efetivamente fica muito difícil.

Em razão do exposto, análises sistêmicas são em geral desenvolvidas a partir dos compo-

mentes e suas relações dentro da arquitetura do sistema. As técnicas sistêmicas mais utilizadas por engenheiros de confiabilidade são os Diagramas de Bloco de Confiabilidade (*RBD - Reliability Block Diagrams*, Anexo B.1) e Análise de Árvores de Falha (*FTA - Fault Tree Analysis*, Anexo B.3).

Outras técnicas de modelagem de sistemas conhecidas são Cadeias de Markov (Anexo B.4), Redes-Petri (Anexo B.5), Redes Bayesianas (Anexo B.6), entre outras. Tais técnicas são importantes para modelagem de sistemas que assumem estados intermediários (sistemas multi-estado), no entanto, para sistemas complexos com um grande número de sub-sistemas e componentes, seu desenvolvimento e avaliação quantitativa pode se tornar inviável sem o uso de pacotes computacionais e de técnicas de simulação como a simulação de Monte Carlo (Anexo B.7).

Todas as técnicas citadas são representações que modelam relações entre as variáveis de interesse (*e.g.*, tempos e modos de falha, tempos de reparo, complexidade, aspectos logísticos, etc.), permitindo que, implicitamente, os modelos matemáticos necessários às avaliações quantitativas possam ser obtidos, ainda que não analiticamente. Cada uma delas apresenta vantagens e desvantagens que dependem da sua aplicação, e cabe ao engenheiro decidir qual delas utilizar frente aos resultados que pretende obter.

O primeiro passo para o problema de modelagem de confiabilidade e de manutenibilidade é entender o sistema, qual o objetivo do modelo, quais são as variáveis de interesse, quais são os dados disponíveis (ou mesmo se não há dados, e portanto outras metodologias baseadas no conhecimento de especialistas deverão ser utilizadas), qual o contexto operacional (os conceitos de confiabilidade e de manutenibilidade são dependentes das condições de uso, pois as chances de falha aumentam caso o sistema seja utilizado para fins e de formas para os quais não foi projetado), quais os limites do sistema (interfaces são sempre grandes fontes de falhas potenciais), etc. Após a compreensão desse contexto, a técnica e o modelo a serem empregados podem ser selecionados.

Em engenharia de confiabilidade é comum o uso de modelos paramétricos para o desenvolvimento dos estudos. Tais modelos precisam ter seus parâmetros estimados a partir de alguma técnica, e posteriormente validados por meio de alguma metodologia, e eventualmente dispostos

graficamente e/ou analiticamente. Um fluxograma genérico para o processo de modelagem e análise de sistemas é apresentado na Figura 3.1.

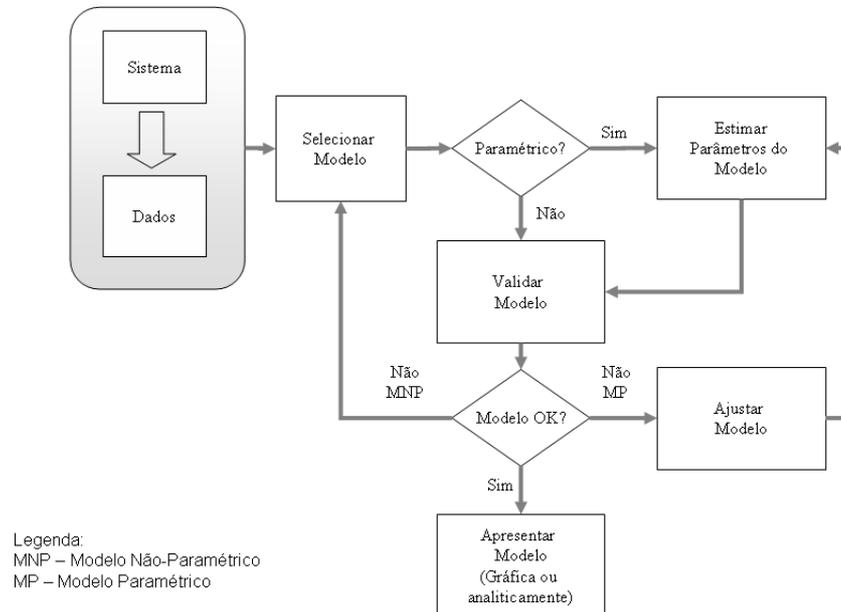


Figura 3.1: Fluxograma genérico para modelagem e análise matemática de sistemas

A seguir apresentam-se as técnicas para modelagem de sistemas reparáveis e não-reparáveis sob a perspectiva da engenharia de confiabilidade e de manutenibilidade. Os conceitos e terminologia utilizados para o estudo de ambos os tipos de sistemas são similares, com algumas sutis diferenças. As técnicas de modelagem não-paramétricas e paramétricas convencionais são revistas sob os seus aspectos teóricos e práticos. As técnicas não-paramétricas são apresentadas primeiro, pois é em geral possível a identificação de alguma tendência nos dados de falha o que pode facilitar a escolha dos modelos paramétricos a serem adotados.

Em geral a escolha de modelos paramétricos para sistemas não-reparáveis depende do comportamento da função taxa de falha do sistema. No caso de sistemas reparáveis, a escolha de modelos paramétricos depende do comportamento da função intensidade de falhas. As funções taxa de falha e intensidade de falhas serão apresentadas como parte da explicação sobre a modelagem de sistemas não-reparáveis e reparáveis, respectivamente.

3.1 Modelagem de Sistemas Não-Reparáveis

Sistemas não-reparáveis caracterizam-se por não serem passíveis de nenhum tipo de ação de reparo (manutenção) após uma falha. Além disso, a falha de um sistema não afeta o desempenho de outros sistemas similares, sendo razoável considerar que os seus tempos de vida sejam independentes. Assumindo-se que sistemas similares estejam sujeitos às mesmas condições, é razoável também que tempos de vida sigam uma mesma distribuição de probabilidade (Rigdon and Basu, 2000). O tempo até a falha, ou tempo de vida, é modelado como uma variável aleatória, e as suposições descritas anteriormente equivalem a dizer que os tempos de vida de sistemas similares são independentes e identicamente distribuídos (i.i.d) sendo provenientes de alguma função de distribuição cumulativa. A seguir apresentam-se as técnicas não-paramétricas e paramétricas de modelagem estocástica (Papoulis, 1991) de sistemas não-reparáveis.

3.1.1 Técnicas Não-Paramétricas

Técnicas não-paramétricas são em geral menos eficientes que técnicas paramétricas nos casos em que se conhece a distribuição dos tempos de falha, e mais eficientes caso contrário. Lee and Wang 2003 sugerem que técnicas não-paramétricas sejam utilizadas antes do ajuste de alguma função paramétrica aos dados de falha (censurados ou não). Além disso, se o objetivo da análise é a escolha de um modelo para os dados de falha, as estimativas obtidas a partir de técnicas não-paramétricas podem ser úteis e auxiliam na decisão sobre qual função adotar.

Há duas técnicas não-paramétricas mais utilizadas na modelagem de confiabilidade: Limite-Produto, conhecida também por estimador de Kaplan-Meier (Kaplan and Meier, 1958), e o modelo atuarial baseado em Tabelas de Vida. O estimador de Kaplan-Meier pode ser utilizado tanto para amostras pequenas quanto grandes. No entanto, quando as amostras são muito grandes, os dados já estão agrupados em intervalos ou há interesse em avaliar grandes populações, as Tabelas de Vida são mais convenientes (Lee and Wang, 2003). As estatísticas obtidas por ambas as técnicas são similares, e a única diferença entre elas é que a primeira baseia-se no tempos de falha de cada sistema individualmente, enquanto na segunda, os tempos de falha são agrupados em intervalos. Um inconveniente presente em ambas as técnicas é que as esti-

mativas entre dois tempos de falha distintos são iguais, e para obter uma estimativa em um tempo intermediário, a mesma deve ser calculada por interpolação. Um exemplo de estimativa da função confiabilidade obtida por meio do estimador de Kaplan-Meier é apresentado na Figura 3.2. Mais detalhes sobre a utilização dos estimadores de Kaplan-Meier e Tabelas de Vida podem ser obtidos em Lee and Wang 2003 e Freitas and Colosimo 1997.

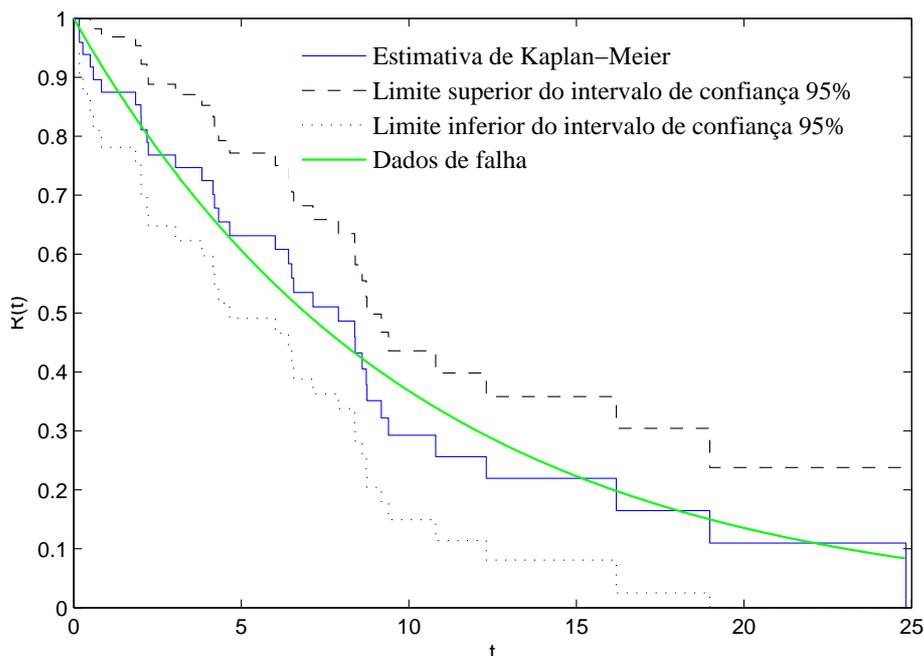


Figura 3.2: Estimativa de Confiabilidade utilizando estimador de Kaplan-Meier para dados de falha gerados aleatoriamente segundo uma distribuição exponencial. Para a estimativa, utilizou-se a função `ecdf(.)` do *Statistical Toolbox* do Matlab®

3.1.2 Técnicas Paramétricas

É possível modelar o tempo de vida até a falha de um sistema não-reparável como uma variável aleatória, contínua e que assume somente valores não negativos. A unidade de medida para o tempo de vida pode ser horas, dias ou anos, ou mesmo uma unidade que represente o uso, como ciclos de operação ou quilômetros.

Uma variável aleatória pode ser descrita por sua função densidade de probabilidade (*probability density function* – **pdf**), sua função de distribuição cumulativa (*cumulative distribution*

function – **cdf**), além das estimativas para a média e variância (Papoulis, 1991). Assumindo-se que a função densidade de probabilidade para o tempo de falha do sistema seja conhecida, estamos interessados em estimar a probabilidade de o sistema não falhar após um instante t (confiabilidade ou probabilidade de sobrevivência), que é dada pela equação 3.1 (Birolini, 2004).

$$R(t) = P(T > t) = \int_t^{\infty} f(x)dx \quad (3.1)$$

A função de distribuição cumulativa (*cdf*) é dada pela equação 3.2.

$$F(t) = P(T \leq t), \quad t > 0 \quad F(t) = 0, \quad t \leq 0 \quad (3.2)$$

Assim, a confiabilidade $R(t)$ é dada também por

$$R(t) = 1 - F(t) \quad (3.3)$$

A função densidade de probabilidade (para variáveis aleatórias contínuas) é dada por

$$f(t) = \lim_{\Delta t \rightarrow 0} \frac{F(t + \Delta t) - F(t)}{\Delta t} \quad (3.4)$$

A função de confiabilidade $R(t)$ é a probabilidade do tempo de vida ou sobrevivência T de um sistema ou componente ser maior que t . De outra maneira, a não-confiabilidade é a probabilidade do sistema falhar antes de t . O tempo médio de vida até a falha ou *MTTF* (*Mean Time to Failure*) é obtido por meio do operador esperança $E[.]$ dado por 3.5.

$$MTTF = E[T] = \int_0^{\infty} R(t)dt \quad (3.5)$$

Uma outra medida de interesse é a confiabilidade condicional do sistema. Esta é definida como a probabilidade de um sistema operar adequadamente por mais um período de tempo τ , dado que o mesmo não tenha falhado até o instante t , e é dada por 3.6.

$$R(\tau|t) = P(t > t + \tau | T > t) = \frac{R(t + \tau)}{R(t)} \quad (3.6)$$

Outra função importante para estudos de confiabilidade é a função taxa de falha (*failure rate function* ou *hazard function*) que é definida como a probabilidade de um sistema falhar no próximo instante de tempo $t + \Delta t$, dado que o mesmo não tenha falhado até o instante t . Tal função é bastante utilizada na prática pois fornece evidências sobre a condição de operação do sistema do ponto de vista da sua confiabilidade, ou seja, conhecida a taxa de falha do sistema em um certo instante, é possível inferir sobre a sua condição em uma instante imediatamente posterior. Por exemplo, uma alta taxa de falha em um instante t indica uma alta probabilidade de falha do sistema em um instante de tempo $t + \Delta t$. Pela sua definição e após desenvolvimentos matemáticos, a função taxa de falha é dada por 3.7.

$$h(t) = \lim_{\Delta t \rightarrow 0} P(T \leq t + \Delta t | T > t) = \frac{f(t)}{R(t)} \quad (3.7)$$

A função taxa de falha cumulativa é dada por 3.8.

$$H(t) = \int_0^t h(x) dx \quad (3.8)$$

A partir das equações 3.7 e 3.8, e após alguns desenvolvimentos matemáticos, podemos estimar a taxa de falha média de um sistema em um intervalo de tempo (t_1, t_2) por meio da equação 3.9.

$$\overline{h(t_1, t_2)} = \frac{1}{t_2 - t_1} \int_{t_1}^{t_2} h(t) dt = \frac{H(t_2) - H(t_1)}{t_2 - t_1} \quad (3.9)$$

As funções taxa de falha $h(t)$, densidade de probabilidade $f(t)$, de distribuição cumulativa $F(t)$, de confiabilidade $R(t)$ e taxa de falha cumulativa $H(t)$ estão relacionadas pelas equações 3.10 e 3.11.

$$h(t) = -\frac{d}{dt} \ln R(t) \quad (3.10)$$

$$R(t) = e^{-H(t)} \quad (3.11)$$

Uma vez conhecida qualquer das funções, o comportamento do sistema fica completamente descrito, pois as demais podem ser deduzidas a partir de 3.10 ou 3.11.

As funções de distribuição de probabilidades mais utilizadas em estudos de confiabilidade são apresentadas no Anexo A, assim como algumas considerações acerca de suas propriedades e aplicações.

Como comentado anteriormente, os modelos estocásticos paramétricos podem ser utilizados para a análise de confiabilidade de sistemas e componentes. No entanto, é em geral mais apropriado obter modelos para os componentes e então, através de alguma técnica de modelagem sistêmica como *RBD*, *FTA* ou Cadeias de Markov, obter o modelo para o sistema. Uma introdução às técnicas de modelagem sistêmicas está disponível no Anexo B.

3.2 Modelagem de Sistemas Reparáveis

Sistemas reparáveis caracterizam-se por serem passíveis de alguma ação de manutenção após falhar. O tempo até a primeira falha de um sistema reparável é modelado de forma similar aos sistemas não-reparáveis. Após a primeira falha, uma ação de manutenção (reparo) pode ser executada, e o sistema volta à sua condição de operação. O tempo até a próxima falha depende do tipo de reparo realizado, o qual não é necessariamente explicado pela distribuição de probabilidade utilizada para descrever o tempo até a primeira falha. Assim, as suposições de independência dos tempos de falha e de que os mesmos sejam identicamente distribuídos (**i.i.d**) não são sempre válidas (Rigdon and Basu, 2000). Conseqüentemente, os dados de falha de sistemas reparáveis precisam receber um tratamento estatístico diferente dos sistemas não-reparáveis (dos Santos and Colosimo, 2003).

Dados de falha de sistemas reparáveis são em geral representados por meio de processos pontuais (processos de contagem), que por sua vez, podem ser especificados em função de sua intensidade de recorrência de falhas. Rigdon and Basu (2000) definem processos pontuais como modelos estocásticos que descrevem a ocorrência de eventos no tempo, referindo-se a “ocorrência no tempo” como sendo os tempos entre falhas de um sistema reparável.

O'Connor (2002) define processos pontuais como sendo uma seqüência de eventos discre-

tos que ocorrem aleatoriamente dentro de um intervalo. Segundo o mesmo autor, processos como esse não podem ser adequadamente representados por uma única função de distribuição contínua. Os tempos entre ocorrências não são nem independentes nem identicamente distribuídos. Essas características influenciam na escolha do modelo a ser adotado e depende da interpretação e/ou conhecimento que o analista tem sobre o sistema e os dados de falha e reparo.

Sistemas que apresentam várias falhas ao longo do seu ciclo de vida e que podem ter sua função (ou funções) restauradas a partir de uma ação de manutenção são denominados sistemas reparáveis. Nesse caso, o MTTF é o tempo médio até a primeira falha. Após o reparo, o tempo médio até a próxima falha é denominado tempo médio entre falhas ou **MTBF** (*Mean Time Between Failures*). O tempo entre falhas é medido entre o instante de tempo em que o sistema teve sua função reparada até o instante em que apresente uma nova falha, ou seja, não leva em consideração o tempo de reparo da função (Kuo and Zuo, 2003).

Um aspecto importante para a análise de sistemas reparáveis, é o conhecimento sobre a natureza do reparo realizado, que pode restaurar a função do sistema para um estado de, por exemplo, tão-bom-quanto-novo (*as-good-as-new*), ou seja, o reparo é perfeito, e nesse caso o tempo médio até a primeira falha será igual ao tempo médio entre falhas ($MTTF = MTBF$). Na hipótese de um reparo perfeito, o comportamento de falha do sistema segue a mesma distribuição de probabilidade. No entanto, esta consideração nem sempre é válida na prática, mas é uma das hipóteses simplificadoras utilizadas em grande parte da literatura referente à engenharia de confiabilidade.

Os tempos de reparo também se caracterizam como variáveis aleatórias e podem ser descritos através de funções de distribuição de probabilidade. Assim, uma vez escolhida a distribuição de probabilidade que melhor representa o tempo de reparo, pode-se de forma similar ao que é feito para os tempos de falha, obter a estimativa para o tempo médio de reparo ou **MTTR** (*Mean Time to Repair*). Para sistemas não-reparáveis, a média (**MTTF**) e a variância das distribuições são medidas adequadas para descrever o comportamento de falha do sistema. No caso de sistemas reparáveis a *disponibilidade intrínseca* é geralmente empregada, pois contempla tanto os tempos de falha como os tempos de reparo na sua formulação, permitindo uma representação mais adequada do comportamento do sistema no tempo.

Assumindo-se um reparo perfeito, e após desenvolvimentos matemáticos, a equação para cálculo da *disponibilidade intrínseca* em regime estacionário é uma função da confiabilidade, representada por uma taxa de falha constante igual a λ , e da manutenibilidade, representada por uma taxa de reparo constante igual a μ , ambas seguindo uma distribuição exponencial, é dada por 3.12.

$$A = \frac{MTBF}{MTBF + MTTR} \quad (3.12)$$

Sendo $\lambda = \frac{1}{MTBF}$ e $\mu = \frac{1}{MTTR}$, a equação 3.12 pode ser reescrita como 3.13.

$$A = \frac{\lambda}{\lambda + \mu} \quad (3.13)$$

Os modelos mais comuns para sistemas reparáveis cujas ações de manutenção são reparos imperfeitos (reparo mínimo) são os baseados em processos de Poisson não-homogêneos (PPNH). Caso as ações de manutenção sejam reparos perfeitos, os modelos mais utilizados são os que se baseiam em um processo de renovação (RP), sendo os processos de Poisson homogêneos (reparo perfeito com confiabilidade e manutenibilidade exponenciais e as respectivas taxas de falha e reparo constantes, são casos particulares de um processo de renovação (Lindqvist, 1998)).

Conforme comentado anteriormente, as falhas em um sistema reparável podem ser modeladas segundo um processo de contagem, para o qual é definida uma função número de recorrências $N(t)$ no intervalo $(0, t]$. A intensidade de recorrência $I(t)$ de um processo de contagem é definida como:

$$I(t) = \lim_{dt \rightarrow 0} \frac{P(\text{Recorrências no intervalo } (t, t + dt])}{dt} = \lim_{dt \rightarrow 0} \frac{E[dN(t)]}{dt} \quad (3.14)$$

Assumindo-se que não acontecem recorrências simultâneas, a equação 3.14 reduz-se a 3.15.

$$I(t) = \lim_{dt \rightarrow 0} \frac{E[N(t)]}{dt} \quad (3.15)$$

Fazendo-se $M(t) = E[N(t)]$, e integrando-se em t ambos os lados da equação 3.15, obtém-se a estimativa para o número médio de recorrências até o tempo t , que é igual à intensidade de falhas acumulada. $M(t)$ é conhecida por função cumulativa média (MCF - *Mean Cumulative Function*) e é dada por 3.16, para um tempo de missão T .

$$M(T) = E[N(t)] = \int_0^T I(u)du \quad (3.16)$$

A seguir os modelos não-paramétricos e paramétricos para sistemas reparáveis são revistos sob seus aspectos teóricos e práticos.

3.2.1 Técnicas Não-Paramétricas

Assim como em sistemas não-reparáveis, existem técnicas que independem da especificação de uma função paramétrica para que as inferências sobre a confiabilidade de sistemas reparáveis possam ser realizadas. Uma técnica gráfica conhecida é a plotagem da função de média acumulada (MCF - *Mean Cumulative Function*) em função do tempo, dada pela equação 3.16, na qual é possível verificar a existência de tendências na função intensidade de falhas.

Sistemas cuja **MCF** apresente alguma tendência de crescimento ou decrescimento, são modelados por processos de Poisson não-homogêneos. Ou seja, o uso da técnica de plotagem da **MCF** fornece informações quanto a natureza do modelo a ser empregado na modelagem de um sistema reparável. A **MCF** é similar à taxa de falha cumulativa definida para sistemas não-reparáveis. Na Figura 3.3 apresenta-se um exemplo da MCF para um sistema reparável.

3.2.2 Técnicas Paramétricas

A maioria dos modelos paramétricos para sistemas reparáveis são escolhidos dependendo do tipo de reparo realizado no sistema após uma falha que pode ser um (1) reparo perfeito, que conduz a um processo de contagem conhecido por processo de renovação (PR), (2) um reparo mínimo, que conduz a um processo de Poisson não-homogêneo (PPNH), ou (3) reparo imperfeito, situação intermediária entre as situações (1) e (2).

No caso de reparo perfeito, o processo de renovação é utilizado na modelagem. Um caso particular do processo de renovação é o processo de Poisson homogêneo (PPH), o mais

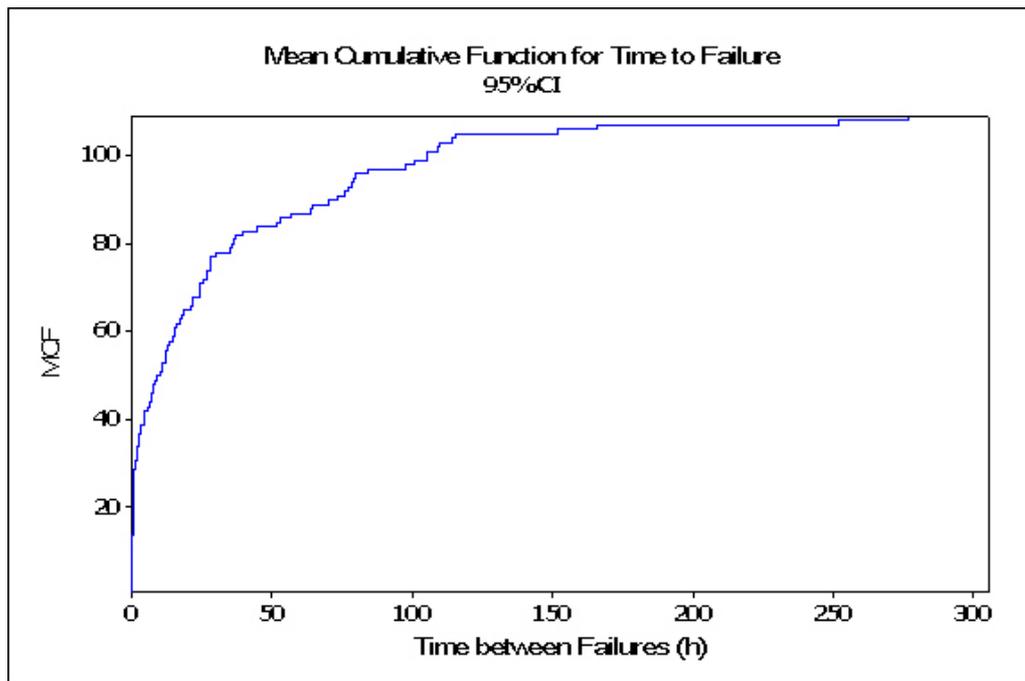


Figura 3.3: Exemplo de MCF para dados de falha de um sistema reparável. A MCF foi obtida utilizando-se o pacote estatístico Minitab® 15.1.1.0.

simples dos modelos que descrevem a ocorrência de falha em sistemas reparáveis. No entanto, o modelo PPH assume que o sistema é estacionário, ou seja, seus componentes não estão sujeitos a deterioração com o tempo, e que não há nenhum desgaste em tempo local, ou seja, no tempo entre falhas, considerações que evidentemente não são observadas na prática (Rigdon and Basu, 2000).

3.3 Estimação de Parâmetros

Modelos paramétricos, seja para sistemas reparáveis ou não-reparáveis, precisam ter seus parâmetros estimados a partir de alguma técnica para que fiquem completamente caracterizados. Os métodos de estimação de parâmetros mais utilizados são o da máxima verossimilhança (*Maximum Likelihood Estimator* - MLE) e o de mínimos quadrados (*Least Square Estimator* - LSE).

3.3.1 Estimador de Máxima Verossimilhança – MLE

O estimador de máxima verossimilhança é um método estatístico para a identificação das funções e parâmetros que melhor explicam um conjunto de dados disponíveis (amostra). Um vetor de parâmetros θ deve ser escolhido com o objetivo de maximizar uma função de verossimilhança $\mathcal{L}(\theta)$, dada por:

$$\mathcal{L}(\theta) = f_{\theta}(x_1, \dots, x_N | \theta) \quad (3.17)$$

,onde f_{θ} é alguma função de distribuição de probabilidade e x_1, \dots, x_N uma amostra dos dados de falha ou fenômeno de interesse.

Quando os dados x_1, \dots, x_N são independentes e identicamente distribuídos (i.i.d) com parâmetros desconhecidos, a equação 3.17 pode ser substituída por:

$$\mathcal{L}(\theta) = \prod_{i=1}^n f_{\theta}(x_i | \theta) \quad (3.18)$$

A equação 3.19 é obtida aplicando-se o operador logaritmo a ambos os lados da equação 3.18.

$$\mathcal{L}^*(\theta) = \sum_{i=1}^n \log f_{\theta}(x_i | \theta) \quad (3.19)$$

Após esta transformação, 3.19 é utilizada em um problema de otimização para que sejam encontrados os parâmetros que maximizam a função de verossimilhança. Nesse caso, são aplicáveis algoritmos de otimização determinísticos.

O estimador de máxima verossimilhança pode ser utilizado tanto para dados censurados como para dados não-censurados (censuras referem-se aos eventos para os quais análises de confiabilidade são desenvolvidas porém uma falha não tenha sido observada até o momento que as amostras tenham sido coletadas. No caso de sistemas não-reparáveis, suponha-se que vários sejam submetidos a testes durante um certo período ou até que um determinado número de eventos falha tenham sido observados, as censuras referem-se aos sistemas/componentes que

ainda não haviam falhado até o fim do teste. Para mais informações sobre conceito de censura vide (O'Connor, 2002) e (Freitas and Colosimo, 1997).

3.3.2 Estimador de Mínimos Quadrados – LSE

O estimador de mínimos quadrados baseia-se na minimização do quadrado dos resíduos quando se compara os valores reais e os valores obtidos por meio do modelo ajustado aos dados. Não é um método indicado para casos em que os dados são censurados, pois não é capaz de incorporar essa informação ao cálculo dos parâmetros.

O estimador de mínimos quadrados é a técnica que embasa a utilização de plotagem de confiabilidade, a qual pode ser também utilizada para se obter uma estimativa para os parâmetros do modelo.

Para maiores detalhes sobre o estimador de mínimos quadrados, Aguirre (2007) é uma boa referência.

3.4 Validação de Modelos - Testes de Adequação

A validação de modelos de confiabilidade para sistemas reparáveis ou não-reparáveis se dá por meio de testes estatísticos (testes de hipótese) ou com auxílio de técnicas gráficas. A resposta que se pretende obter por meio da etapa de validação é se o modelo adotado é adequado à representação dos dados de falha e/ou reparo de um sistema em estudo.

A etapa de validação de modelos é essencial ao trabalho do analista/engenheiro de confiabilidade, pois o uso de modelos inadequados pode levar a decisões equivocadas. A seguir são apresentadas as técnicas mais utilizadas para a validação de modelos de sistemas não-reparáveis e reparáveis.

3.4.1 Técnicas Gráficas

3.4.1.1 Para Sistemas Não-Reparáveis

Uma das técnicas de validação de modelos para sistemas não-reparáveis é conhecida por Plotagem de Probabilidade. Tal técnica consiste basicamente em plotar os dados do modelo linearizado em um gráfico x-y em escala logarítmica. Tais gráficos são padronizados para cada

tipo de distribuição e conhecidos como papéis de probabilidade. É uma técnica simples na qual a conclusão sobre se o modelo é adequado ou não aos dados se dá quando estes estão alinhados ao modelo linearizado.

Uma vantagem da plotagem de confiabilidade e o uso de gráficos padronizados é que, uma vez que o modelo tenha sido validado, os parâmetros do modelo podem ser facilmente obtidos diretamente dos gráficos.

Outra técnica simples bastante utilizada é a análise do gráfico função taxa de falha. Neste gráfico é em geral possível a identificação de tendências nos dados, o que pode auxiliar na escolha de distribuições mais adequadas. Não é, no entanto, um método conclusivo.

3.4.1.2 Para Sistemas Reparáveis

Para sistemas reparáveis três técnicas gráficas são geralmente empregadas, são elas: Plotagem da intensidade de falha vs. Tempo, Gráfico de Duane (*Duane Plot*) e Gráfico de Tempo total em teste (*TTT plot*). Estas técnicas gráficas possibilitam a visualização de tendências nos dados de falha de um sistema reparável, e auxiliam na decisão ou validação sobre o modelo paramétrico utilizado.

O Gráfico de Duane é obtido traçando-se um gráfico x-y em escala logarítmica de $\frac{N(t_i)}{t_i}$ versus t_i , sendo $i = 1, 2, \dots, n$. Tal gráfico é usualmente empregado para aceitar ou rejeitar a hipótese de que os dados de falha possam ser adequadamente representados por um processo de lei de potência (PLP). Se o gráfico obtido é aproximadamente linear, o modelo PLP é adequado. Rigdon and Basu (2000) apresenta uma prova para tal afirmação. Os parâmetros do modelo PLP linearizado podem ser obtidos por meio do estimador de mínimos quadrados, o qual é tão eficiente quanto o de máxima verossimilhança.

O Gráfico de Tempo total em teste (TTT) é também empregado para avaliar a adequação do modelo PLP. Caso o gráfico TTT obtido esteja aproximadamente sobre diagonal de um quadrado unitário, a hipótese de que o PLP seja um modelo adequado é aceita. Rigdon and Basu (2000) fornece mais detalhes sobre a construção do gráfico TTT. Tal gráfico pode ser utilizado também para sistemas não-reparáveis.

3.4.2 Testes Estatísticos

Testes de hipótese são utilizados para se verificar se um modelo adotado é suficientemente adequado para representar um conjunto de dados. São vários os testes disponíveis que consistem em aceitar ou rejeitar a hipótese de que os dados de falha/reparo analisados sejam oriundos de um modelo em particular. Para mais detalhes sobre testes de hipótese, Sheskin (2003) e Montgomery and Runger (1994) são ótimas referências.

Capítulo 4

Técnicas de Modelagem baseadas em Inteligência Computacional

O estudo de sistemas naturais e o avanço computacional vêm auxiliando cada vez mais na solução de problemas complexos. Antes de se ter recursos computacionais como se tem atualmente, conceitos bio-inspirados eram difíceis de ser implementados. Ao conjunto de técnicas provenientes do estudo de sistemas naturais aliado aos métodos estocásticos dá-se o nome de Inteligência Computacional. Tais técnicas são listadas a seguir:

- Redes Neurais Artificiais;
- Computação Evolucionária;
- Inteligência Coletiva ou de Enxame;
- Sistemas Nebulosos;
- Sistemas Imunológicos Artificiais.

4.1 Redes Neurais Artificiais

Uma das topologias de redes neurais artificiais denominada Multi Layer Perceptron (MLP). Cada neurônio artificial recebe um sinal do ambiente ou de outros neurônios, coleta esses sinais e quando ativado transmite um sinal para todos os outros neurônios a ele conectados. Diversos tipos de redes neurais já foram propostas as quais têm potenciais de aplicação

diversificados (Engelbrecht, 2003).

Em uma rede neural artificial, sinais de entrada inibem ou excitam um neurônio através de pesos negativos ou positivos associados a cada neurônio da rede. A ativação do neurônio e a força do sinal de excitação são controlados por uma função de ativação. O neurônio capta todos os sinais de entrada e calcula um sinal líquido como uma função dos respectivos pesos. O sinal líquido serve como uma entrada de ativação que calcula o sinal de saída do neurônio.

Redes neurais podem ser aplicadas à engenharia de confiabilidade para aproximar funções densidade de probabilidade e nas análises de confiabilidade com base nos dados de falha (Najim *et al.*, 2004; de B. Pereira and Rao, 2005). Mais detalhes sobre o projeto e aplicações de redes neurais artificiais podem ser obtidos em (Haykin, 1999).

4.2 Computação Evolucionária

As técnicas de computação evolucionária têm como objetivo modelar o processo de evolução natural, onde o principal conceito associado é o de sobrevivência dos mais adaptados ao ambiente. Na evolução natural, a capacidade de sobrevivência é atingida por meio de um processo de reprodução, cujos filhos que são gerados de dois ou mais pais, contêm material genético de ambos ou todos, e com as melhores características de todos. Os indivíduos que herdam características ruins, são fracos e perdem a batalha pela sobrevivência.

Em computação evolucionária uma população de indivíduos é gerada para evoluir. Um indivíduo é denominado cromossomo. Um cromossomo define as características de indivíduos em uma população. Cada característica é denominada gene. O valor de um gene é denominado alelo. Para cada geração, indivíduos competem para reproduzir e gerarem filhos. Os indivíduos com melhor capacidade de sobrevivência têm maiores chances de se reproduzirem. Um filho é gerado pela combinação de partes dos pais por um processo denominado cruzamento (*crossover*). Cada indivíduo na população pode sofrer mutações que alteram alguns dos alelos do cromossomo.

A força de sobrevivência de um indivíduo é medida usando uma função de adequação (*fitness*), a qual reflete os objetivos e as restrições do problema a ser resolvido. Após cada geração, os melhores indivíduos podem ser selecionados para a próxima geração (elitismo). Além disso

características comportamentais podem ser usadas para influenciar o processo evolucionário de duas formas: fenótipos podem ser influenciados por meio de mudanças genéticas, e/ou características comportamentais separadamente, promovendo um desenvolvimento gradual e natural dos indivíduos de uma população.

Engelbrecht (2003) cita as classes de algoritmos que compõem o que se denomina Computação Evolucionária:

- Algoritmos genéticos: modelam o processo de evolução;
- Programação Genética: baseiam-se nos algoritmos genéticos, porém os indivíduos são programas representados por árvores;
- Programação Evolucionária: decorre da simulação do comportamento adaptativo de um processo de evolução (evolução de fenótipos);
- Estratégias de Evolução: modelam os parâmetros que controlam o processo de evolução, ou seja, a evolução da evolução;
- Evolução Diferencial: similar aos algoritmos genéticos, porém apresenta diferenças no processo de reprodução;
- Evolução Cultural: modela a evolução da cultura de uma população, bem como a influência da cultura sobre a evolução genética e do fenótipo dos indivíduos;
- Co-evolução: processo de evolução de indivíduos inicialmente não adaptados por meio de um processo de cooperação ou competição com demais indivíduos.

Segundo o mesmo autor a computação evolucionária tem sido aplicada com sucesso em problemas reais como, por exemplo, em mineração de dados (*datamining*), otimização combinatoria, diagnóstico de falhas, classificação, clusterização, programação e aproximação de séries temporais.

No capítulo 6 uma aplicação da computação evolucionária é apresentada com resultados obtidos. O trabalho foi apresentado no I Simpósio de Inteligência Computacional realizado em

Florianópolis-SC (SBIC) promovido pela Sociedade Brasileira de Redes Neurais (SBRN), tendo sido muito bem avaliado. Foi também um dos artigos convidados à submissão de uma versão revisada para a revista *Linear and Non-Linear Models* da SBRN (Salgado *et al.*, 2007).

Mais detalhes sobre o projeto e aplicações da computação evolucionária podem ser obtidos em Ashlock (2005), Menon (2004) e Jong (1997). Levitin (2007) apresenta diversos exemplos de aplicação de técnicas de computação evolucionária a problemas de engenharia de confiabilidade.

4.3 Inteligência de População (*Swarm Intelligence*)

Inteligência de população é um conceito relativamente novo, com muito potencial de desenvolvimento e ainda com poucas aplicações a problemas reais. O conceito originou-se do estudo de colônias ou populações de indivíduos sociais. Estudos de comportamento social de organismos em colônias são empregados no projeto de algoritmos de otimização e clusterização muito eficientes (Kennedy and Eberhart, 2001).

As abordagens mais atuais de inteligência de população aplicáveis a problemas de otimização são o de enxame de partículas (*Particle Swarm Optimization* – PSO) e o de Colônia de formigas (*Ant-Colony Optimization* – ACO). A seguir apresentam-se algumas características das duas abordagens.

PSO É uma abordagem de otimização global, inspirada no comportamento social de grupos de pássaros. Cada indivíduo na população é um indivíduo chamado partícula, e várias partículas constituem um enxame de partículas. O ajuste da posição de uma partícula depende da sua própria posição e também da posição dos seus vizinhos. O PSO pode ser aplicado em aproximação de funções, clusterização, otimização de estruturas mecânicas e solução de sistemas de equações;

ACO É uma abordagem de otimização global que modela o processo de depósito de feromônios por formigas na sua procura pelo caminho mais curto para a fonte de alimento, resultando no desenvolvimento de algoritmos de otimização na busca pelo caminho-mínimo.

Mais detalhes sobre as técnicas de inteligência de população podem ser obtidas em

Kennedy and Eberhart (2001). Levitin (2007) apresenta diversos exemplos de aplicação de técnicas de inteligência de população em problemas de engenharia de confiabilidade.

4.4 Sistemas Nebulosos (*Fuzzy Systems*)

Sistemas nebulosos (*fuzzy systems*) baseiam-se na teoria da lógica nebulosa (*fuzzy logic*), na qual a incerteza devido à imprecisão ou informação vaga é modelada por meio de funções de pertinência (Jang, 1997). A idéia principal no uso da lógica nebulosa é a de modelar o raciocínio humano por meio de variáveis linguísticas e as regras pelas quais as mesmas se relacionam. Constitui-se em uma ferramenta poderosa, pois na prática a informação necessária à modelagem ou análise de um problema ou sistema de interesse somente pode ser obtida por meio de um processo de elicitación, no qual especialistas são consultados. Muitas vezes os especialistas não são capazes de expressar o seu conhecimento de forma numérica. Na engenharia de confiabilidade esse é um problema bastante comum e que restringe o uso de técnicas tradicionais baseadas em modelos estocásticos. As técnicas nebulosas são então alternativas interessantes que podem viabilizar o desenvolvimento de técnicas de modelagem e análise que incorporem o conhecimento tácito dos especialistas, e que sejam menos dependentes da disponibilidade de dados históricos.

Confiabilidade nebulosa (*fuzzy reliability*) é o termo empregado na comunidade científica para se referir às técnicas de modelagem e análise de confiabilidade baseadas em modelos nebulosos. Como comentado na seção 2.1, em confiabilidade nebulosa, ao invés de se empregar distribuições de probabilidade, utiliza-se distribuições de possibilidades, e a maioria das técnicas de modelagem gráficas como RBD e FTA podem ser quantificadas por meio de modelos nebulosos, ao invés de modelos estocásticos. Em Sandri *et al.* (1990) o processo de elicitación para o desenvolvimento de modelos possibilísticos é investigado. Dubois *et al.* (1993) investiga a transformação de modelos estocásticos em modelos possibilísticos. Em Levitin (2007) exemplos de aplicação da confiabilidade nebulosa são apresentados.

4.5 Sistemas Imunológicos Artificiais (*Artificial Immune Systems*)

Mais recentemente uma classe de algoritmos inspirada em mecanismos de sistemas imunológicos têm sido aplicadas a diversos problemas de diagnóstico de falhas e reconhecimento de padrões (de Castro and Zuben, 2002; de Castro Silva, 2003; de Castro e Silva, 2008). No presente trabalho, um algoritmo imune baseado no princípio da seleção clonal, o qual é bem explicado por de Castro Silva (2003), é utilizado para solução de um problema de Otimização de Confiabilidade e comparado a um algoritmo genético (vide 6). Há vários outros princípios dos Sistemas Imunológicos que podem ser aplicados a diversos problemas complexos de engenharia.

Capítulo 5

Otimização de Confiabilidade

No capítulo 3 procurou-se apresentar as técnicas tradicionais aplicáveis à engenharia de confiabilidade utilizadas na modelagem de sistemas com foco em confiabilidade e manutenibilidade. Por meio de um processo de modelagem e análise do sistema e dados de falha (os quais podem ser dados de campo, dados de testes ou dados de especialistas) disponíveis, modelos matemáticos são obtidos. O modelo pode ser utilizado tanto na predição de desempenho do sistema em algum instante futuro quanto para sua otimização (Figura 1.2).

A otimização de confiabilidade, no presente trabalho, recebeu atenção especial por se tratar de um problema prático de muita relevância no contexto industrial, seja em projeto de sistemas ou na definição de metas e políticas de manutenção otimizadas. 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 a década de 70 é apresentada em Kuo and Prasad (2000), com excelente revisão bibliográfica do assunto.

Em otimização de confiabilidade, estamos interessados na escolha da arquitetura e dos componentes de um sistema de forma a atender requisitos tecnológicos, assim como mercadológicos. A otimização de confiabilidade refere-se também à alocação de metas de confiabilidade para os sistemas já em operação. Em Levitin (2007), cinco formulações para problemas de otimização

de confiabilidade são apresentadas. São elas:

- Maximizar confiabilidade, ou minimizar custo sujeito a uma meta de confiabilidade/custo, e demais restrições (**Formulação Tradicional**);
- Maximizar tempo de vida residual (*percentile life*) sujeito a restrições, em caso de sistemas com tempo da missão indeterminado;
- Maximizar a disponibilidade de sistemas multi-estado satisfazendo curvas de demanda para um dado período de operação do sistema e nível de desempenho do sistema estabelecidos;
- Maximizar a confiabilidade e minimizar os custos sujeito a restrições (**Formulação Multiobjetivo**)
- Para sistemas série-paralelo: maximizar o mínimo da confiabilidade dos sub-sistemas, sujeito a uma ou mais restrições, lineares ou não lineares.

O estudo de técnicas de otimização é extremamente importante ao 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 deve se dar de forma irrestrita, pois os recursos são finitos e não há como não levar em consideração os custos decorrentes das escolhas do engenheiro. Assim, na prática, estamos sempre buscando soluções para problemas com restrição mono ou multiobjetivo.

A meta principal de todo engenheiro de confiabilidade é a de encontrar alternativas com foco no atendimento à confiabilidade de sistemas. Kuo and Zuo (2003) cita alguns dos princípios aceitos como boas práticas para a garantia/melhoria de confiabilidade:

- Manter a arquitetura do sistema otimizada e compatível com os níveis de desempenho desejados;
- Aumentar a confiabilidade dos componentes do sistema;
- Utilizar redundância ativa para componentes de baixa confiabilidade;

- Utilizar redundância *stand-by*, que se torna ativa somente quando da ocorrência de falhas;
- Realizar manutenção corretiva onde componentes em estado de falha são substituídos ou reparados, e não voltam automaticamente ao estado operacional;
- Realizar manutenção preventiva de forma que componentes são substituídos por novos quando falham ou em algum intervalo de tempo fixo ou com base na sua condição, o que acontecer primeiro;
- Utilizar arquiteturas otimizadas para troca de componentes;
- Utilizar fatores de segurança ou programas gerenciais de melhoria do sistema;
- Utilizar *burn-in* para componentes que apresentam altas taxas de falhas.

A implementação dos passos descritos acima vão normalmente consumir recursos e um equilíbrio entre a confiabilidade do sistema e o consumo de recursos é essencial. Todos os nove métodos melhoram a confiabilidade do sistema e requerem conhecimento profundo do mesmo e dos modelos de confiabilidade.

Problemas de otimização de confiabilidade que englobam alocação de redundâncias e confiabilidade de componentes são reconhecidos na literatura como problemas *NP-difíceis*, por se tratarem de problemas de natureza combinatória e que, portanto, não podem ser resolvidos de forma eficiente por nenhum método exato (Trevisan, 2004). Assim, técnicas de computação evolucionária são aplicáveis, por se tratarem de técnicas estocásticas que permitem que o espaço de busca seja explorado adequadamente. O presente trabalho teve por objetivo demonstrar a aplicação da computação evolucionária, assim como do algoritmo imune ao problema de otimização de confiabilidade. Foi também aplicado um algoritmo tradicional, após aplicação de algum dos algoritmos estocásticos com o objetivo de melhorar a busca local.

A seguir são apresentados os problemas de otimização e os resultados obtidos por meio da aplicação de dois algoritmos estocásticos ao problema de otimização na sua formulação tradicional. Vale lembrar que toda a teoria de modelagem e análise de confiabilidade apresentada no capítulo 3 é a base para a formulação do problema de otimização aqui apresentado. O modelo para o sistema e as variáveis de interesse devem ser utilizados para a definição de uma

função-objetivo, uma medida de confiabilidade e/ou custos, e as restrições para o problema de otimização. Os modelos de confiabilidade para os sistemas genéricos utilizados na aplicação desenvolvida são obtidos por meio da análise dos blocos de confiabilidade (Anexo B.1). Um modelo exponencial para confiabilidade dos componentes foi assumido (Anexo A).

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.

Três sistemas genéricos constituídos por cinco sub-sistemas são estudados: sistema série S_1 , sistema série-paralelo S_2 e um sistema ponte (complexo) S_3 . Para esses três sistemas, problemas de otimização foram formulados. No presente trabalho adotou-se o que foi denominado formulação tradicional (mono-objetivo) a qual foi também adotada por Chen (2006). Adicionalmente, foram formulados problemas multi-objetivo.

Problemas de alocação de redundância-confiabilidade são tipicamente definidos na forma de programação não-linear mista-inteira (Gen and Yun, 2006). Os problemas de otimização mono-objetivo tratados no presente trabalho são formulados como segue:

$$\begin{aligned} & \text{maximize } R_S(\mathbf{r}, \mathbf{n}) \\ & \text{sujeito a } \mathbf{g}(\mathbf{r}, \mathbf{n}) \geq 0 \end{aligned} \tag{5.1}$$

onde R_S é a função-objetivo e $\mathbf{g}(\mathbf{r}, \mathbf{n})$ são as restrições do problema de otimização.

Na formulação multi-objetivo, são consideradas duas funções-objetivo

$$\begin{aligned} & \text{maximize } [R_S(\mathbf{r}, \mathbf{n}), \frac{1}{C_S(\mathbf{r}, \mathbf{n})}] \\ & \text{sujeito a } \mathbf{g}(\mathbf{r}, \mathbf{n}) \geq 0 \\ & R_S \geq R \end{aligned} \tag{5.2}$$

onde R_S e $\frac{1}{C_S}$ são as funções-objetivo e $\mathbf{g}(\mathbf{r}, \mathbf{n})$ e R são as restrições do problema de otimização, sendo esta última referente ao mínimo de confiabilidade esperada do sistema.

Tanto na formulação mono-objetivo como na multi-objetivo, $\mathbf{r} \in [0, 1]^m$ é o vetor de confiabilidades dos componentes dos sub-sistemas e $\mathbf{n} \in \mathbb{N}^m$ o vetor de número de redundâncias de cada sub-sistema.

5.1 Problemas de Otimização - Formulação Mono-objetivo

A formulação do problema de otimização de confiabilidade na sua versão mono-objetivo é realizada escrevendo-se as funções de confiabilidade dos sistemas S_1 , S_2 e S_3 a partir das confiabilidades de seus sub-sistemas, as quais são obtidas a partir da confiabilidade de seus componentes.

A confiabilidade de um Sistema série S_1 com $m = 5$ sub-sistemas, como ilustrado na Figura 5.1, é dada por (vide Anexo B.1, seção B.1.1):

$$R_{S_1}(\mathbf{r}, \mathbf{n}) = \prod_{i=1}^m R_i \quad (5.3)$$

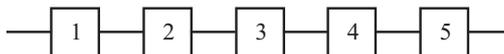


Figura 5.1: Sistema série genérico com cinco sub-sistemas.

A confiabilidade do sistema série-paralelo S_2 com $m = 5$ sub-sistemas, como ilustrado na Figura 5.2 é dada por (vide Anexo B.1, seção B.1.3):

$$R_{S_2}(\mathbf{r}, \mathbf{n}) = 1 - (1 - R_1 R_2) \{1 - [1 - (1 - R_3)(1 - R_4)] R_5\} \quad (5.4)$$

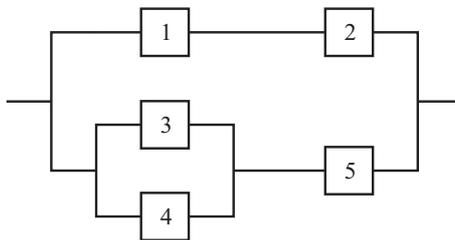


Figura 5.2: Sistema série-paralelo genérico com cinco sub-sistemas.

A confiabilidade do sistema complexo S_3 com $m = 5$ sub-sistemas, como ilustrado na

Figura 5.3 é dada por (vide Anexo B.1, seção B.1.7):

$$\begin{aligned}
 R_{S_3}(\mathbf{r}, \mathbf{n}) = & R_1R_2 + R_3R_4 + R_1R_4R_5 + R_2R_3R_5 \\
 & - R_1R_2R_3R_4 - R_1R_2R_3R_5 \\
 & - R_1R_2R_4R_5 - R_1R_3R_4R_5 \\
 & - R_2R_3R_4R_5 + 2R_1R_2R_3R_4R_5
 \end{aligned} \tag{5.5}$$

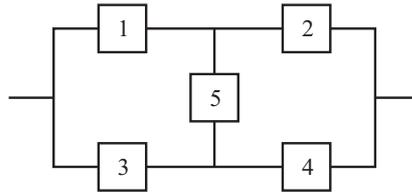


Figura 5.3: Sistema complexo (ponte) com cinco sub-sistemas.

Em cada um dos sistemas apresentados anteriormente, há $m = 5$ sub-sistemas. Ao se alocar redundâncias aos m sub-sistemas, cada sub-sistema passa a ser representado por um modelo RBD consistindo em n componentes em paralelo. Assumindo-se que os componentes redundantes alocados em cada sub-sistema sejam idênticos ao componente primário todos com confiabilidade r_i , pode-se então escrever a confiabilidade equivalente de cada sub-sistema $R_i (i = 1, 2, \dots, m)$ como (vide Anexo B.1, seção B.1.2):

$$R_i(r_i, n_i) = 1 - (1 - r_i)^{n_i}, \quad i = 1, \dots, m. \tag{5.6}$$

Por exemplo, para o sistema série da Figura 5.1, se em cada um dos seus sub-sistemas for alocado um novo componente de confiabilidade r_i igual ao componente original obtém-se um sistema como o apresentado na Figura 5.4.

Suponha-se que se pretende otimizar a confiabilidade de um sistema sujeita a limitações em termos de Custos, Volume e Peso. Desta forma, definem-se as funções de restrição para o problema de otimização mono-objetivo como segue Tillman *et al.* (1980):

$$g_1(\mathbf{r}, \mathbf{n}) = V - \sum_{i=1}^m w_i v_i^2 n_i^2 \tag{5.7}$$

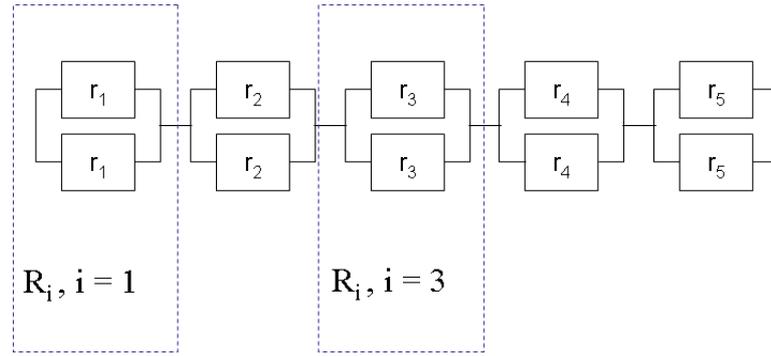


Figura 5.4: Sistema equivalente para o sistema série quando um componente redundante é alocado em cada um de seus sub-sistemas e possui confiabilidade r_i igual ao componente original do sub-sistema.

, onde g_1 refere-se à função de restrição em volume;

$$g_2(\mathbf{r}, \mathbf{n}) = C - \sum_{i=1}^m \alpha_i \left(-\frac{T}{\ln r_i} \right)^{\beta_i} (n_i + e^{n_i/4}) \quad (5.8)$$

, onde g_2 refere-se à função de restrição em custo e T é o tempo da missão do sistema;

$$g_3(\mathbf{r}, \mathbf{n}) = W - \sum_{i=1}^m w_i n_i e^{n_i/4} \quad (5.9)$$

, onde g_3 refere-se a função de restrição em peso;

As funções 5.7, 5.8 e 5.9 relativas às restrições dependem das características de seus sub-sistemas e componentes. Os valores α e β são parâmetros assumidos constantes que representam características físicas dos componentes dos sub-sistemas, \mathbf{r} é o vetor de confiabilidade dos componentes de cada sub-sistema. V , C e W são as metas (limites) para o volume, o custo e o peso do sistema a ser otimizado.

As restrições 5.7 e 5.8 dependem somente do número de redundâncias alocadas em cada sub-sistema, assumindo-se serem conhecidos o volume e o peso de cada componente os quais são assumidos idênticos em um dado sub-sistema.

A restrição 5.8 depende do número de redundâncias como também da confiabilidade de cada componente sendo alocado aos sub-sistemas. É obtida deduzindo-se a relação existente entre a confiabilidade de cada sub-sistema e componente, e os custos para obtê-la. É intuitivo que componentes mais confiáveis exijam maior dispêndio de recursos (no projeto ou na manutenção).

No modelo desenvolvido, uma taxa de falhas constante é assumida e, portanto, uma distribuição exponencial é adequada para modelar a confiabilidade dos componentes. Partindo-se desta premissa, e assumindo-se serem conhecidos os custos de cada componente de cada um dos sub-sistemas, o custo total do sistema pode ser obtido pelo somatório do custo de cada sub-sistema, o qual é o somatório do custo de cada componente. No caso da formulação utilizada no presente trabalho, o custo de cada componente é dado por 5.10.

$$C(r_i) = \frac{\alpha_i}{\lambda_i^{\beta_i}} \quad (5.10)$$

,sendo r_i dado pela equação 5.11.

$$r_i = e^{-\lambda_i t} \quad (5.11)$$

Aplicando-se o logaritmo natural a ambos os lados de 5.11, chega-se à equação que define a taxa de falha de um dado componente i do sub-sistema, e é dada por:

$$\lambda_i = -\frac{\ln(r_i)}{T} \quad (5.12)$$

Assim, 5.10 pode ser reescrita como:

$$C(r_i) = \alpha_i \left(\frac{-T}{\ln(r_i)} \right)^{\beta_i} \quad (5.13)$$

,que é exatamente a base para a equação 5.8.

Apresenta-se em (5.14) a formulação completa para o problema de otimização mono-objetivo.

$$\begin{aligned} & \text{maximize } R_{S_k}(\mathbf{r}, \mathbf{n}) \\ & \text{sujeito a } \mathbf{g}(\mathbf{r}, \mathbf{n}) \geq 0 \\ & \quad 0 \leq r_i \leq 1, \\ & \quad n_i \in \mathbb{I}^+, \\ & \quad 1 \leq i \leq m \\ & \quad m = 5 \end{aligned} \quad (5.14)$$

,sendo R_{S_k} ($k = 1, 2, 3$) a função-objetivo correspondente ao sistema que se pretende otimizar (Série, Série-paralelo e Ponte).

Por se tratar de um problema misto, envolvendo variáveis inteiras (número de redundâncias), 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 (5.1), o que motiva o estudo de técnicas estocásticas.

Neste trabalho, o algoritmo genético (computação evolucionária) e o algoritmo imune (baseado no princípio da função clonal de sistemas imunológicos, parte de estudos de técnicas atualmente conhecidas como sistemas imunológicos artificiais) são avaliados na otimização de confiabilidade de sistemas. Foram implementados os operadores fundamentais destes algoritmos com codificação real, e adicionado um tratamento diferenciado das restrições.

5.1.1 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 por meio de operadores de cruzamento, mutação e seleção. Este algoritmo proporciona uma boa exploração dos locais entre os melhores indivíduos. A estrutura básica de um algoritmo genético é apresentada no fluxograma da Figura 5.5.

5.1.2 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). A estrutura básica de um algoritmo imune é apresentada no fluxograma da Figura 5.6.

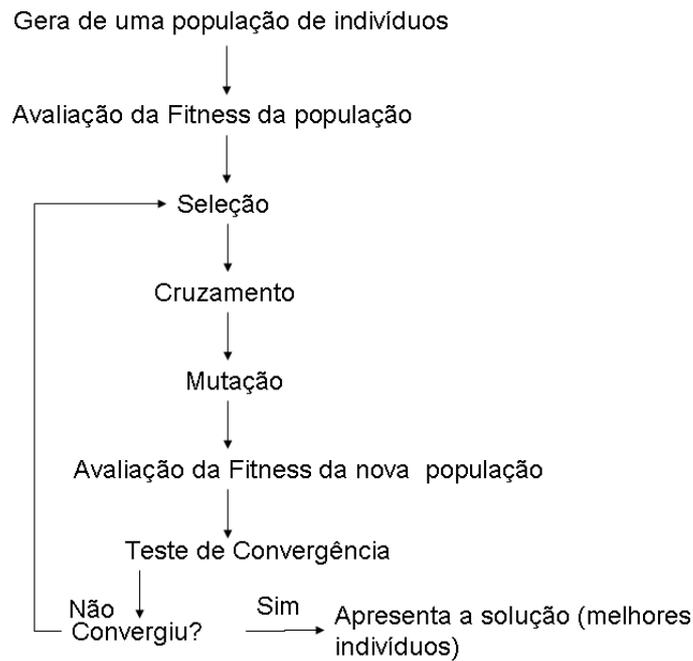


Figura 5.5: Estrutura básica do algoritmo genético (Ashlock, 2005).

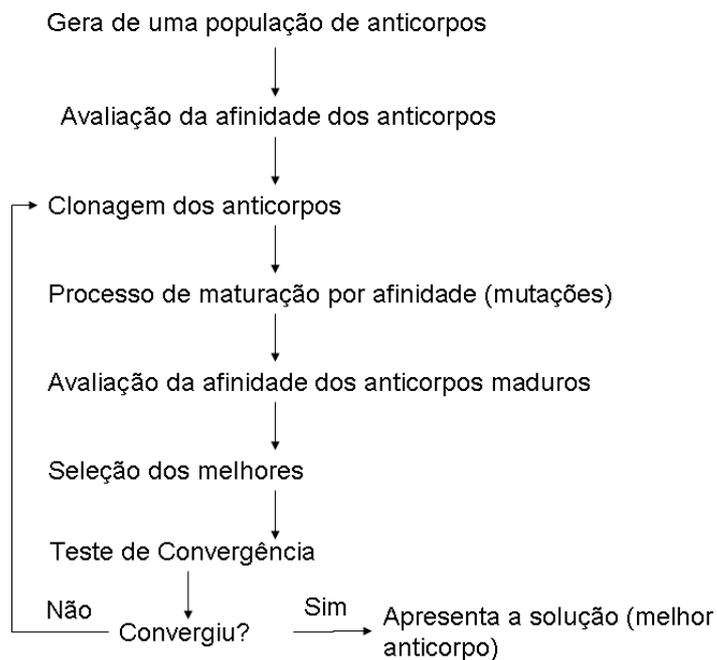


Figura 5.6: Estrutura básica do algoritmo imune (de Castro and Zuben, 2002).

5.1.3 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. 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, como ilustrado na Figura 5.7). Sua convergência foi acelerada com o uso de múltiplos cortes, provindos de cortes passados ou de várias restrições ativas (Vieira *et al.*, 2007).

Sua aplicação no presente trabalho teve como objetivo uma melhor exploração local para a variável de decisão real (confiabilidade), mantidas fixas as variáveis inteiras (número de redundâncias) dos sistemas genéricos estudados. Embora seja um algoritmo de otimização em uma visão não necessariamente de Inteligência Computacional, considerou-se adequada sua inserção no presente trabalho, pois foi possível a obtenção de resultados melhores do que os disponíveis na literatura como decorrência da sua aplicação.

O algoritmo consiste na atualização de uma solução inicial x_k selecionada na primeira iteração $k = 0$ tal que o ponto ótimo x^* da função-objetivo f_0 em estudo esteja contido no elipsoide E_0 definido por 5.15, onde Q_k é uma matriz positiva definida, e sujeito a restrições $f_i, i = 1, \dots, m$, definidas por 5.16.

$$E_0 = \{x \in \mathbb{R}^n \mid (x - x_k)^T Q_k^{-1} (x - x_k) \leq 1\} \quad (5.15)$$

$$x \in S = \{x \in \mathbb{R}^n \mid f_i(x) \leq 0, i = 1, \dots, m\} \quad (5.16)$$

As funções f_0 e f_i devem ser convexas, mas não é necessária a hipótese de diferenciabilidade.

Nas iterações subsequentes, é definida uma função de restrição f_v na qual $f_i(x_k)$ assume o maior valor positivo ou a função-objetivo se $f_i(x_k) \leq 0, \forall i$. O gradiente g_k da função de restrição f_v é calculado. Se $g_k = 0$ ou suficientemente pequeno (dada uma precisão estabelecida), não são necessárias outras iterações pois $x_k = x^*$, ou seja, o ponto ótimo foi encontrado. Do contrário, é necessário o cálculo da parcela de atualização da solução x_k para que uma nova

solução viável x_{k+1} seja gerada (cálculo da direção de busca d e da matriz Q_{k+1} dadas por 5.17 e 5.18, respectivamente).

$$x_{k+1} = x_k - \beta_1 d \quad (5.17)$$

$$Q_{k+1} = \beta_2 \left\{ Q_k - \beta_3 \frac{Q_k g_k (Q_k g_k)^T}{g_k^T Q_k g_k} \right\} \quad (5.18)$$

As constantes β_1 , β_2 , β_3 são funções da dimensão n do problema e são dadas por:

$$\beta_1 = \frac{1}{n+1} \quad (5.19)$$

$$\beta_2 = \frac{n^2}{n^2 - 1} \quad (5.20)$$

$$\beta_3 = \frac{2}{[n(n+1)]} \quad (5.21)$$

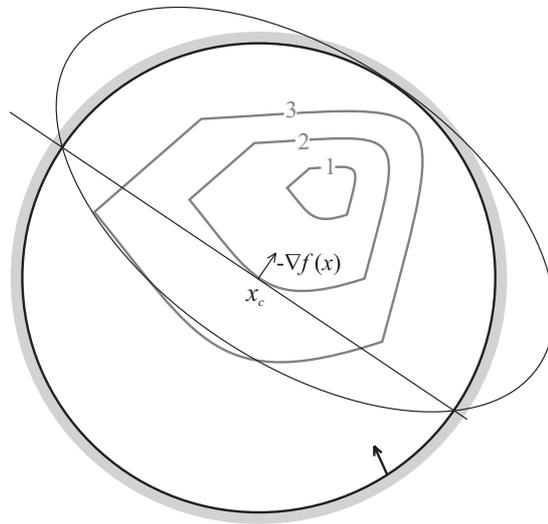


Figura 5.7: Atualização iterativa de uma elipse com o corte de um semiplano.

5.1.4 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 5.1, com o problema multi-objetivo irrestrito

$$\begin{aligned} & \text{maximize } R_s(\mathbf{r}, \mathbf{n}) \\ & \min\{\mathbf{g}(\mathbf{r}, \mathbf{n}), 0\} \end{aligned} \tag{5.22}$$

onde as funções objetivo adicionais são dadas por cada função de restrição limitada superiormente em zero. Dessa maneira o ponto ótimo do problema (5.1) pertence ao conjunto Pareto ótimo de (5.22). Além disso, ela permite uma melhor exploração de locais onde a função objetivo é menor em regiões inactiváveis ou mesmo atravessar regiões inactiváveis. 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.

5.2 Resultados - Formulação Mono-objetivo

Os problemas de teste usados são dados pelas instâncias de (5.1) 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 5.1 e 5.2. Os parâmetros apresentados referem-se a características físicas dos componentes utilizados em cada subsistema dos sistemas de interesse (série, série-paralelo e complexo).

Foi feita uma análise estatística para 200 resultados, ilustrada nas Figuras 5.8, 5.9 e 5.10. 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 de 1%.

Cada problema foi avaliado 25.000 vezes em cada simulação do GA e do IA. O GA

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 5.1: 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 5.2: Parâmetros para a instância de configuração série-paralela.

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. A solução nas variáveis contínuas do ótimo local (possivelmente global) obtido pelo GA e pelo IA, foi refinada com o auxílio do algoritmo elipsoidal (EM) (Vieira *et al.*, 2007) com as variáveis inteiras fixadas.

Os melhores resultados da otimização são mostrados nas Tabelas 5.3, 5.4 e 5.5. Como pode ser verificado, o refinamento da solução utilizando o EM possibilitou a superação dos melhores resultados apresentados na literatura para os sistemas série, série-paralelo e complexo.

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 5.23.

$$MMP(\%) = \frac{R_S - R_C}{1 - R_C} \quad (5.23)$$

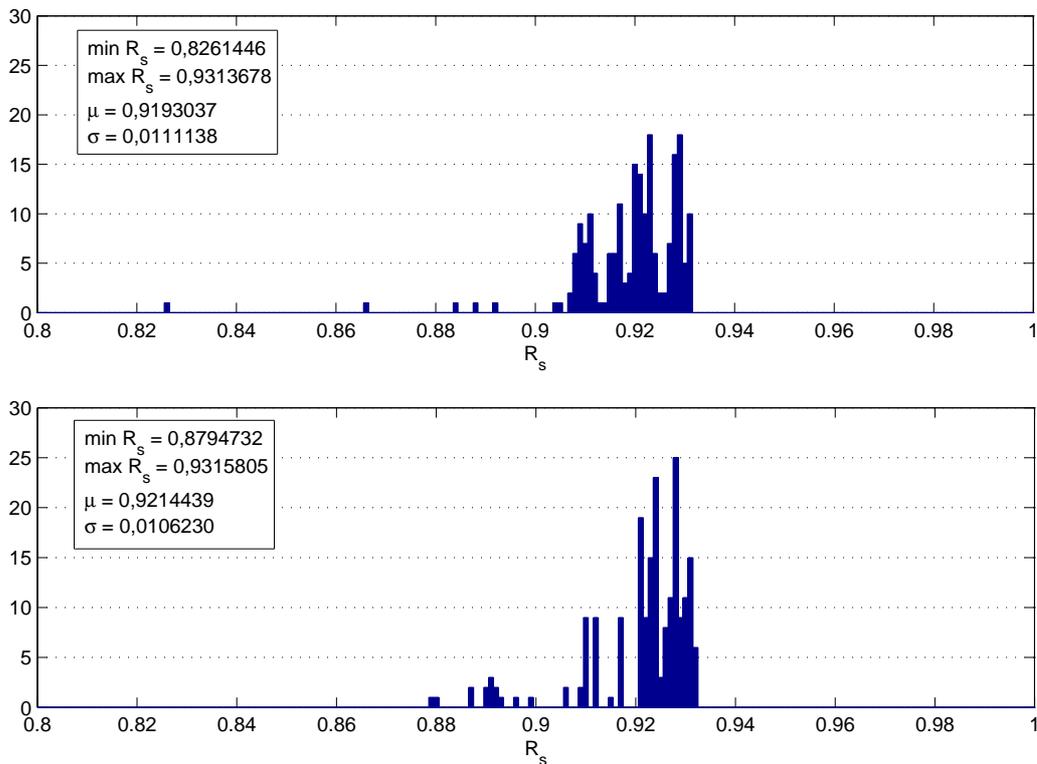


Figura 5.8: Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema série.

	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	0,931678
g(r, n)	27	27	27	27
	0,004118	0,073122	0,000000	0,001559
	7,518918	7,518918	7,518918	7,518918

Tabela 5.3: Melhores resultados da otimização do sistema série.

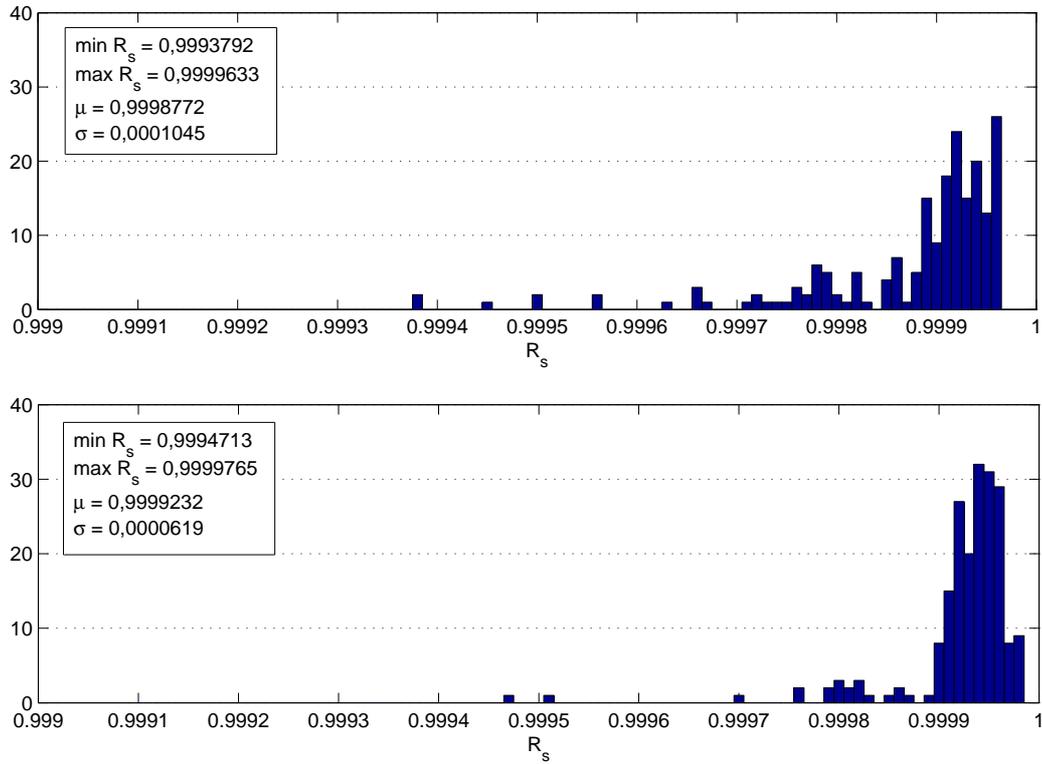


Figura 5.9: Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema série-paralelo.

	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
$R_s(\mathbf{r}, \mathbf{n})$	0,9999633	0,9999765	0,9999766	0,99997658
g(r, n)	18	40	40	40
	0,0525863	0,0462522	0,000000	0,02627
	0,5839591	1,6092890	1,6092890	1,6092890

Tabela 5.4: Melhores resultados da otimização do sistema série-paralelo.

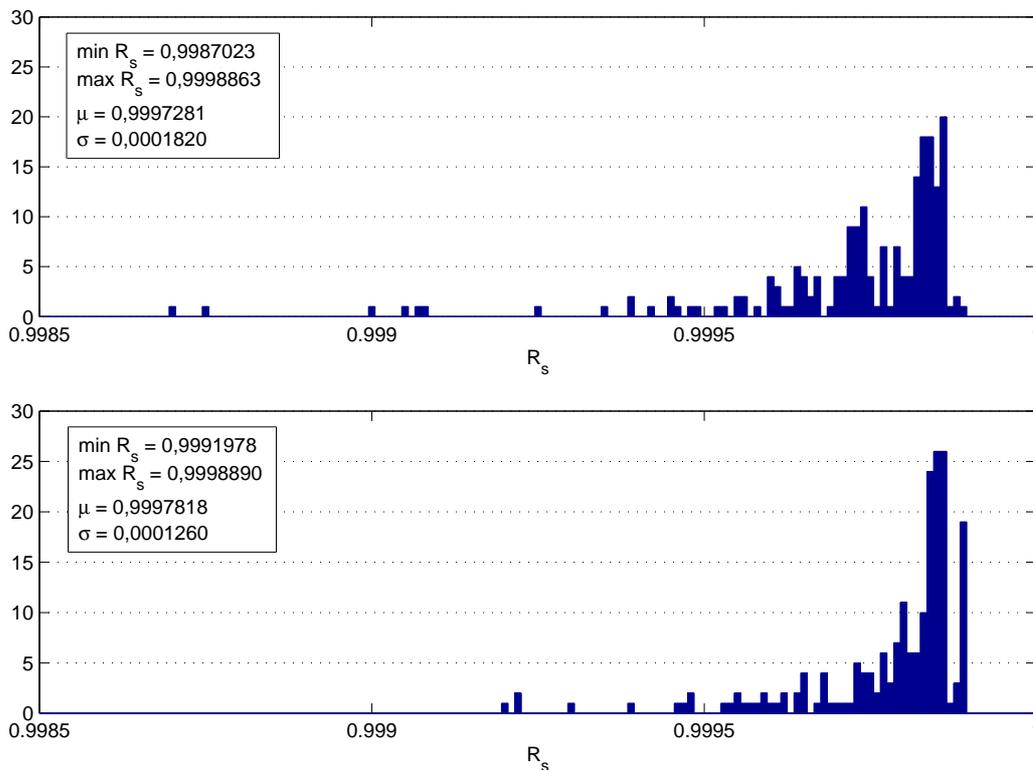


Figura 5.10: Análise estatística de 200 resultados do GA (acima) e do IA (abaixo) para o problema complexo.

	GA	IS	EM	Chen (2006)
n	(3,3,3,3,1)	(3,3,2,4,1)	(3,3,2,4,1)	(3,3,3,3,1)
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(r, n)	18	5	5	18
	0,0740375	0,0411987	0,0000000	0,001494
	4,2647698	1,5604663	1,5604663	4,264770

Tabela 5.5: Melhores resultados da otimização do sistema complexo.

,onde R_S é a confiabilidade do sistema obtida no presente trabalho e R_C a confiabilidade do sistema obtida por Chen (2006).

Aplicando-se a 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. Isso pode ser demonstrado na Figura 5.11, onde se avalia o impacto da confiabilidade de dois tipos de componentes praticamente de mesma confiabilidade (diferença de 0,009 pontos percentuais) em sistemas série constituídos de números diferentes de sub-sistemas.

Número de componentes em série	Confiabilidade dos Componentes	
	99.999%	99.990%
	Confiabilidade do Sistema	
100	99.90%	99.01%
250	99.75%	97.53%
500	99.50%	95.12%
1000	99.01%	90.48%
10000	90.48%	36.79%
100000	36.79%	0.01%

Figura 5.11: Impacto da confiabilidade de componentes na confiabilidade de sistemas 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 n) resultante dos algoritmos implementados apresentou variação em relação ao resultado obtido por Chen (2006) para o mesmo sistema (Vide coluna Chen2006 das tabelas 5.3, 5.4 e 5.5) mesmo

representando um pequeno ganho na confiabilidade do sistema. Contudo, obter confiabilidades próximas da melhor encontrada não é improvável para os algoritmos utilizados.

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 5.12. 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 otimização para a melhoria de confiabili-

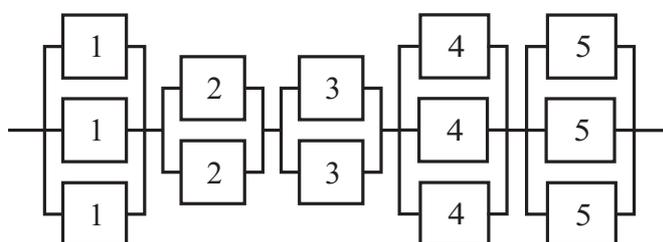


Figura 5.12: Nova arquitetura para o sistema série.

dade, pois com o aumento da complexidade qualquer pequena variação na confiabilidade dos componentes empregados pode afetar significativamente a confiabilidade do sistema.

5.3 Problemas de Otimização - Formulação Multi-objetivo

Na seção 5.1, problemas de otimização de confiabilidade mono-objetivo foram formulados para os sistemas série (Figura 5.1), série-paralelo (Figura 5.2) e complexo (Figura 5.3). Formulações multi-objetivo são mais adequadas à prática, pois a obtenção de alternativas são em geral requeridas pelo engenheiro de confiabilidade. Assim, o problema 5.1 foi alterado para formulação onde se considera também como objetivo o custo decorrente das escolhas dos componentes e o número de redundâncias em cada sub-sistema, o qual é dado por (5.8). 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.

O algoritmo imune na versão multi-objetivo foi implementado, e o tratamento de restri-

ções seguiu a mesma abordagem adotada para o problema mono-objetivo. As soluções obtidas foram ordenadas segundo o princípio da não-dominância (Deb, 1999; Deb *et al.*, 2000) e assim, obtidas as curvas Pareto-ótimas para os três problemas. As Figuras 5.13, 5.14 e 5.15 mostram as curvas Pareto que podem ser utilizadas de forma a se obter um compromisso entre confiabilidade e custos dos sistemas em um processo de tomada de decisão.

Apresenta-se em 5.24 a formulação completa para o problema de otimização multi-objetivo, que é bem similar com 5.14 porém considera-se também como objetivo a função $\frac{1}{C_S}$ igual a (5.8) referente ao custo do sistema, e adiciona-se a condição de confiabilidade mínima R .

$$\begin{aligned}
 & \text{maximize } [R_{S_k}(\mathbf{r}, \mathbf{n}), \frac{1}{C_S(\mathbf{r}, \mathbf{n})}] \\
 & \text{sujeito a } \mathbf{g}(\mathbf{r}, \mathbf{n}) \geq 0 \\
 & R_S \geq R \\
 & 0 \leq r_i \leq 1, \\
 & n_i \in \mathbb{I}^+, \\
 & 1 \leq i \leq m \\
 & m = 5
 \end{aligned} \tag{5.24}$$

5.4 Resultados - Formulação Multi-objetivo

A seguir apresentam-se as curvas Pareto-ótimas para os problemas multi-objetivo formulados para os sistemas série (Figura 5.13), série-paralelo (Figura 5.14) e complexo (Figura 5.15). 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.

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 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.

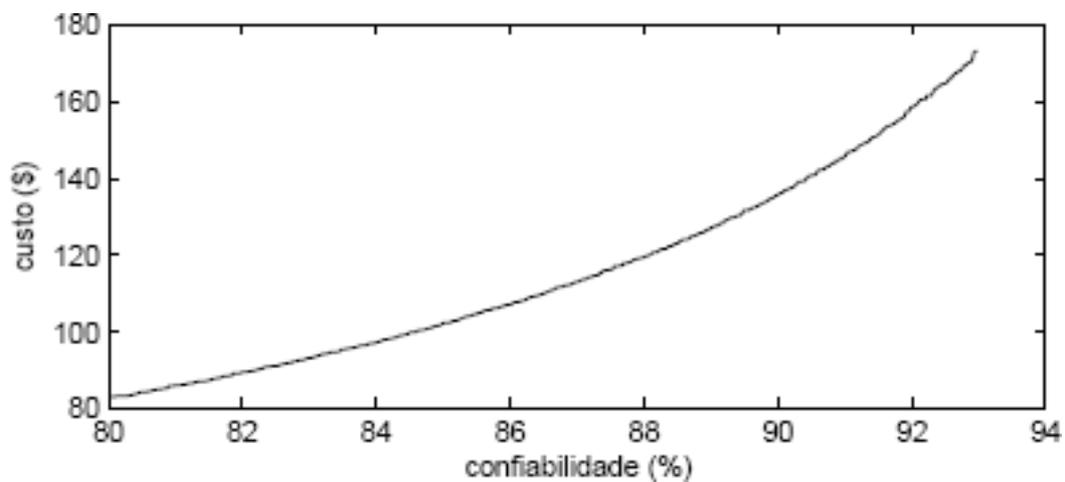


Figura 5.13: Curva Pareto-ótimo para confiabilidade e custo do sistema série

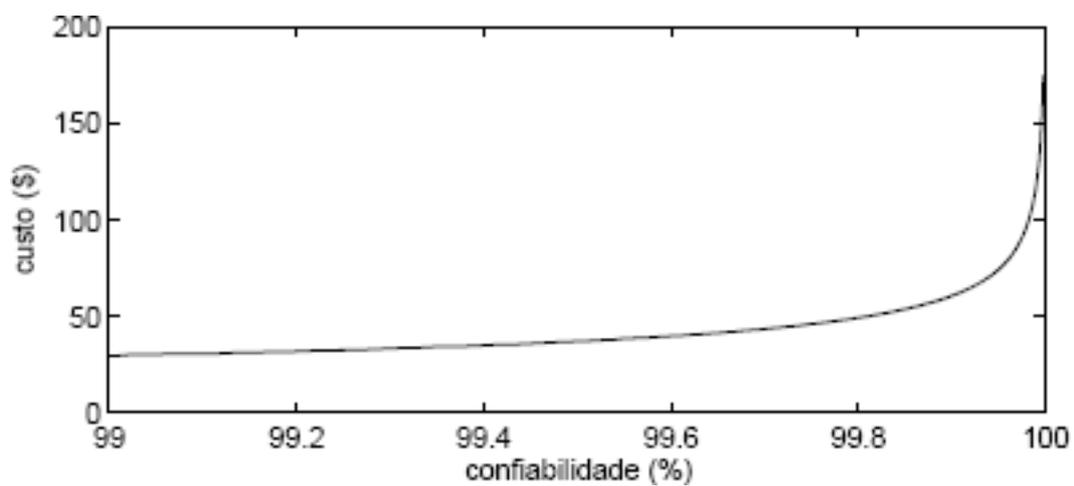


Figura 5.14: Curva Pareto-ótimo para confiabilidade e custo do sistema série-paralelo

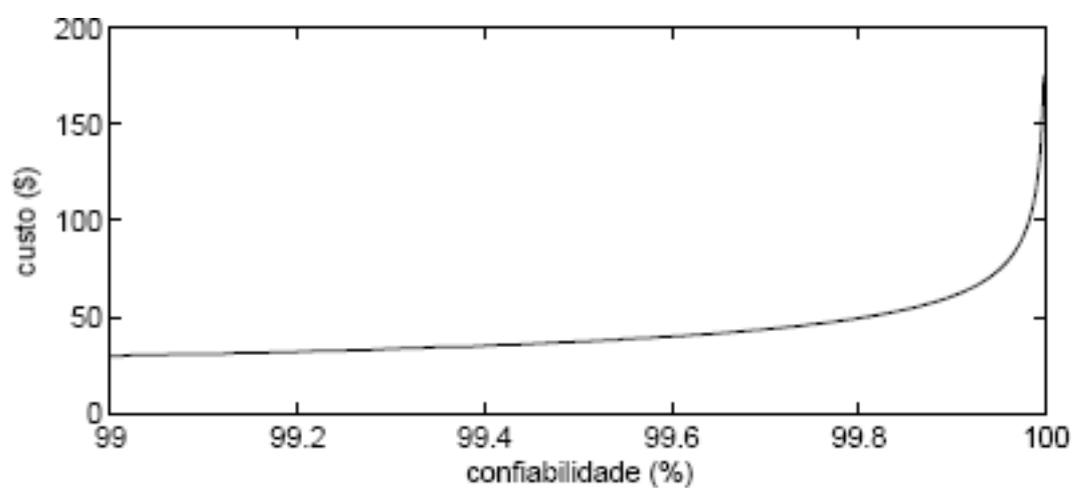


Figura 5.15: Curva Pareto-ótimo para confiabilidade e custo do sistema complexo

Capítulo 6

Conclusões e Propostas de Continuidade

As engenharias de confiabilidade e manutenibilidade são essenciais ao projeto e manutenção de sistemas industriais. Técnicas tradicionais estão bastante desenvolvidas, no entanto, ainda há grande potencial de aplicação a sistemas reais, pois por experiência da autora deste trabalho, ainda há poucas empresas que tenham atingido padrões de desempenho classe mundial. Conclui-se então que o esforço de aplicação dos conceitos e técnicas de confiabilidade e manutenibilidade pode ser ainda mais significativo, ainda que sujeita às limitações impostas pela complexidade dos sistemas modernos. Confiabilidade de sistemas é um fator importantíssimo à competitividade das empresas, pois a eficácia operacional depende de ações que garantam operacionalidade a custos cada vez mais baixos e com segurança.

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.

Algumas das limitações práticas à aplicação de técnicas tradicionais de confiabilidade e manutenibilidade podem ser minimizadas por meio da aplicação de técnicas da inteligência computacional. O presente trabalho procurou apresentar estas técnicas e suas aplicações. Foi

possível identificar grande potencial de aplicação das técnicas em uma lista vasta de problemas difíceis de serem resolvidos por meio de técnicas tradicionais. Como propostas de continuidade, vislumbram-se:

- O Desenvolvimento de modelos para sistemas reais e aplicação dos algoritmos empregados no presente trabalho;
- A implementação de outros algoritmos utilizando-se outras técnicas de Inteligência Computacional e sua aplicação a problemas de confiabilidade e manutenibilidade reais aplicáveis à indústria.

Apêndice A

Probabilidade e Processos Estocásticos

A.0.1 Definições

Técnicas probabilística podem ser aplicadas sob duas nuances: Probabilidade clássica (*Let the data speak for themselves*) ou Probabilidade bayesiana (*Prior knowledge - belief must be taken into account*).

A seguir apresentam-se as definições de probabilidade.

Definição Axiomática:

S: Evento certeza $A + B = A \cup B$, significando a ocorrência de A, B ou ambos. $A.B = A \cap B$, significando a ocorrência de A e B simultaneamente. Se A e B são mutuamente exclusivos: A implica B não ocorreu.

Axiomas:

- $P(A) \geq 0$;
- $P(S) = 1$;
- Se A e B são mutuamente exclusivos $\Rightarrow P(A + B) = P(A) + P(B)$.

Quando há dados, pode-se definir a probabilidade como uma frequência relativa dada por:

$$P(A) = \lim_{n \rightarrow \infty} \frac{n_A}{n} \tag{A.1}$$

,onde n_A é o número de amostras em que o evento A ocorre e, n é o número total de amostras.

Quando algum conhecimento prévio está disponível sobre o fenômeno observado, adota-se a definição clássica de probabilidade dada por:

$$P(A) = \frac{N_A}{N} \quad (\text{A.2})$$

,onde N_A é o número de eventos em que A ocorre e, N é o número total de eventos possíveis.

Outras definições importantes são as de probabilidade condicional e probabilidade conjunta, matematicamente expressas por $P(A | B)$ (Probabilidade de A ocorrer está condicionada à observação ou evidência sobre B), e $P(A, B)$ (Probabilidade de A e B ocorrerem conjuntamente), respectivamente. As probabilidades condicional e conjunta estão relacionadas como segue:

$$P(A, B) = P(A | B)P(B) \quad (\text{A.3})$$

,onde $P(B)$ é a probabilidade de B ocorrer.

Para o cálculo da probabilidade condicional, é necessária a aplicação do Teorema de Bayes expresso matematicamente por:

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad (\text{A.4})$$

,onde $P(A)$ é a probabilidade de A ocorrer.

Generalizando-se a equação (A.4), chega-se a:

$$P(A | B) = \frac{P(B | A)P(A)}{\sum_{i=1}^n P(B | A_i)P(A_i)} \quad (\text{A.5})$$

,onde $P(A_i)$ é a probabilidade “a priori” de A ocorrer, e $P(B | A)$ é a verossimilhança (*likelihood*). Pode-se definir também $P(A_i | B)$ como a probabilidade “a posteriori” de A.

A.0.2 Funções de Distribuição de Probabilidade

São várias as distribuições de probabilidade aplicáveis à engenharia de confiabilidade. Algumas delas são apresentadas na Figura A.1.

Distribuição	Função densidade de probabilidade $f(t)$	Distribuição de probabilidade $R(t)$ - Confiabilidade	Função taxa de falha $\lambda(t)$	Variância σ^2
Poisson	$\frac{(\lambda \cdot t)^x \cdot e^{-\lambda t}}{x!}$	$1 - \sum_{j=0}^n \frac{(\lambda \cdot t)^j \cdot e^{-\lambda t}}{j!}$	-	$\lambda \cdot t$
Gaussiana	$\frac{1}{\sigma \cdot \sqrt{2 \cdot \pi}} \cdot e^{-\left[\frac{(t-\mu)^2}{2\sigma^2}\right]}$	$\int_t^{\infty} \frac{1}{\sigma \cdot \sqrt{2 \cdot \pi}} \cdot e^{-\left[\frac{(t-\mu)^2}{2\sigma^2}\right]} dt$	$\frac{f(t)}{R(t)}$	σ^2
Exponencial	$\lambda \cdot e^{-\lambda t}$	$e^{-\lambda t}$	λ	$\frac{1}{\lambda}$
Weibull	$\frac{\beta \cdot t^{\beta-1}}{\alpha^\beta} \cdot e^{-\left[\frac{t^\beta}{\alpha^\beta}\right]}$	$e^{-\left[\frac{t^\beta}{\alpha^\beta}\right]}$	$\frac{\beta \cdot t^{\beta-1}}{\alpha^\beta}$	$\alpha^2 \cdot \left[\Gamma\left(1 + \frac{2}{\beta}\right) - \Gamma^2\left(1 + \frac{1}{\beta}\right) \right]$

Figura A.1: Modelos probabilísticos e parâmetros usualmente empregados em estudos de Confiabilidade

Kececioglu (2002) apresenta uma ótima revisão das várias distribuições de probabilidade aplicáveis à engenharia de confiabilidade.

Apêndice B

Modelagem e Análise de Confiabilidade Sistêmica

A modelagem e análise de confiabilidade de sistemas pode ser realizada por diferentes metodologias as quais serão brevemente apresentadas. Mais detalhes podem ser obtidos na vasta literatura disponível sobre o assunto. A revisão apresentada a seguir baseou-se em especial em Yang, 2007.

B.1 Diagramas de Bloco de Confiabilidade - RBD (*Reliability Block Diagram*)

A partir da modelagem por meio de blocos de confiabilidade é possível a obtenção da função de confiabilidade para o sistema em função de seus componentes. É uma das técnicas mais utilizadas por engenheiros de confiabilidade e possui como uma grande vantagem o fato de se constituir em uma ferramenta gráfica. Um inconveniente do RBD é o de não incorporar características dinâmicas do sistema nem a dependência entre eventos. Em sistemas complexos de grande porte com muitos sub-sistemas e componentes, uma simplificação do diagrama de blocos é geralmente necessária quando se pretende realizar análises quantitativas de confiabilidade. Tais simplificações são obtidas por meio de diferentes métodos. A seguir apresentam-se as configurações típicas de blocos de confiabilidade e os métodos utilizados para a obtenção da função de confiabilidade para o sistema dada a confiabilidade dos sub-sistemas e componentes.

B.1.1 Configuração Série

Um sistema é definido como série se a falha de um ou mais de seus componentes resulte na falha do sistema, ou seja, todos os componentes devem funcionar para que o sistema cumpra sua missão. Um sistema série genérico é apresentado na Figura B.1.



Figura B.1: Sistema série genérico com m componentes

Supondo-se que um sistema série consista em m componentes mutuamente independentes, onde independência mútua significa que a falha de um componente em particular não afeta a vida de outros componentes, pode-se deduzir a função de confiabilidade do sistema por meio do cálculo da probabilidade conjunta de sucesso de todos os componentes do sistema, a qual pode ser substituída pelo produto das probabilidades de sucesso de cada componente individualmente. Sob tais condições a função de confiabilidade do sistema série da Figura B.1 é dada pela Equação B.1.

$$R_s = \prod_{i=1}^m R_i \quad (\text{B.1})$$

,onde R_i é a confiabilidade de cada sub-sistema ou componente.

Caso os sub-sistemas ou componentes sejam idênticos com confiabilidade R_0 , a Equação B.1 reduz-se a B.2.

$$R_s = R_0^m \quad (\text{B.2})$$

B.1.2 Configuração Paralela

Um sistema é definido como paralelo se, e somente se, a falha de todos seus componentes resulte na falha do sistema, ou seja, um sistema paralelo é capaz de cumprir sua missão se pelo menos um de seus componentes funcione adequadamente. Um sistema paralelo genérico é apresentado na Figura B.2.

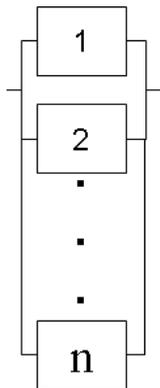


Figura B.2: Sistema paralelo genérico com n sub-sistemas ou componentes

Supondo-se que um sistema paralelo consista em n componentes mutuamente independentes, onde independência mútua significa que a falha de um componente em particular não afeta a vida de outros componentes, pode-se deduzir a função probabilidade de falha do sistema por meio do cálculo da probabilidade conjunta de falha de todos os componentes do sistema, a qual pode ser substituída pelo o produto das probabilidades de falha de cada componente individualmente. A confiabilidade é o complemento da função probabilidade de falha e sob a condição de independência dos componentes, a função de confiabilidade do sistema paralelo da Figura B.2 é dada pela Equação B.3.

$$R_s = 1 - \prod_{i=1}^n (1 - R_i) \quad (\text{B.3})$$

,onde R_i é a confiabilidade de cada componente.

Caso os sub-sistemas ou componentes sejam idênticos com confiabilidade R_0 , a Equação B.3 reduz-se a B.4.

$$R_s = 1 - (1 - R_0)^n \quad (\text{B.4})$$

Caso a confiabilidade R_s seja estabelecida como uma meta a ser atingida, o número mínimo de componentes requeridos no sistema é dado pela Equação B.5.

$$n = \frac{\ln(1 - R_s)}{\ln(1 - R_0)} \quad (\text{B.5})$$

B.1.3 Configuração Série-Paralela

Um sistema Série-paralelo é em geral composto por m sub-sistemas em série com m_i ($i = 1, 2, \dots, n$) componentes em paralelo em cada sub-sistema i , como apresentado na Figura B.3.

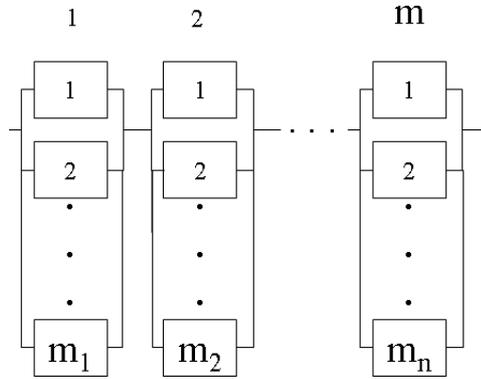


Figura B.3: Sistema série-paralelo genérico com m sub-sistemas em série consistindo em m_i ($i = 1, 2, \dots, n$) componentes em paralelo.

Para calcular a confiabilidade do sistema, os blocos de confiabilidade de cada sub-sistema paralelo i são reduzidos a blocos equivalentes utilizando-se a Equação B.3, assumindo-se a independência entre os m_i componentes, obtendo-se a Equação B.6.

$$R_i = 1 - \prod_{j=1}^{m_i} (1 - R_{ij}) \quad (\text{B.6})$$

,onde R_{ij} é a confiabilidade do j -ésimo componente do sub-sistema i , sendo $i = 1, 2, \dots, n$ e $j = 1, 2, \dots, m_i$. Após a redução dos sub-sistemas paralelos, os m sub-sistemas equivalentes em série são reduzidos utilizando-se a Equação B.1, obtendo-se a confiabilidade do sistema R_s dada por:

$$R_s = \prod_{i=1}^m [1 - \prod_{j=1}^{m_i} (1 - R_{ij})] \quad (\text{B.7})$$

Caso a confiabilidade de todos os componentes do sistema série-paralelo e o número de componentes em cada sub-sistema são iguais, a Equação B.7 reduz-se a:

$$R_s = [1 - (1 - R_0)^m]^n \tag{B.8}$$

,onde R_0 é a confiabilidade de cada componente e n o número de componentes em cada sub-sistema.

B.1.4 Configuração Paralelo-série

Um sistema Paralelo-série é composto por m sub-sistemas em paralelo com n_i ($i = 1, 2, \dots, m$) componentes em série em cada sub-sistema i , como apresentado na Figura B.1.4.

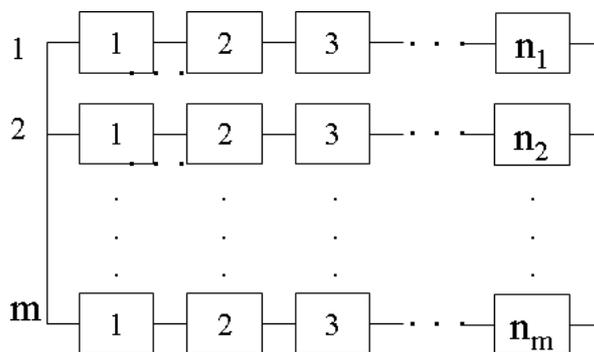


Figura B.4: Sistema paralelo-série genérico com m sub-sistemas em paralelo consistindo em n_i ($i = 1, 2, \dots, m$) componentes em série.

Para calcular a confiabilidade do sistema, os blocos de confiabilidade de cada sub-sistema série i são reduzidos a blocos equivalentes utilizando-se a Equação B.1, assumindo-se a independência entre os n_i componentes, obtendo-se a Equação B.9.

$$R_i = \prod_{j=1}^{n_i} (1 - R_{ij}) \tag{B.9}$$

,onde R_{ij} é a confiabilidade do j -ésimo componente do sub-sistema i , sendo $i = 1, 2, \dots, m$ e $j = 1, 2, \dots, n_i$. Após a redução dos sub-sistemas série, os m sub-sistemas equivalentes em paralelo são reduzidos utilizando-se a Equação B.3, obtendo-se a confiabilidade do sistema R_s dada por:

$$R_s = 1 - \prod_{i=1}^m (1 - \prod_{j=1}^{n_i} R_{ij}) \tag{B.10}$$

Caso a confiabilidade de todos os componentes do sistema série-paralelo e o número de componentes em cada sub-sistema são iguais, a Equação B.10 reduz-se a:

$$R_s = 1 - (1 - R_0^n)^m \quad (\text{B.11})$$

,onde R_0 é a confiabilidade de cada componente e n o número de componentes em cada sub-sistema série.

B.1.5 Configuração k-de-n

A configuração k-de-n refere-se a sistemas que requerem ao menos k de seus n componentes em estado operacional (sem falha) para cumprirem sua missão.

Se os tempos até a falha dos n componentes do sistema são independentes e identicamente distribuídos (i.i.d), pode-se definir uma variável aleatória x representando o número de componentes em estado operacional em um certo instante de tempo e que segue uma distribuição binomial. A confiabilidade de um sistema k-de-n é calculada como a probabilidade de se ter ao menos k componentes em estado operacional com confiabilidade R_0 , e é dada por:

$$R_s = P(x \geq k) = \sum_i^n C_n^i R_0^i (1 - R_0)^{n-i} \quad (\text{B.12})$$

Se $k = 1$, a Equação B.12 reduz-se a B.3. Se $k = n$, a Equação B.12 reduz-se a B.1.

B.1.6 Sistemas Redundantes

Um sistema redundante contém um ou mais componentes ou sub-sistemas em *standby* os quais permitem que o sistema continue operando mesmo que a unidade primária tenha falhado. A falha do sistema somente ocorre caso uma ou mais unidades *standby* e, portanto, é uma técnica de projeto que permite o aumento da confiabilidade do sistema. Tal técnica é bastante utilizada em sistemas críticos.

Unidades *standby* são denominadas ativas se estão completamente energizadas quando o sistema está em uso, e passivas se são energizadas somente quando a unidade primária falha.

Se a unidade primária está em estado operacional perfeito, a unidade redundante é mantida como reserva, e nesse caso esta última é denominada *cold standby* (Figura B.5). Por outro lado, se a unidade primária estiver em estado operacional e ainda assim a unidade redundante é mantida em estado parcialmente operacional (parcialmente energizado ou com carga parcial), esta última é denominada *warm standby*.

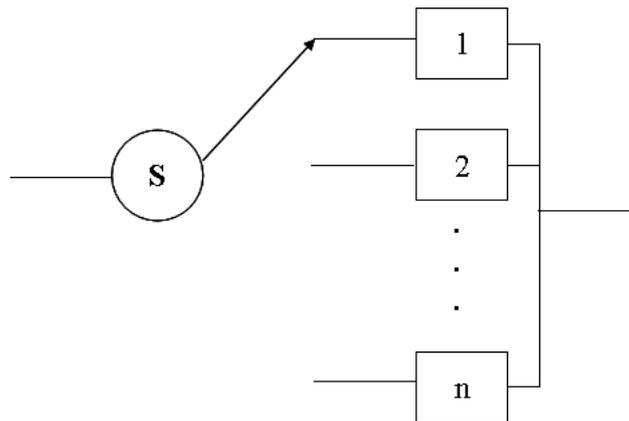


Figura B.5: Sistema redundante com n componentes e sub-sistema de chaveamento S - *Cold Standby*

O uso de unidades reserva requer que sistemas de detecção de falhas e chaveamento sejam implementados. No entanto, os mecanismos de detecção e chaveamento são também sujeitos a falhas e, nesse caso, a confiabilidade do sistema redundante depende não somente da confiabilidade dos seus componentes como também da confiabilidade dos mecanismos citados. Se os mecanismos de detecção e chaveamento são assumidos 100% confiáveis, diz-se que o chaveamento é perfeito. Nesse caso, a confiabilidade do sistema é dada pela confiabilidade de todos os seus componentes. Se os mecanismos de detecção e chaveamento estão também sujeitos a falhas diz-se que o chaveamento é imperfeito. Em ambos os casos, a equação da confiabilidade de sistemas redundantes pode ser deduzida utilizando-se a Equação B.13. A facilidade de dedução das equações analíticas e cálculo da confiabilidade depende da condição em que os tempos até a falha de todos os componentes são assumidos independentes e identicamente distribuídos (i.i.d). Se tal condição não se confirma, o cálculo de B.13 torna-se mais difícil e deve ser realizado por meio de métodos numéricos.

$$R(t) = P(T > t) = \int_t^{\infty} f(t)dt \quad (\text{B.13})$$

,onde $f(t)$ é a função densidade de probabilidade para o tempo até a falha do sistema, a qual é dada por B.14 (para variáveis aleatórias contínuas).

$$f(t) = \lim_{\Delta t \rightarrow 0} \frac{f(t + \Delta t) - F(t)}{\Delta t} \quad (\text{B.14})$$

B.1.7 Configuração Complexa

Sistemas complexos referem-se a sistemas constituídos de sub-sistemas e componentes que interagem de forma a possibilitar que o sistema apresente certas propriedades ou características, não necessariamente explicadas por alguns ou nenhum de seus componentes.

A maior parte dos sistemas reais não pode ser representada ou decomposta facilmente por meio das configurações apresentadas anteriormente. Configurações mais complexas são utilizadas, para as quais métodos mais avançados para a dedução das equações analíticas e análise e cálculo de confiabilidade são necessários. Em sistemas complexos de grande porte, tais tarefas tornam-se impraticáveis quando se tenta realizá-las sem o auxílio de pacotes computacionais. Há disponíveis no mercados diversos pacotes como Reliasoft, Relex, entre outros. Todos apresentam-se como ferramentas úteis para a representação do diagrama de blocos e avaliação quantitativa de confiabilidade por meio de técnicas de simulação. A seguir apresentam-se métodos que nos auxiliam na dedução de blocos de confiabilidade de sistemas.

B.1.7.1 Método de Redução

O método de redução de blocos de confiabilidade refere-se a uma técnica por meio da qual sistemas complexos constituídos de sub-sistemas independentes em série, paralelo, série-paralelo, etc, têm seus blocos de confiabilidade simplificados utilizando-se as equações apresentadas nas seções anteriores de forma a se obter uma equação equivalente para o sistema. É uma técnica simples e efetiva quando se consegue identificar os sub-sistemas e aplicar as regras apresentadas nas seções anteriores. Apresenta-se na Figura B.6 um sistema complexo com 7 sub-sistemas.

Para obter-se a equação de confiabilidade para B.6 procede-se como segue: os blocos 4

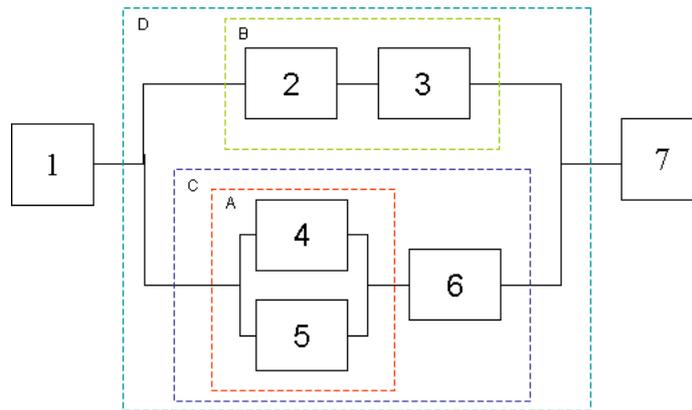


Figura B.6: Sistema complexo genérico com 7 sub-sistemas

e 5 apresentam-se na configuração paralela, assim a confiabilidade equivalente R_A é dada pela equação B.3. Os blocos 2 e 3 estão na configuração série, assim a confiabilidade equivalente R_B é dada pela equação B.1 (Figura B.7).

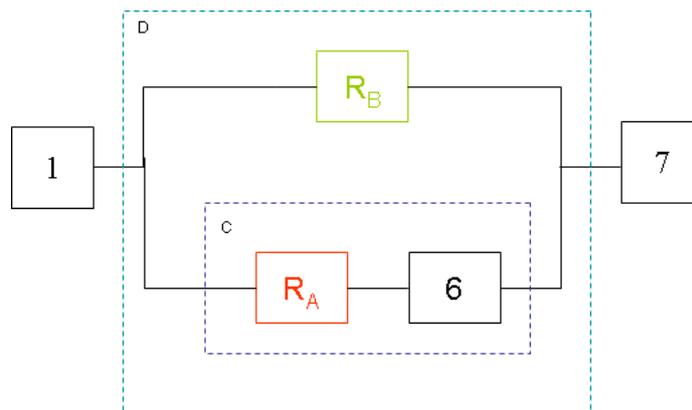


Figura B.7: Sistema equivalente para B.6, sendo $R_A = 1 - (1 - R_4)(1 - R_5)$ e $R_B = R_2 R_3$.

O bloco equivalente R_A por sua vez está em série com o bloco 6, assim pode-se obter a confiabilidade equivalente R_C por meio da equação B.1 (Figura B.8).

Ao se realizar tal procedimento, verifica-se que os blocos R_B e R_C estão em paralelo, podendo-se reduzi-los ao bloco de confiabilidade equivalente R_D por meio da equação B.3.

Finalmente, verifica-se que os sub-sistemas 1, R_D e 7 estão em série, e mais uma vez aplica-se a equação B.1 para que se obtenha a confiabilidade equivalente R_S do sistema (Figura B.10).

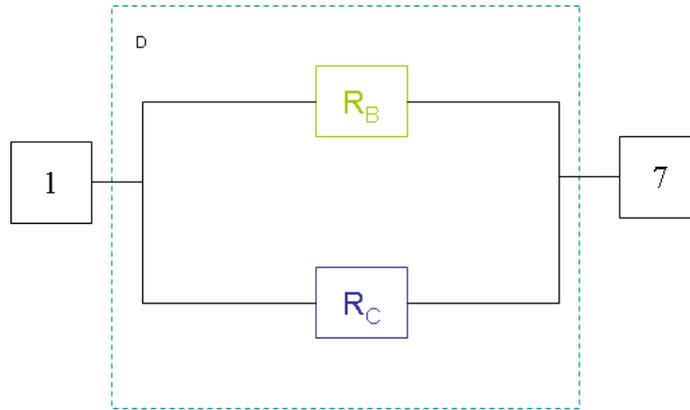


Figura B.8: Sistema equivalente para B.7, sendo $R_C = R_A R_6$.



Figura B.9: Sistema equivalente para B.8, sendo $R_D = 1 - (1 - R_B)(1 - R_C)$.

Realizando-se as substituições adequadas, a confiabilidade do sistema B.6 é dada por:

$$R_S = R_1 \{ 1 - [(1 - R_2 R_3)(1 - (1 - (1 - R_4)(1 - R_5))R_6)] \} R_7 \quad (\text{B.15})$$

B.1.7.2 Método da Decomposição

Em sistemas complexos nos quais sub-sistemas não podem ser facilmente reduzidos conforme comentado na seção anterior, aplica-se um método mais avançado conhecido por método da decomposição, o qual se baseia no Teorema de Bayes. Um sistema complexo em que é necessária a aplicação do método de decomposição para se obter a equação analítica de confiabilidade é o sistema ponte, como o apresentado na Figura B.11.

Para aplicar o método, é necessária a escolha de um componente de interface a partir do qual as análises são realizadas. O componente escolhido é então assumido como 100 % confiável e é substituído no diagrama de blocos por uma linha. Em um segundo momento, o componente escolhido é assumido como em estado de falha e é então removido do sistema.

Considere-se o sistema ponte genérico apresentado na Figura B.11. O componente escolhido para dar início à análise é o componente 5. Se tal componente é 100% confiável, o novo

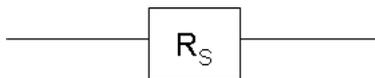


Figura B.10: Sistema equivalente para B.9, sendo $R_S = R_1R_D R_7$.

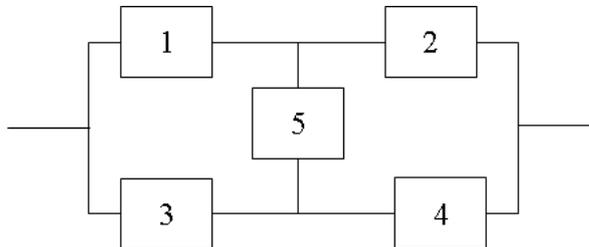


Figura B.11: Sistema ponte genérico com 5 sub-sistemas

sistema equivalente é então representado como na Figura B.12. Se o componente está em estado de falha, o novo sistema equivalente é representado como na Figura B.13.

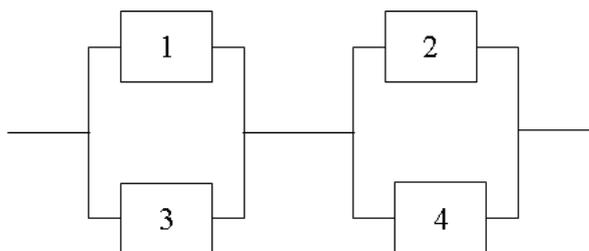


Figura B.12: Sistema ponte equivalente com componente 5 assumido como livre de falhas.

A confiabilidade do sistema é então calculada nas duas situações. Seja A um evento no qual o componente 5 é 100% confiável, \bar{A} o evento no qual componente 5 está em estado de falha, e S o evento que define o sucesso do sistema. Pelos axiomas da probabilidade, a confiabilidade geral do sistema é dada por:

$$R_S = P(S | A)P(A) + P(S | \bar{A})P(\bar{A}) \tag{B.16}$$

, onde $P(S | A)$ e $P(S | \bar{A})$ são probabilidades condicionais, e $P(A)$ e $P(\bar{A})$ são probabilidades marginais de sucesso e falha do componente 5 iguais a R_5 e $(1 - R_5)$, respectivamente.

Para o sistema ponte equivalente apresentado na Figura B.12, pode-se aplicar o método de redução de blocos de confiabilidade para se obter a probabilidade condicional $P(S | A)$

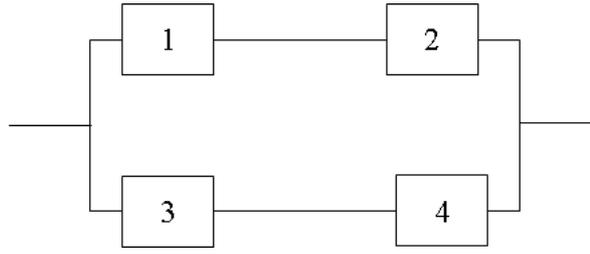


Figura B.13: Sistema ponte equivalente com componente 5 em estado de falha.

que multiplicada pela probabilidade marginal $P(A)$ permite a obtenção da primeira parcela da Equação B.16, dada por:

$$R_{S1} = P(S | A)P(A) = \{[(1 - (1 - R_1)(1 - R_3))(1 - (1 - R_2)(1 - R_4))]R_5\} \quad (\text{B.17})$$

Para o sistema ponte equivalente apresentado na Figura B.13, pode-se aplicar o método de redução de blocos de confiabilidade, para se obter a probabilidade condicional $P(S | \bar{A})$ que multiplicada pela probabilidade marginal $P(\bar{A})$ permite a obtenção da segunda parcela da Equação B.16, dada por:

$$R_{S2} = P(S | \bar{A})P(\bar{A}) = \{[(1 - (1 - R_1R_3)(1 - R_2R_4))](1 - R_5)\} \quad (\text{B.18})$$

Realizando-se as substituições de B.17 e B.18 bem como os desenvolvimentos necessários na Equação B.16, obtém-se a Equação para a confiabilidade do sistema ponte dada por:

$$\begin{aligned} R_S = & R_1R_2 + R_3R_4 + R_1R_4R_5 + R_2R_3R_5 \\ & - R_1R_2R_3R_4 - R_1R_2R_3R_5 \\ & - R_1R_2R_4R_5 - R_1R_3R_4R_5 \\ & - R_2R_3R_4R_5 + 2R_1R_2R_3R_4R_5 \end{aligned} \quad (\text{B.19})$$

A eficiência do método da decomposição depende da escolha do componente a partir do qual se inicia a análise. Em alguns casos é necessária a escolha de mais de um componente e a Equação B.16 apresentará 2^m parcelas caso m componentes sejam escolhidos (quando são assumidos estados binários), ou seja, o sistema original é decomposto em 2^m sub-sistemas para

os quais são obtidas as probabilidades condicionais dadas as evidências (estado dos componentes escolhidos) para cada um dos sub-sistemas.

B.1.7.3 Método de Conjunto de Cortes Mínimos

Define-se como um conjunto de cortes mínimos a combinação mínima, necessária e suficiente, de componentes que se falharem simultaneamente interrompem todas as conexões entre a entrada e a saída de um sistema causando, então, a sua falha. Considerando-se um evento de falha do sistema C_i decorrente do conjunto de cortes mínimos i , pode-se representar matematicamente a confiabilidade do sistema por:

$$R_S = 1 - P(C_1 \cup C_2 \cup C_3 \cup \dots \cup C_n) \quad (\text{B.20})$$

onde $C_i (i = 1, 2, \dots, n)$ representa o evento falha simultânea de todos os componentes no conjunto de cortes mínimos i , e n é o número total de conjuntos de cortes mínimos para o sistema em estudo.

A Equação B.20 pode ser avaliada quantitativamente por meio da aplicação da regra de inclusão-exclusão que é dada por:

$$\begin{aligned} P(C_1 \cup C_2 \cup \dots \cup C_n) = & \sum_{i=1}^n P(C_i) - \sum_{i < j=2}^n P(C_i \cap C_j) \\ & + \sum_{i < j < k=3}^n P(C_i \cap C_j \cap C_k) + \dots \\ & + (-1)^{n-1} P(C_1 \cap C_2 \cap \dots \cap C_n) \end{aligned} \quad (\text{B.21})$$

Para o sistema ponte apresentado na seção anterior, por exemplo, pode-se identificar os seguintes conjuntos de cortes mínimos: $\{1,3\}$, $\{2,4\}$, $\{1,4,5\}$, $\{2,3,5\}$. Seja $A_j (j = 1, \dots, 5)$ o evento de falha do j -ésimo componente do sistema ponte apresentado na Figura B.11. Assim, definem-se os eventos descritos pelos cortes mínimos como $C_1 = A_1 \cap A_3$, $C_2 = A_2 \cap A_4$, $C_3 = A_1 \cap A_4 \cap A_5$, e $C_4 = A_2 \cap A_3 \cap A_5$. Pela aplicação das equações B.20 e B.21, e após simplificações por meio de regras da álgebra booleana, obtém-se a Equação B.22 para cálculo da confiabilidade do sistema.

$$\begin{aligned}
R_S = & R_1R_2 + R_3R_4 + R_1R_4R_5 + R_2R_3R_5 \\
& - R_1R_2R_3R_4 - R_1R_2R_3R_5 \\
& - R_1R_2R_4R_5 - R_1R_3R_4R_5 \\
& - R_2R_3R_4R_5 + 2R_1R_2R_3R_4R_5
\end{aligned} \tag{B.22}$$

,que é igual à equação obtida pela aplicação do método da decomposição apresentado na seção anterior.

B.2 Análise dos Modos e Efeitos de Falha - FMEA (*Failure Mode and Effect Analysis*)

A metodologia FMEA é uma ferramenta que auxilia na identificação e priorização de modos de falha potenciais facilitando a descoberta de deficiências de projeto, seus efeitos e mecanismos e conduz à proposição de ações corretivas para modos de falha priorizados. É uma metodologia indutiva mista (qualitativa e quantitativa) elaborada por meio de um processo de análise *bottom-up*. Pode ser aplicada nas várias fases do ciclo de vida de um sistema seja na fase conceitual, revisão de projeto, processo de fabricação ou operação e na sua manutenção (É uma das ferramentas utilizadas na Manutenção Centrada em Confiabilidade - MCC, como forma a identificar as falhas potenciais e avaliar as melhores práticas de manutenção aplicáveis (Moubrey, 2001)).

De forma resumida, após a identificação de todos os modos e mecanismos de falha para os componentes de um sistema ou sub-sistema, são avaliadas a gravidade dos efeitos, a frequência de falhas e o grau de detectabilidade de cada mecanismo a partir de critérios de pontuação (quando há dados que fundamentem a frequência de falha estes podem ser utilizados, do contrário a análise é subjetiva e dependente da experiência da equipe técnica envolvida no trabalho), os quais são multiplicados para se obter um número representando a prioridade de um dado modo/mecanismo de falha, denominado Número de Prioridade de Risco ou *Risk Priority Number* (RPN). A seguir apresentam-se os passos necessários para a aplicação da metodologia.

1. Definir o sistema e sub-sistemas: Priorizar os sistemas que deverão ser escopo para o

trabalho;

2. Selecionar os componentes que serão analisados;
3. Descrever as funções de cada componente;
4. Listar todos os modos de falha dos componentes (Modos);
5. Listar os efeitos de todos os modos de falha (Efeitos);
6. Avaliar a gravidade de cada efeito (Gravidade);
7. Identificar os mecanismos de falha que conduzem à ocorrência dos modos de falha (Causas);
8. Avaliar a frequência com que os mecanismos de falha ocorrem (Ocorrência);
9. Listar ações de controle/corretivas para atuar proativamente sobre os mecanismos de falha;
10. Avaliar grau de detecção dos mecanismos de falha versus as técnicas sugeridas (Detecção);
11. Calcular o RPN (*Risk Priority Number*) como o produto dos índices Ocorrência, Gravidade e Detecção;
12. Recomendar ações corretivas mais adequadas;
13. Documentar e acompanhar a implementação das ações recomendadas e seus resultados.

Os passos acima são documentados em tabelas de forma que o histórico de análise seja preservado. Na Figura B.14 apresenta-se um exemplo de tabela utilizada no registro das análises elaboradas como resultado da aplicação da metodologia FMEA.

B.3 Análise de Árvore de Falhas - FTA (*Fault Tree Analysis*)

A árvore de falhas é uma representação gráfica de relações entre eventos de falha por meio de portas lógicas com o objetivo de se modelar um evento topo de interesse. É uma metodologia dedutiva mista (qualitativa e quantitativa) elaborada por meio de um processo de análise *top-down*. É usualmente aplicada conjuntamente com a técnica FMEA com o objetivo

ITEM	COMPONENTE/ ETAPA DO PROCESSO	FUNÇÃO	FALHAS			SITUAÇÃO ATUAL					AÇÕES CORRETIVAS			RESULTADOS				
			MODO	EFEITO	CAUSAS	CONTROLES ATUAIS	OCORRÊNCIA (O)	GRAVIDADE (G)	DETECÇÃO (D)	RPN (O x G x D)	RECOMENDADAS	TOMADAS	RESP.	OCORRÊNCIA (O)	GRAVIDADE (G)	DETECÇÃO (D)	RPN (O x G x D)	

Figura B.14: Exemplo de tabela utilizada na aplicação de FMEA.

de melhorar o processo de identificação de mecanismos de falha que levam à ocorrência de modos de falha com efeitos de alta gravidade. Assim como o RBD, é bastante utilizado por engenheiros de confiabilidade e muito aplicável à obtenção de soluções sistêmicas para problemas de confiabilidade.

Análises qualitativas de árvores de falha podem ser elaboradas por meio da identificação dos conjuntos de cortes mínimos de forma similar ao que foi apresentado na seção B.1.7.3. As simplificações necessárias para identificação dos conjuntos são realizadas por meio da aplicação de regras da álgebra booleana de acordo com as conexões representadas pelas portas lógicas. A avaliação quantitativa dos conjuntos de cortes mínimos é dada da mesma forma apresentada na Equação B.21.

Análise quantitativas podem também ser realizadas por meio da conversão da árvore de falhas em seu RBD correspondente, e aplicação das técnicas apresentadas na seção B.1. Uma árvore de falha pode ser facilmente convertida em um RBD, sendo que eventos conectados por portas lógicas “E” são correspondentes a blocos de confiabilidade em paralelo, e eventos conectados por portas lógicas “OU” são correspondentes a blocos de confiabilidade em série. A conversão de árvores de falha em digramas de blocos de confiabilidade se dá por meio de um processo de análise *bottom-up* na árvore. Scapin (1999) apresenta exemplos de aplicação da FTA. Apresenta-se na Figura B.15.

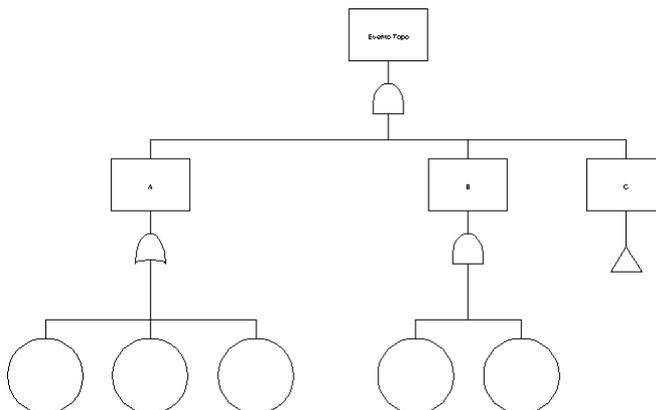


Figura B.15: Exemplo genérico de árvore de falhas criado por meio do software livre OpenFTA©.

B.4 Cadeias de Markov

As cadeias de Markov buscam representar um sistema por meio de um modelo em espaço de estados, sejam eles binários ou não. Sua complexidade aumenta conforme o número de componentes e estados que se pretende representar. É bastante eficaz na obtenção de modelos para sistemas reparáveis e transparente na representação das mudanças de estado, que são quantificadas exatamente por meio das taxas de falha e reparo representando as probabilidades de mudança de estado. Um inconveniente é que Cadeias de Markov somente podem ser aplicadas para sistemas que possam ser modelados por distribuições exponenciais em que as taxas de transição entre estados são constantes.

B.5 Redes Petri

Assim como as cadeias de Markov, redes Petri representam um sistema por meio de um modelo em espaço de estados dinâmico. Pode-se modelar a dependência entre eventos e ainda analisar as transições entre estados bem como momento em que as mesmas ocorrem. Portanto, Redes Petri apresentam capacidade de modelagem superior a RBDs.

B.6 Redes Bayesianas

Uma Rede Bayesiana (RB) é uma metodologia probabilística usada para modelar e prever o comportamento de um sistema, baseando-se em fenômenos estocásticos observados. O

principal objetivo ao se construir uma RB é estimar o grau de crença de um evento específico não observável (ou evento cujo custo de observação é elevado).

A estrutura de uma RB é composta por uma parte qualitativa e outra quantitativa. A qualitativa é construída a partir da teoria de grafos e a quantitativa utiliza a teoria de probabilidade. O conhecimento especializado é muito importante, pois para obtermos um grafo que represente bem o domínio do problema é necessária muita habilidade na técnica de grafos e também conhecimento profundo do problema. Em Langseth and Portinale (2007) a modelagem de redes bayesianas aplicadas à confiabilidade é estudada. Um exemplo de aplicação redes bayesianas ao estudo de confiabilidade de controladores lógicos programáveis é apresentado em Portinale and Bobbio (1999).

B.7 Simulação de Monte Carlo

Em engenharia de confiabilidade é muitas vezes necessária a utilização de técnicas de simulação estocástica para que seja possível o estudo de sistemas complexos em razão da dificuldade em se resolver analiticamente as equações que definem o comportamento do sistema. Uma técnica de simulação estocástica é a que se baseia em métodos de Monte Carlo, os quais consistem basicamente na geração de realizações de um processo estocástico por meio de amostragem (pseudo) aleatória de um modelo previamente escolhido ou modelado (O'Connor, 2002). Como base nas realizações é possível estimar medidas como média e variância de variáveis de interesse. Um aspecto que deve ser ressaltado, é que embora simulação de Monte Carlo seja eficiente na obtenção de soluções aproximadas para problemas complexos (o erro de estimação de métodos de Monte Carlo decresce com a raiz quadrada do número de amostras ou tentativas enquanto o erro de estimação de outros métodos decresce com a raiz m -ésima do número de tentativas, onde m é a dimensão do problema de interesse), sua convergência para solução é lenta e exige esforço computacional considerável. Com o avanço dos recursos computacionais atuais, tal limitação tende a ser minimizada. Muitos pacotes computacionais comerciais já incorporam funcionalidades que permitem a simulação de sistemas complexos por meio de métodos de Monte Carlo. Mais detalhes sobre métodos de Monte Carlo podem ser obtidos em Fishman (1996).

Aplicação de Técnicas de Otimização à Engenharia de Confiabilidade

Marcia de Fatima Platilha Salgado

28 de março de 2008

Referências Bibliográficas

- Aguirre, L. A. (2007). *Introdução à Identificação de Sistemas: Técnicas Lineares e Não-lineares Aplicadas a Sistemas Reais*. Editora UFMG, 3rd edition.
- Ascher, H. and Feingold, H. (1984). *Repairable Systems - Modeling, inference, misconceptions and their causes*. Marcel Dekker.
- Ashlock, D. (2005). *Evolutionary Computation for Modeling and Optimization*. Springer Verlag.
- Birolini, A. (2004). *Reliability Engineering: Theory and Practice*. Springer-Verlag, 4 edition.
- Bittencourt, G. (2008). Inteligência computacional. <http://www.das.ufsc.br/gia/softcomp/node18.html>, Acessado em 10/02/2008.
- Chen, T.-C. (2006). Ias based approach for reliability redundancy allocation problems. *Elsevier Applied Mathematics and Computation*, **182**, 1556–1567.
- de B. Pereira, B. and Rao, C. R. (2005). Survival analysis neural networks. *Learning and Nonlinear Models – Revista da Sociedade Brasileira de Redes Neurais (SBRN)*, **3**(2), 50–60.
- 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*, **6th**, 239–251.
- de Castro e Silva, L. N. (2008). Artificial immune systems.
- de Castro Silva, L. N. (2003). *Engenharia Imunológica: Desenvolvimento e Aplicação de Ferramentas Computacionais Inspiradas em Sistemas Imunológicos Artificiais*. Ph.d. thesis, UNICAMP.
- Deb, K. (1999). *Evolutionary Algorithms in Engineering and Computer Science*, chapter volu-tionary Algorithms for Multi-Criterion Optimization in Engineering Design, pages 135–161. John Wiley.
- Deb, K., Agarwal, S., Pratap, A., and Meyarivan, T. (2000). A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: Nsga-ii. In *Proceedings of the Parallel Problem Solving from Nature VI Conference*.
- Dhillon, B. (2002). *Engineering Maintenance: A Modern Approach*. CRC Press.

- Dhillon, B. (2006). *Maintainability, Maintenance, and Reliability for Engineers*. CRC Press.
- dos Santos, W. B. and Colosimo, E. (2003). *Determinação da Periodicidade da Manutenção Preventiva em Sistemas Reparáveis*. Dissertação de mestrado, Programa de Pós-Graduação em Estatística, Universidade Federal de Minas Gerais.
- Dubois, D. and Kalfsbeek, H. (1990). Elicitation, assessment and pooling of expert judgment using possibility theory. In *Proc. of the 8th Inter. Congress of Cybernetics and Systems (C.N. Manikopoulos, ed.)*.
- Dubois, D., Prade, H., and Sandri, S. (1993). *Fuzzy Logic: State of the Art (R. Lowen, M. Roubens, eds.)*, chapter On possibility/probability transformations, pages 103–112. Kluwer Academic.
- Engelbrecht, A. P. (2003). *Computational Intelligence: An Introduction*, volume 39-40. John Wiley.
- Fishman, G. S. (1996). *Monte Carlo: Concepts, Algorithms and Applications*. Springer-Verlag.
- Freitas, M. A. and Colosimo, E. A. (1997). *Confiabilidade: Análise de Tempo de Falha e Testes de Vida Acelerados*, volume 12 of *Ferramentas da Qualidade*. Fundação Cristiano Ottoni, Belo Horizonte: Fundação Cristiano Ottoni, Escola de Engenharia da UFMG.
- 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.
- Haykin, S. (1999). *Neural Networks - A Comprehensive Foundation*. Prentice Hall, 2nd edition.
- Higgins, L. R., Mobley, R. K., and Smith, R. (2002). *Maintenance Engineering Handbook*. McGraw-Hill, 6th edition.
- INCOSE (2002). *System Engineering Handbook*.
- Jang, J.-S. R. (1997). *Neuro-fuzzy and Soft Computing: A computational approach to learning and machine intelligence*. Prentice Hall.
- Jong, K. D. (1997). *The handbook of Evolutionary Computation*. IOP Publishing Ltd and Oxford University Press.
- Kaplan, E. L. and Meier, P. (1958). Nonparametric estimation from incomplete observations. *Journal of the American Statistical Association*, (53), 457–48.
- Kececioglu, D. (2002). *Reliability Engineering Handbook*, volume 1-2. DEStech publications.
- Kennedy, J. and Eberhart, R. C. (2001). *Swarm Intelligence*. Morgan Kaufman.
- 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. and Zuo, M. J. (2003). *Optimal Reliability Modeling: Principles and Applications*. John Wiley.
- Kuo, W., Prasad, V. R., Tillman, F. A., and Hwang, C.-L. (2001). *Optimal Reliability Design: Fundamentals and Applications*. Cambridge University Press, 1 edition.
- Langseth, H. and Portinale, L. (2007). Bayesian networks in reliability. *Reliability Engineering and System Safety*, (92), 92–108.
- Lee, E. and Wang, J. (2003). *Statistical Methods for Survival Data Analysis*. John Wiley, 3rd edition.
- Levitin, G. (2007). *Computational Intelligence in Reliability Engineering: Evolutionary Techniques in Reliability Analysis and Optimization and New Metaheuristics, Neural and Fuzzy Techniques in Reliability*, volume 39-40. Springer-Verlag.
- Lindqvist, B. (1998). *Statistical and probabilistic models in reliability*, chapter Statistical modeling and analysis of repairable systems, pages 3–25. Birkhauser.
- Menon, A. (2004). *Frontiers of Evolutionary Computation*. Kluwer Academics Publishers.
- Mobley, K. (2004). *Maintenance Fundamentals*. Butterworth-Heinemann.
- Montgomery, D. C. and Runger, G. C. (1994). *Applied Statistics and Probability for Engineers*. John Wiley.
- Moubray, J. (2001). *Reliability Centered Maintenance*. Industrial Press Inc., 2nd edition.
- Najim, K., Ikonen, E., and Daoud, A.-K. (2004). *Stochastic Processes: Estimation, Optimization and Analysis*. Kogan Page Science.
- NASA (1995). *System Engineering Handbook*. NASA.
- NBR-5462 (1994). *Confiabilidade e Mantabilidade*.
- NSWC, N. S. W. C. (2007). Handbook of reliability prediction procedures for mechanical equipment. Technical report, Naval Surface Warfare Center, Carderock Division, Logistics Technology Support, West Bethesda, Maryland 20817-5700.
- O'Connor, P. (2002). *Practical Reliability Engineering*. John Wiley, 4th edition.
- O'Hagan, A., Buck, C. E., Daneshkhah, A., Eiser, J. R., Garthwaite, P. H., Jenkinson, D. J., Oakley, J. E., and Rakow, T. (2006). *Uncertain Judgements: Eliciting Experts' Probabilities*. John Wiley.
- Palade, V., Bocaniala, C. D., and Jain, L. (2006). *Computational Intelligence in Fault Diagnosis*. Springer-Verlag.
- Papoulis, A. (1991). *Probability, Random Variables and Stochastic Processes*. McGraw-Hill, 3rd edition.

- Portinale, L. and Bobbio, A. (1999). Bayesian networks for dependability analysis: an application to digital control reliability. In *Proceedings of the fifteenth conference on uncertainty in artificial intelligence*, pages 551–8, San Francisco, CA. Morgan Kaufmann Publishers.
- Rigdon, S. E. and Basu, A. P. (2000). *Statistical Methods for the Reliability of Repairable Systems*. John Wiley.
- Salgado, M. F. P., Lisboa, A. C., Saldanha, R. R., Caminhas, W. M., and Menezes, B. R. (2007). Aplicação da computação evolucionária na otimização da confiabilidade de sistemas. In *Anais do I Simpósio Brasileiro de Inteligência Computacional (SBIC)*, Florianópolis, Santa Catarina.
- Sandri, S., Dubois, D., and Kalfsbeek, H. (1990). Elicitation, assessment and pooling of expert judgements using possibility theory.
- Scapin, C. A. (1999). *Análise Sistêmica de Falhas*. Editora de Desenvolvimento Gerencial.
- Sheskin, D. J. (2003). *Handbook of Parametric and Nonparametric Statistical Procedures*. Chapman Hal/CRC, 3 edition.
- Tillman, F. A., Hwang, C.-L., and Kuo, W. (1980). *Optimization of Systems Reliability*. M Dekker.
- Trevisan, L. (2004). Inapproximability of combinatorial optimization problems.
- U.S.F.A.A (2000). System safety handbook. Technical report, FAA, Washington, DC, USA.
- 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 Optoeletronis*, **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*.
- Yang, G. (2007). *Life Cycle Reliability Engineering*. Wiley, 1 edition.