

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**AVALIAÇÃO DA CONFIABILIDADE PREVENTIVA
DE SISTEMAS ELÉTRICOS DE GRANDE PORTE
UTILIZANDO REDES NEURAIS**

LEONIDAS CHAVES DE RESENDE

Tese submetida ao
INSTITUTO DE SISTEMAS ELÉTRICOS E ENERGIA DA UNIFEI
como requisito para obtenção do título de
Doutor em Ciências em Engenharia Elétrica

Orientador: Prof. Armando Martins Leite da Silva
Co-Orientador: Prof. Luiz Antônio da Fonseca Manso

OUTUBRO 2006

ITAJUBÁ – MG – BRASIL

À Valquíria pelo amor e cumplicidade,

Aos meus pais e irmãos,

João, Dolores, Vera, Aurely, Liliane, Maria Inês e Stella,

que mesmo distantes estão sempre presentes.

AGRADECIMENTOS

Aos professores Armando Martins Leite da Silva e Luiz Antônio da Fonseca Manso, pela amizade, incentivo, confiança e orientação durante o desenvolvimento deste trabalho.

A todos os professores do curso de Pós-Graduação em Engenharia Elétrica.

Ao Grupo de Engenharia de Sistemas (GESis) pela infra-estrutura e apoio.

Ao Instituto de Engenharia de Sistemas e Computadores do Porto (INESC Porto), em especial aos professores Vladimiro Miranda e Edgardo Daniel Castronuovo.

Ao professor Júlio César Stacchini de Souza (Universidade Federal Fluminense – UFF) pelos seus comentários.

Aos colegas da Pós-Graduação, que me auxiliaram, me compreenderam e compartilharam comigo alegrias e ansiedades.

À CAPES pelo apoio financeiro.

RESUMO

A avaliação de índices de confiabilidade preventiva ou de bem-estar (*well-being*) foi proposta, recentemente, como uma nova ferramenta para se determinar o grau de adequação dos sistemas de potência, tendo como principal objetivo a incorporação de critérios determinísticos ao processo de análise da confiabilidade. A base conceitual para esta técnica é obtida através da classificação dos estados operativos do sistema em três grupos: saudável, marginal e de falha. Para a identificação destes estados, o sistema é submetido a um critério determinístico.

Em relação aos sistemas compostos de geração e transmissão, a identificação de um estado saudável ou marginal se torna bem mais complexa que aquela utilizada, por exemplo, em sistemas de geração. Qualquer critério determinístico a ser empregado deve considerar uma lista de contingências. Em princípio, para cada estado operativo considerado, é necessário realizar um número de análises adicionais de desempenho igual ao número de elementos da lista. Acrescenta-se, ainda, a necessidade de análises de adequação dos estados utilizando algoritmos de fluxo de potência, com otimização de medidas corretivas. Portanto, a grande dificuldade encontrada na avaliação de índices de bem-estar consiste em conciliar o critério determinístico e a natureza combinatorial do problema.

Esta tese trata da avaliação de índices de bem-estar de sistemas elétricos de potência de grande porte, compostos de geração e transmissão. Para este fim, é proposta a utilização de técnicas como: simulação Monte Carlo não seqüencial com uma nova função teste; modelo de fluxo de potência ótimo baseado em pontos interiores com restrições reduzidas; equivalente probabilístico de rede; e a incorporação de redes neurais artificiais na classificação dos estados operativos. Tais técnicas podem propiciar reduções significativas no custo computacional exigido durante a classificação dos estados. Para a verificação dos conceitos e modelos propostos, a metodologia desenvolvida é aplicada em vários sistemas testes incluindo uma configuração da rede elétrica brasileira.

ABSTRACT

The well-being analysis was recently proposed as a new framework to measure the degree of adequacy of power systems, which has as the main objective the incorporation of deterministic criteria into the reliability analysis process. The conceptual basis for this framework is obtained through the classification of the system states into three groups: healthy, marginal and at risk. For the identification of these operation states, the system is submitted to a deterministic criterion.

In composite generation and transmission systems, the identification of a healthy or marginal state becomes much more complex than that one used, for example, in generation systems. Any deterministic criterion to be used must consider a list of contingencies. In principle, for each considered operation state, it is necessary to carry out a number of additional performance analyses equal to the number of elements in the list. Moreover, these adequacy analyses involve load flow runs with corrective measure optimizations. Therefore, the major difficulty found in assessing well-being indices consists of conciliating the deterministic criterion and the combinatorial nature of the problem.

In this thesis, the evaluation of well-being indices for bulk composite generation and transmission power systems is focused. For this purpose, the following techniques are considered: non-sequential Monte Carlo simulation with a new test function; interior point method for optimal power flow with reduced constraints; probabilistic equivalent network; and incorporation of artificial neural nets in the classification of the operation states. These techniques can provide considerable reductions in the computational cost demanded during the classification of states. In order to verify the proposed concepts and models, the developed methodology is applied to several test systems, including a configuration of the Brazilian power network.

SUMÁRIO

LISTA DE FIGURAS	X
LISTA DE TABELAS	XII
LISTA DE ABREVIATURAS E SÍMBOLOS	XV
CAPÍTULO 1 – INTRODUÇÃO.....	1
1.1 CONSIDERAÇÕES GERAIS.....	1
1.2 DESENVOLVIMENTO HISTÓRICO	7
1.3 ESTRUTURA DA TESE.....	10
CAPÍTULO 2 – CONFIABILIDADE PREVENTIVA.....	12
2.1 INTRODUÇÃO.....	12
2.2 CONFIABILIDADE COMPOSTA	14
2.3 CONFIABILIDADE PREVENTIVA UTILIZANDO SIMULAÇÃO MONTE CARLO NÃO-SEQÜENCIAL	16
2.3.1 Índices de Probabilidade	20
2.3.2 Índices de Freqüência	20
2.3.3 Índices de Freqüência - Processo de Transição de Estado um Passo à Frente	23
2.3.4 Índices de Duração.....	24
2.4 O CRITÉRIO DETERMINÍSTICO	26

2.5	O ALGORITMO DE CONFIABILIDADE PREVENTIVA	28
2.6	CONCLUSÕES.....	29
CAPÍTULO 3 – REDUÇÃO PROBABILÍSTICA DA REDE DE TRANSMISSÃO		31
3.1	INTRODUÇÃO.....	31
3.2	SISTEMAS UTILIZADOS.....	32
3.3	O PROBLEMA DE OTIMIZAÇÃO	35
3.3.1	Fluxo de potência DC	36
3.3.2	Método Simplex.....	38
3.3.3	Programação Linear - Pontos Interiores.....	39
3.3.4	Base Reduzida	39
3.4	REDUÇÃO DA REDE DE TRANSMISSÃO	48
3.5	APLICAÇÕES.....	52
3.5.1	O Sistema IEEE-MRTS-96	52
3.5.2	O Sistema Sul-Sudeste Brasileiro (SSB).....	58
3.6	CONCLUSÕES.....	60
CAPÍTULO 4 – REDES NEURAS NA AVALIAÇÃO DA CONFIABILIDADE PREVENTIVA		62
4.1	INTRODUÇÃO.....	62
4.2	REDES NEURAS PLÁSTICAS (GMDH).....	65
4.3	REDE GMDH PROPOSTA – CONFIABILIDADE CONVENCIONAL.....	67
4.3.1	Variáveis de Entrada	67
4.3.2	Dados de Entrada.....	68

4.3.3	Análise da rede RN_c	69
4.4	APLICAÇÕES – CONFIABILIDADE CONVENCIONAL.....	76
4.4.1	Sistema IEEE-RTS	76
4.4.2	Sistema IEEE-MRTS	77
4.4.3	Sistema IEEE-RTS-96.....	79
4.4.4	Sistema IEEE-MRTS-96.....	80
4.4.5	Sistema SSB	82
4.5	REDE GMDH PROPOSTA – CONFIABILIDADE PREVENTIVA.....	84
4.5.1	Variáveis de entrada.....	84
4.5.2	Treinamento e validação da rede RN	84
4.5.3	Subdivisão do Espaço de Estados	87
4.5.4	Utilização de duas redes: RN_1 e RN_2	88
4.6	APLICAÇÕES – CONFIABILIDADE PREVENTIVA	92
4.6.1	Sistema IEEE-MRTS	92
4.6.2	Sistema IEEE-MRTS-96.....	94
4.6.3	Sistema SSB	95
4.7	CONCLUSÕES.....	97
CAPÍTULO 5 – COMBINAÇÃO DE TÉCNICAS DE REDUÇÃO DA TRANSMISSÃO E DE REDES NEURAIS		98
5.1	INTRODUÇÃO.....	98
5.2	SISTEMA IEEE-MRTS-96	99
5.3	SISTEMA SUL-SUDESTE BRASILEIRO (SSB).....	102
5.4	CONCLUSÕES.....	106

CAPÍTULO 6 – CONCLUSÕES	107
6.1 INTRODUÇÃO.....	107
6.2 CONCLUSÕES DO TRABALHO	109
6.3 PROPOSTA DE CONTINUIDADE DOS TRABALHOS	112
6.4 PRODUÇÃO CIENTÍFICA	114
APÊNDICE A – TRANSIÇÃO DE ESTADO UM PASSO A FRENTE	117
A.1 INTRODUÇÃO.....	117
A.2 EXEMPLO NUMÉRICO	120
APÊNDICE B – O PRIMAL-DUAL DE PONTOS INTERIORES	122
B.1 INTRODUÇÃO.....	122
B.2 ALGORITMO PRIMAL-DUAL DE PONTOS INTERIORES	124
APÊNDICE C – GMDH	129
C.1 INTRODUÇÃO.....	129
C.2 ALGORITMO PARA TREINAMENTO E VALIDAÇÃO.....	131
APÊNDICE D – IEEE RELIABILITY TESTE SYSTEM	135
D.1 INTRODUÇÃO.....	135
D.2 DADOS DO SISTEMA.....	135
REFERÊNCIAS BIBLIOGRÁFICAS	139

LISTA DE FIGURAS

Figura 1.1: Modelo para Análise de Confiabilidade Preventiva.	5
Figura 2.1: Modelo de Markov a Dois Estados.	16
Figura 2.2: Modelo de Markov Não-Agregado com Múltiplos Níveis.	17
Figura 2.3: Transições entre Estados Saudáveis, Marginais e de Falha.	21
Figura 3.1: Diagrama do Sistema IEEE-RTS.	33
Figura 3.2: Diagrama Simplificado do Sistema SSB.	34
Figura 3.3: Curva de Carga para Semana Pico – Sistema IEEE-MRTS.	43
Figura 3.4: Divisão da Rede de Transmissão de um Sistema de Grande Porte.	49
Figura 3.5: Sistema IEEE-MRTS-96 (Áreas 21, 22 e 23).	53
Figura 4.1: Modelo do Neurônio.	65
Figura 4.2: Exemplo de uma Rede Polinomial.	66
Figura 4.3: Capacidade Indisponível × Reserva de Geração – Área 2, Limiar 18.	70
Figura 4.4: Capacidade Indisponível × Reserva de Geração – Área 2, Limiar 13.	71
Figura 4.5: Capacidade Indisponível × Reserva de Geração – Área 2, Limiar 12.	71
Figura 4.6: Fluxograma da Metodologia Proposta.	75
Figura 4.7: Plano “Carga × Reserva de Geração” – Limiar 15.	86
Figura 4.8: Plano “Carga × Reserva de Geração” – Limiares 12 e 18.	87
Figura 4.9: Plano “Carga × Reserva de Geração” – Rede RN ₁	90

Figura 4.10: Plano “Carga × Reserva de Geração” – Rede RN ₂	90
Figura A.1: Estado de Falha x^k e sua Vizinhança.....	117
Figura A.2: Sistema Simples com 6 estados.....	120
Figura C.1: Modelo do Neurônio.	130
Figura C.2: Padrões de Entrada-Saída.	130
Figura C.3: Matriz Z.....	132
Figura C.4: Curva de RMIN.....	133
Figura C.5: Árvore de Polinômios.....	133

LISTA DE TABELAS

Tabela 3.1: Lista de Contingências – Sistema IEEE-RTS.....	44
Tabela 3.2: Índices de Confiabilidade Preventiva – Caso 1 e Caso 2.....	44
Tabela 3.3: Lista de Contingências – Sistema IEEE-MRTS-96.....	46
Tabela 3.4: Índices de Confiabilidade Preventiva – Caso 3 e Caso 4.....	46
Tabela 3.5: Índices de Confiabilidade – Sistema IEEE-MRTS-96, Curva de Carga Original.....	54
Tabela 3.6: Índices de Confiabilidade Preventiva – Sistema IEEE-MRTS-96, Curva de Carga Original.....	55
Tabela 3.7: Índices por Barra Caso 5/Caso 8 – Sistema IEEE-MRTS-96.....	56
Tabela 3.8: Índices de Confiabilidade – Sistema IEEE-MRTS-96, Curva de Carga da Semana Pico.....	57
Tabela 3.9: Índices de Confiabilidade Preventiva – Sistema IEEE-MRTS-96, Curva de Carga da Semana Pico.....	57
Tabela 3.10: Índices de Confiabilidade – Sistema SSB.....	58
Tabela 3.11: Índices de Confiabilidade Preventiva – Sistema SSB.....	59
Tabela 4.1: Desempenho da Rede RN_c com Limiar 18 – Sistema IEEE-RTS.....	72
Tabela 4.2: Desempenho da Rede RN_c com Limiar 13 – Sistema IEEE-RTS.....	72
Tabela 4.3: Desempenho da Rede RN_c com Limiar 12 – Sistema IEEE-RTS.....	72
Tabela 4.4: Índices de Confiabilidade – Sistema IEEE-RTS, Curva de Carga Original.....	77

Tabela 4.5: Desempenho da Rede RN_c – Sistema IEEE-MRTS.....	78
Tabela 4.6: Índices de Confiabilidade – Sistema IEEE-MRTS.	79
Tabela 4.7: Desempenho da Rede RN_c – Sistema IEEE-RTS-96.....	79
Tabela 4.8: Índices de Confiabilidade – Sistema IEEE-RTS-96.	80
Tabela 4.9: Desempenho da Rede RN_c – Sistema IEEE-MRTS-96.....	81
Tabela 4.10: Índices de Confiabilidade – Sistema IEEE-MRTS-96.	81
Tabela 4.11: Desempenho da Rede RN_c – Sistema SSB.	82
Tabela 4.12: Índices de Confiabilidade – Sistema SSB.	82
Tabela 4.13: Subdivisão do Espaço de Estados.	88
Tabela 4.14: Desempenho das Redes RN_1 e RN_2 – Sistema IEEE-MRTS-96.....	91
Tabela 4.15: Índices de Confiabilidade Preventiva – IEEE-MRTS.	93
Tabela 4.16: Desempenho das Redes RN_1 e RN_2 – Sistema IEEE-MRTS.....	94
Tabela 4.17: Índices de Confiabilidade Preventiva – IEEE-MRTS-96.	94
Tabela 4.18: Índices de Confiabilidade Preventiva – SSB.	95
Tabela 5.1: Índices de Confiabilidade – IEEE-MRTS-96.....	101
Tabela 5.2: Índices de Confiabilidade – SSB.	103
Tabela 5.3: Informações Adicionais – SSB.	103
Tabela 5.4: Técnicas Utilizadas.....	104
Tabela 5.5: Índices de Confiabilidade – SSB Reforçado (+30MW).	104
Tabela 5.6: Informações Adicionais – SSB Reforçado (+30MW).	105
Tabela D.1: Dados de Classes de Usina.....	135

Tabela D.2: Dados de Usina.	136
Tabela D.3: Composição da Carga.	136
Tabela D.4: Dados Determinísticos de Circuito.	137
Tabela D.5: Dados Estocásticos de Circuito.	138

LISTA DE ABREVIATURAS E SÍMBOLOS

- λ_{km} : taxa de transição do estado x^k para o estado x^m ;
- $\Delta\lambda_{FM}$: somatório das taxas de transição entre o estado marginal x^{falha} e todos os estados marginais que podem ser alcançados mediante uma única transição;
- $\Delta\lambda_{FS}$: somatório das taxas de transição entre o estado marginal x^{falha} e todos os estados saudáveis que podem ser alcançados mediante uma única transição;
- $\Delta\lambda_{MF}$: somatório das taxas de transição entre o estado marginal $x^{marginal}$ e todos os estados de falha que podem ser alcançados mediante uma única transição;
- $\Delta\lambda_{MS}$: somatório das taxas de transição entre o estado marginal $x^{marginal}$ e todos os estados saudáveis que podem ser alcançados mediante uma única transição;
- β : coeficiente de variação;
- λ : taxa de falha de um equipamento modelado a dois estados;
- μ : taxa de reparo de um equipamento modelado a dois estados;
- Ω_M : grupo dos estados marginais;
- Ω_R : grupo dos estados de falha;
- Ω_S : grupo dos estados saudáveis;
- f_k^{out} : freqüência de saída do estado x^k ;
- f_{km} : freqüência de transição do estado x^k para o estado x^m ;
- λ_k^{out} : somatório das taxas de transição do estado x^k para todos os estados diretamente ligados a ele;

- λ_k^{out} : taxa de transição do estado x^k para todos os outros estados;
- r_j : corte de carga na barra j ;
- \mathbf{B} : matriz de susceptância de barra, equivalente à matriz de admitância de barra para um sistema sem perdas;
- P_{km} : probabilidade de ocorrência da transição km , definida como a probabilidade do sistema ingressar no estado x^m partindo do estado x^k ;
- \vec{r} : vetor de corte de carga;
- \vec{d} : vetor de demanda por barra;
- \vec{g} : vetor de geração por barra;
- \vec{f}_{max} : vetor de máxima capacidade de fluxo por circuito.
- \vec{g}_{max} : vetor de máxima capacidade de geração por barra;
- \vec{g}_{min} : vetor de mínima capacidade de geração por barra;
- $\vec{\theta}$: vetor dos ângulos das barras;
- \vec{f} : vetor dos fluxos nos circuitos; e
- Dur(F): duração média de estados de falha;
- Dur(M): duração média de estados marginais;
- Dur(S): duração média de estados saudáveis;
- E(.): operador valor esperado;
- EENS: expected energy not supplied;
- EPNS: expected power not supplied;
- F(.): função teste;
- Freq(F): frequência dos estados de falha;
- Freq(M): frequência dos estados marginais;

- Freq(S): frequência dos estados saudáveis;
- G: estado com pelo menos um equipamento de geração indisponível, porém este não pertence à lista de contingências;
- G_0 : estado com todos os equipamentos de geração disponíveis;
- G_L : estado com indisponibilidade de pelo menos um equipamento de geração pertencente à lista de contingências;
- GMDH: group method data handling;
- IEEE-MRTS: modified IEEE reliability test system;
- IEEE-MRTS-96: modified IEEE reliability test system, 1996;
- IEEE-RTS: IEEE reliability test system;
- IEEE-RTS-96: IEEE reliability test system, 1996;
- LOLC: loss of load cost;
- LOLD: loss of load duration;
- LOLE: loss of load expectation;
- LOLF: loss of load frequency;
- LOLP: loss of load probability;
- MTTR: mean time to repair;
- n : número total de barras do sistema;
- P(F): probabilidade de ocorrência dos estados de falha;
- P(M): probabilidade de ocorrência dos estados marginais;
- P(S): probabilidade de ocorrência dos estados saudáveis;
- P(x): probabilidade da cada estado x ;
- reg*: critério da regularidade;
- SOM: Self Organizing Map;
- SSB: sul sudeste brasileiro;

- T: estado com pelo menos um equipamento de transmissão indisponível, porém este não pertence à lista de contingências;
- T_0 : estado com todos os equipamentos de transmissão disponíveis;
- T_L : estado com indisponibilidade de pelo menos um equipamento de transmissão pertencente à lista de contingências;
- $V(.)$: operador variância;
- X : espaço de estados;
- x : estado do sistema.

CAPÍTULO 1

INTRODUÇÃO

1.1 CONSIDERAÇÕES GERAIS

Um dos objetivos básicos no planejamento de sistemas de potência é determinar o quanto de capacidade de geração é requerido para garantir o suprimento da demanda futura. Outro objetivo, de igual importância, é a expansão adequada da rede de transmissão para transportar a energia gerada a todos os pontos de carga. Os equipamentos da rede de transmissão devem ser cuidadosamente combinados com o segmento de geração para permitir o fluxo de energia a partir das fontes até as cargas. A probabilidade de consumidores serem desconectados pode ser reduzida por meio de acréscimos nos investimentos realizados durante a fase de planejamento. Sobre-investimentos podem levar a excessivos custos de investimentos, os quais devem refletir no cálculo da tarifa. Desta forma, a restrição econômica pode ser violada, ainda que o sistema fique altamente confiável. Por outro lado, sub-investimentos levam a uma situação oposta. Portanto, a competição entre o objetivo econômico e a confiabilidade fica evidente, o que leva a um processo de tomada de difíceis decisões.

A confiabilidade de sistemas compostos de geração e transmissão pode ser referida como a capacidade de suprir a demanda de energia elétrica em qualquer ponto de carga. Tradicionalmente, a confiabilidade de sistemas de potência é considerada como um problema que pode ser dividido em dois aspectos: adequação (*adequacy*) e segurança (*security*) [BA88, AB89].

A maioria das ferramentas disponíveis atualmente para a avaliação da confiabilidade está relacionada à adequação. Em geral, o enfoque de adequação torna-se mais evidente na avaliação da confiabilidade preventiva, visto que a análise de adequação de cada estado da rede elétrica está associada às condições estáticas, as quais não incluem a dinâmica do sistema e a resposta a distúrbios transitórios. Os diferentes estados operativos de um sistema de potência são analisados sem levar em consideração possíveis instabilidades, que podem ser introduzidas pelas falhas dos seus componentes. A verificação da adequação de cada estado de um sistema compreende estudos de fluxo de potência sob condições normais de operação e sob emergências, pois caso a configuração em análise não atenda totalmente à carga, medidas corretivas (redespacho de geração e/ou cortes de carga) devem ser acionadas, determinando se o estado do sistema é saudável, marginal ou de falha.

Já sob o aspecto de segurança, o desempenho do sistema está relacionado a distúrbios transitórios, envolvendo a análise do comportamento dinâmico do sistema, sob os enfoques de estabilidade transitória e dinâmica, de desligamentos seqüenciais (em cascata) e de colapsos de tensão. A capacidade para avaliar a confiabilidade quanto à segurança ainda é muito limitada devida, principalmente, à complexidade associada com a modelagem do comportamento dinâmico do sistema [LEW93].

Nos últimos 10 anos, a necessidade de uma avaliação completa da confiabilidade, a qual deve incluir os efeitos de contingências na análise de adequação (estática) e na análise de segurança (dinâmica), tem sido reconhecida. Em outras palavras, os estudos de adequação devem ser combinados com os estudos de segurança [LEW93, RLJM00]. Entretanto, devido à alta complexidade do estudo combinado, nesta tese é considerada apenas a análise de adequação para a avaliação dos estados operativos do sistema.

Os métodos com a abordagem da teoria de probabilidades se mostraram eficazes na avaliação da confiabilidade e têm sido amplamente aplicados na avaliação da capacidade de geração. Entretanto, o planejamento de sistemas compostos e,

principalmente, o de sistemas de transmissão são tradicionalmente baseados em critérios determinísticos, como a garantia que o sistema continua a operar, sem violar restrições previamente determinadas, com a saída de um ou mais de seus componentes.

A abordagem determinística possui características muito atrativas: implementação direta, fácil entendimento e o fato do julgamento de condições severas e plausíveis ser usualmente consistente com base no histórico da operação do sistema no passado. Entretanto, esta abordagem possui limitações que têm sido reconhecidas nos últimos anos, como:

- Não consideração da natureza aleatória e estocástica do sistema;
- Dificuldade da obtenção do grau de confiabilidade;
- Definição de decisões que não são econômicas, comparadas à decisão ótima.

Uma alternativa para os métodos determinísticos é a utilização de métodos baseados na teoria de probabilidades, onde os aspectos estocásticos são representados explicitamente. As vantagens práticas e conceituais das técnicas probabilísticas foram reconhecidas nas últimas décadas. Como exemplos destas vantagens, podem ser citados a quantificação e o acesso à resposta da confiabilidade, resultante de trocas na configuração dos equipamentos e da implantação de reforços no sistema. Entretanto, a transição da base determinística para a base probabilística tem sido muito lenta. Algumas dificuldades encontradas nesta transição são:

- *Coleta de dados* - as estatísticas relacionadas às saídas dos equipamentos são baseadas em registros históricos, que freqüentemente são incompletos e contêm erros;
- *Modelagem probabilística* - as saídas dos equipamentos devem ser modeladas separadamente, considerando o tipo de equipamento, sua vida útil, os modos de falha, etc.;

- *Modelagem da resposta do sistema* - os cálculos probabilísticos devem ser efetuados através de modelos computacionais capazes de realizar uma simulação precisa do comportamento do sistema e, portanto, reproduzir um grande número de condições operativas;
- *Dificuldade de interpretação dos índices* - operadores e planejadores de sistemas de potência ainda relutam em aplicar técnicas probabilísticas devido à dificuldade de interpretação de simples índices numéricos de risco.

A obtenção de sistemas bem planejados requer um conhecimento amplo do sistema existente para prover uma base firme que avalie, identifique e priorize áreas que precisam de desenvolvimentos futuros. A combinação de critérios determinísticos com índices probabilísticos na monitoração do grau de adequação de sistemas elétricos de potência, que tem gerado considerável interesse, propicia um conhecimento mais completo e compreensivo do sistema em questão.

A maioria dos métodos para a avaliação da confiabilidade divide os estados operativos dos sistemas em dois grupos: *sucesso e falha*. O sistema está em um estado de *sucesso* quando é capaz de suprir toda a demanda. Quando há necessidade de corte de carga, seja por insuficiência de geração ou por violação de alguma restrição de operação, o sistema se encontra em um estado de *falha*. Neste nível de análise, somente índices referentes à falha são obtidos, não havendo informação alguma quanto ao grau de adequação dos estados de *sucesso*. Quando um sistema apresenta índices de confiabilidade dentro de limites aceitáveis, não é possível definir ou estimar se a operação deste sistema está mais "próxima" ou mais "distante" da fronteira *sucesso/falha*.

Recentemente, foi proposta uma metodologia [BK92, BL94, BF94, R02, MLRSB04, LRMB04] que incorpora critérios determinísticos e índices probabilísticos no planejamento da geração e na avaliação do grau de adequação de sistemas compostos. Neste novo contexto, é utilizada uma estrutura chamada bem-estar (*well-being*), também referida como confiabilidade preventiva [R02, MLRSB04, RLMM06], onde o desempenho de um sistema é avaliado considerando três

diferentes grupos de estados operativos, chamados estados *saudáveis*¹, *marginais* e de *falha*. Para a identificação destes estados, o sistema é submetido a um critério determinístico. Como exemplo [BK99b], para avaliação de sistemas de geração utiliza-se como critério determinístico a perda da maior unidade geradora disponível no estado em análise. Já para a avaliação de sistemas compostos utiliza-se como critério determinístico uma lista de contingências [LRMB04].

A Figura 1.1 mostra a divisão dos estados operativos do sistema para a avaliação da confiabilidade preventiva. O grupo de estados de *sucesso*, utilizado pela maioria das metodologias de confiabilidade convencional, agora está dividido em dois grupos: estados saudáveis e estados marginais. Um sistema opera em um estado saudável quando apresenta reserva de geração e capacidade de transmissão suficientes para atender a um critério determinístico. Se, apesar de não apresentar qualquer problema, o sistema não tiver margem suficiente ou apresentar alguma violação em equipamentos de transmissão para atender ao critério determinístico especificado, então, ele estará residindo em um estado marginal. Finalmente, um estado de falha é caracterizado pela necessidade de haver corte de carga.

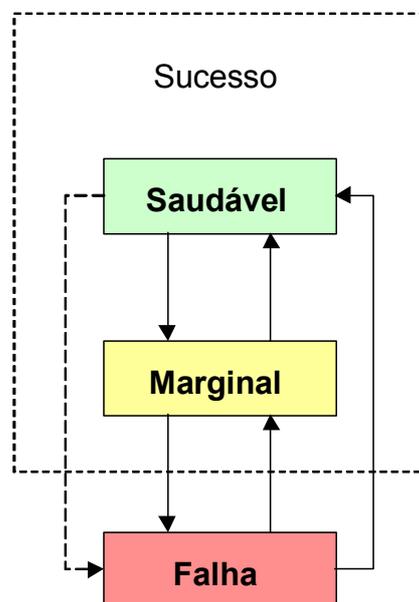


Figura 1.1: Modelo para Análise de Confiabilidade Preventiva.

¹ A estrutura *well-being* utiliza os termos *healthy*, *margin* e *at risk* na definição dos estados operativos. Neste trabalho de tese, o termo *healthy* foi traduzido do inglês como *saudável*.

No que se refere à confiabilidade preventiva de sistemas compostos, é importante destacar que qualquer critério determinístico a ser empregado na identificação de um estado saudável ou marginal, se torna bem mais complexo, devendo considerar uma lista de contingências, o que implica em um número extremamente elevado de análises adicionais. Acrescenta-se, ainda, a necessidade de uma análise de adequação dos estados, utilizando algoritmos de fluxo de potência com otimização das medidas corretivas. Por conseguinte, no presente trabalho considera-se a utilização de técnicas para tornar a classificação de estados saudáveis e marginais menos dispendiosa do ponto de vista computacional. Dentre estas técnicas, pode-se destacar a:

- Solução de problema de otimização linear via pontos interiores;
- Utilização de fluxo de potência DC com base reduzida;
- Redução probabilística da rede de transmissão; e
- Adoção de redes neurais artificiais na classificação dos estados.

A aplicação de confiabilidade preventiva em sistemas reais é um importante suporte nos processos de tomada de decisões em diferentes estágios. Como exemplo, em planejamento da operação, pode-se obter listas de contingências reduzidas e a programação da manutenção dos equipamentos pode ser baseada em índices relacionados com os estados marginais. Já para a expansão da geração considerando fontes renováveis, os índices de confiabilidade baseados nos estados de falha podem não ser suficientes, visto que as capacidades destas fontes possuem altos níveis de flutuação [LMSRAMLM04].

1.2 DESENVOLVIMENTO HISTÓRICO

A aplicação da teoria de probabilidades é bem documentada na avaliação da confiabilidade de sistemas compostos por meio de um grande número de artigos [PB92, ABBG94, ABBG99, BFB01].

A preocupação com a determinação do valor da confiabilidade tem sido crescente nas últimas décadas [BO88, BG90, DGF96]. Um estudo comparativo apresentado pela referência [LPMM97] demonstrou que, para uma valoração precisa da confiabilidade, é necessária a reprodução sintética dos processos de falha (i.e. cortes de carga).

Com a classificação dos estados operativos de sistemas compostos em diferentes grupos, os índices de confiabilidade foram calculados de acordo com o grau de adequação [D67, FC78, BK92]. Na referência [BL94] utiliza-se uma estrutura simplificada dos estados operativos do sistema, classificados em [BK92], baseada em três grupos: estados saudáveis, marginais e de falha. Para a identificação destes estados o sistema é submetido a critérios determinísticos, tal como a perda de qualquer um dos seus componentes. O critério determinístico utilizado é dependente do planejamento e da filosofia de operação.

Uma avaliação da reserva operativa de sistemas de geração foi proposta em [BF94]. Neste trabalho, os conceitos de estados operativos para sistemas compostos apresentados em [BL94] são utilizados visando à quantificação da margem de segurança em adição ao índice de risco.

Vários trabalhos foram desenvolvidos buscando a obtenção dos índices *well-being* ou índices de confiabilidade preventiva [BL94, BF94, FB97, BKF98]. Entretanto, a aplicação destes trabalhos ficou restrita a sistemas de pequeno porte e para a condição de carga constante, devido ao comportamento explosivo do custo

computacional quando o número de variáveis consideradas no processo de estimação aumenta.

Um método baseado na representação por espaço de estados [BK99a], que utiliza a tabela COPT (*Capacity Outage Probability Table* – tabela de probabilidades das capacidades indisponíveis) [BA94] da geração e as probabilidades condicionais da maior unidade geradora estar disponível em diferentes intervalos, pode ser usado para calcular os índices confiabilidade preventiva de sistemas de pequeno porte. A utilização destas técnicas podem se tornar muito complexas quando um grande número de variáveis é considerado no processo de cálculo [BK99b].

Na referência [BK99b], foi proposto um método baseado em simulação Monte Carlo cronológica capaz de avaliar índices de confiabilidade preventiva para sistemas de geração de grande porte. Este foi o primeiro trabalho a calcular índices de frequência e duração na avaliação da confiabilidade preventiva.

Um método probabilístico para avaliar os índices de confiabilidade preventiva de sistemas compostos de geração e transmissão baseado em enumeração de estados foi proposto em [GF99]. Neste método é feita a inclusão de critérios determinísticos em índices de confiabilidade convencionais para a identificação dos estados saudáveis e marginais. Os impactos da filosofia de corte de carga e as características da carga também foram avaliados neste trabalho. Porém, devido à explosão combinatorial do número de estados, em razão do aumento do número de variáveis consideradas, a aplicação deste método também ficou restrita a sistemas pequenos e à condição de carga constante.

Recentemente, estendendo os conceitos apresentados em [BK99b], uma metodologia baseada na simulação Monte Carlo não-sequencial foi proposta para a avaliação da confiabilidade preventiva de sistemas compostos [LRMB04]. Porém, devido ao excessivo número de análises adicionais necessárias no processo de classificação entre estados saudáveis e marginais, o esforço computacional exigido ainda era elevado para sistemas de médio e grande porte.

Como se pode concluir, a utilização dos métodos baseados em enumeração de estados na análise da confiabilidade preventiva tem sua aplicação limitada a sistemas de pequeno porte. Já a metodologia proposta pela referência [LRMB04] ainda necessita de aperfeiçoamentos, visando a sua aplicação em sistemas reais. O presente trabalho visa analisar e implementar algumas técnicas que podem reduzir o esforço computacional requerido na avaliação de índices de bem estar de sistemas de grande porte, sem deteriorar a precisão das estimativas para os índices.

1.3 ESTRUTURA DA TESE

Esta tese é composta por seis capítulos, os quais são descritos, de forma resumida, a seguir.

O presente Capítulo introduziu o problema do planejamento da operação e expansão de sistemas de potência, bem como apresentou algumas das razões pelas quais se justifica a aplicação da confiabilidade preventiva. Apresentou, também, características de alguns trabalhos relacionados à análise da confiabilidade preventiva, assim como os objetivos deste trabalho.

O Capítulo 2 apresenta uma revisão dos conceitos básicos de confiabilidade e de confiabilidade preventiva. Em relação à confiabilidade convencional, são apresentados os modelos markovianos dos componentes, o modelo de representação da carga e uma breve revisão de simulação Monte Carlo não-seqüencial. Já na confiabilidade preventiva, são descritos seus conceitos básicos e apresentadas as funções teste adotadas para estimar os índices de bem-estar.

Nos Capítulos 3 e 4 são propostas algumas técnicas que podem propiciar reduções significativas no esforço computacional requerido na avaliação da confiabilidade preventiva, o que viabiliza sua aplicação em sistemas de grande porte.

No Capítulo 3, são apresentadas as técnicas de: programação linear sucessiva via método de pontos interiores com barreira logarítmica; fluxo de potência com *base reduzida*, o qual considera um subconjunto das restrições físicas do sistema; e redução probabilística da rede de transmissão. Também são apresentados os sistemas utilizados para a verificação dos conceitos propostos.

No Capítulo 4, uma metodologia que utiliza redes neurais plásticas, baseada no método de grupo para manipulação de dados (GMDH – *Group Method of Data*

Handling), durante a análise de adequação dos estados operativos do sistema, é apresentada. Também são apresentados e discutidos alguns resultados.

A utilização simultânea dos conceitos propostos nos capítulos anteriores é investigada no Capítulo 5. Os resultados são apresentados e analisados.

Finalmente no Capítulo 6, são apresentados o resumo dos estudos realizados e as principais conclusões. Algumas sugestões para continuidade dos trabalhos também são abordadas.

CAPÍTULO 2

CONFIABILIDADE PREVENTIVA

2.1 INTRODUÇÃO

A base teórica da análise da confiabilidade preventiva consiste na divisão dos estados operativos do sistema em três grupos: estados saudáveis, marginais e de falha. Para a identificação destes estados, o sistema é submetido a um critério determinístico.

O estudo da confiabilidade preventiva de sistemas de geração supõe que carga e geração estão localizadas em uma única barra. Desta forma, um critério determinístico muito utilizado é a perda da maior unidade geradora disponível no estado. Este critério é capaz de representar muito bem o grau de adequação do sistema, pois é o caso em que o sistema pode transitar para a pior condição de operação. Já no estudo de sistemas compostos, a identificação da pior condição que o sistema pode atingir torna-se bem mais complexa. Isto ocorre não apenas em função da inclusão das restrições de transmissão, mas pela necessidade de se considerar uma lista de contingências, o que implica em um número extremamente elevado de análises adicionais.

Um sistema opera no estado saudável (S) quando todas as restrições de operação são respeitadas, antes e depois da aplicação do critério determinístico. No estado marginal (M), o sistema, inicialmente, não viola as restrições de operação, porém há necessidade de corte de carga quando o critério é aplicado. Finalmente, um estado de falha (F) apresenta corte de carga, independentemente da aplicação do critério especificado.

Na próxima seção, são apresentados alguns conceitos relacionados à avaliação da confiabilidade composta, os quais são imprescindíveis para a avaliação da confiabilidade preventiva.

2.2 CONFIABILIDADE COMPOSTA

A maioria das avaliações de confiabilidade composta apresenta seus resultados em termos de índices de desempenho ou de perda de carga. As estimativas destes índices para sistemas compostos são, usualmente, obtidas por meio de algoritmos de confiabilidade baseados em duas representações distintas: a representação por espaço de estados e a representação cronológica. Em geral, os algoritmos de confiabilidade são compostos de três passos principais [LPS89]:

- i) Selecione* um estado do sistema, definindo suas condições operativas, a disponibilidade de seus equipamentos e o nível de carga, etc.;
- ii) Analise* o desempenho do estado selecionado, verificando a capacidade da configuração selecionada de geradores e de circuitos atender à carga definida para este estado sem violar limites operativos. Se necessário, acione medidas corretivas tais como redespacho de geração, corte de carga, etc.;
- iii) Estime* índices de confiabilidade, executando o cálculo dos índices baseado na análise do estado selecionado, i.e. baseado no resultado do passo “*ii*”. Se a precisão da estimativa dos índices for aceitável, pare. Caso contrário retorne ao passo “*i*”.

A diferença básica entre as representações por espaço de estados e cronológica está na forma como os estados são gerados (passo “*i*” do algoritmo acima). A enumeração de estados e a simulação Monte Carlo não-sequencial são exemplos de algoritmos baseados na representação por espaço de estados, a qual utiliza modelos de Markov para reproduzir as transições de estado para equipamentos e carga. Portanto, os estados são selecionados sem qualquer conexão cronológica ou memória. Já a simulação Monte Carlo sequencial e a simulação Monte Carlo pseudo-cronológica são exemplos de algoritmos baseados na representação cronológica. Neste caso, é necessário que os estados sejam selecionados sequencialmente no tempo, ao menos para reproduzir o processo de falha. Uma descrição detalhada das metodologias empregadas na avaliação da confiabilidade

composta pode ser encontrada em [PB92, MPL92, BL93, MPL93, MPL94, UA94, SB95, MLP97, M99, LMMB00].

Para sistemas de grande porte, os métodos de avaliação da confiabilidade baseados em simulação Monte Carlo são mais atrativos que os métodos de enumeração de estados [PB92, SPF93]. Já para a avaliação da confiabilidade preventiva, a simulação Monte Carlo não-sequencial tem sido considerada a mais indicada, dado que esta é capaz de fornecer, de forma precisa e eficiente, os índices de confiabilidade preventiva [R02].

2.3 CONFIABILIDADE PREVENTIVA UTILIZANDO SIMULAÇÃO MONTE CARLO NÃO-SEQÜENCIAL

Antes que seja feita a abordagem sobre a confiabilidade preventiva utilizando a simulação Monte Carlo não-seqüencial, é conveniente apresentar alguns conceitos relacionados à representação por espaço de estados.

Um sistema de potência é composto de elementos que podem ser encontrados em diversos estados operativos. Por exemplo, um elemento de transmissão pode estar operando normalmente ou desligado devido a algum tipo de falha. Neste caso, este elemento pode ser representado por um modelo Markoviano a dois estados. Modelos multiestados podem ser utilizados para a representação da carga e unidades geradoras.

O modelo dos componentes

Na Figura 2.1, os estados UP e DN correspondem aos estados em que o componente se encontra em operação e fora de operação (em reparo), respectivamente. A taxa de falha (λ) é obtida dividindo-se o número de falhas do componente pelo tempo total em que o componente ficou sujeito à falha (tempo total em operação). Já a taxa de reparo (μ) é obtida por meio da divisão do número de reparos executados no componente pelo tempo total em que o componente ficou em reparo. Estas taxas representam as transições entre os estados e são dimensionadas em ocorrências (falhas ou reparos) pelo tempo de permanência no estado.



Figura 2.1: Modelo de Markov a Dois Estados.

O modelo da carga

Qualquer modelo de carga irá reproduzir de maneira aproximada o seu real comportamento. A quantidade e qualidade de dados disponíveis definem a precisão de cada modelo. O comportamento da carga pode ser representado por modelos de Markov.

Dado um período T , o modelo de carga apresentado na Figura 2.2 é composto por um conjunto de T níveis múltiplos conectados na mesma ordem em que aparecem no histórico da carga. O modelo utiliza uma taxa de transição constante $\lambda_L = 1/\Delta T$, onde ΔT representa a unidade de tempo usada para discretizar T . Para cada uma das m áreas consideradas, é fornecido o nível de carga por intervalo de tempo. Como exemplo, $L_h(A_m)$ corresponde ao nível de carga da hora h apresentado pela área m . Como demonstra a Figura 2.2, quando a carga da área 1 transita do estado 1 para o estado 2, i.e. de $L_1(A_1)$ para $L_2(A_1)$, o mesmo ocorre para as demais áreas, ou seja, $L_1(A_2)$ transita para $L_2(A_2)$, ... e $L_1(A_m)$ transita para $L_2(A_m)$. Visto que todas as taxas de transição são iguais, as cargas permanecerão, em média, ΔT horas em cada estado, assim como o período de análise terá, em média, T horas. É importante destacar que, a variação dos níveis de carga para cada área pode não ser correlacionada. Como exemplo, a carga de uma determinada região pode aumentar e, na mesma hora h , as cargas de outras áreas podem diminuir. Analogamente, o conceito de área pode ser estendido para barra ou classe consumidora [MLM99a].

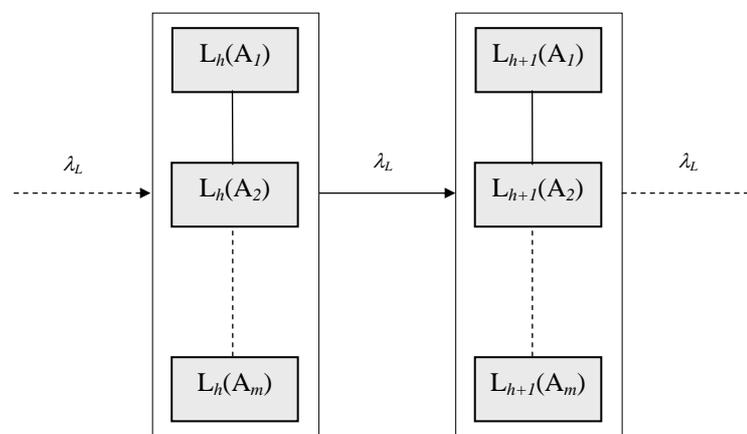


Figura 2.2: Modelo de Markov Não-Agregado com Múltiplos Níveis.

O modelo a múltiplos níveis da Figura 2.2 é extremamente flexível e superior à maioria dos modelos de Markov discutidos pela literatura [MLM99a]. Uma grande vantagem deste modelo está em manter, de maneira aproximada, a representação cronológica. Em média, a hora h do modelo corresponderá à hora h da curva cronológica da carga. Este modelo de carga é fundamental para a avaliação de índices de confiabilidade preventiva via Simulação Monte Carlo Não-sequencial.

A representação dos estados operativos de um sistema

Cada estado de um sistema de potência de q componentes, entre eles a carga, pode ser representado por um vetor $x = (x_1, x_2, \dots, x_j, \dots, x_q)$ em que x_j é o estado do componente j , associado a uma probabilidade de ocorrência $p(x_j)$. O conjunto de todos os estados possíveis do sistema é o espaço de estados X . Conhecendo-se o espaço de estados de cada componente do sistema e suas respectivas probabilidades de ocorrência, é possível determinar a probabilidade de ocorrência do vetor x , $P(x)$, ou seja, a probabilidade de ocorrência de cada estado do sistema. Caso as falhas dos componentes do sistema sejam estatisticamente independentes, $P(x)$ é dada pelo produto das probabilidades individuais de cada componente.

A avaliação do desempenho de cada estado é feita por meio de funções teste $F(x)$. O objetivo destas funções teste é verificar se uma determinada configuração de unidades geradoras e de equipamentos de transmissão é capaz de atender à demanda. Por exemplo, $F(x)$ pode representar o valor do corte de carga requerido para aliviar as violações das restrições de operação. Neste caso, diz-se que x é um estado de falha se $F(x) > 0$, i.e., se há corte de carga associado ao estado x . Por outro lado, $F(x) = 0$ indica que x é um estado de sucesso (saudável ou marginal). Como x é um vetor aleatório, $F(x)$ é uma variável aleatória, cujo valor esperado é dado por:

$$E(F) = \sum_{x \in X} F(x)P(x) \quad (2.1)$$

Estabelecidos os conceitos preliminares, os índices de confiabilidade preventiva são obtidos a partir do valor esperado de funções teste, Equação (2.1), que avaliam os estados do sistema, amostrados via sorteios não-seqüenciais.

Na simulação Monte Carlo não-seqüencial, a seleção dos estados do sistema é baseada na distribuição de probabilidades de seus componentes. Estas distribuições de probabilidades são acessadas por meio de representações Markovianas como a apresentada na Figura 2.1. Como exemplo, as probabilidades de ocorrência dos estados de falha (P_{DN}) e operação (P_{UP}) são conhecidas. Desta forma, o estado de cada componente é determinado por um número amostrado de uma distribuição uniforme $U[0,1]$, como mostra a Equação (2.2). Se $P(x_i) \leq P_{DN}$, então o componente i está falhado, caso contrário, ele se encontra no estado de operação. Determina-se, então, o vetor x , a sua probabilidade $P(x)$ e as funções teste $F(x)$.

$$P(x_i) = U \quad i = 1, \dots, q \quad (2.2)$$

Repetindo-se este processo NS vezes, é possível calcular a estimativa de $\tilde{E}[F]$ como a média dos valores encontrados para cada estado x^k amostrado:

$$\tilde{E}(F) = \frac{1}{NS} \sum_{k=1}^{NS} F(x^k) \quad (2.3)$$

Uma vez que $F(x)$ é uma variável aleatória, a estimativa ou média amostral, Equação (2.3), também é uma variável aleatória com variância dada por:

$$V(\tilde{E}(F)) = \frac{V(F)}{NS} \quad (2.4)$$

em que $V(F)$ é a variância amostral da função $F(x)$. A Equação (2.4) confirma a noção intuitiva de que a precisão do experimento é tão melhor quanto maior for o

número de amostras analisadas. A incerteza do processo é normalmente representada pelo coeficiente de variação:

$$\beta = \frac{\sqrt{V(\tilde{E}(F))}}{\tilde{E}(F)} \times 100\% \quad (2.5)$$

A convergência do processo de simulação é verificada pelo coeficiente β .

2.3.1 Índices de Probabilidade

As funções teste utilizadas para avaliar as probabilidades de ocorrência dos estados saudáveis, $P(S)$, dos estados marginais, $P(M)$ e dos estados de falha, $P(F)$, assumem os seguintes valores, respectivamente:

$$F(x^k) = \begin{cases} 1 & ; \text{ se } x^k \text{ é estado saudável} \\ 0 & ; \text{ em caso contrário} \end{cases} \quad (2.6)$$

$$F(x^k) = \begin{cases} 1 & ; \text{ se } x^k \text{ é estado marginal} \\ 0 & ; \text{ em caso contrário} \end{cases} \quad (2.7)$$

$$F(x^k) = \begin{cases} 1 & ; \text{ se } x^k \text{ é estado de falha} \\ 0 & ; \text{ em caso contrário} \end{cases} \quad (2.8)$$

Pode-se notar que a função teste utilizada para o cálculo de $P(F)$, é a mesma usada para avaliar o índice LOLP na avaliação da confiabilidade tradicional.

2.3.2 Índices de Freqüência

Considere a Figura 2.3, onde Ω_S , Ω_M e Ω_F representam, respectivamente, o conjunto de todos os estados saudáveis, marginais e de falha. Ainda nesta figura, dado que $x^{\text{marginal}} \in \Omega_M$, $\Delta\lambda_{MS}$ corresponde ao somatório das taxas de transição entre o estado x^{marginal} e todos os estados saudáveis que podem ser alcançados mediante uma

transição. Já o termo $\Delta\lambda_{MF}$ representa o somatório das taxas de transição entre o estado $x^{marginal}$ e todos os estados de falha que podem ser alcançados mediante uma transição. Analogamente, dado que $x^{falha} \in \Omega_F$, $\Delta\lambda_{FS}$ corresponde ao somatório das taxas de transição entre o estado x^{falha} e todos os estados saudáveis que podem ser alcançados mediante uma transição. Já o termo $\Delta\lambda_{FM}$ representa o somatório das taxas de transição entre o estado x^{falha} e todos os estados marginais que podem ser alcançados mediante uma transição.

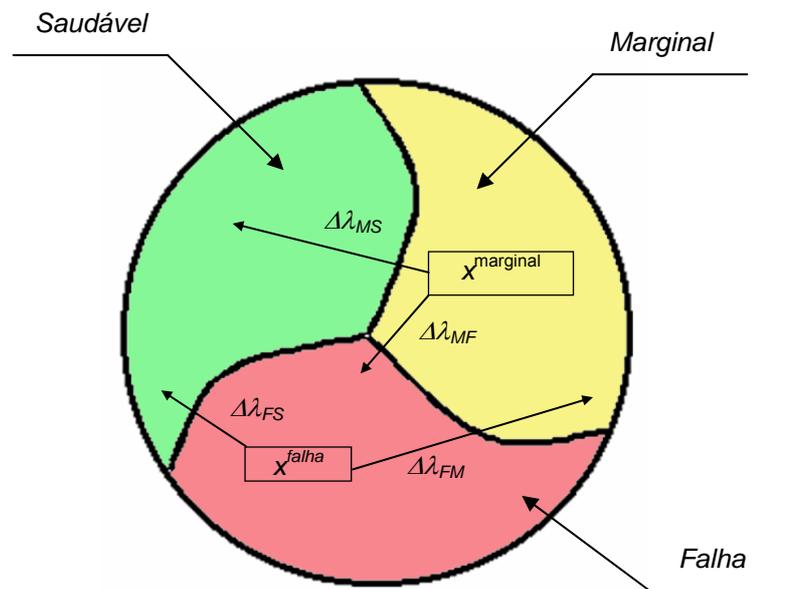


Figura 2.3: Transições entre Estados Saudáveis, Marginais e de Falha.

De acordo com a Figura 2.3, a freqüência com que o sistema reside em cada um dos estados operativos pode ser avaliada a partir dos estados pertencentes a Ω_M e Ω_F . Então, a freqüência com a qual o sistema opera de modo saudável, $Freq(S)$, pode ser estimada através de uma função teste que assume os valores:

$$F(x^k) = \begin{cases} 0 & ; \text{ se } x^k \text{ é estado saudável} \\ \Delta\lambda_{MS} & ; \text{ se } x^k \text{ é estado marginal} \\ \Delta\lambda_{FS} & ; \text{ se } x^k \text{ é estado de falha} \end{cases} \quad (2.9)$$

Para o cálculo da freqüência com que o sistema opera em estados marginais, $Freq(M)$, a função teste utilizada deve assumir os valores:

$$F(x^k) = \begin{cases} \Delta\lambda_{MS} + \Delta\lambda_{MF} & ; \text{ se } x^k \text{ é estado marginal} \\ 0 & ; \text{ em caso contrário} \end{cases} \quad (2.10)$$

Finalmente, para o cálculo de $Freq(F)$, freqüência de residência do sistema em estados de falha, a função teste é dada por:

$$F(x^k) = \begin{cases} \Delta\lambda_{FS} + \Delta\lambda_{FM} & ; \text{ se } x^k \text{ é estado de falha} \\ 0 & ; \text{ em caso contrário} \end{cases} \quad (2.11)$$

O cálculo dos termos $\Delta\lambda_{MS}$, $\Delta\lambda_{MF}$, $\Delta\lambda_{FS}$ e $\Delta\lambda_{FM}$ é muito caro do ponto de vista computacional. Para cada estado sorteado, $x^{marginal}$ ou x^{falha} , de um sistema com n_c componentes, a princípio, seria necessário realizar um número de análises adicionais superior a n_c . Somente para identificar os estados de falha, vizinhos ao estado $x^{marginal}$ ou x^{falha} , seriam necessárias n_c análises. Novas análises seriam, então, aplicadas aos demais estados vizinhos, i.e. que não são de falha, para distingui-los entre estados saudáveis e marginais.

A aplicação das funções teste propostas em sistemas de grande porte torna-se inviável, dado que o número de análises adicionais de desempenho é elevado e, conseqüentemente, o esforço computacional envolvido. Para transpor estas barreiras, uma nova metodologia, que utiliza uma extensão do processo de transição de estado um passo à frente [ML02], foi proposta para a avaliação de índices de freqüência e duração na análise de confiabilidade preventiva [R02].

2.3.3 Índices de Freqüência - Processo de Transição de Estado um Passo à Frente

Utilizando a metodologia do processo de transição de estado um passo à frente, as freqüências $Freq(S)$, $Freq(M)$ e $Freq(F)$ podem também ser calculadas por meio de amostragens de um estado x^m a partir do estado x^k (marginal ou de falha). Neste caso as novas funções teste usadas para estimar as freqüências dos estados saudáveis, $Freq(S)$, dos estados marginais, $Freq(M)$, e dos estados de falha, $Freq(F)$, deverão assumir os seguintes valores, respectivamente:

$$F(x^k) = \begin{cases} 0 & ; \text{ se } x^k \text{ é estado saudável} \\ \lambda_k^{out} & ; \text{ se } x^k \text{ é estado marginal e } x^m \text{ é estado saudável} \\ 0 & ; \text{ se } x^k \text{ é estado marginal e } x^m \text{ não é estado saudável} \\ \lambda_k^{out} & ; \text{ se } x^k \text{ é estado de falha e } x^m \text{ é estado saudável} \\ 0 & ; \text{ se } x^k \text{ é estado de falha e } x^m \text{ não é estado saudável} \end{cases} \quad (2.12)$$

$$F(x^k) = \begin{cases} 0 & ; \text{ se } x^k \text{ é estado saudável} \\ \lambda_k^{out} & ; \text{ se } x^k \text{ é estado marginal e } x^m \text{ não é estado marginal} \\ 0 & ; \text{ se } x^k \text{ é estado marginal e } x^m \text{ é estado marginal} \\ 0 & ; \text{ se } x^k \text{ é estado de falha} \end{cases} \quad (2.13)$$

$$F(x^k) = \begin{cases} 0 & ; \text{ se } x^k \text{ é estado saudável} \\ 0 & ; \text{ se } x^k \text{ é estado marginal} \\ \lambda_k^{out} & ; \text{ se } x^k \text{ é estado de falha e } x^m \text{ não é estado de falha} \\ 0 & ; \text{ se } x^k \text{ é estado de falha e } x^m \text{ é estado de falha} \end{cases} \quad (2.14)$$

onde λ_k^{out} é o somatório das taxas de transição do estado x^k para todos os estados diretamente ligados a ele, e x^m é um estado qualquer, encontrado a partir de x^k por meio de uma simples transição.

Este novo método simula somente uma das possíveis transições partindo de um estado (marginal ou de falha) x^k , de modo a selecionar um estado vizinho x^m . Este

estado x^m é selecionado a partir de uma função distribuição de probabilidade relacionada com as possíveis transições de partida do estado amostral x^k . Esta função distribuição de probabilidade é construída com base na Equação (2.15), a qual é derivada do processo de transição de estado um passo à frente [ML02]:

$$P_{km} = \frac{f_{km}}{f_k^{out}} = \frac{\lambda_{km}}{\lambda_k^{out}} = \frac{\lambda_{km}}{\sum_{i=1}^{MT} \lambda_{ki}} \quad (2.15)$$

onde:

P_{km} é a probabilidade de ocorrência da transição km, definida como a probabilidade do sistema ingressar no estado x^m partindo do estado x^k ;

f_{km} é a freqüência de transição do estado x^k para o estado x^m ;

f_k^{out} é a freqüência de saída do estado x^k ;

λ_{km} é a taxa de transição do estado x^k para o estado x^m ;

λ_k^{out} é a taxa de transição do estado x^k para todos os outros estados; e

MT é o conjunto formado por todos os estados vizinhos ao estado x^k .

Neste caso, é possível observar que a metodologia dispensa a necessidade de examinar todos os estados vizinhos a x^k , sendo preciso simular apenas uma única transição. Isto implica em uma redução significativa do número de análises adicionais de desempenho e, conseqüentemente, do esforço computacional.

Os conceitos descritos pela função teste dada pela Equação (2.14) são demonstrados no Apêndice A. Estes conceitos também podem ser utilizados para estimar os índices Freq(S) e Freq(M).

2.3.4 Índices de Duração

As durações médias de residência do sistema em estados saudáveis, marginais e de falha, expressas em horas, são dadas respectivamente por:

$$Dur(S) = \frac{P(S)}{Freq(S)} \quad (2.16)$$

$$Dur(M) = \frac{P(M)}{Freq(M)} \quad (2.17)$$

$$Dur(F) = \frac{P(F)}{Freq(F)} \quad (2.18)$$

Pode-se concluir que $Dur(F)$ é igual ao índice LOLD.

2.4 O CRITÉRIO DETERMINÍSTICO

A confiabilidade preventiva é caracterizada pela inclusão de critérios determinísticos em metodologias probabilísticas. A escolha ou determinação do critério determinístico a ser utilizado na avaliação da confiabilidade preventiva depende muito do sistema em estudo e da política de planejamento. Um critério determinístico muito utilizado por operadores e planejadores de sistemas de potência é o critério “N-1”. Porém, a utilização deste critério em sistemas de grande porte torna-se inviável ou proibitiva, dado que seriam necessárias tantas análises adicionais de adequação de estados quanto for o número de equipamentos do sistema.

Em sistemas compostos, utiliza-se como critério determinístico os prováveis eventos de saídas de equipamentos, referido aqui como uma lista de contingências. As contingências que ocorrem freqüentemente e que têm um impacto significativo no desempenho do sistema devem ser selecionadas e testadas, visando à obtenção de uma análise de confiabilidade preventiva mais completa. As probabilidades associadas, as freqüências de ocorrência e a severidade são fatores que devem ser considerados na construção da lista de contingências.

Por outro lado, para manter ou adquirir uma eficiência computacional nos algoritmos utilizados na avaliação da confiabilidade preventiva, é necessário que a lista de contingências tenha o menor número possível de equipamentos. Portanto, a elaboração da lista de contingências é de extrema importância na avaliação da confiabilidade preventiva de sistemas compostos.

Vale ressaltar que a principal característica da confiabilidade preventiva, ou análise de bem estar, é alertar quando o sistema caminha para um ponto de operação pertencente ao grupo de estados marginais. Estes estados são altamente dependentes da lista de contingências e indicam ao operador que situações críticas, como a presença de cortes de carga, podem ocorrer. Desta forma, o operador tem em mãos uma ferramenta a mais para a tomada de decisões. Visto isso, busca-se dar um alerta ao operador sempre que o sistema opera em um estado marginal.

Tendo em mente estas considerações, uma lista de contingências bem elaborada, ou “boa”, é aquela na qual a possibilidade do sistema operar em um estado de falha, sem o operador ser previamente alertado, é minimizada. A frequência de transição dos estados de falha para os estados saudáveis, a qual pode ser obtida a partir de $\Delta\lambda_{FS}$ na Figura 2.3, permite determinar se uma lista de contingências é ou não uma lista boa. A transição de um estado saudável para um estado de falha se dá pela mudança de estado de um único elemento j do sistema (do estado a para o estado b). O mesmo é válido para a transição contrária ($\Delta\lambda_{FS}$), onde a única diferença está no sentido da mudança do elemento j (do estado b para o estado a). Logo, este elemento j não pertence à lista de contingências e a frequência de transição do estado a para o estado b contribui na frequência de transição dos estados saudáveis para os de falha, o que é indesejável no estudo em questão. Ao incluirmos este elemento j na lista de contingências, a parcela $\Delta\lambda_{FS}$ diminui, portanto, esta nova lista de contingências fica mais bem elaborada que a antiga.

Por meio da utilização de uma lista boa, a frequência de estados saudáveis pode ser estimada apenas pela parcela $\Delta\lambda_{MS}$ na Figura 2.3. Deste modo, o número de análises adicionais decresce, tornando o esforço computacional requerido significativamente menor.

Um sistema onde existe a possibilidade de variações bruscas da carga, pode estar operando em um estado saudável, mas quando a carga transitar para o próximo ponto na curva de carga, o sistema pode transitar para um estado de falha. Portanto, esta transição de carga contribuirá com a frequência de transição de estados saudáveis para estados de falha. Logo, o próximo ponto de carga deve ser incluído na lista de contingências, proporcionando uma lista ainda melhor.

Com a elaboração da lista de contingências, um estado x^k que não pertence ao grupo de estados de falha é classificado como marginal, se pelo menos um evento pertencente à lista levar o sistema a residir em um estado de falha.

2.5 O ALGORITMO DE CONFIABILIDADE PREVENTIVA

O algoritmo básico da confiabilidade preventiva [R02, LRMB04], utilizando simulação Monte Carlo não-seqüencial, é reproduzido a seguir:

- i)* amostre um estado $x^k \in X$, baseado em sua distribuição de probabilidade $P(x^k)$;
- ii)* analise o desempenho do estado amostrado x^k por meio de estudos de fluxo de potência. Se necessário, acione medidas corretivas tais como redespacho de geração, corte de carga, etc. Se x^k é um estado de falha, estime $P(F)$, EPNS, Freq(S) e Freq(F) e vá para o passo *(iv)*; em caso contrário, prossiga para o passo *(iii)*;
- iii)* Submeta o estado x^k à lista de contingências, se x^k é estado saudável estime $P(S)$; se não, estime $P(M)$, Freq(S) e Freq(M);
- iv)* avalie o coeficiente de variação β . Se a convergência desejada não é obtida, retorne ao passo *"i"*; em caso contrário, pare após avaliar os índices Dur(S), Dur(M) e Dur(F).

2.6 CONCLUSÕES

Neste capítulo, foram revistos alguns conceitos básicos de confiabilidade convencional e preventiva. No que se refere à confiabilidade convencional, foram apresentados os modelos markovianos dos equipamentos (e.g. geradores e circuitos de transmissão), o modelo de carga e uma breve revisão de simulação Monte Carlo não-seqüencial. Já para a confiabilidade preventiva, foram revisados seus conceitos básicos e reproduzidas as funções teste utilizadas para estimar os índices de bem-estar. Vale lembrar que os modelos apresentados na confiabilidade convencional também são utilizados na confiabilidade preventiva.

A maior parcela do esforço computacional necessário à avaliação da confiabilidade de sistemas compostos é consumida pela análise de adequação dos estados operativos do sistema (passo “*ii*” do algoritmo da Seção 2.2). Já para a avaliação da confiabilidade preventiva, o esforço computacional é ainda mais acentuado, dado que todos os estados de sucesso devem ser submetidos à lista de contingências para a identificação dos estados saudáveis e marginais (passo “*iii*” do algoritmo da Seção 2.5).

Uma forte restrição computacional à utilização da simulação Monte Carlo não-seqüencial na avaliação da confiabilidade preventiva [R02], qual seja, a obtenção de estimativas para índices de frequência e duração, foi eliminada com o uso de um modelo de Markov não agregado para a representação da carga [MLM99a] e do *processo de transição de estado um passo a frente* [ML02, LRMB04].

O critério determinístico utilizado na avaliação da confiabilidade preventiva impacta de forma bastante significativa nos resultados dos índices, no esforço computacional exigido e na eficiência do método proposto. Como exemplo, em sistemas compostos, um aumento no número de componentes pertencentes à lista de contingências aumenta o número de análises adicionais de adequação de estados e, conseqüentemente, o esforço computacional fica ainda mais elevado. Por outro lado, a determinação de uma lista com poucos componentes, ou com componentes que

não causam impacto significativo no desempenho do sistema, pode produzir resultados *pobres*.

Nos próximos capítulos, são apresentadas algumas técnicas para reduzir a carga computacional requerida na análise de adequação dos estados operativos, realizada nos passos “*ii*” e “*iii*” do algoritmo da Seção 2.5. Espera-se que estas técnicas tornem o algoritmo de confiabilidade mais eficiente computacionalmente, isto é, de execução mais rápida, sem comprometer a precisão dos resultados.

CAPÍTULO 3

REDUÇÃO PROBABILÍSTICA DA REDE DE TRANSMISSÃO

3.1 INTRODUÇÃO

Conforme comentado nos capítulos anteriores, o número de metodologias probabilísticas propostas para a avaliação da confiabilidade composta (geração e transmissão) convencional e preventiva têm aumentado a cada ano. Com a tendência atual de uma maior competição entre as empresas, o planejamento da expansão de sistemas de potência necessita cada vez mais de abordagens metodológicas bem fundamentadas e coerentes.

A metodologia proposta em [R02, LRMB04] se mostrou capaz de avaliar a confiabilidade preventiva de sistemas compostos. Porém, devido ao excessivo número de análises adicionais necessárias no processo de classificação entre estados saudáveis e marginais, o esforço computacional exigido ainda é elevado.

Tendo em vista a redução do esforço computacional demandado na análise de adequação dos estados operativos do sistema, nas seções seguintes será apresentada uma técnica de redução da rede de transmissão que poderá ser aplicada no algoritmo de confiabilidade preventiva. Tal técnica pode viabilizar ainda mais a avaliação da confiabilidade preventiva de sistemas de grande porte. Porém, antes serão apresentados os sistemas utilizados nos estudos de caso e a resolução do problema de otimização, via métodos de pontos interiores, realizado durante a análise de adequação dos estados.

3.2 SISTEMAS UTILIZADOS

Os resultados apresentados neste e nos próximos capítulos são provenientes de estudos de caso realizados com os sistemas IEEE-RTS, IEEE-MRTS, IEEE-MRTS-96 e Sul-Sudeste Brasileiro (SSB), descritos a seguir.

O sistema IEEE-RTS – *Reliability Test System*, ilustrado pela Figura 3.1, possui 24 barras, 38 circuitos e 32 unidades geradoras distribuídas em 14 usinas, perfazendo um total de 3405 MW de potência instalada. O valor de pico anual da carga total do sistema atinge 2850 MW. A partir da curva anual de carga do sistema, foi produzido um modelo de Markov sem qualquer agregação entre seus estados (Figura 2.2), o qual é utilizado pela simulação não-seqüencial. Através deste modelo é assumido que todas as barras de cargas seguem o mesmo padrão da curva de carga do sistema, porém, isto não é mandatório para a metodologia proposta nesta tese. Diferentes padrões de carga por área, ou até mesmo por barra, podem ser utilizados [LRMB04]. Os dados referentes a este sistema estão detalhados no Apêndice C.

O IEEE-MRTS (*Modified IEEE Reliability System*) resulta de modificações feitas no sistema IEEE-RTS [APM79], com o objetivo de estressar a rede de transmissão. Para tal, são duplicadas a capacidade de geração e a carga, em cada barra do sistema, perfazendo um total de 6810 MW de potência instalada e 5700 MW de pico anual da carga. É adotada a curva de carga original do sistema IEEE-RTS.

O sistema IEEE-RTS-96 *Reliability Test System 1996* foi desenvolvido por meio de modificações e atualizações do sistema IEEE-RTS [APM99]. Dentre estas modificações, a principal foi a consideração da interligação de regiões (ou ilhas). Cada região é idêntica ao sistema IEEE-RTS. A capacidade de geração e o pico de carga atingem 10,21 GW e 8,55 GW, respectivamente. O sistema possui 120 circuitos e 96 unidades geradoras distribuídas em 42 usinas. É adotada a curva de carga original do sistema IEEE-RTS e, conseqüentemente, o mesmo modelo de Markov não-agregado é utilizado também para o sistema IEEE-RTS-96.

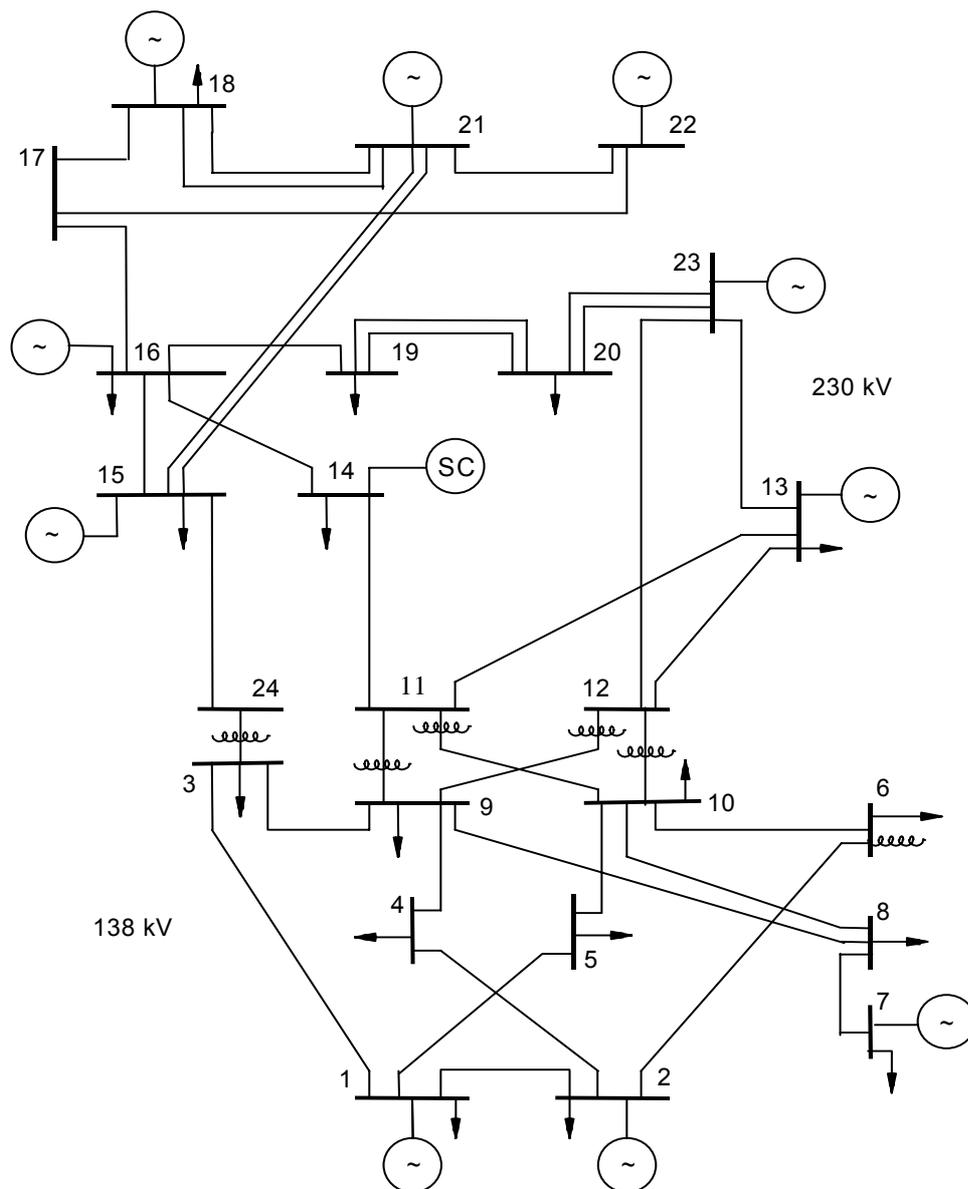


Figura 3.1: Diagrama do Sistema IEEE-RTS.

O sistema IEEE-MRTS-96 (*IEEE Modified Reliability Test System 1996*), analogamente ao sistema IEEE-MRTS, resulta de modificações feitas no IEEE-RTS-96 [APM99], com o objetivo de estressar a rede de transmissão. A capacidade de geração e a carga são duplicadas em cada barra do sistema. A nova capacidade instalada fica igual a 20,4 GW e o pico anual de carga atinge 17,1 GW.

A configuração utilizada para o sistema Sul-Sudeste Brasileiro (SSB) contém 413 barras, 685 circuitos e 255 estações geradoras. A capacidade instalada e o pico anual de carga são iguais a 46 GW e 41 GW, respectivamente. Esta era a configuração utilizada em estudos de planejamento durante a década de 90. Uma curva típica anual é utilizada para representar o comportamento da carga em todas as áreas do sistema. A Figura 3.2 ilustra as informações básicas do sistema através de um diagrama simplificado das cargas (L), gerações (G) e áreas de transmissão mais importantes. A composição da carga total do sistema SSB é aproximadamente 19% residencial, 28% comercial e 53% industrial.

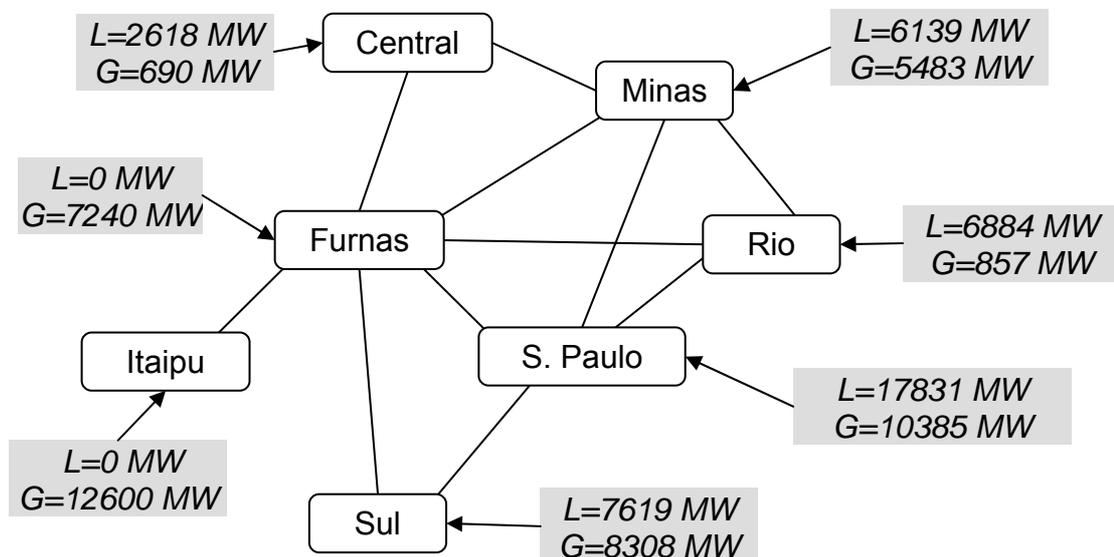


Figura 3.2: Diagrama Simplificado do Sistema SSB.

Finalmente, vale destacar que em todos os testes apresentados nesta tese foi utilizado um computador Pentium IV com 2,80 GHz.

3.3 O PROBLEMA DE OTIMIZAÇÃO

Durante as análises de adequação dos estados operativos do sistema elétrico, procura-se caracterizá-los como saudável, marginal ou de falha, sendo a classificação função dos critérios de desempenho estipulados. A base conceitual de cada estado operativo foi apresentada na Seção 2.1.

A avaliação do desempenho de um sistema composto (geração e transmissão) é realizada, geralmente, utilizando um fluxo de potência AC ou DC, acoplado a um algoritmo de aplicação de medidas corretivas capaz de determinar o novo ponto de operação do sistema. Este algoritmo permite estabelecer um conjunto de ações de controle que devem reconduzir o sistema a um ponto de operação viável, no qual não haja violações técnicas dos limites das tensões dos barramentos e dos carregamentos dos circuitos de transmissão. Caso o objetivo não seja atingido, o algoritmo de medidas corretivas deve determinar a mínima injeção de reativos e/ou o mínimo corte de carga necessários para que o sistema seja reconduzido para um ponto de operação viável.

A determinação do conjunto de ações de controle, para reconduzir o sistema a um ponto de operação viável, pode ser formulada como um Problema de Otimização Não Linear.

A formulação geral de um Problema de Otimização consiste na minimização (ou maximização) de um índice de desempenho, que pode ser representado analiticamente por uma função objetivo, sujeita a um conjunto de equações e inequações, que representam o comportamento e as limitações físicas do sistema, denominadas restrições. Em termos matemáticos, este Problema de Otimização pode ser expresso da seguinte forma:

$$\text{Min } f(\vec{z}) \tag{3.1}$$

Sujeito a:

$$g(\bar{z}) = 0 \quad (3.2)$$

$$h(\bar{z}) \leq 0 \quad (3.3)$$

$$\bar{z} \geq 0 \quad (3.4)$$

onde,

\bar{z} é o vetor de variáveis de decisão do problema;

$f : R^n \rightarrow R$ é a função objetivo;

$g : R^n \rightarrow R^m$ é o vetor de funções das restrições de igualdade; e

$h : R^n \rightarrow R^p$ é o vetor de funções das restrições de desigualdades.

O sistema de potência é modelado através das restrições de igualdade e desigualdade, dadas pelas Equações (3.2) e (3.3). Por outro lado, a função objetivo, Equação (3.1), representa o montante de interesse que se deseja otimizar, sendo peculiar a cada sistema. Uma vez modelado o Problema de Otimização, deve-se encontrar uma metodologia que permita a sua resolução.

3.3.1 Fluxo de potência DC

Nesta tese, é utilizado um fluxo de potência DC para a avaliação do desempenho do sistema, sendo o corte de carga a ação de controle tomada para a determinação de um estado operativo viável. A política de corte de carga é a regra segundo a qual se determina em que locais se deve cortar carga. O corte de carga torna-se necessário quando há a ocorrência de estados operativos com insuficiência de geração e/ou sobrecargas em elementos de transmissão que não podem ser eliminadas por ajustes no sistema (e.g. redespacho de geração, etc.).

Nos casos com sobrecarga, a definição das barras que serão afetadas é mais rígida, pois o corte de carga deve ser feito localmente. Já para os casos de estados com insuficiência de geração, precisa-se, inicialmente, cortar um montante de carga igual à diferença entre a demanda e a capacidade de geração disponível. Em princípio,

existem muitas possibilidades de se cortar carga em diversas barras, de modo que o montante global cortado seja aquele necessitado pelo caso em questão. Para se definir os locais de corte, deve-se fornecer ao algoritmo de otimização uma política de corte de carga.

Para o caso específico desta tese, utiliza-se a política de mínimo corte de carga, onde todas as barras têm penalidades de interrupção iguais. Portanto, não se fornece ao algoritmo de otimização uma ordenação das barras para fins de corte. Em situações de insuficiência de geração, os cortes podem ser feitos em quaisquer barras sem se obedecer a qualquer ordem de prioridade. Outras políticas de corte de carga podem ser utilizadas na avaliação do desempenho do sistema. Sabe-se que diferentes políticas podem influenciar fortemente os índices de confiabilidade por barra. No entanto, grande parte dos índices globais para o sistema tende a não depender da política de corte de carga adotada.

Tendo em vista estas considerações, a minimização do corte de carga é utilizada como função objetivo e o problema de otimização dado pelas Equações (3.1) a (3.4) se torna [M94]:

$$z = \text{Min} \sum_{j=1}^n r_j \quad (3.5)$$

Sujeito a:

$$\mathbf{B} \vec{\theta} + \vec{g} + \vec{r} = \vec{d} \quad (3.6)$$

$$\vec{g} \leq \vec{g}_{\max} \quad (3.7)$$

$$\vec{g} \geq \vec{g}_{\min} \quad (3.8)$$

$$|\vec{f}| \leq \vec{f}_{\max} \quad (3.9)$$

$$\vec{r} \leq \vec{d} \quad (3.10)$$

onde,

- r_j é o corte de carga na barra i ;
- n é o número total de barras do sistema;
- \mathbf{B} é a matriz de susceptância de barra, equivalente à matriz de admitância de barra para um sistema sem perdas;
- $\vec{\theta}$ é o vetor dos ângulos das barras;
- \vec{g} é o vetor de geração por barra;
- \vec{r} é o vetor de corte de carga;
- \vec{d} é o vetor de demanda por barra;
- \vec{g}_{\max} é o vetor de máxima capacidade de geração por barra;
- \vec{g}_{\min} é o vetor de mínima capacidade de geração por barra;
- \vec{f} é o vetor dos fluxos nos circuitos; e
- \vec{f}_{\max} é o vetor de máxima capacidade de fluxo por circuito.

Dois algoritmos para a resolução do problema de otimização dado pelas Equações (3.5) a (3.10) são apresentados: o Dual-Simplex, modificado para explorar as características de esparsidade das equações da rede elétrica [SM79], e Primal-Dual de pontos interiores com barreira logarítmica [C01, B04].

3.3.2 Método Simplex

O método simplex é um procedimento matricial para resolver o problema de otimização apresentado na seção anterior. Dada uma solução inicial viável, o método simplex caminha pelos vértices da região factível, isto é do polígono formado pelas restrições do problema, até encontrar uma solução que não possua soluções vizinhas melhores que ela. Esta é considerada a solução ótima. Existem duas situações nas quais não há solução ótima: quando não há nenhuma solução viável para o problema, devido a restrições incompatíveis; ou quando não há máximo (ou mínimo), isto é, uma ou mais variáveis podem tender a infinito e as restrições continuarem sendo satisfeitas, o que fornece um valor sem limites para a função objetivo. Ao leitor interessado em mais detalhes sobre o método simplex é indicada a referência [SB85].

3.3.3 Programação Linear - Pontos Interiores

O Método de Pontos Interiores pressupõe a resolução de um sistema de equações não lineares para a obtenção do ponto candidato a ótimo. Esta resolução é realizada através de um processo iterativo, requerendo-se em cada iteração a solução de um sistema linear de grande dimensão e alto grau de esparsidade. O ponto chave do método de otimização por pontos interiores [AKRV89] consiste em transformar as restrições de desigualdade em restrições de igualdade através da incorporação de variáveis de folga, e associar uma função barreira logarítmica à função objetivo do problema. Com isto, pode-se construir uma Função Lagrangeana expandida contendo somente restrições de igualdade e aplicar as condições de estacionaridade da Lagrangeana (condições de otimalidade de primeira ordem Karush-Kuhn-Turker – KKT) a esta função [G94, WDM94].

Este método, conhecido como Primal-Dual de Pontos Interiores, tem se mostrado eficiente no tratamento de sistemas de grande porte, mal condicionado e com violações das restrições, uma vez que, entre outras características, ele não precisa partir de um fluxo de potência convergido (solução viável).

No Apêndice B são apresentados maiores detalhes sobre a resolução de um problema de otimização utilizando a metodologia de pontos interiores.

3.3.4 Base Reduzida

Na análise de adequação de sistemas compostos são encontrados problemas adicionais em relação ao caso dos sistemas de geração. Estes problemas decorrem do aumento de variáveis aleatórias envolvidas e da maior complexidade apresentada pela análise de desempenho de cada estado. Em função das restrições de transmissão, a análise de adequação dos estados deve utilizar um algoritmo de fluxo de potência com otimização das medidas corretivas.

Como pode ser verificado, o número de restrições dado pela Equação (3.9) é diretamente proporcional ao número de circuitos considerados no problema de otimização.

Como já foi mencionado, a análise de adequação dos estados operativos do sistema constitui a maior parcela do esforço computacional na avaliação da confiabilidade preventiva de sistemas compostos. Desta forma, é proposta uma ação para enfrentar este problema. Esta ação consiste na divisão da resolução do problema de otimização apresentado pelas Equações (3.5) a (3.10) nas duas etapas descritas a seguir.

- *Etapa 1* – consiste em resolver o problema de otimização sem considerar a Equação (3.9). Neste caso, a capacidade de transmissão dos circuitos não é limitada, o que resulta em um problema de otimização com dimensões reduzidas;
- *Etapa 2* – consiste em resolver o problema de otimização considerando os limites de capacidade dos circuitos. Para tal, são identificadas, através dos resultados da *Etapa 1*, quais restrições da Equação (3.9) estão ativas, ou seja, quais circuitos de transmissão têm seus limites de capacidade violados.

Na *Etapa 1* somente as equações estáticas de fluxo de potência são consideradas como restrições do problema. Portanto, o resultado obtido é um fluxo DC. Neste ponto, qualquer política de despacho de geração pode ser utilizada. No entanto, deve-se levar em conta o impacto da política adotada na aplicação da *Etapa 2*.

Em relação à *Etapa 2*, existem várias opções para se determinar quais restrições estão ativas no estado em questão. Como exemplo, pode-se considerar como restrições ativas somente aqueles circuitos que apresentaram fluxos acima de suas capacidades máximas. Neste trabalho, foi considerado um percentual da capacidade máxima de cada circuito como o limite para a determinação das restrições ativas. Por exemplo, dado um resultado da *Etapa 1*, se um circuito qualquer tiver seu fluxo acima de 75% de sua capacidade máxima, a restrição referente a este circuito será considerada na resolução do problema de otimização da *Etapa 2*.

É importante ressaltar que, caso a solução da *Etapa 2* ainda apresente alguma violação das restrições de transmissão, é necessário repetir esta etapa até se obter uma solução que não viole nenhuma restrição.

Para exemplificar a redução do problema de otimização, é utilizado o sistema IEEE-MRTS-96, o qual possui 42 barras de geração, 51 barras de carga e 132 circuitos. A forma matricial do problema original é:

$$\begin{bmatrix} \mathbf{B} & \mathbf{I}' & \mathbf{I}'' \\ \mathbf{I}''' & \mathbf{0} & \mathbf{0} \\ \mathbf{I}''' & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{I}' & \mathbf{0} \\ \mathbf{0} & \mathbf{I}' & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{I}'' \\ \mathbf{0} & \mathbf{0} & \mathbf{I}'' \end{bmatrix} \times \begin{bmatrix} \bar{\theta} \\ \bar{g} \\ \bar{r} \end{bmatrix} = \begin{bmatrix} \bar{d} \\ \leq \Delta\theta_{max} \\ \geq -\Delta\theta_{max} \\ \leq \bar{g}_{max} \\ \geq \bar{g}_{min} \\ \leq \bar{d} \\ \geq 0 \end{bmatrix} \quad (3.11)$$

onde,

- \mathbf{I}' é a matriz de elementos unitários referentes à geração, de ordem $n \times n_{ger}$;
- \mathbf{I}'' é a matriz de elementos unitários referentes à carga, de ordem $n \times n_{car}$;
- \mathbf{I}''' é a matriz de elementos unitários referentes aos ângulos das barras terminais dos circuitos, de ordem $ncir \times n$;
- $\Delta\theta_{max}$ é o vetor de máxima abertura angular dos circuitos, de ordem $ncir \times n$;
- n é o número total de barras do sistema;
- n_{ger} é o número total de barras de geração;
- n_{car} é o número total de barras de carga; e
- $ncir$ é o número total de circuitos.

O número de linhas e de colunas da matriz para o problema original, Equação (3.11), são, respectivamente:

$$\begin{aligned} nlin &= (n + 2 * ncir + 2 * nger + 2 * ncar) \\ ncol &= (n + nger + ncar) \end{aligned} \quad (3.12)$$

Substituindo os valores do sistema IEEE-MRTS-96 na Equação (3.12), temos uma matriz com 535 linhas por 178 colunas.

Aplicando o conceito de base reduzida, a formulação matricial do problema na *Etapa 1* fica:

$$\begin{bmatrix} \mathbf{B} & \mathbf{I}' & \mathbf{I}'' \\ \mathbf{0} & \mathbf{I}' & \mathbf{0} \\ \mathbf{0} & \mathbf{I}' & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{I}'' \\ \mathbf{0} & \mathbf{0} & \mathbf{I}'' \end{bmatrix} \times \begin{bmatrix} \vec{\theta} \\ \vec{g} \\ \vec{r} \end{bmatrix} = \begin{bmatrix} \vec{d} \\ \leq \vec{g}_{max} \\ \geq \vec{g}_{min} \\ \leq \vec{d} \\ \geq 0 \end{bmatrix} \quad (3.13)$$

E para o número de linhas e colunas, temos:

$$\begin{aligned} nlin &= (n + 2 * nger + 2 * ncar) \\ ncol &= (n + nger + ncar) \end{aligned} \quad (3.14)$$

Para o sistema IEEE-MRTS-96, a matriz do problema de otimização tem 271 linhas e 178 colunas. Durante a *Etapa 2*, a dimensão da matriz do problema torna-se um pouco maior. Entretanto, sua dimensão permanece bem menor que aquela apresentada no problema original.

Como pode-se concluir, é proposta uma metodologia que consiste na divisão de um problema maior em dois subproblemas menores. Para avaliar o impacto desta metodologia no tempo de processamento, apresentam-se a seguir alguns resultados preliminares utilizando o sistema IEEE-MRTS e o sistema IEEE-MRTS-96. Em todos os testes realizados, o critério de parada adotado foi a obtenção de um coeficiente de incerteza relativa β , dado pela Equação (2.5), menor ou igual a 5% para todos os índices.

O sistema IEEE-MRTS

A curva de carga adotada, dada pela Figura 3.3, é referente à semana pico. Neste caso, repete-se 52 vezes a semana 51 da curva de carga original do sistema IEEE-RTS .

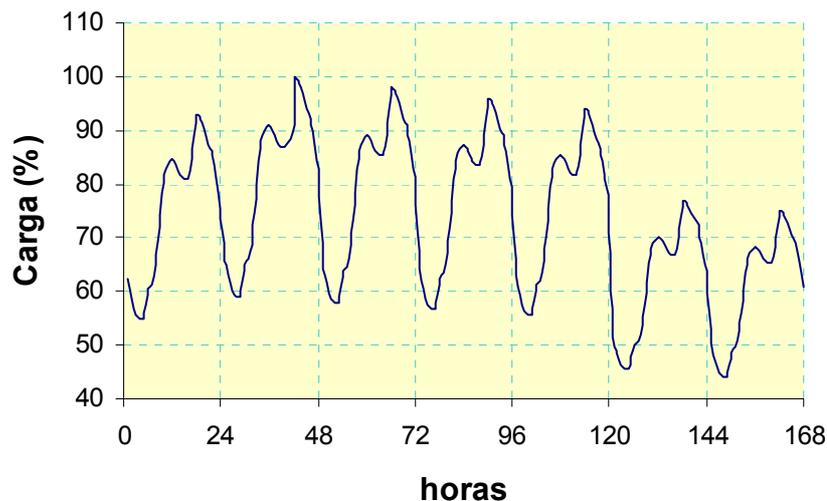


Figura 3.3: Curva de Carga para Semana Pico – Sistema IEEE-MRTS.

Dois estudos de caso são realizados para o sistema IEEE-MRTS, nos quais se utiliza a lista de contingências apresentada na Tabela 3.1:

- *Caso 1* – resolução do problema de otimização original, i.e. considerando todas as restrições de transmissão;
- *Caso 2* – resolução do problema de otimização reduzido, o que implica na desconsideração de restrições de transmissão inativas.

Na Tabela 3.2 estão apresentados os resultados para os índices $P(S)$, $P(M)$, $P(F)$, $Freq(M)$ e $Dur(M)$. As estimativas obtidas para os outros índices são muito semelhantes. São também apresentados, os erros percentuais cometidos pelo Caso 2 em relação ao Caso 1, o qual foi considerado *exato*. Estes erros aparecem entre parêntesis logo abaixo do correspondente índice.

Tabela 3.1: Lista¹ de Contingências – Sistema IEEE-RTS.

EVENTOS					
Usina 40MW	1	Circ.	24	-	15
Usina152MW	1	Circ.	3	-	24
Usina 40 MW	2	Circ.	10	-	11
Usina 152MW	2	Circ.	14	-	16
Usina	7	Circ.	11	-	13
Usina	13	Circ.	10	-	12
Usina	15	Circ.	9	-	12
Usina	16	Circ.	12	-	23
Usina	18	Circ.	9	-	11
Usina	21	Circ.	11	-	14
Usina	22	Valor de carga da hora seguinte			
Usina 310MW	23				
Usina 700MW	23				

Tabela 3.2: Índices de Confiabilidade Preventiva – Caso 1 e Caso 2.

CASO	P(S)	P(M)	P(F)	Freq(M) (oc./ano)	Dur(M) (horas)
1	0,5882	0,3598	0,0519	392,42	8,01
2	0,5881 (0,02%)	0,3599 (0,03%)	0,0520 (0,15%)	392,22 (0,05%)	8,02 (0,12%)

Para o Caso 1, a simulação Monte Carlo não-sequencial analisou 11.881 estados. A classificação entre estados saudáveis e marginais necessitou de 78.400 análises adicionais. Outras 11.346 análises adicionais foram realizadas para a estimação dos índices Freq(S) e Freq(M). Portanto, o total de análises de adequação foi de 101.627. O tempo de processamento necessário para a convergência dos índices foi de 85,38 minutos.

¹ Lêem-se os termos “circ. $a - b$ ” como circuito da barra “a” para a barra “b” e “Usina c ” como uma unidade geradora para a usina da barra “c”.

Através do Caso 2 é investigado o impacto da não consideração de todas as restrições no problema de otimização. Pode-se constatar pela Tabela 3.2, que as diferenças apresentadas entre os dois casos são muito pequenas e, além disto, estão dentro da margem de incerteza do coeficiente β (5%). O total de análises de adequação realizadas no Caso 2 foi de 101.334, muito próximo se comparado ao Caso 1. Porém o tempo de processamento gasto para atingir a convergência dos índices foi de 32,72 minutos, representando um *speedup* de 2,61 em relação ao Caso 1.

Este sistema reside 59% em estados saudáveis, 36% em estados marginais e 5% em estados de falha. A frequência e a duração média dos estados marginais são, aproximadamente, 392 ocorrências por ano e 8 horas, respectivamente. Portanto, o sistema ingressa em um estado marginal, em média, todo dia, e permanece nesta condição por 8 horas. As informações obtidas através da avaliação da confiabilidade preventiva são extremamente importantes e fornecem aos planejadores, em uma base probabilística, a percepção correta da operação de um sistema. Além disso, é possível dividir os estados marginais em crítico ou não, dependendo do montante de carga cortado durante a análise da lista de contingências. Para os Casos 1 e 2, adotando um corte limite de 200 MW, cerca de 23% dos estados marginais foram classificados como críticos.

O sistema IEEE-MRTS-96

Novamente, a curva de carga adotada é referente à semana pico. Também são realizados dois estudos de caso para o sistema IEEE-MRTS-96:

- Caso 3 – resolução do problema de otimização original;
- Caso 4 – resolução do problema de otimização reduzido.

A Tabela 3.3 apresenta a lista de contingências utilizada nos Casos 3 e 4. Uma ordenação inteligente [R02, LRMB04] foi utilizada para selecionar esta lista.

Tabela 3.3: Lista de Contingências – Sistema IEEE-MRTS-96.

EVENTOS					
Usina 152MW	201	Circ.	203	-	224
Usina 152MW	202	Circ.	209	-	211
Usina	207	Circ.	209	-	212
Valor de carga da hora seguinte		Circ.	210	-	211
		Circ.	210	-	212
		Circ.	214	-	216
		Circ.	215	-	224

Na Tabela 3.4 estão apresentados os resultados para os índices P(S), P(M), P(F), Freq(M) e Dur(M). Como no estudo anterior, as estimativas obtidas para os outros índices também são muito semelhantes. Vale ressaltar que foi utilizada a mesma lista de contingências para os dois casos.

Tabela 3.4: Índices de Confiabilidade Preventiva – Caso 3 e Caso 4.

CASO	P(S)	P(M)	P(F)	Freq(M) (oc./ano)	Dur(M) (horas)
3	0,5823	0,3732	0,0445	344,21	9,4714
4	0,5819 (0,07%)	0,3733 (0,04%)	0,0448 (0,54%)	346,46 (0,65%)	9,4139 (0,61%)

Para o Caso 3, o total de análises de adequação foi de 158.833, requerendo um tempo de processamento para atingir a convergência dos índices de 582,85 minutos. O impacto da adoção da metodologia proposta neste sistema pode ser verificado através do Caso 4. O total de análises de adequação realizadas no Caso 4 foi de 156.900, também muito próximo do valor apresentado no Caso 2. Porém o tempo de processamento para atingir a convergência dos índices foi de 222,43 minutos, obtendo-se um *speedup* de 2,62 em relação ao Caso 2.

Com os resultados apresentados nesta seção, espera-se que o conceito de base reduzida propicie grandes reduções, em relação ao tempo de processamento,

quando aplicado em sistemas de grande porte. Os resultados apresentados nas próximas seções e capítulos utilizarão sempre o conceito de base reduzida na resolução do problema de otimização.

3.4 REDUÇÃO DA REDE DE TRANSMISSÃO

A avaliação da confiabilidade preventiva de sistemas de grande porte requer uma grande quantidade de dados e um elevado esforço computacional. A análise de adequação dos estados operativos, através de algoritmos de otimização, e a obtenção dos índices de confiabilidade, através de modelos probabilísticos, constituem a maior parcela destes dados/cálculos. Para contornar este problema, a rede de transmissão original é representada considerando quatro partes ou áreas, conforme metodologia apresentada em [ML04]. Estas áreas estão descritas a seguir e ilustradas na Figura 3.4.

- *Área de Contingência* – define a primeira parte da rede, a qual adota representação estocástica para os seus equipamentos de geração e transmissão;
- *Área de Otimização* – incluindo a primeira parte da rede, esta área define os elementos que serão representados para a análise de adequação do sistema (estudo de fluxo de potência com adoção de medidas corretivas). Os equipamentos desta rede que não pertencem à área de contingência não poderão falhar. No entanto, os geradores poderão ser redespachados e as cargas poderão ser cortadas, caso seja necessário;
- *Área Externa* – corresponde à terceira parte da rede e representa, através de equivalentes, os equipamentos externos à área de Otimização;
- *Área de Interesse* – delimita a região na qual os índices de confiabilidade serão avaliados. Esta área deve ser envolvida pela área de contingência.

Os índices de desempenho, i.e. índices de confiabilidade convencional e preventiva e custo de produção, podem ser calculados para a área de otimização e para suas subáreas e barras. A definição da área de interesse permite aumentar a precisão dos índices estimados. Esta área corresponde à região do sistema cujos índices de desempenho terão maior relevância para o processo de decisão. Não existe nenhuma regra geral para a definição das áreas do sistema, no entanto, o conhecimento e a experiência de planejadores e operadores podem ter um papel importante [ML04].

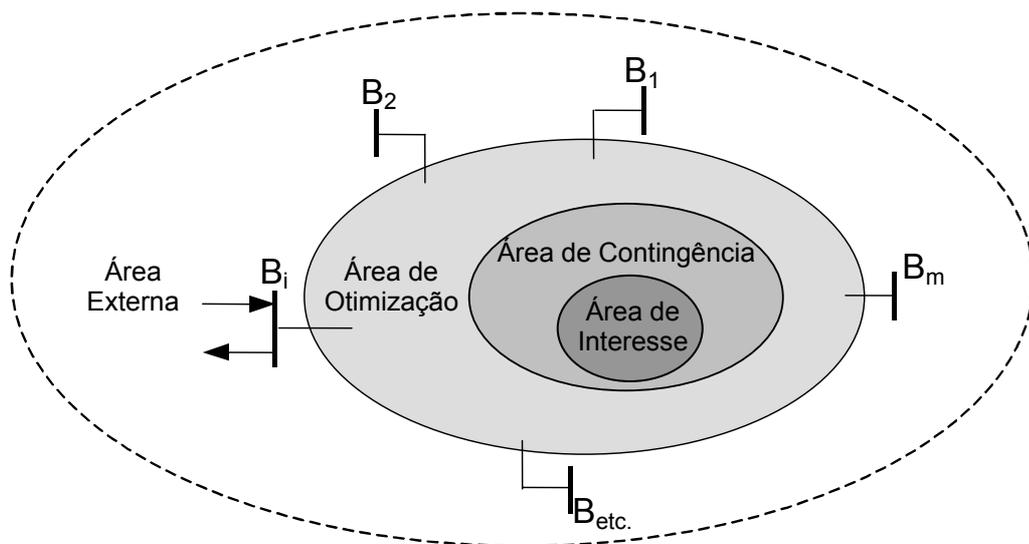


Figura 3.4: Divisão da Rede de Transmissão de um Sistema de Grande Porte.

Uma vez determinadas estas áreas, as reduções que serão aplicadas à representação da rede, os equipamentos que terão representação estocástica e os pontos onde haverá avaliação de índices de confiabilidade preventiva são definidos.

A técnica de *Equivalent Ward* [W49, MDGS79] é utilizada para a obtenção da área externa, complementar da área de otimização. Como a representação linear para as equações de fluxo de potência é utilizada neste trabalho, o equivalente Ward produz resultados precisos. O modelo equivalente é obtido por meio dos seguintes passos:

- i) Um *Caso Base* para o fluxo de potência é obtido por um processo de otimização das fontes de geração do sistema completo, i.e. sem redução. Este processo de otimização tem como objetivo atender o pico anual de demanda sem produzir nenhum corte de carga;
- ii) A rede equivalente, reduzida às barras de fronteira, é obtida pelo uso de equações de *Ward*;

- iii) As cargas equivalentes, localizadas nas barras de fronteira, são obtidas através das correspondentes equações de *Ward*, aplicadas à carga do *Caso Base*, fornecida pelo usuário;
- iv) Para a obtenção das gerações equivalentes das barras de fronteira, as mesmas equações do passo "iii" são aplicadas ao ponto de operação definido, no passo "i", para o *Caso Base*;
- v) Um *Caso Máximo* para o fluxo de potência é obtido por um outro processo de otimização, o qual maximiza a potência ativa exportada da área externa para a área de otimização [ML04]. Assim como no *Caso Base*, este processo é aplicado ao sistema completo;
- vi) Novas gerações equivalentes são obtidas através do emprego das correspondentes equações de *Ward* ao ponto de operação definido pelo *Caso Máximo*. Os valores obtidos determinam a quantidade máxima de potência que pode ser gerada em cada barra de fronteira.
- vii) Se necessário, poderão ser realizados alguns ajustes no montante máximo de potência gerada nas barras de fronteira. Tais ajustes têm como objetivo principal a reprodução do impacto das falhas de equipamentos externos na área de interesse [LRM06].

As barras de fronteira e suas conexões são incorporadas ao processo de simulação Monte Carlo, o que permite reproduzir as respostas da área externa aos impactos das saídas, forçadas e programadas, de equipamentos da área de contingência. É possível observar que, a geração nas barras de fronteira poderão variar de acordo com os seus limites obtidos para auxiliar o processo de otimização. Entretanto, nas barras de fronteira, não serão considerados custos de produção para as unidades geradoras, bem como não serão considerados custos de interrupção para as cargas equivalentes. Também, será assumida a capacidade ilimitada para os circuitos equivalentes.

Vale ressaltar que, com o objetivo de obter resultados mais precisos e minimizar o esforço computacional, é aconselhável utilizar uma dimensão para a área de interesse bem menor que aquela apresentada pelo sistema original. Já a área de contingência, maior que a área de interesse, pode ter, a princípio a mesma dimensão da área de otimização. Estas dimensões devem ser definidas de tal forma que a área de interesse fique eletricamente distante da área externa.

A metodologia apresentada permite a aplicação de políticas de corte (como parte das ações remediadoras) nas cargas equivalentes das barras de fronteira. Isto significa, a princípio, que houve restrições de exportação de energia da área de otimização para a área externa, em determinadas emergências. Porém, os índices por ponto de carga das barras de fronteira não serão considerados nesta tese.

Observe que a divisão adequada do sistema original (entre as áreas externa, otimização, contingência e interesse) é fundamental para o sucesso da metodologia. Alguns conceitos de trabalhos anteriores [KB88, FSM95, MA99, AE00, WBG02, AHLM03, WB03] são utilizados pela metodologia apresentada, porém a representação equivalente fica restrita à rede elétrica de parte do sistema. Portanto, não são necessários equivalentes para a representação estocástica dos equipamentos. Além disso, a metodologia apresentada é simples e de fácil implementação em qualquer algoritmo existente para a avaliação da confiabilidade composta e de índices de bem-estar.

O desempenho deste modelo de equivalente para a rede de transmissão será verificado pela análise dos índices de confiabilidade, apresentada na próxima seção.

3.5 APLICAÇÕES

São realizados vários estudos de caso utilizando os sistemas IEEE MRTS-96 e SSB. A análise de adequação de cada estado amostrado é realizada através de um fluxo de potência DC e de um algoritmo de otimização das medidas corretivas baseado em programação linear, cujo objetivo é minimizar o corte de carga. É importante destacar que um modelo de fluxo AC poderia ser empregado. No entanto, o emprego deste modelo elevaria o custo computacional da análise de adequação. Em todos os testes realizados, um coeficiente de incerteza relativa $\beta \leq 5\%$, dado pela Equação (2.5), é utilizado para medir a convergência de índices de confiabilidade convencional e de bem-estar.

3.5.1 O Sistema IEEE-MRTS-96

Como já foi mencionado, o sistema IEEE-MRTS-96 resulta de modificações feitas no IEEE-RTS-96. No entanto, o sistema IEEE-RTS-96 foi construído através da interligação de três sistemas IEEE-RTS, os quais foram denominados de áreas A, B e C. As oito áreas consideradas para a aplicação dos conceitos apresentados na seção anterior são descritas a seguir:

- *Área 11* – é composta pelas barras de 138 kV (exceto barra 107) da área A do sistema original IEEE-RTS-96;
- *Área 12* – é formada pelas barras de 230 kV da área A;
- *Área 13* – corresponde à barra 107 (área A);
- *Área 21* – é composta pelas barras 201, 202, 204-208 (área B – 138 kV);
- *Área 22* – é formada pelas barras de 230 kV da área B;
- *Área 23* – é composta pelas barras 203, 209, 210 (área B – 138 kV);
- *Área 31* – é formada pelas barras de 138 kV da área C;
- *Área 32* – é formada pelas barras de 230 kV da área C.

- **Caso 5** – análise de adequação submetida ao sistema completo e representação estocástica de todos os equipamentos. Isto implica em: área de contingência = área de otimização = sistema completo. Este caso considera o sistema completo e, portanto, fornece a referência para todos os resultados;
- **Caso 6** – análise de adequação submetida ao sistema reduzido composto pelas áreas 12, 13, 21, 22, 23 e 32. Isto implica em: área de contingência = área de otimização < sistema completo;
- **Caso 7** – análise de adequação submetida ao sistema reduzido composto pelas áreas 13, 21, 22 e 23. Isto implica em: área de contingência = área de otimização << sistema completo;
- **Caso 8** – Este é similar ao caso 7, mas são realizados alguns ajustes na potência máxima que pode ser gerada nas barras de fronteira, para reproduzir o impacto da falha de algum equipamento externo na área de interesse.

Tendo em vista determinar os índices de bem-estar, os casos 5 até 8 utilizam o mesmo critério determinístico, o qual consiste da lista de eventos (contingências) apresentadas na Tabela 3.3.

As Tabelas 3.5 e 3.6 mostram os resultados, considerando os quatro casos, para todos os índices de confiabilidade convencional e preventiva, calculados para a área de interesse. A curva de carga original com 8736 horas é utilizada.

Tabela 3.5: Índices de Confiabilidade – Sistema IEEE-MRTS-96, Curva de Carga Original.

CASO	LOLP	LOLF (oc./ano)	EENS (MWh)	LOLD (horas)
5	0,00110	2,023	280,8	4,73
6	0,00108 (1,81%)	2,031 (0,41%)	282,6 (0,63%)	4,63 (2,19%)
7	0,00105 (3,91%)	1,913 (5,43%)	285,3 (1,59%)	4,81 (1,60%)
8	0,00108 (1,10%)	2,080 (2,81%)	290,9 (3,60%)	4,55 (3,81%)

Tabela 3.6: Índices de Confiabilidade Preventiva – Sistema IEEE-MRTS-96, Curva de Carga Original.

CASO	P(S)	P(M)	Freq(S) (oc./ano)	Freq(M) (oc./ano)	Dur(S) (horas)	Dur(M) (horas)
5	0,9688	0,0301	50,17	50,68	168,70	5,19
6	0,9690 (0,02%)	0,0299 (0,60%)	50,60 (0,86%)	51,40 (1,41%)	167,32 (0,82%)	5,08 (1,97%)
7	0,9689 (0,01%)	0,0300 (0,19%)	49,21 (1,92%)	49,20 (2,93%)	172,01 (1,96%)	5,33 (2,82%)
8	0,9688 (0,00%)	0,0301 (0,02%)	49,26 (1,82%)	49,63 (2,08%)	171,82 (1,85%)	5,30 (2,13%)

Como pode ser visto das Tabelas 3.5 e 3.6, todos os resultados obtidos com o equivalente proposto (Casos 6, 7 e 8) são muito próximos ao obtido para o sistema original. Como exemplo, considerando o sistema completo, são esperadas 2,02 falhas por ano, enquanto que as representações reduzidas indicarão: 2,03 falhas por ano no Caso 6; 1,91 falhas por ano no Caso 7 e 2,08 falhas por ano no Caso 8.

Em todos os quatro casos, mais de 2 milhões de estados foram amostrados para o coeficiente β atingir 5%. Os tempos de processamento, em minutos, para os Casos 5, 6, 7 e 8 foram, respectivamente, 231,87; 131,62; 52,60 e 50,77. Pode-se perceber que o *speedup* obtido para os Casos 7 e 8 foi cerca de 4,5.

A Tabela 3.7 mostra três índices de confiabilidade convencional e três índices de bem-estar, para as barras mais relevantes da área de interesse, obtidos através dos Casos 5 e 8. Considerando que a incerteza relativa dos índices por barra (β variando entre 3 a 18%) é, em geral, maior que a apresentada pelos índices globais do sistema, pode-se afirmar que o desempenho do equivalente proposto é muito bom.

Tabela 3.7: Índices por Barra Caso 5/Caso 8 – Sistema IEEE-MRTS-96.

Barra	LOLP	LOLF (oc./ano)	EENS (MWh)	P(S)	P(M)	Freq(M) (oc./ano)
205	0,00010	0,2021	16,69	0,9760	0,02393	41,55
	0,00009	0,1910	13,63	0,9753	0,02465	40,27
206	0,00091	1,6450	216,0	0,9934	0,00566	6,637
	0,00091	1,6969	231,2	0,9941	0,00498	5,687
207	0,00013	0,2721	25,60	0,9960	0,00390	3,781
	0,00012	0,2780	25,77	0,9962	0,00371	5,580
208	0,00013	0,2874	19,04	0,9947	0,00513	3,902
	0,00012	0,3048	18,26	0,9951	0,00480	5,580

Os ajustes realizados nas potências máximas das barras de fronteira, para reproduzir o impacto da falha de algum equipamento da área externa na área de interesse, foi, em média, uma redução de 4% nas potências máximas de geração. Existem duas maneiras de se fazer estes ajustes. A primeira é executar um conjunto de simulações Monte Carlo, testando o impacto de diferentes reduções nas gerações das barras de fronteira nos índices de confiabilidade da área de interesse. A idéia é minimizar os erros considerando o caso referência (Caso 5). A outra possibilidade é especificar as barras de geração mais importantes da área externa e avaliar o impacto das falhas das unidades de geração destas barras de fronteira. Assim, é possível criar uma tabela de probabilidade e frequência da capacidade indisponível que será utilizada durante o processo de simulação Monte Carlo para a rede de transmissão reduzida. Em relação ao Caso 8, foi utilizada a primeira maneira para obter o ajuste de 4%.

Com o intuito de testar o mesmo sistema IEEE-MRTS-96 em uma condição mais estressante, o modelo de carga cronológico da semana pico, ilustrado pela Figura 3.3, é utilizado. Nas Tabelas 3.8 e 3.9 são apresentados os resultados obtidos considerando os Casos 5 e 8. Obviamente o sistema se torna menos confiável. Por exemplo, a frequência de falha aumenta de 2,02 ocorrências por ano para 22,8 ocorrências por ano no Caso 5 ou 22,3 ocorrências por ano no Caso 8. A frequência

de estados marginais aumenta de 50,68 ocorrências por ano para 384,8 ocorrências por ano no Caso 5 ou 374,4 ocorrências por ano no Caso 8.

Tabela 3.8: Índices de Confiabilidade – Sistema IEEE-MRTS-96, Curva de Carga da Semana Pico.

CASO	LOLP	LOLF (oc./ano)	EENS (MWh)	LOLD (horas)
5	0,0103	22,81	2104,07	3,94
8	0,0095 (7,97%)	22,31 (2,18%)	2061,29 (2,03%)	3,71 (5,92%)

Tabela 3.9: Índices de Confiabilidade Preventiva – Sistema IEEE-MRTS-96, Curva de Carga da Semana Pico.

CASO	P(S)	P(M)	Freq(S) (oc./ano)	Freq(M) (oc./ano)	Dur(S) (horas)	Dur(M) (horas)
5	0,6471	0,3426	362,77	384,79	15,56	7,77
8	0,6458 (0,21%)	0,3448 (0,64%)	360,07 (0,75%)	374,35 (2,71%)	15,68 (0,77%)	8,04 (3,45%)

É possível verificar que, o desempenho do equivalente proposto sob estas condições estressantes e, também, sob a variação horária da carga ainda é muito bom.

Enfim, este sistema ainda é pequeno para medir o benefício real de equivalentes. Para o Caso 8, a redução não é tão significativa e a área de interesse é eletricamente próxima da área externa. Ainda assim, o equivalente proposto produziu bons resultados, apresentado um *speedup* significativo, chegando até a 3,6 vezes (Caso 5 com 137 minutos e Caso 8 com 38 minutos). Os ajustes nas barras de fronteira serão mínimos para sistemas práticos de grande porte, desde que a especificação das áreas seja simples e efetiva.

3.5.2 O Sistema Sul-Sudeste Brasileiro (SSB)

As principais características do sistema SSB foram apresentadas na Seção 3.2. A seguir são descritos os dois casos considerados para este sistema:

- *Caso 9* – análise de adequação submetida ao sistema completo e representação estocástica de todos os equipamentos. Isto implica em: área de contingência = área de otimização = sistema completo. Este é o caso referência;
- *Caso 10* – análise de adequação submetida ao sistema reduzido e as áreas de contingência e de otimização serão restritas à área Minas. Isto implica em: áreas de contingência e de otimização = área Minas (com 79 barras, inclusive barras de fronteira) << sistema completo (413 barras).

Uma subárea do estado de Minas Gerais é utilizada como área de interesse. Esta subárea possui 15 barras de carga, de um total de 19. Com o objetivo de estimar os índices de bem-estar, os Casos 9 e 10 utilizam o mesmo critério determinístico, o qual consiste de uma lista de eventos pré-especificados [LRMB04]. Uma curva de carga cronológica com 8736 horas é convertida em um modelo markoviano não-agregado (Figura 2.2), para ser utilizado na simulação Monte Carlo não-sequencial.

Os índices de confiabilidade convencional estão apresentados na Tabela 3.10. Já os índices de bem-estar estão apresentados na Tabela 3.11. Não foram necessários ajustes nas gerações máximas das barras de fronteira. Os erros introduzidos pelos equivalentes são muito pequenos, isto é, compatíveis com a tolerância de 5% utilizada para interromper o processo de simulação Monte Carlo.

Tabela 3.10: Índices de Confiabilidade – Sistema SSB.

CASO	LOLP	LOLF (oc./ano)	EENS (MWh)	LOLD (horas)
9	0,0105	11,36	1319	8,07
10	0,0104 (0,31%)	10,91 (3,98%)	1307 (0,84%)	8,35 (3,49%)

Tabela 3.11: Índices de Confiabilidade Preventiva – Sistema SSB.

CASO	P(S)	P(M)	Freq(S) (oc./ano)	Freq(M) (oc./ano)	Dur(S) (horas)	Dur(M) (horas)
9	0,5110	0,4786	387,68	387,39	11,53	10,81
10	0,5017 (1,81%)	0,4878 (1,94%)	393,93 (1,61%)	391,75 (1,13%)	11,11 (3,67%)	10,86 (0,48%)

Para o Caso 9, foram analisados 601.154 estados, acarretando um tempo de processamento de 490,1 minutos. Já para o Caso 10, foram analisados 419.719 estados em 13,8 minutos, o que representa um *speedup* de 35,5.

A precisão dos índices obtidos deve ser considerada muito boa, pois as diferenças apresentadas entre os Casos 9 e 10 (valores entre parêntesis logo abaixo ao correspondente índice) ficaram dentro da margem de incerteza (5%).

3.6 CONCLUSÕES

Neste capítulo, foram apresentadas algumas técnicas com o intuito de reduzir o esforço computacional demandado durante a avaliação da confiabilidade preventiva de sistemas elétricos de potência.

A resolução do problema através do fluxo de potência DC, baseado em programação linear via algoritmo Primal-Dual de Pontos Interiores, tem se mostrado eficiente, quando aplicada a sistemas de grande porte. Resultados obtidos confirmaram que, ao utilizar esta técnica, a análise de desempenho dos estados operativos se torna mais robusta e mais rápida.

Tendo em vista a redução do número de restrições, o fluxo de potência DC foi resolvido em duas etapas: na primeira, as capacidades de transmissão dos circuitos foram consideradas ilimitadas (isto é, sem restrições de transmissão); e, na segunda, foram consideradas somente as restrições de capacidade de transmissão associadas aos circuitos que apresentarem fluxos acima de um percentual de seus respectivos limites (e.g. 75% de suas capacidades nominais). Com este procedimento, a dimensão da matriz de coeficientes do problema de otimização, apresentada pela Equação (3.11), é sensivelmente reduzida.

A redução probabilística da rede de transmissão consiste em dividir o sistema em quatro áreas: interesse, contingência, otimização e externa. Sua aplicação em algoritmos de avaliação da confiabilidade preventiva é bastante atrativa, não só pela redução do esforço computacional obtido, como também pela manutenção da precisão dos índices.

A partir dos resultados obtidos, verifica-se que a estratégia de redução da rede de transmissão produz ganhos expressivos (e.g. *speedups* de até 35 vezes), em termos de tempo computacional. Além disso, não houveram perdas de precisão significativas para as estimativas dos índices, tornando ainda mais viável a aplicação

da confiabilidade preventiva em estudos de planejamento de sistemas de grande porte.

No próximo Capítulo, será apresentada outra técnica para aumentar a eficiência computacional do algoritmo utilizado para avaliar a confiabilidade convencional e preventiva.

CAPÍTULO 4

REDES NEURAIS NA AVALIAÇÃO DA CONFIABILIDADE PREVENTIVA

4.1 INTRODUÇÃO

A aplicação de metodologias probabilísticas para avaliar os índices de confiabilidade torna imprescindível o conhecimento dos estados operativos do sistema. Normalmente, a análise de fluxo de potência é utilizada para definir se este estado é saudável, marginal ou de falha. É possível constatar da Seção 3.3 que, o custo computacional para tal análise depende das características do sistema (e.g. dimensão do sistema). Portanto, a avaliação de muitos estados operativos, principalmente em estudos de confiabilidade convencional preventiva, pode se tornar cara, ou até mesmo inviável.

Muitos trabalhos têm sido propostos para reduzir a carga computacional demandada na análise de adequação dos estados. Em [SMP96] foi proposto um método, denominado *Fuzzy Optimal Power Flow*, para construir uma função que mapeie a energia não suprida. Em [SBZ05] um método, denominado *Fuzzy Self Organizing Map* (FSOM), utiliza redes neurais artificiais para filtrar estados “inválidos”. Estes estados tendem a apresentar instabilidades dinâmicas. Recentemente, foi proposta uma metodologia para classificar estados operativos do sistema, em de falha ou de não-falha (sucesso), que utiliza o SOM (*Self Organizing Map*) [LSP00].

Uma característica comum entre os métodos citados no parágrafo anterior é o fato da análise de adequação dos estados operativos do sistema ser obtida diretamente

através das técnicas utilizadas. O uso de tais técnicas pode até produzir bons resultados para índices globais. Porém, ao olharmos características pontuais (e.g. áreas e/ou barras do sistema), tais métodos tornam-se limitados ou até inviáveis, visto de uma perspectiva computacional. Por exemplo, para estimar índices por área/barra, seria necessário treinar uma rede para cada área/barra ou uma rede com múltiplas saídas. Outra barreira a ser transposta é a obtenção correta do montante de energia não suprida. Estes métodos são, geralmente, indicados para a classificação de estados do sistema. Portanto, o índice EENS (*Expected Energy Not Supplied*) e os índices de confiabilidade por barra ainda deverão ser estimados através do modo convencional, i.e. através de fluxo de potência com otimização de medidas corretivas.

A utilização de computação paralela e distribuída [BFMM01] é outra alternativa para reduzir o tempo computacional gasto na avaliação da confiabilidade de sistemas compostos. No entanto o esforço computacional ainda será o mesmo, uma vez que o tempo de avaliação reduz devido à divisão das tarefas executadas na simulação Monte Carlo por vários computadores.

Neste capítulo é apresentada uma metodologia para avaliar índices de confiabilidade composta convencional e preventiva. Baseado no modelo de carga da Seção 2.2 e no processo *transição de estado um passo à frente*, o método utiliza a Simulação Monte Carlo com *memória*. Para tal, uma pré-classificação dos estados operativos é realizada através de técnicas de redes neurais artificiais, onde os estados analisados durante o início do processo de simulação são considerados como dados de entrada para o conjunto de treinamento e validação. Com a adoção deste procedimento, um grande número de estados é classificado por uma simples avaliação polinomial [F84, I71], propiciando reduções significativas no custo computacional exigido.

Uma rede neural artificial baseada no método de manipulação de dados (*Group Method of Data Handling* – GMDH) desempenha uma análise de reconhecimento de padrões para identificar se um estado é de perda de carga (falha) ou não (sucesso). Em relação à confiabilidade preventiva, a análise desempenhada por essa rede

indicará se o estado de sucesso é saudável ou marginal. A principal razão para a escolha desta rede é que, toda vez que as classes associadas às amostras para treinamento estão disponíveis, modelos baseados em aprendizado supervisionado propiciam melhores desempenhos, quando submetidos a novos casos, àqueles que utilizam aprendizado não supervisionado. Além disso, a rede neural artificial baseada no GMDH leva a arquiteturas simples e a processos de treinamento muito rápidos quando comparados a outros métodos, como por exemplo o SOM (*Self Organizing Map*) [SLA96a, SLA96b, SLA97].

O modelo de rede neural citado no parágrafo anterior tem sido aplicado em vários problemas de sistemas elétricos de potência. Como exemplo, cita-se a depuração de dados utilizados na supervisão em tempo real [S96] e a modelagem dinâmica de cargas elétricas [F98].

4.2 REDES NEURAIS PLÁSTICAS (GMDH)

O GMDH (*Group Method Data Handling*) pode ser visto como uma rede neural com treinamento supervisionado, que realiza uma aproximação polinomial entre os dados de entrada e a saída desejada. Nesta rede, a saída de cada neurônio pode ser expressa como uma função polinomial de grau dois de suas entradas. Isto está ilustrado na Figura 4.1, onde x_i e x_j são suas entradas; A, B, C, D, E e F são os coeficientes do polinômio, que equivalem aos pesos das conexões de uma outra rede neural cuja função de ativação é o combinador linear; e y é a saída do neurônio, que é dada pela Equação (4.1).

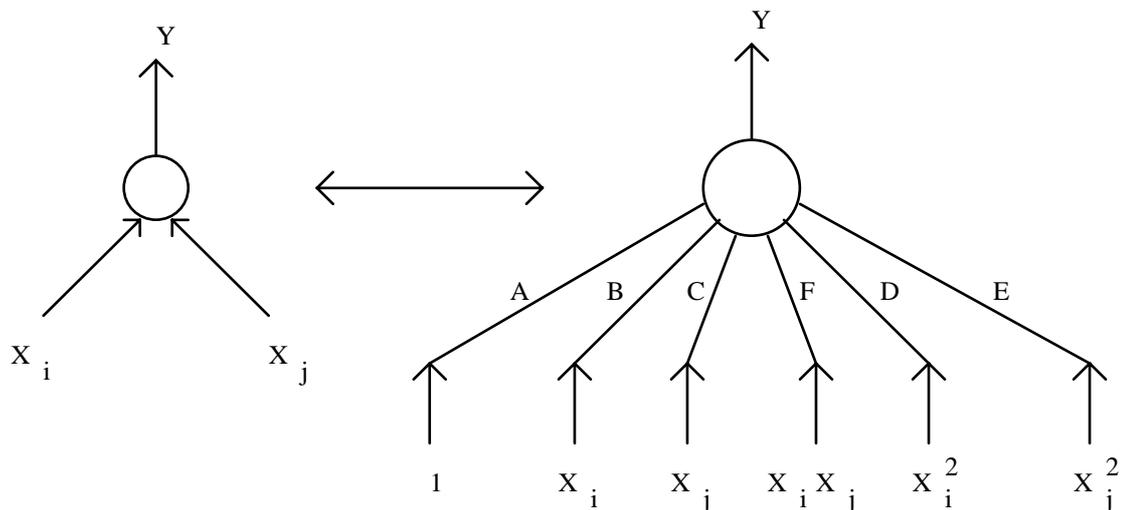


Figura 4.1: Modelo do Neurônio.

$$y = A + Bx_i + Cx_j + Dx_i^2 + Ex_j^2 + Fx_i x_j \quad (4.1)$$

Durante a fase de treinamento, as camadas da rede são construídas uma a uma, a partir da camada de entrada. Em cada nova camada, os neurônios são gerados através da combinação das variáveis de entrada duas a duas, conforme indica o modelo representado na Figura 4.1. É importante ressaltar que na construção da primeira camada, os neurônios são gerados pela combinação das variáveis originais

(entradas), enquanto na construção das demais camadas as saídas dos neurônios da última camada gerada são tomadas como entradas a serem combinadas para a geração dos novos neurônios.

A Figura 4.2 mostra um exemplo de uma rede polinomial com 7 entradas. Pode-se verificar, nesta figura, que o algoritmo de treinamento selecionou apenas 5 entradas para a rede final. Esta capacidade de seleção automática das entradas relevantes é uma característica importante, a qual está presente na rede GMDH. Portanto, o risco de se superdimensionar a rede e, conseqüentemente, perder a capacidade de generalização é minimizado.

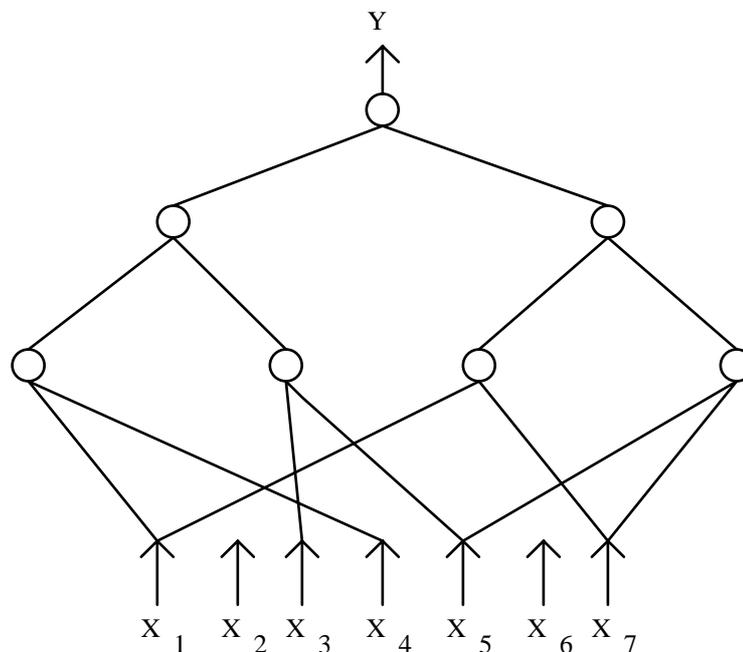


Figura 4.2: Exemplo de uma Rede Polinomial.

O algoritmo detalhado para o treinamento da rede neural baseada no GMDH pode ser encontrado no Apêndice C.

4.3 REDE GMDH PROPOSTA – CONFIABILIDADE CONVENCIONAL

Nesta seção é apresentado como a técnica de reconhecimento de padrões pode ser incluída na avaliação da confiabilidade convencional. Inicialmente, são citadas as variáveis de entrada, i.e. variáveis representativas para a análise de adequação de sistemas de potência, para o treinamento e validação da rede. Em seguida, é mostrado como os dados de entrada são coletados. Finalmente, é realizada uma análise do desempenho apresentado pelas redes obtidas. Estudos de caso aplicados aos sistemas apresentados na Seção 3.2 são realizados para a verificação dos conceitos propostos.

4.3.1 Variáveis de Entrada

A capacidade de a rede neural distinguir os estados de sucesso dos estados de falha se baseia no fato de que, para cada grupo de estados, o conjunto de variáveis do problema apresenta um padrão característico bem definido. A rede deve, durante a fase de treinamento, capturar estes padrões de modo a efetuar classificações corretas quando aplicada ao sistema (ou aos novos estados amostrados).

Existem diversas combinações de variáveis que podem ser consideradas como entrada da rede neural para o problema da classificação dos estados. Como exemplo em sistemas elétricos de potência, podemos citar: a carga do sistema, a reserva de geração disponível, as injeções de potência nas barras, os fluxos de potência nos circuitos, as indisponibilidades de equipamentos de geração e de transmissão etc. Nesta tese, são adotadas as seguintes variáveis de entrada:

- Reserva de geração por área; e,
- Capacidade de geração indisponível por área.

As variáveis de entrada adotadas para treinamento e validação da rede, citadas no parágrafo anterior, não são capazes de fornecer informações sobre a configuração da rede de transmissão. Para adicionar tais informações, a capacidade indisponível de transmissão do sistema (em MW) também será incluída no conjunto de variáveis de entrada da rede. A adoção desta variável pode parecer simplista, uma vez que contingências de transmissão de segunda ordem ou superior tendem a causar impactos mais severos ao sistema. No entanto, para evitar este problema e, também, pelo fato de que, normalmente, as linhas de transmissão possuem baixas taxas de falha, a rede neural treinada será utilizada somente nos estados em que ocorrer no máximo uma contingência de transmissão. Para os estados com contingências de transmissão duplas ou superiores, a análise de adequação será realizada pelo algoritmo de fluxo de potência.

4.3.2 Dados de Entrada

Os dados para treinamento e validação da rede são obtidos a partir dos estados iniciais amostrados pela simulação Monte Carlo não-sequencial. O tamanho da amostra de dados pode ser determinado pela experiência (i.e. definir um número fixo de amostras), pelo critério de regularidade [I71, F84, SLA96, SLA97a, SLA97b], ou pela convergência do coeficiente de variação β , dado pela Equação (2.5). Neste trabalho foi utilizado um coeficiente de variação $\beta = 20\%$ para definir o conjunto de dados.

Outro aspecto importante é que a razão entre o número de amostras de estados de falha e o de estados de sucesso tende ser proporcional à razão entre a probabilidade de falha e a de sucesso. Desta forma, em sistemas com baixas probabilidades de falha, a amostra de dados deverá possuir um número de casos de sucesso muito superior ao número de casos de falha. Isto pode dificultar a captura correta dos padrões do sistema pela rede, principalmente aqueles relacionados a estados de falha. Com o intuito de se obter uma amostra mais “balanceada”, adotou-se, nesta tese, o critério de recolher dois casos de sucesso para cada caso de falha.

Como exemplo, quando β atingiu o valor de 20% durante a avaliação da confiabilidade do sistema IEEE-RTS, foram obtidos dados de 396 estados operativos, sendo 264 amostras de sucesso e 132 de falha. Nestes dados, estão presentes as informações relacionadas à carga, à reserva de geração, às disponibilidades dos equipamentos (geração e transmissão) e à classificação dos estados (sucesso ou falha). Tais dados foram utilizados como entrada para o treinamento e validação de uma rede neural artificial, denominada RN_c , para a avaliação da confiabilidade convencional. Os valores numéricos 10 e 20 foram adotados para representar as saídas desejadas dos estados de falha e sucesso, respectivamente.

Vale ressaltar que, pelo fato do sistema IEEE-RTS possuir duas áreas (uma de geração e outra de carga), o número de variáveis de entrada para a rede foi igual a 5 (i.e. capacidade indisponível de geração por área, reserva de geração por área e capacidade indisponível de transmissão).

4.3.3 Análise da rede RN_c

A rede RN_c treinada e validada pelos dados da seção anterior possui apenas uma camada. Portanto, das 5 variáveis fornecidas para o treinamento, somente duas foram consideradas relevantes (e.g. capacidade indisponível e reserva de geração da área 2). A visualização dos dados de entrada/saída da rede RN_c é ilustrada nas Figuras 4.3, 4.4 e 4.5. Na Figura 4.3, foi assumido que os estados de sucesso (caractere “x” em azul, sendo atribuído o valor 20 durante a fase de treinamento) são identificados quando as classificações obtidas pela rede forem maiores que 18. O status dos estados restantes, i.e. com classificação inferior a 18, será definido pela análise de adequação convencional (e.g. fluxo de potência). Desta forma, será possível determinar não só se o estado é de falha, mas também o montante do corte de carga em cada barra. O caractere “+” na cor vermelha representa os estados de falha (sendo atribuído o valor 10 durante a fase de treinamento) e o caractere “•” na cor preta representa os estados de sucesso não classificados pela rede. Já na Figura 4.4, os estados de sucesso são identificados quando as classificações apresentarem valores acima de 13. Para os estados restantes, (caracteres “+” e “•”),

é necessária a análise de adequação convencional. Finalmente, na Figura 4.5 os estados de sucesso são identificados quando as classificações apresentarem valores acima de 12. Vale ressaltar que, ocorreram dois erros de classificação neste caso, representados pelo caractere “o”.

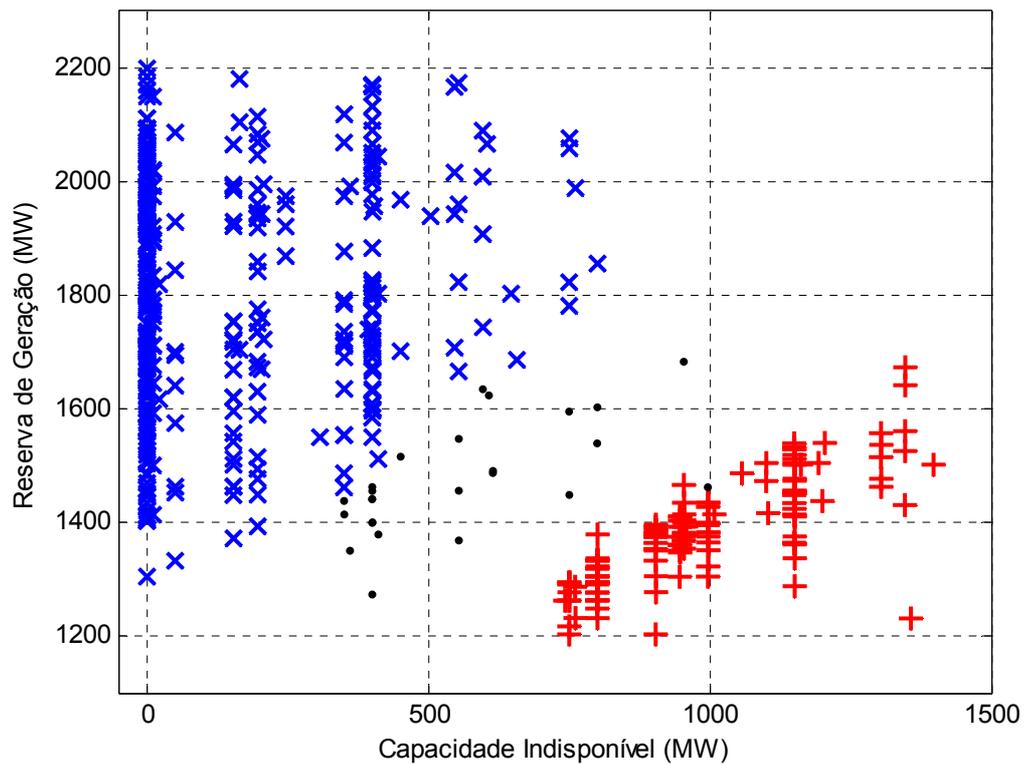


Figura 4.3: Capacidade Indisponível × Reserva de Geração – Área 2, Limiar 18.

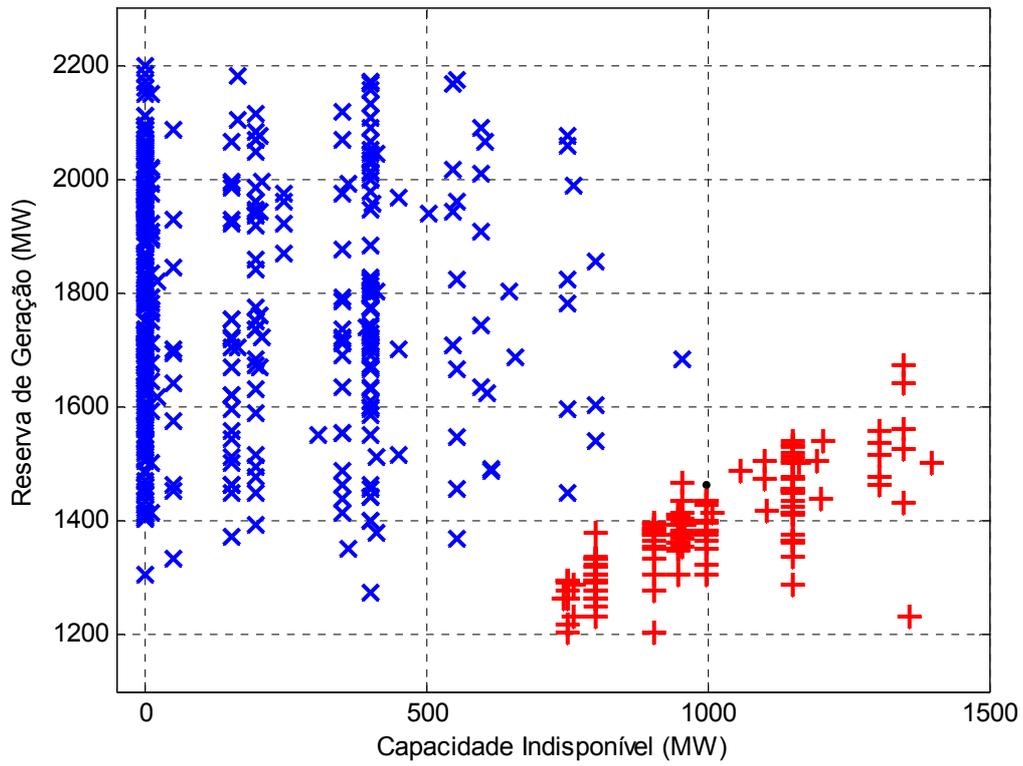


Figura 4.4: Capacidade Indisponível × Reserva de Geração – Área 2, Limiar 13.

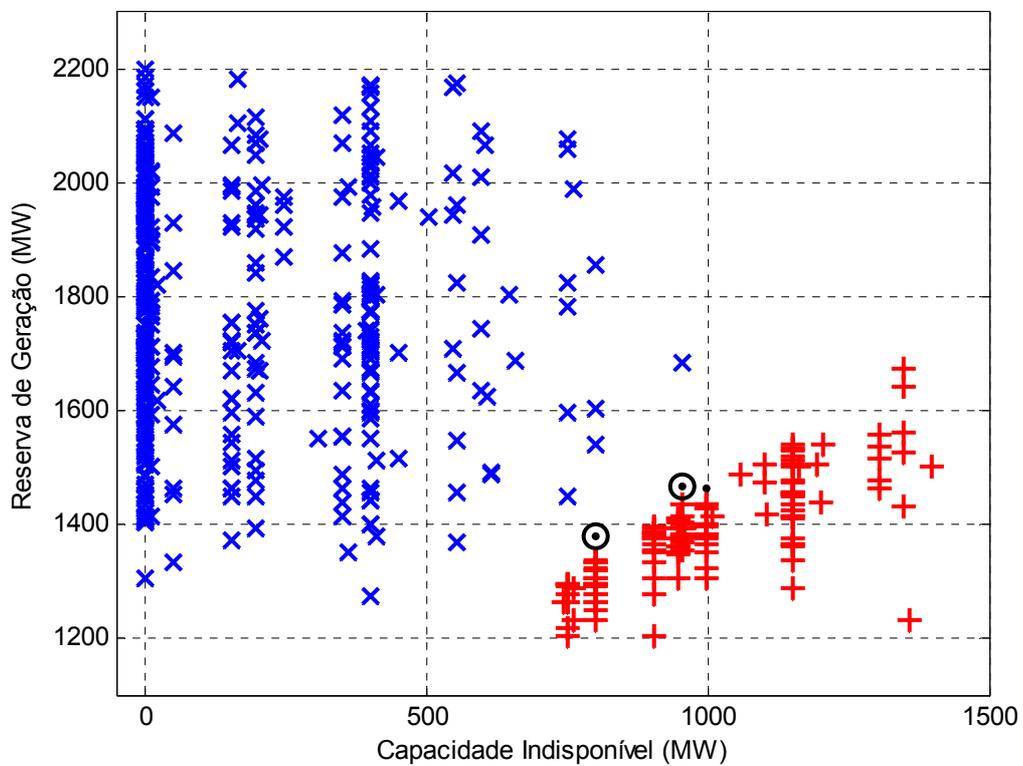


Figura 4.5: Capacidade Indisponível × Reserva de Geração – Área 2, Limiar 12.

As Tabelas 4.1, 4.2 e 4.3 apresentam o desempenho da rede RN_c nos conjuntos de treinamento e teste, considerando os limiares 18, 13 e 12, respectivamente. O tempo necessário para treinamento e validação da rede foi inferior a 1 segundo.

Tabela 4.1: Desempenho da Rede RN_c com Limiar 18 – Sistema IEEE-RTS.

	TREINAMENTO	TESTE	TOTAL
Número de casos	198	198	396
Classificações corretas	126 (132)	118 (132)	244 (264)
Classificações erradas	0	0	0
Casos não-classificados	72 (66)	80 (66)	152 (132)
Taxa de erro	0,00%	0,00%	0,00%

Tabela 4.2: Desempenho da Rede RN_c com Limiar 13 – Sistema IEEE-RTS.

	TREINAMENTO	TESTE	TOTAL
Número de casos	198	198	396
Classificações corretas	132 (132)	131 (132)	263 (264)
Classificações erradas	0	0	0
Casos não-classificados	66 (66)	67 (66)	133 (132)
Taxa de erro	0,00%	0,00%	0,00%

Tabela 4.3: Desempenho da Rede RN_c com Limiar 12 – Sistema IEEE-RTS.

	TREINAMENTO	TESTE	TOTAL
Número de casos	198	198	396
Classificações corretas	132 (132)	131 (132)	263 (264)
Classificações erradas	1	1	2
Casos não-classificados	65 (66)	66 (66)	131 (132)
Taxa de erro	1,51%	1,51%	1,51%

Os máximos de classificações corretas que a rede RN_c pode atingir, independentemente do limiar adotado, são 132, tanto para o conjunto de treinamento quanto para o conjunto de teste, e 264 para o conjunto total. As classificações corretas estão relacionadas ao número de amostras de estados de

sucesso, presente nos dados. Por outro lado, os mínimos de estados não classificados são 66 nos conjuntos de treinamento e de teste, e 132 no conjunto total. Os estados não-classificados correspondem ao número de estados de falha, presente nos dados. Os valores correspondentes aos máximos de classificações corretas e aos mínimos de estados não classificados estão entre parêntesis nas Tabelas 4.1 a 4.3. A linha “Taxa de erro” indica o erro percentual de classificações dos estados, que é dado pela razão entre o número de classificações erradas e o número de amostras de estados de falha, presente no conjunto de dados. Vale ressaltar que a rede RN_c só comete erro se um estado de falha for classificado como sucesso. Se a rede classificar equivocadamente um estado de sucesso como sendo de falha, este erro será corrigido ao realizar a análise de adequação através do fluxo de potência com otimização das medidas corretivas.

A partir das Tabelas 4.1, 4.2 e 4.3, note que, com a metodologia proposta, são realizadas 152, 133 e 131 análises de fluxo de potência (i.e. estados não classificados) para os limiares 18, 13 e 12, respectivamente. Sem o emprego da rede RN_c , seriam necessárias 396 análises de fluxo de potência. Desta forma, pode-se concluir que o objetivo da utilização da rede foi alcançado, e, em uma análise simples com os limiares 13 e 12, cerca de 99,6% dos estados de sucesso (i.e. 263/264) seriam identificados pela rede RN_c . Portanto, das análises de fluxo de potência com otimização das medidas corretivas, normalmente aplicadas aos estados de sucesso, este seria o valor percentual evitado ao se empregar uma avaliação da confiabilidade com a metodologia proposta.

Observe também que, ao reduzir o limiar, o número de estados de sucesso identificado pela rede RN_c tende a aumentar. Porém, deve-se atentar para que a taxa de erro não aumente também. O valor do limiar pode ser obtido automaticamente por meio da aplicação de ferramentas estatísticas nos dados de entrada fornecidos para treinamento e validação da rede. O valor ideal para determinar esta “fronteira” é aquele que maximiza o número de classificações corretas (i.e. estados de sucesso) e, ao mesmo tempo, minimiza a taxa de erro (i.e. estados de falha classificados como sucesso).

Indiscutivelmente, a rede RN_c proposta para compor a análise de adequação dos estados operativos apresentou excelentes resultados para o sistema IEEE-RTS. O desempenho da aplicação de redes neurais em outros sistemas poderá ser verificado na próxima seção.

Para um melhor entendimento, a Figura 4.6 ilustra o fluxograma da metodologia proposta para a avaliação da confiabilidade convencional.

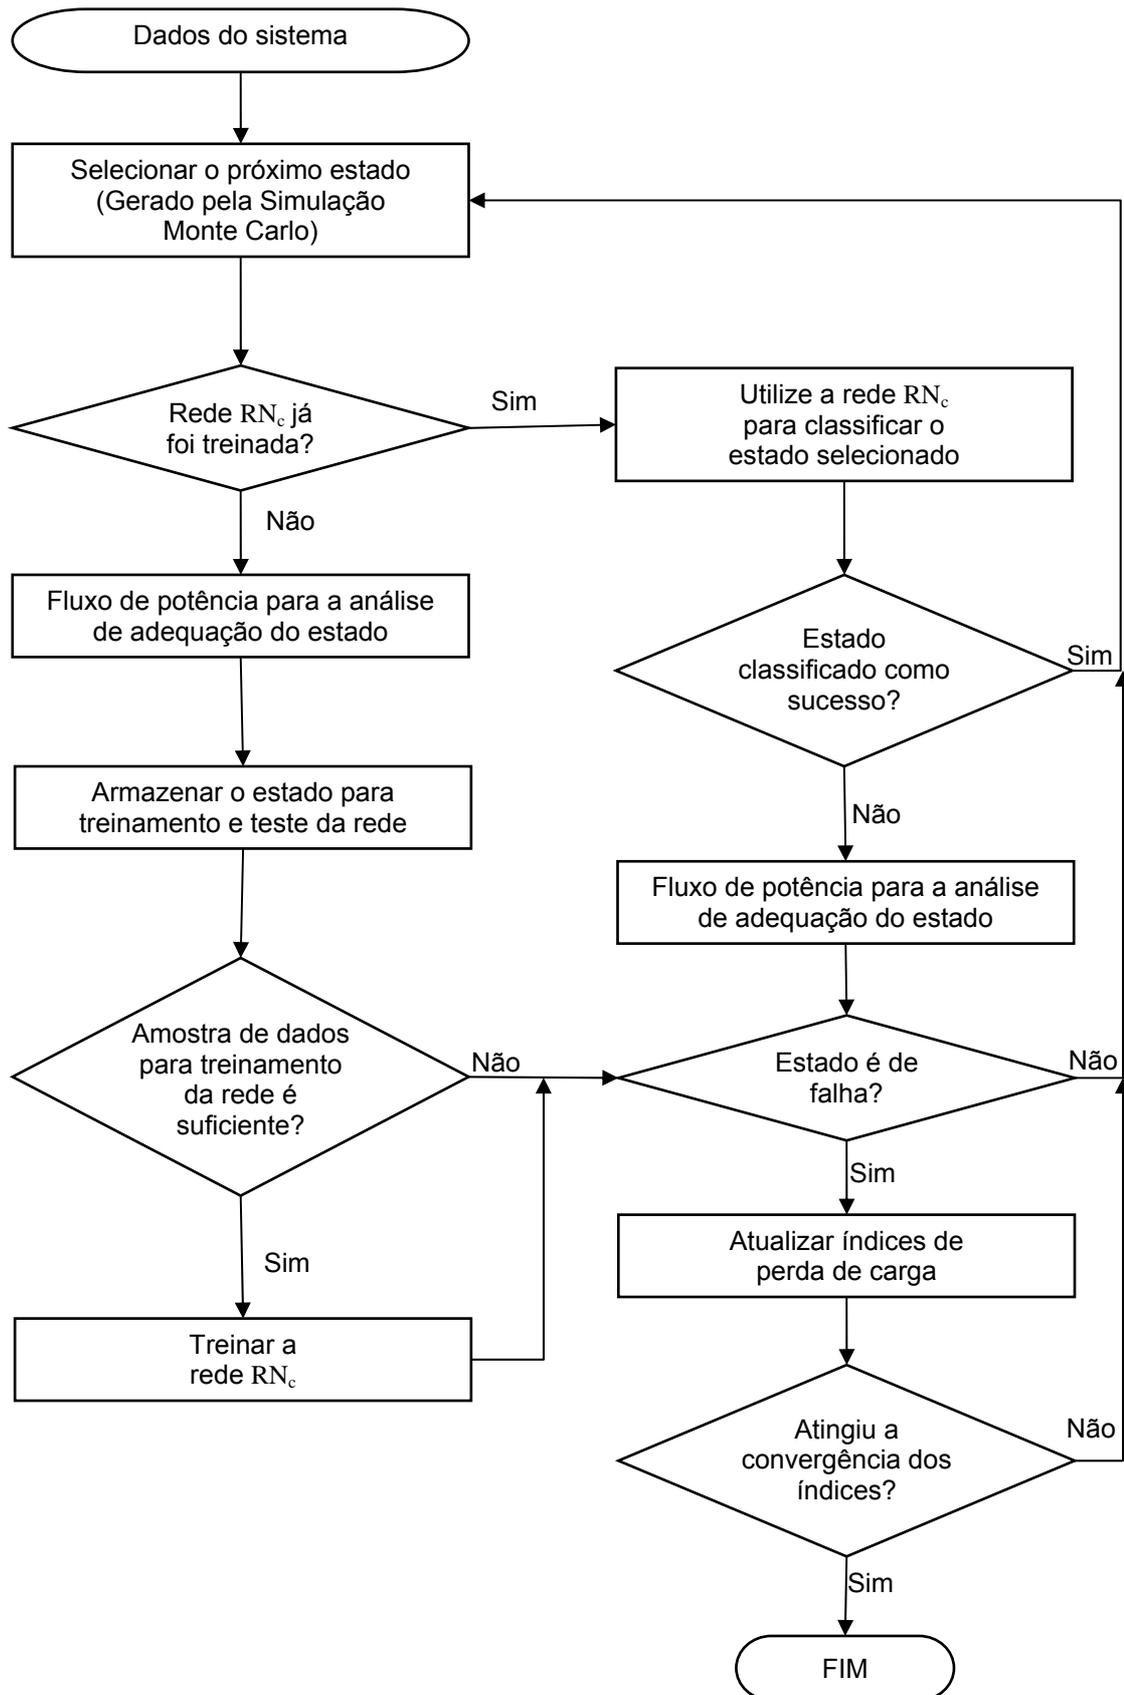


Figura 4.6: Fluxograma da Metodologia Proposta.

4.4 APLICAÇÕES – CONFIABILIDADE CONVENCIONAL

Os sistemas utilizados para a verificação da metodologia proposta são aqueles apresentados na Seção 3.2. A análise de adequação de cada estado amostrado também é desempenhada pelo fluxo de potência DC e pela programação linear (algoritmo de otimização baseado em pontos interiores), cujo principal objetivo é minimizar o corte de carga. Em todos os testes, o critério de parada adotado para a simulação Monte Carlo não-sequencial foi a obtenção de um coeficiente de variação $\beta \leq 5\%$, para todos os índices. Vale ressaltar que, a dimensão dos conjuntos de treinamento e validação das redes neurais é definida pelo coeficiente β (i.e. quando $\beta \leq 20\%$), conforme mencionado na Seção 4.3.2.

4.4.1 Sistema IEEE-RTS

Dois estudos de caso são realizados para o sistema IEEE-RTS com a curva de carga original: no primeiro (Caso 11) são apresentados os resultados sem utilizar redes neurais (referência); e no segundo (Caso 12) é utilizada a simulação Monte Carlo com redes neurais artificiais.

O desempenho e as características da rede neural obtida para este sistema foram apresentados na Subseção 4.3.3. O valor “13” foi adotado para o limiar desta rede. As estimativas para os índices de confiabilidade convencional para ambos os casos estão apresentados na Tabela 4.4.

Para o Caso 11, o total de estados amostrados foi aproximadamente $1,94 \times 10^6$, sendo necessário realizar $1,93 \times 10^6$ fluxos de potência e 5.083 otimizações das medidas remediadoras (redespacho e/ou corte de carga). O tempo de processamento necessário para a convergência dos índices foi de 16,72 minutos. O impacto da utilização de redes neurais, resultante da redução de análises de fluxo de potência e/ou otimização das medidas remediadoras, é investigado através do Caso 12. O número de estados amostrados foi $1,93 \times 10^6$, muito próximo ao

apresentado no Caso 11, porém, o total de análises de fluxo de potência foi $0,15 \times 10^6$, muito abaixo se comparado ao Caso 11 (12,55 vezes menos). Já o número de otimizações das medidas remediadoras foi 4.354. A redução de análises de fluxo de potência e de otimizações implicou em uma redução no tempo de processamento para 2,95 minutos, apresentando um *speedup* de 5,67 em relação ao Caso 11. É possível notar que, o erro percentual médio nas estimativas foi de 0,46%, ficando dentro da margem de incerteza ($\beta = 5\%$) para todos os índices.

Tabela 4.4: Índices de Confiabilidade – Sistema IEEE-RTS, Curva de Carga Original.

CASO	LOLP	LOLF (oc./ano)	EENS (MWh)	LOLD (horas)
11	0,000998	1,97	1095	4,43
12	0,000998 (0,02%)	1,98 (0,79%)	1099 (0,33%)	4,40 (0,80%)

No que diz respeito à interpretação dos índices de confiabilidade, pode-se perceber do Caso 11 que as chances do sistema operar em um estado de falha são de, aproximadamente, 0,1%, ou interpretando de outra forma, o sistema passará em média 8,57 horas por ano (i.e. $0,0010 \times 8736$ horas) em um estado de falha. Da mesma forma, são esperadas, em média, 1,97 visitas por ano aos estados de falha, enquanto que pelas técnicas de reconhecimentos de padrões, utilizadas no Caso 12, são esperadas 1,98 visitas por ano. Cada visita a estados de falha dura, em média, 4,43 horas (Caso 11) ou 4,40 horas (Caso 12).

4.4.2 Sistema IEEE-MRTS

Dois estudos de caso são realizados para o sistema IEEE-MRTS: no primeiro (Caso 13) são apresentados os resultados sem utilizar redes neurais; e no segundo (Caso 14) é utilizada a metodologia proposta.

O conjunto de variáveis de entrada/saída utilizado para o treinamento da rede RN_c para este sistema é o mesmo do sistema IEEE-RTS, resguardando as modificações

realizadas com o intuito de “estressar” o sistema IEEE-RTS. Diferentemente da rede obtida na Seção 4.4.1, a rede neural treinada para o sistema IEEE-MRTS contém 3 camadas e utiliza 4 das 5 variáveis fornecidas (a capacidade de geração indisponível da área 1 foi descartada pela rede) nos conjuntos de treinamento e teste. Um algoritmo de projeção de dados de um espaço multidimensional, tal como o apresentado em [SLA97b], pode ser utilizado para compreender melhor a tendência de agrupamentos dos padrões dessas variáveis. O desempenho desta rede pode ser verificado na Tabela 4.5.

Tabela 4.5: Desempenho da Rede RN_c – Sistema IEEE-MRTS.

	TREINAMENTO	TESTE	TOTAL
Número de casos	225	225	450
Classificações corretas	144 (150)	148 (150)	292 (300)
Classificações erradas	3	0	3
Casos não-classificados	78 (75)	77 (75)	155 (150)
Taxa de erro	1,33%	0,00%	0,67%

A Tabela 4.6 mostra os resultados obtidos para os dois estudos de caso realizados. O total de estados amostrados na simulação Monte Carlo, o número de análise de fluxo de potência e o número de otimizações das medidas remediadoras foram 436.790; 423.172 e 23.481 para o Caso 13 e 457.172; 46.527 e 19.108 para o Caso 14, respectivamente. Com a utilização da rede neural, foram evitadas 376.645 (89,0%) análises de fluxo de potência e 4.373 (18,62%) otimizações das medidas remediadoras. Os tempos de processamento foram de 7,80 minutos para o Caso 13 e 4,88 minutos para o Caso 14, o que resulta em um *speedup* de aproximadamente 1,60 em relação ao Caso 13.

Considerando somente a redução das análises de fluxo de potência, o *speedup* deveria ficar em torno de 9 (100%, no Caso 13, dividido por 11%, no Caso 14). De maneira análoga, o *speedup* resultante da redução do número de otimizações seria, aproximadamente, 1,23 (100%, no Caso 13, dividido por 81,38%, no Caso 14). O custo computacional da análise de fluxo de potência é bem menor que o da

otimização das medidas corretivas, o que explica a obtenção de um valor para o *speedup* mais próximo da redução do número de otimizações.

Os erros relativos apresentados estão dentro da margem de incerteza do parâmetro β e os resultados obtidos demonstram, novamente, um bom desempenho da metodologia proposta, mesmo em sistemas mais estressados.

Tabela 4.6: Índices de Confiabilidade – Sistema IEEE-MRTS.

CASO	LOLP	LOLF (oc./ano)	EENS (MWh)	LOLD (horas)
13	0,004975	8,73	6121	4,98
14	0,004727 (4,98%)	8,33 (4,56%)	6064 (0,93%)	4,96 (0,44%)

4.4.3 Sistema IEEE-RTS-96

A rede neural obtida é composta por duas camadas e quatro variáveis foram consideradas relevantes. Vale ressaltar que o conjunto de dados de entrada da rede era composto por 17 variáveis. O desempenho desta rede está apresentado na Tabela 4.7. O tempo necessário para treinamento e validação da rede também foi inferior a 1 segundo.

Tabela 4.7: Desempenho da Rede RN_c – Sistema IEEE-RTS-96.

	TREINAMENTO	TESTE	TOTAL
Número de casos	316	317	633
Classificações corretas	211 (211)	211 (211)	422 (422)
Classificações erradas	4	6	10
Casos não-classificados	101 (105)	100 (106)	201 (211)
Taxa de erro	3,81%	5,66%	4,74%

A Tabela 4.8 mostra os resultados obtidos para os dois estudos de caso realizados. O Caso 15 apresenta os resultados sem utilizar redes neurais e no Caso 16 utiliza-

se a metodologia proposta. Em ambos os casos, a curva de carga da semana pico (semana 51) do sistema IEEE-RTS foi utilizada.

Tabela 4.8: Índices de Confiabilidade – Sistema IEEE-RTS-96.

CASO	LOLP	LOLF (oc./ano)	EENS (MWh)	LOLD (horas)
15	0,000720	2,49	1160	2,52
16	0,000714	2,58	1152	2,42
	(0,81%)	(3,41%)	(0,63%)	(4,08%)

Pode-se constatar da Tabela 4.8 que, as diferenças apresentadas entre os dois casos são muito pequenas, com erro médio de 1,91%, dentro da margem de incerteza do coeficiente β . O total de estados amostrados na simulação Monte Carlo, o número de análise de fluxo de potência e o número de otimizações das medidas remediadoras foram 1.711.969; 1.717.594 e 4.840, respectivamente, para o Caso 15 e 1.657.307; 139.699 e 3.046 para o Caso 16. Com a utilização da rede neural, foram evitadas 1.577.594 (91,87%) análises de fluxo de potência e 1.794 (37,07%) otimizações das medidas remediadoras. Os tempos de processamento foram de 35,88 minutos para o Caso 15 e 13,02 minutos para o Caso 16, o que resulta em um *speedup* de aproximadamente 2,76 em relação ao Caso 15.

Utilizando a curva original do sistema IEEE-RTS, dois novos casos foram realizados com o sistema IEEE-RTS-96. Os resultados obtidos indicaram que o erro médio nas estimativas dos índices de confiabilidade foi 4,17%. Os tempos de processamento foram 210 minutos para o caso referência e 95 minutos para o caso baseado em redes neurais, resultando em um *speedup* igual a 2,23.

4.4.4 Sistema IEEE-MRTS-96

Assim como na seção anterior, a rede neural obtida é composta por duas camadas e quatro variáveis. O desempenho desta rede, nos conjuntos de treinamento e validação, é apresentado na Tabela 4.9. Já as estimativas dos índices de

confiabilidade para os dois estudos de caso realizados (referência e metodologia proposta, Casos 17 e 18, respectivamente) estão apresentadas na Tabela 4.10.

Tabela 4.9: Desempenho da Rede RN_c – Sistema IEEE-MRTS-96.

	TREINAMENTO	TESTE	TOTAL
Número de casos	275	274	549
Classificações corretas	104 (184)	102 (182)	206 (366)
Classificações erradas	0	2	2
Casos não-classificados	171 (91)	170 (92)	341 (183)
Taxa de erro	0,00%	0,73%	0,36%

Tabela 4.10: Índices de Confiabilidade – Sistema IEEE-MRTS-96.

CASO	LOLP	LOLF (oc./ano)	EENS (MWh)	LOLD (horas)
17	0,004548	7,63	1768	5,21
18	0,004518	7,80	1763	5,06
	(0,66%)	(2,19%)	(0,29%)	(2,79%)

Novamente, as diferenças apresentadas entre os dois casos são muito pequenas, com erro médio de 1,48%. O total de estados amostrados na simulação Monte Carlo, o número de análise de fluxo de potência e o número de otimizações das medidas remediadoras foram 554.557; 495.787 e 64.787, respectivamente, para o Caso 17 e 542.545; 196.310 e 60.289 para o Caso 18. Com a utilização da rede neural, foram evitadas 299.477 (60,4%) análises de fluxo de potência e 4.498 (6,9%) otimizações das medidas remediadoras. Os tempos de processamento foram de 96,67 minutos para o Caso 17 e 87,67 minutos para o Caso 18, o que resulta em um *speedup* de aproximadamente 1,10 em relação ao Caso 17.

Pode-se notar que, em relação ao sistema IEEE-RTS-96, houve uma redução do ganho computacional propiciado pela utilização da metodologia proposta no sistema IEEE-MRTS-96, onde a rede de transmissão se encontra estressada. Esta redução

foi consequência do baixo percentual (e.g. 6,9%) de otimizações das medidas remediadoras evitadas.

4.4.5 Sistema SSB

O sistema SSB está subdividido em 33 áreas, logo o número de variáveis de entrada fornecido para o treinamento e validação da rede foi 67. A rede neural obtida para este sistema é composta por duas camadas e quatro variáveis foram consideradas relevantes. O desempenho desta rede está apresentado na Tabela 4.11. Novamente, o tempo necessário para treinamento e validação da rede foi inferior a 1 segundo.

Tabela 4.11: Desempenho da Rede RN_c – Sistema SSB.

	TREINAMENTO	TESTE	TOTAL
Número de casos	474	474	948
Classificações corretas	308 (316)	312 (316)	620 (632)
Classificações erradas	1	1	2
Casos não-classificados	165 (158)	161 (158)	326 (316)
Taxa de erro	0,21%	0,21%	0,21%

Dois estudos de caso são realizados. O primeiro (Caso 19) apresenta os resultados sem utilizar redes neurais. Já no segundo (Caso 20), utiliza-se a metodologia proposta. Os resultados obtidos para o sistema SSB estão apresentados na Tabela 4.12.

Tabela 4.12: Índices de Confiabilidade – Sistema SSB.

CASO	LOLP	LOLF (oc./ano)	EENS (MWh)	LOLD (horas)
19	0,010423	11,36	1319	8,02
20	0,010119 (2,91%)	10,85 (4,44%)	1266 (4,05%)	8,15 (1,60%)

Considerando os Casos 19 e 20, o total de estados amostrados na simulação Monte Carlo, o número de análise de fluxo de potência e o número de otimizações das medidas remediadoras foram 484.503; 445.668 e 43.406, respectivamente, para o Caso 19 e 505.075; 47.764 e 16.008 para o Caso 20. Os tempos de processamento foram 320,60 minutos para o Caso 19 e 105,32 minutos para o Caso 20, resultando em um *speedup* de 3,04.

Para este sistema, de maior dimensão que os anteriores, verifica-se que, a metodologia baseada no emprego de redes neurais produziu bons resultados em termos de precisão de índices, apresentando uma maior redução do esforço computacional. Portanto, espera-se que, para sistemas de maior porte, o desempenho da metodologia proposta fique ainda melhor.

4.5 REDE GMDH PROPOSTA – CONFIABILIDADE PREVENTIVA

Nesta seção, é apresentada uma nova metodologia para a avaliação da confiabilidade preventiva de sistemas compostos. Esta metodologia utiliza também redes neurais para classificar, entre os estados de sucesso, estados saudáveis e marginais.

Assim como na Seção 4.3, a idéia é utilizar técnicas de reconhecimento de padrões na análise de adequação dos estados. Vale ressaltar que, na avaliação da confiabilidade preventiva, será obtida uma rede diferente daquela obtida na confiabilidade convencional (i.e. daquela utilizada para classificar estados operativos em sucesso ou em falha).

4.5.1 Variáveis de entrada

Assim como na Seção 4.3.1, o conjunto de dados de entrada para treinamento e validação de uma rede neural para a avaliação da confiabilidade preventiva pode conter diversas variáveis. Nesta tese, são adotadas as seguintes variáveis, incluindo também suas extensões, tais como a soma, o produto, etc.:

- Carga do sistema;
- Reserva de geração disponível.

4.5.2 Treinamento e validação da rede RN

A partir da avaliação da confiabilidade preventiva via simulação Monte Carlo não-seqüencial, aplicada ao sistema IEEE-MRTS-96 (detalhado na Seção 3.2), foram recolhidos dados de 963 estados operativos, os quais são divididos em dois conjuntos: de treinamento (481 estados) e de teste (482 estados). Nesta massa de dados, estão presentes as informações relacionadas (valores reais das grandezas) com a carga, a reserva de geração, as disponibilidades dos equipamentos (geração

e transmissão) e a classificação dos estados (saudáveis ou marginais). Estes dados são utilizados como entrada para o treinamento e teste de uma rede neural denominada RN. Os valores numéricos 10 e 20 foram adotados para representar as saídas desejadas dos estados marginais e saudáveis, respectivamente. Vale destacar que, o tamanho do conjunto de dados foi determinado pelo coeficiente de variação β . Além disso, não foi necessário obter uma amostra balanceada, uma vez que a probabilidade de estados marginais (e.g. 0,36) não é muito baixa, em relação à probabilidade de estados saudáveis (e.g. 0,59).

Os resultados obtidos pela rede RN estão ilustrados na Figura 4.7. Durante a fase de treinamento, foi atribuído aos estados saudáveis o valor 20. Desta forma, estes estados são identificados quando as classificações obtidas forem maiores que 15. Analogamente, estados marginais, sendo atribuído o valor 10 durante a fase de treinamento, são identificados quando as classificações obtidas forem menores que 15. Considerando os dados obtidos na seção anterior, 933 estados foram classificados corretamente e ocorreram 30 erros de classificação, o que resulta em uma taxa de erro de 3,12% (2,70% no treinamento e 3,53% no teste). A taxa de erro, neste caso, é dada pela razão entre estados classificados e classificações erradas. Diferentemente da avaliação da confiabilidade convencional, a qual considerava apenas os estados de falha, o cálculo da taxa de erro engloba todos os estados analisados.

Os estados saudáveis estão representados pelo caractere “x” em azul, os estados marginais pelo caractere “+” em vermelho e os erros de classificação pelos destaques com um círculo preto.

É possível notar que, a partir da Figura 4.7, a maioria dos erros de classificação se concentra na região de *fronteira* entre os estados saudáveis e marginais. Uma maneira de evitar estes erros pode ser realizada através da consideração de uma região de *dúvida* (i.e. uma região na qual não se pode ter certeza quanto à classificação do estado analisado). A especificação desta região está relacionada aos valores limites utilizados para definir a classificação dos estados.

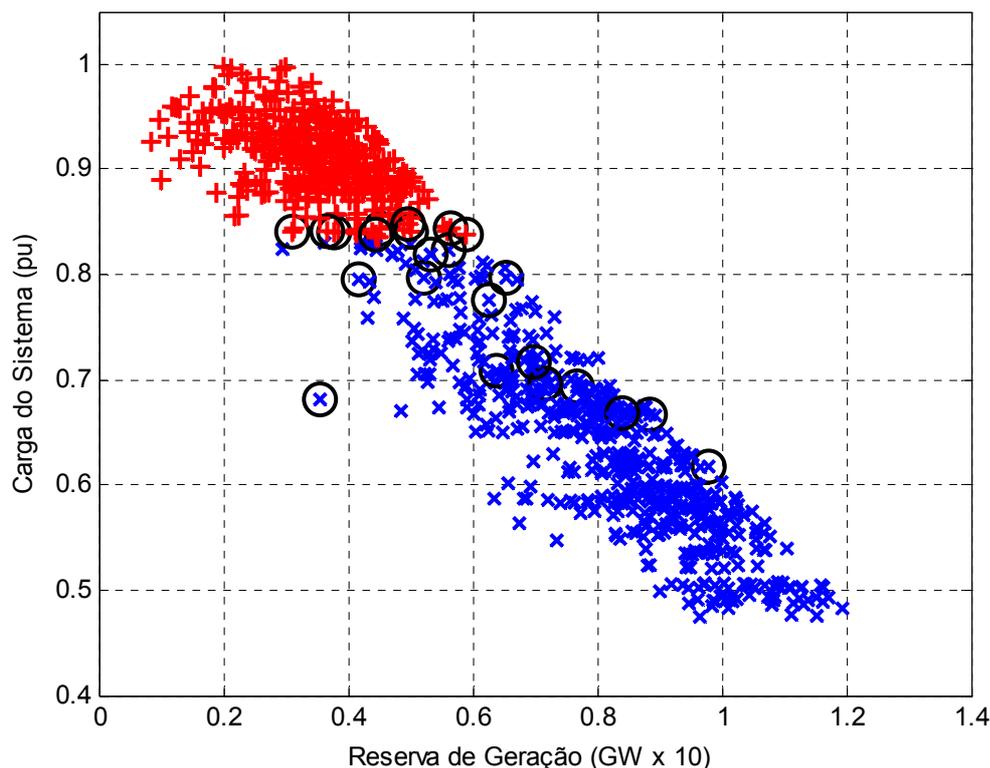


Figura 4.7: Plano “Carga × Reserva de Geração” – Limiar 15.

Na Figura 4.8 é apresentada uma nova projeção dos dados de treinamento e validação. Os estados saudáveis e marginais são identificados somente quando as classificações apresentarem valores acima de 18 e abaixo de 12, respectivamente. Para os estados restantes, i.e. classificações obtidas dentro do intervalo [12;18] (pontos em laranja), é necessária a análise de adequação submetida à lista de contingências. Neste caso, 788 estados foram classificados corretamente, 167 estados não foram classificados pela rede RN e ocorreram apenas 8 erros de classificação, i.e. taxa de erro de 0,83% (0,42% no treinamento e 1,24% no teste).

Pode-se observar na Figura 4.8 que existe uma área de superposição dos grupos de estados saudáveis e marginais (pontos em laranja). Nesta área, a rede RN não se apresentou capaz de classificar corretamente os estados, deixando esta tarefa a cargo da análise de adequação submetida à lista de contingências. No entanto, a grande vantagem da utilização da rede GMDH está nas áreas extremas, onde os grupos de estados estão bem definidos. Nestes casos, a distinção entre estados

saudáveis e marginais é feita pela rede RN, o que reduz drasticamente o custo computacional. Para os estados classificados pela rede todo o processo de análise de adequação (i.e. fluxo de potência e/ou algoritmo de otimização com medidas corretivas), envolvendo a aplicação da lista de contingências, é substituído por uma simples avaliação polinomial.

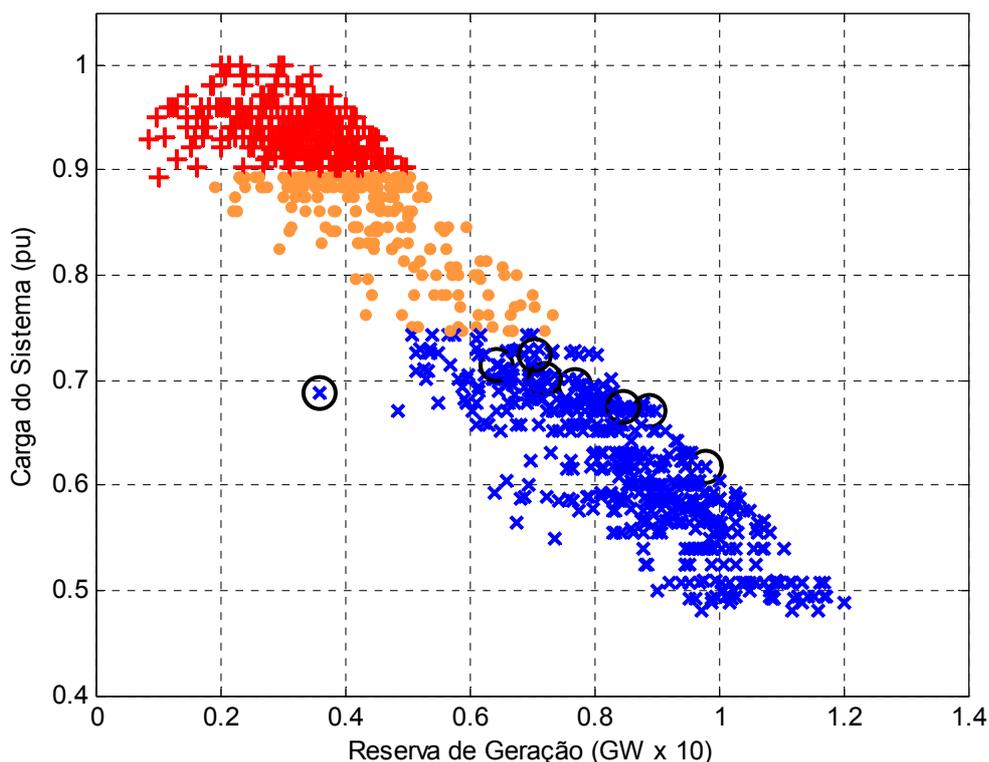


Figura 4.8: Plano “Carga × Reserva de Geração” – Limiares 12 e 18.

4.5.3 Subdivisão do Espaço de Estados

A avaliação da confiabilidade preventiva de sistemas compostos é caracterizada pelas complexidades inerentes à rede de transmissão. Desta forma, é razoável adotar subdivisões do espaço de estados, onde diferentes redes neurais poderão ser treinadas para identificar os estados saudáveis e marginais. Portanto, dada uma lista de contingências, propõe-se dividir o espaço de estados em nove regiões distintas. Estas regiões estão apresentadas na Tabela 4.13 a seguir.

Tabela 4.13: Subdivisão do Espaço de Estados.

CENÁRIO	REGIÃO
G_0-T_0	1
$G-T_0$	2
G_0-T	3
$G-T$	4
G_L-T_0	5
G_L-T	6
G_0-T_L	7
$G-T_L$	8
G_L-T_L	9

Onde:

G_0 - Estado com todos os equipamentos de geração disponíveis;

G - Estado com pelo menos um equipamento de geração indisponível, porém este não pertence à lista de contingências;

G_L - Estado com indisponibilidade de pelo menos um equipamento de geração pertencente à lista de contingências;

T_0 - Estado com todos os equipamentos de transmissão disponíveis;

T - Estado com pelo menos um equipamento de transmissão indisponível, porém este não pertence à lista de contingências;

T_L - Estado com indisponibilidade de pelo menos um equipamento de transmissão pertencente à lista de contingências.

4.5.4 Utilização de duas redes: RN_1 e RN_2

Em relação aos 8 erros de classificação obtidos pela rede RN (Figura 4.8), foi verificado que 7 deles envolviam estados das regiões 7, 8 e 9 da Tabela 4.13 (i.e.

indisponibilidades de pelo menos um equipamento de transmissão pertencente à lista de contingências). Isto pode ser um indicativo de que as variáveis de entradas não foram capazes de construir um espaço de representação bem definido para estados pertencentes a estas regiões. Tendo em vista estas considerações e, também, objetivando melhorar a eficiência da utilização de técnicas de reconhecimento de padrões na confiabilidade preventiva, duas novas redes neurais são propostas para a classificação dos estados saudáveis e marginais. A primeira rede neural (RN_1) contempla os estados pertencentes às regiões 1, 2, 3 e 4 (Tabela 4.13) e, a segunda (RN_2) às regiões 5 e 6. Ambas as redes utilizam os limiares 12 e 18, para a classificação dos estados marginais e saudáveis, respectivamente.

As Figuras 4.9 e 4.10 apresentam os resultados obtidos por estas duas redes, utilizando o sistema IEEE-MRTS-96. Os treinamentos das redes RN_1 e RN_2 são realizados durante a avaliação da confiabilidade preventiva. Para tal, são utilizados como dados de entrada os estados iniciais simulados na avaliação.

O tempo necessário para treinamento e teste das redes RN_1 e RN_2 foi inferior a 1 segundo. Como ilustração, o desempenho das redes RN_1 e RN_2 é apresentado na Tabela 4.14. Os resultados mostram uma redução significativa da taxa de erro em relação à rede RN apresentada na Seção 4.3.3 (3,12 % para 0,11 %). O impacto da utilização das redes RN_1 e RN_2 no tempo de processamento e na precisão dos índices, durante a avaliação da confiabilidade preventiva, poderá ser verificado através dos resultados apresentados na próxima seção.

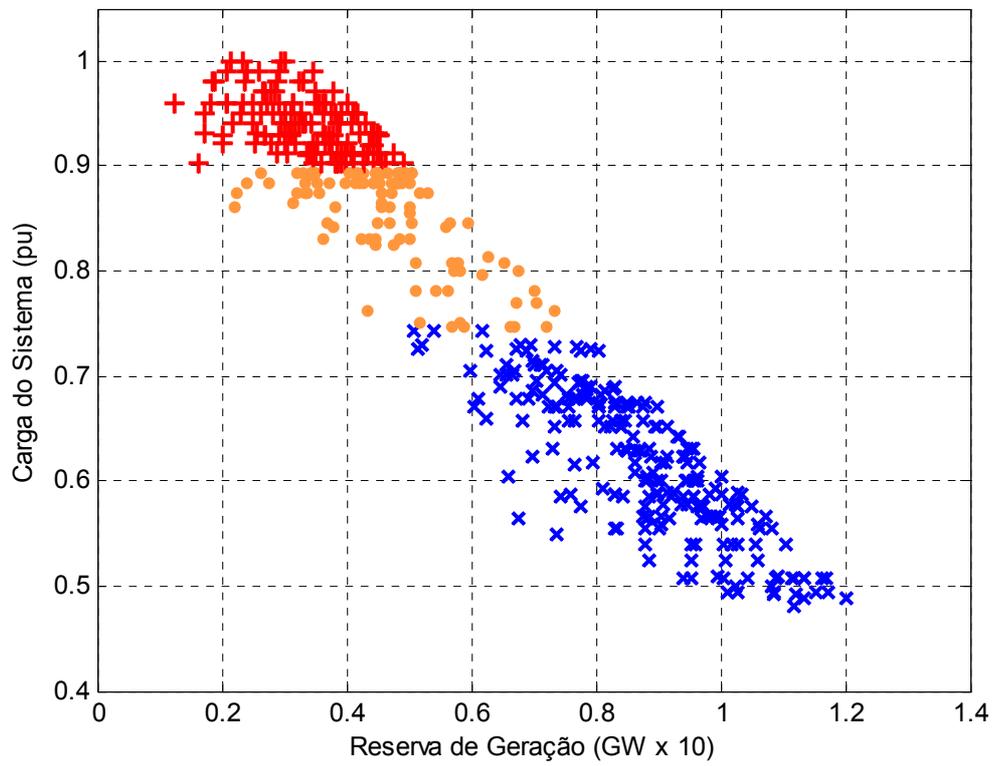


Figura 4.9: Plano “Carga × Reserva de Geração” – Rede RN₁.

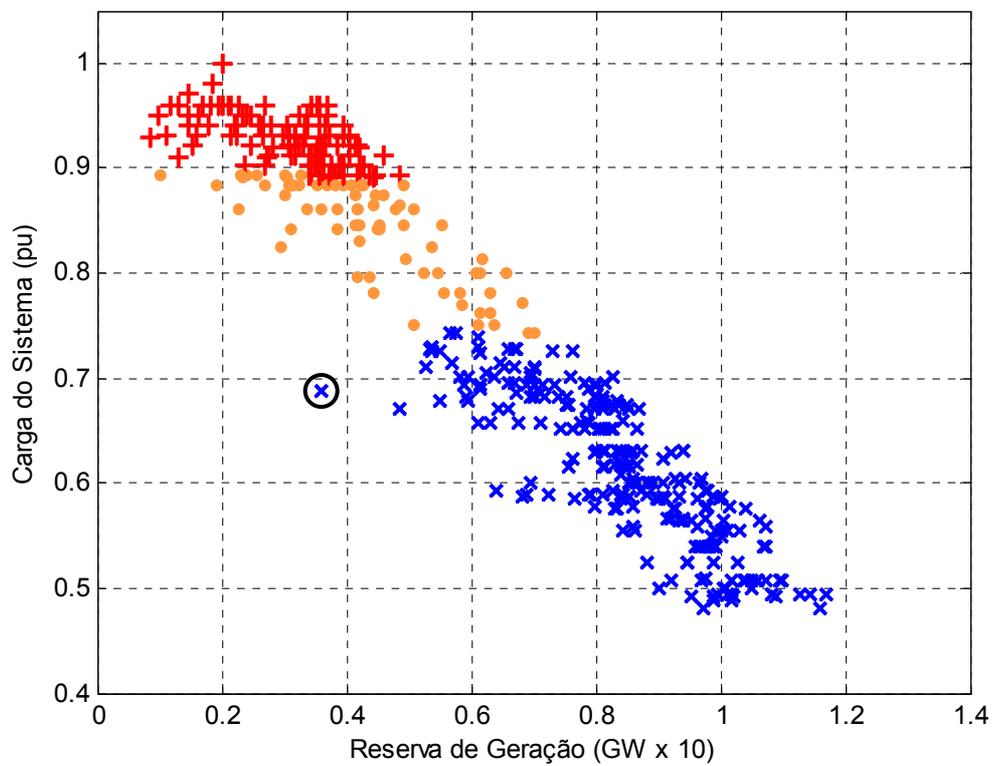


Figura 4.10: Plano “Carga × Reserva de Geração” – Rede RN₂.

Tabela 4.14: Desempenho das Redes RN₁ e RN₂ – Sistema IEEE-MRTS-96.

REDE		RN₁	RN₂	RN₁+RN₂
Número de estados testados		427	464	891
Classificações corretas		355	343	698
Estados não classificados		71	121	192
Classificações errôneas		0	1	1
Taxa de erro	treinamento	0,00%	0,00%	0,00%
	teste	0,00%	0,47%	0,22%
	total	0,00%	0,23%	0,11%

4.6 APLICAÇÕES – CONFIABILIDADE PREVENTIVA

Três sistemas são utilizados para a verificação dos conceitos propostos nesta seção: o IEEE-MRTS, o IEEE-MRTS-96 e uma configuração do sistema Sul-Sudeste Brasileiro (SSB). Novamente, a análise de adequação de cada estado amostrado é desempenhada pelo fluxo de potência DC e pela programação linear, cujo principal objetivo é minimizar o corte de carga. Em todos os testes, o critério de parada adotado para a simulação Monte Carlo não-sequencial foi a obtenção de um coeficiente de variação $\beta \leq 5\%$ para todos os índices. A dimensão dos conjuntos de treinamento e validação das redes neurais é definida quando β atinge 20%.

4.6.1 Sistema IEEE-MRTS

Dois estudos de caso são realizados para o sistema IEEE-MRTS: no primeiro (Caso 19) são apresentados os resultados sem utilizar redes neurais; e no segundo (Caso 20) é utilizada a metodologia proposta. Tendo em vista a determinação dos índices de bem-estar, ambos os casos utilizam o mesmo critério determinístico, o qual consiste da lista de eventos apresentada na Tabela 3.1.

Uma ordenação inteligente [R02, LRMB04] foi utilizada para selecionar esta lista. Na Tabela 4.15 estão apresentados os resultados para os índices de bem-estar referentes aos estados saudáveis e marginais. Os índices referentes aos estados de falha não se alteram com a utilização da metodologia proposta. São também apresentados os erros percentuais cometidos pelo Caso 22 em relação ao Caso 21, o qual foi tomado como referência. Estes erros aparecem entre parêntesis logo abaixo do índice correspondente.

Tabela 4.15: Índices de Confiabilidade Preventiva – IEEE-MRTS.

CASOS	<i>P(S)</i>	<i>P(M)</i>	<i>Freq(S)</i> (oc./ano)	<i>Freq(M)</i> (oc./ano)	<i>Dur(S)</i> (horas)	<i>Dur(M)</i> (horas)
21	0,5881	0,3599	303,08	392,22	16,95	8,02
22	0,6127 (4,18%)	0,3353 (6,83%)	303,12 (0,01%)	378,74 (3,44%)	17,66 (4,16%)	7,73 (3,51%)

Para o Caso 21, o total de análises de adequação foi de 101.334. O tempo de processamento necessário para a convergência dos índices foi de 32,72 minutos. Através do Caso 22 é investigado o impacto da utilização de redes neurais para a análise de adequação dos estados operativos (saudáveis e marginais). O total de análises de adequação realizadas no Caso 22 foi de 48.592, muito abaixo se comparado ao Caso 21 (2,09 vezes menos). Isto implica em uma redução no tempo de processamento para 15,27 minutos, apresentando um *speedup* de 2,14 em relação ao Caso 21. É possível notar que, o erro percentual médio foi de 3,69%, ficando dentro da margem de incerteza dos índices.

No que diz respeito à interpretação dos índices de confiabilidade preventiva, pode-se perceber do Caso 21 que as chances do sistema operar em um estado marginal são de, aproximadamente, 36%, ou interpretando de outra forma, o sistema passará em média 3144 horas por ano (i.e. 0.3599×8736 horas) em um estado marginal. Da mesma forma, são esperadas, em média, 392,22 visitas por ano aos estados marginais, enquanto que pelas técnicas de reconhecimento de padrões (i.e. Caso 22) são esperadas 378,74 visitas por ano. Cada visita a estados marginal dura, em média, 8,02 horas (Caso 21) ou 7,73 horas (Caso 22).

O desempenho das redes RN_1 e RN_2 treinadas para o sistema IEEE-MRTS está apresentado na Tabela 4.16. Vale destacar que o tempo necessário para treinamento e validação das duas redes também foi inferior a 1 segundo.

Tabela 4.16: Desempenho das Redes RN₁ e RN₂ – Sistema IEEE-MRTS.

REDE	RN ₁	RN ₂	RN ₁ +RN ₂
Número de estados testados	388	299	687
Classificações corretas	303	240	543
Estados não classificados	85	59	144
Classificações errôneas	0	0	0
Taxa de erro	0,00%	0,00%	0,00%

4.6.2 Sistema IEEE-MRTS-96

Também são realizados dois estudos de caso, nos quais se utiliza o mesmo critério determinístico (lista de contingência com 37 elementos). O primeiro (Caso 23) apresenta os resultados sem utilizar redes neurais. Já no segundo (Caso 24), utiliza-se a metodologia proposta.

Na Tabela 4.17 estão apresentados os resultados para os índices de bem-estar. Pode-se constatar que, as diferenças apresentadas entre os dois casos são muito pequenas, com erro médio de 1,76%, dentro da margem de incerteza do coeficiente β . Os totais de análises de adequação realizadas foram 156.900 e 71.921 para os Casos 23 e 24, respectivamente. Os tempos de processamento foram de 222,43 minutos para o Caso 23 e 53,42 minutos para o Caso 24, o que resulta em um *speedup* de aproximadamente 4,16 em relação ao Caso 23. Tomando o Caso 23 como referência, o desempenho alcançado pela metodologia proposta foi, mais uma vez, excelente. As características e o desempenho das redes RN₁ e RN₂ para este sistema foram apresentados na Seção 4.5.4.

Tabela 4.17: Índices de Confiabilidade Preventiva – IEEE-MRTS-96.

CASOS	P(S)	P(M)	Freq(S) (oc./ano)	Freq(M) (oc./ano)	Dur(S) (horas)	Dur(M) (horas)
23	0,5819	0,3733	262,96	346,46	19,33	9,41
24	0,5831 (0,20%)	0,3730 (0,10%)	256,31 (2,53%)	337,91 (2,47%)	19,87 (2,80%)	9,64 (2,43%)

4.6.3 Sistema SSB

Os índices de bem-estar estimados são referentes a uma subárea do estado de Minas Gerais, a qual contém 20 barras (15 barras de carga). São realizados dois estudos: Caso 25, sem o uso de redes neurais, e Caso 26 que utiliza a metodologia proposta. Todos os casos utilizam uma lista de contingências com cinco elementos, como critério determinístico, para a subárea em questão. Os resultados obtidos para o sistema SSB estão apresentados na Tabela 4.18.

Tabela 4.18: Índices de Confiabilidade Preventiva – SSB.

CASOS	<i>P(S)</i>	<i>P(M)</i>	<i>Freq(S)</i> (oc./ano)	<i>Freq(M)</i> (oc./ano)	<i>Dur(S)</i> (horas)	<i>Dur(M)</i> (horas)
25	0,5115	0,4781	356,89	365,01	12,51	11,43
26	0,5124 (0,18%)	0,4771 (0,20%)	358,33 (0,40%)	359,56 (1,49%)	12,48 (0,19%)	11,58 (1,39%)

A interpretação dos índices de confiabilidade preventiva pode ser feita da seguinte maneira. Esta subárea do SSB terá 47,8% de chances de operar em estados marginais, ou ainda, ela passará um total de 4.176 horas do ano em estados marginais. A frequência média de visitas a esses estados será, em média, 365 no período de um ano, o que é equivalente a uma visita por dia. Ao ingressar em estados marginais, a subárea em questão do SSB permanecerá, em média, nestes estados cerca de 11,4 horas, i.e. quase a metade de um dia. Os índices LOLP e LOLF avaliados para esta subárea indicam, respectivamente, menos de 1% como sendo as chances de corte de carga e cerca de 11 interrupções, em média, por ano.

Considerando os Casos 25 e 26, os totais de análises de adequação realizadas foram de 552.258 e 419.719, respectivamente. Os tempos de processamento foram 542 minutos para o Caso 25 e 513 minutos para o Caso 26. Deve ser observado que os tempos mencionados até agora, para os Casos 21 a 26, incluem as avaliações de todos os índices de confiabilidade preventiva e convencional (i.e. LOLP, LOLF, EENS = *Expected Energy Not Supplied*, etc.). No caso específico da subárea do sistema SSB, somente para avaliar os índices de bem-estar referentes aos estados

saudáveis e marginais, os tempos de processamento para atingir a convergência ($\beta \leq 5\%$) foram 200 e 172 minutos para os Casos 25 e 26, respectivamente, resultando em um *speedup* de 1,16. Este pode ser considerado o ganho real, uma vez que, nestes estudos, as redes neurais treinadas são utilizadas somente na análise de adequação dos estados de sucesso amostrados.

O ganho computacional do Caso 26 em relação ao Caso 25 foi relativamente baixo. Isto se deve à rápida convergência dos índices causada pela alta probabilidade de ocorrência dos estados marginais, aproximadamente 0,48. Além disso, é utilizada uma lista de contingências pequena (cinco elementos), se comparada à dimensão do sistema. Esta lista é compatível ao tamanho desta subárea e consistente do ponto de vista elétrico. Nestes casos é interessante a utilização da redução probabilística da rede de transmissão, proposta no Capítulo 3. No próximo capítulo, serão apresentados resultados de estudos de casos combinando as propostas e os conceitos deste e do Capítulo 3.

4.7 CONCLUSÕES

Neste capítulo foi apresentada uma nova metodologia para a avaliação da confiabilidade convencional e preventiva. Esta metodologia utiliza redes neurais artificiais, especificamente a rede polinomial GMDH, para reduzir o esforço computacional exigido durante a análise de adequação dos estados operativos do sistema.

Dois grupos de redes neurais foram obtidos. O primeiro, utilizado na avaliação de índices referentes à falha (confiabilidade convencional), tem como objetivo distinguir os estados entre falha e sucesso. O ganho deste conjunto de redes é proporcional ao número de estados de sucesso identificados, pois neste caso não é necessário utilizar o algoritmo de programação linear. Já o segundo conjunto, utilizado na avaliação da confiabilidade preventiva, se limita a classificar os estados de sucesso em saudáveis ou marginais. A adoção de uma faixa de *dúvida* e de uma divisão do espaço de estados aumentou significativamente a precisão da rede obtida.

Os resultados apresentados, tanto na avaliação da confiabilidade convencional quanto da confiabilidade preventiva, demonstraram o grande potencial da metodologia proposta. Como exemplo, *speedups* de até 5 foram alcançados e os erros das estimativas, geralmente, ficaram dentro da margem de incerteza quando se utilizou tal metodologia.

CAPÍTULO 5

COMBINAÇÃO DE TÉCNICAS DE REDUÇÃO DA TRANSMISSÃO E DE REDES NEURAIS

5.1 INTRODUÇÃO

O modelo reduzido de fluxo de potência com otimização das medidas corretivas foi utilizado em todos os testes realizados. No entanto, as técnicas propostas para a redução da rede de transmissão, apresentada no Capítulo 3, e para a incorporação de redes neurais na análise de adequação dos estados operativos do sistema, formulada no Capítulo 4, foram utilizadas somente nos estudos de casos apresentados nos respectivos capítulos.

Tendo em vista investigar a precisão nas estimativas dos índices e o ganho computacional, neste capítulo são realizados mais alguns estudos de casos, nos quais se emprega simultaneamente as técnicas citadas no parágrafo anterior. Para tal, são utilizados os sistemas IEEE-MRTS-96 e SSB.

Vale ressaltar que, antes de iniciar o processo de avaliação da confiabilidade através da simulação Monte Carlo não-seqüencial, a rede de transmissão do sistema utilizado é reduzida. Portanto, os dados coletados para treinamento e validação das redes neurais (e.g. RN_c , RN_1 e RN_2) já consideram a transmissão reduzida.

5.2 SISTEMA IEEE-MRTS-96

Utilizando a curva de carga original do sistema IEEE-RTS, dois estudos de caso são realizados. No Caso 27 são apresentados os resultados obtidos sem utilizar qualquer uma das técnicas propostas. Já no Caso 28, são utilizadas as técnicas de redução probabilística da rede de transmissão e de incorporação de redes neurais na análise de adequação dos estados operativos do sistema.

Conforme mencionado no Capítulo 3, o sistema IEEE-MRTS-96 foi construído através da interligação de três sistemas IEEE-MRTS, os quais foram denominados de áreas A, B e C. Para melhor entendimento, as oito áreas consideradas para a aplicação da redução probabilística da rede são repetidas a seguir:

- *Área 11* – é composta pelas barras de 138 kV (exceto barra 107) da área A do sistema original IEEE-MRTS-96;
- *Área 12* – é formada pelas barras de 230 kV da área A;
- *Área 13* – corresponde à barra 107 (área A);
- *Área 21* – é composta pelas barras 201, 202, 204-208 (área B – 138 kV);
- *Área 22* – é formada pelas barras de 230 kV da área B;
- *Área 23* – é composta pelas barras 203, 209, 210 (área B – 138 kV);
- *Área 31* – é formada pelas barras de 138 kV da área C;
- *Área 32* – é formada pelas barras de 230 kV da área C.

As áreas utilizadas para os Casos 27 e 28 são descritas a seguir:

- *Caso 27* – análise de adequação submetida ao sistema completo e representação estocástica de todos os equipamentos. Isto implica em: área de contingência = área de otimização = sistema completo;
- *Caso 28* – análise de adequação submetida a uma área de otimização composta pelas áreas 13, 21, 22 e 23, sendo adotada a representação estocástica para

todos os equipamentos destas áreas. Isto implica em: área de contingência = área de otimização < sistema completo.

Nos dois casos apresentados, a área de interesse é composta pela área 21. A Figura 3.5, apresentada na subseção 3.5.1, ilustra a configuração reduzida do sistema IEEE-MRTS-96, tendo em vista as definições das áreas externas, de otimização, de contingências e de interesse.

O critério determinístico utilizado para estimar os índices de confiabilidade preventiva, em ambos os casos, é a lista de eventos apresentada na Tabela 3.3.

As três rede neurais, RN_c , RN_1 e RN_2 , propostas no Capítulo 4, serão agora, coordenadamente, empregadas para realizar a análise de adequação dos estados operativos do sistema. A primeira rede é utilizada para a classificação dos estados entre sucesso e falha (confiabilidade convencional). Nesta rede, o conjunto de dados para treinamento e validação é composto pelas variáveis: *reserva de geração por área*; *capacidade de geração indisponível por área* e *capacidade indisponível de transmissão do sistema*. Já as outras duas redes são utilizadas para a classificação dos estados de sucesso entre saudável e marginal (Confiabilidade preventiva). Neste caso, o conjunto de dados para treinamento e validação é formado pelas variáveis: *carga do sistema* e *reserva de geração do sistema*. Vale ressaltar que o tamanho dos conjuntos de dados também é definido pelo coeficiente de variação $\beta \leq 20\%$.

Na Tabela 5.1 são apresentados os resultados obtidos para os Casos 27 e 28. O coeficiente de variação β é menor ou igual a 5% para todos os índices estimados. Assim como no Caso 8, os ajustes realizados nas potências máximas de geração das barras de fronteira foi, em média, uma redução de 4%. Os erros introduzidos pela utilização das técnicas propostas são compatíveis com a tolerância de 5%, utilizada para interromper o processo de simulação Monte Carlo.

Tabela 5.1: Índices de Confiabilidade – IEEE-MRTS-96.

ÍNDICES	Caso 27	Caso 28	ERRO (%)
LOLP	0,0011	0,0011	4,14
LOLF (oc./ano)	2,02	1,90	6,09
EENS (MWh)	280,8	276,0	1,73
LOLD (horas)	4,73	4,83	2,09
P(S)	0,9688	0,9695	0,08
P(M)	0,0301	0,0293	2,37
Freq(S) (oc./ano)	50,17	52,58	4,81
Freq(M) (oc./ano)	50,68	51,63	1,87
Dur(S) (horas)	168,7	161,1	4,50
Dur(M) (horas)	5,19	4,97	4,14

Para o Caso 27, o qual é igual ao Caso 5, foram analisados mais de três milhões de estados, acarretando um tempo de processamento de 231,87 minutos. Já para o Caso 28, foram analisados 1.583.962 estados em 62 minutos, o que representa um *speedup* de aproximadamente 3,74.

O Caso 28, o qual utiliza a metodologia proposta, apresentou um acréscimo no tempo computacional em relação aos Casos 7 e 8 (aproximadamente 51 minutos), onde apenas a redução da rede de transmissão é utilizada. Este acréscimo foi consequência da necessidade de um número maior de estados simulados para atingir a convergência dos índices.

5.3 SISTEMA SUL-SUDESTE BRASILEIRO (SSB)

A seguir são descritos os dois casos considerados para este sistema:

- *Caso 29* – análise de adequação submetida ao sistema completo e representação estocástica de todos os equipamentos. Isto implica em: área de contingência = área de otimização = sistema completo. Não serão utilizadas redes neurais na análise de adequação dos estados operativos. Este caso é igual ao Caso 9 (Referência);
- *Caso 30* – análise de adequação submetida ao sistema reduzido e as áreas de contingência e de otimização serão restritas à área Minas. Isto implica em: áreas de contingência e de otimização = área Minas << sistema completo.

A área de interesse é composta de uma subárea do estado de Minas Gerais. Com o objetivo de estimar os índices de confiabilidade preventiva (bem-estar), o critério determinístico utilizado é o mesmo dos Casos 9 e 10. Uma curva de carga cronológica com 8736 horas é convertida em um modelo markoviano não-agregado (Figura 2.2), para ser utilizado na simulação Monte Carlo não-sequencial.

Os índices de confiabilidade, convencional e preventiva, estão apresentados na Tabela 5.2. Não foram realizados ajustes das gerações máximas nas barras de fronteira. Os erros introduzidos pela utilização das técnicas propostas estão dentro de níveis aceitáveis, isto é, compatíveis com a tolerância de 5%, utilizada para interromper o processo de simulação Monte Carlo.

Para o Caso 29, foram analisados 601.154 estados, acarretando um tempo de processamento de 490,1 minutos. Já para o Caso 30, foram analisados 364.042 estados em 10,9 minutos, o que representa um *speedup* de aproximadamente 45. A precisão dos índices obtidos deve ser considerada muito boa, pois as diferenças apresentadas entre os Casos 29 e 30 (Coluna Δ) ficaram próximas da margem de incerteza dada pelo coeficiente de variação $\beta \leq 5\%$.

Tabela 5.2: Índices de Confiabilidade – SSB.

ÍNDICES	Caso 29	Caso 30	Δ (%)
LOLP	0,0105	0,0103	2,00
LOLF (oc./ano)	11,36	12,01	5,66
EENS (MWh)	1319	1275	3,31
LOLD (horas)	8,07	7,47	7,32
P(S)	0,5110	0,5084	0,51
P(M)	0,4786	0,4813	0,58
Freq(S) (oc./ano)	387,68	395,06	1,90
Freq(M) (oc./ano)	387,39	403,25	4,09
Dur(S) (horas)	11,53	11,25	2,44
Dur(M) (horas)	10,81	10,43	3,45

Para melhor entendimento, a Tabela 5.3 apresenta algumas informações adicionais relacionadas aos Casos 29 e 30. Note que as técnicas propostas (i.e. Caso 30) propiciaram reduções modestas nos números de estados simulados e de análises de adequação. No entanto, a grande vantagem está na redução do número de análises de adequação resolvidas por fluxos de potência e por otimização das medidas remediadoras. Novamente, verifica-se o grande potencial da metodologia proposta.

Tabela 5.3: Informações Adicionais – SSB.

	Caso 29	Caso 30
Número de estados simulados	484.926	338.399
Número de análises de adequação	601.154	364.042
Tempo computacional (minutos)	490,05	10,88
<i>Speedup</i>	-	45,03
Número de fluxos de potência	485.931	44.667
Número de otimizações	70.123	10.156

A partir dos resultados obtidos, é possível verificar que a operação na subárea de interesse do sistema SSB é relativamente crítica, pois a chance deste sistema

operar em estados marginais é de aproximadamente 48%. Com o intuito de tornar esta operação menos crítica, são disponibilizados hipoteticamente 30 MW a mais de geração nesta subárea. Considerando este novo reforço em geração, quatro novos estudos de caso são realizados. Conforme apresentado na Tabela 5.4, os dois primeiros (Casos 31 e 32) utilizam a configuração completa do sistema SSB (i.e. 413 barras) e os dois últimos (Casos 33 e 34) utilizam a configuração reduzida (79 barras). A técnica de reconhecimento de padrões, por meio de redes neurais GMDH, é utilizada nos Casos 32 (sistema completo) e 34 (sistema reduzido). As estimativas dos índices de bem-estar considerando estes novos casos estão apresentadas na Tabela 5.5.

Tabela 5.4: Técnicas Utilizadas.

Casos	Redução da Rede de Transmissão	Redes Neurais
31	Não	Não
32	Não	Sim
33	Sim	Não
34	Sim	Sim

Tabela 5.5: Índices de Confiabilidade – SSB Reforçado (+30MW).

ÍNDICES	Caso 31	Caso 32	Caso 33	Caso 34
P(S)	0,9787	0,9795	0,9791	0,9791
P(M)	0,0204	0,0197	0,0202	0,0202
Freq(S) (oc./ano)	147,7	138,09	151,01	152,08
Freq(M) (oc./ano)	147,7	138,09	153,32	152,08
Dur(S) (horas)	57,95	61,96	56,64	56,24
Dur(M) (horas)	1,21	1,24	1,15	1,16

A partir dos resultados apresentados na Tabela 5.5, é possível notar que a adição de apenas 30 MW foi suficiente para tornar a operação na subárea de interesse menos crítica. As chances de operar em um estado marginal reduziram de 47,8% (Casos 29 e 30) para aproximadamente 2%. Os índices referentes à falha também

apresentaram reduções significativas: LOLP de 1% para 0,08% e LOLF de 11 interrupções por ano para aproximadamente 3.

Na Tabela 5.6 são apresentados, para os Casos 31 até 34, o número de estados simulados, o total de análises de adequação, as análises de adequação resolvidas por fluxo de potência e as análises de adequação resolvidas por otimização das medidas remediadoras. Também são apresentados os tempos computacionais e o *speedups* obtido.

Tabela 5.6: Informações Adicionais – SSB Reforçado (+30MW).

	Caso 31	Caso 32	Caso 33	Caso 34
Número de estados simulados	40.140	41.021	26.702	26.990
Número de análises de adequação	242.029	101.584	135.511	38.333
Tempo computacional (minutos)	515,2	206,0	21,5	2,7
<i>Speedup</i>	-	2,50	23,89	190,82
Número de fluxos de potência	173.513	73.601	107.589	34.876
Número de otimizações	67.133	27.191	13.716	1.611

Os Casos 31 a 34 revelaram um excelente desempenho da metodologia proposta. Por exemplo, sem utilizar redes neurais e a rede de transmissão reduzida foram necessários 515,2 minutos para realizar cerca de 242.000 análises de adequação. Com a metodologia proposta, foram gastos apenas 2,7 minutos para analisar cerca de 38.000 estados.

5.4 CONCLUSÕES

Este capítulo apresentou algumas aplicações dos conceitos propostos nos Capítulos 3 e 4 para a avaliação da confiabilidade convencional e preventiva de sistemas compostos. A precisão e eficiência computacional da metodologia proposta foram demonstradas através dos resultados apresentados pelas referidas aplicações.

A utilização simultânea das técnicas de redução probabilística da rede de transmissão e de redes neurais produziu excelentes resultados. Em relação ao sistema IEEE-MRTS-96, o qual se caracteriza pela rede de transmissão estressada, o ganho obtido ficou nos níveis daqueles apresentados pelos estudos individuais de cada técnica. No entanto, para o sistema SSB foram obtidos *speedups* de até 190.

A obtenção de tais *speedups* e a manutenção de bons níveis de precisão para as estimativas dos índices obtidos, demonstram que as ferramentas propostas nesta tese representam contribuições importantes para viabilizar a realização de estudos de confiabilidade, tanto convencional como preventiva, em sistemas reais de grande porte.

CAPÍTULO 6

CONCLUSÕES

6.1 INTRODUÇÃO

A principal característica da avaliação da confiabilidade preventiva é a ligação entre metodologias probabilísticas e determinísticas. Esta ligação é realizada através da utilização de critérios determinísticos, os quais têm impactos significativos na precisão dos índices, no esforço computacional exigido e, portanto, na eficiência dessas metodologias.

A avaliação de índices de bem-estar tem como base conceitual a divisão dos estados operativos do sistema em três grupos: saudáveis, marginais e de falha. No que se refere a sistemas de geração e transmissão, a identificação desses estados deve ser realizada por meio de uma lista de contingências. A utilização de uma lista composta por um grande número de contingências implica em substanciais acréscimos no esforço computacional exigido. Por outro lado, a determinação de uma lista com poucos componentes, ou com componentes que não causam impacto significativo no desempenho do sistema, pode produzir resultados que não atinjam o objetivo da aplicação do método.

Os índices convencionais de confiabilidade são estimados a partir da reprodução dos estados de falha do sistema. Neste caso, as funções testes incidem sobre *eventos raros*, uma vez que, geralmente, os sistemas falham pouco. Além de possuir um grupo a mais de estados operativos, os índices de bem-estar são baseados em complexas funções teste, as quais são calculadas a partir de estados de sucesso: saudáveis ou marginais. Portanto, se o esforço computacional demandado na

avaliação da confiabilidade convencional já é elevado, este se torna ainda mais crítico na avaliação da confiabilidade preventiva.

A pesquisa bibliográfica mostra um número limitado de trabalhos sobre avaliação da confiabilidade preventiva de sistemas compostos. Este fato comprova a grande dificuldade de implementação dessa nova metodologia, principalmente em sistemas reais de grande porte.

Dentre os passos necessários para a avaliação da confiabilidade convencional e preventiva, a análise de adequação dos estados operativos dos sistemas é certamente o que apresenta maior custo computacional. Por este motivo, a presente tese dedicou especial atenção a esta etapa do processo. Estudos detalhados das técnicas propostas para reduzir o esforço computacional foram realizados com o propósito de identificar a validade da aplicação das mesmas.

6.2 CONCLUSÕES DO TRABALHO

A partir dos conceitos teóricos propostos e dos resultados numéricos, obtidos da implementação computacional, a seguir são apresentadas as principais conclusões e contribuições deste trabalho:

- O modelo DC de programação linear via Primal-Dual de Pontos Interiores com base reduzida é utilizado para a análise de desempenho dos estados operativos. Este modelo resolve o problema de otimização das ações remediadoras em duas etapas: na primeira, adota-se uma capacidade de transmissão ilimitada para todos os circuitos; e, na segunda, consideram-se somente as restrições *ativas* de capacidade de transmissão, i.e. aquelas que apresentarem fluxos acima de um percentual de seus respectivos limites (e.g. 70% de suas capacidades nominais). Com este procedimento, a dimensão da matriz de coeficientes do problema de otimização foi sensivelmente reduzida e, conseqüentemente, o custo da análise de adequação dos estados operativos se tornou bem menos *caro*. Ao utilizar este modelo, o erro percentual máximo obtido nas estimativas dos índices foi de 0,65%, o que representou um excelente resultado;
- A metodologia proposta para a redução probabilística da rede de transmissão consiste na divisão do sistema em quatro áreas, a saber: de interesse, de contingência, de otimização e externa. Sua aplicação em algoritmos de avaliação da confiabilidade, tanto convencional quanto preventiva, foi bastante atrativa, não só pela redução do custo das análises de adequação, como também pela manutenção da precisão das estimativas dos índices. Além disso, o espaço de estados do problema é restringido, uma vez que não é mais necessária a simulação de todos os equipamentos do sistema;
- A incorporação de redes neurais na avaliação da confiabilidade preventiva possibilitou a classificação de um grande número de estados operativos do sistema através de um simples polinômio. As redes neurais são utilizadas para classificar os estados de sucesso em saudáveis e marginais, e não para estimar diretamente os índices de bem-estar. Os resultados obtidos comprovaram a grande eficiência desta técnica, pois a perda de precisão nas estimativas ficou

dentro de níveis aceitáveis e o tempo computacional foi significativamente reduzido;

- A metodologia proposta é capaz de dividir os estados marginais em críticos e não-críticos. Para tal, um montante de corte de carga é definido previamente como sendo limite. Ao analisar a lista de contingências, o algoritmo também verifica o montante de corte de carga para cada contingência. Se pelo menos um equipamento levar o sistema ao estado de falha, com corte de carga superior ao valor limite, então o estado é classificado como *marginal crítico*. Em caso contrário, se todos os cortes de carga forem menor que o valor crítico, o estado é *marginal não-crítico*. Obviamente, se não há corte de carga para todas as contingências, o estado é saudável. Com esta divisão nos estados marginais, torna-se possível quantificá-los melhor e, também, determinar duas listas de contingências, onde a primeira é composta pelas contingências críticas e a segunda pelas não-críticas. A identificação da ordem de criticidade dos componentes é um produto bastante relevante na operação de sistemas;
- A obtenção das estimativas para os índices de frequência e duração limitava a utilização da simulação Monte Carlo não-sequencial na avaliação da confiabilidade preventiva de sistemas compostos. Esta barreira foi eliminada com o uso de uma nova função teste, extremamente eficiente, baseada no modelo de Markov para a representação da carga e no processo de transição de estado um passo a frente;
- A partir da experiência adquirida na avaliação da confiabilidade preventiva, também foi proposta a incorporação de redes neurais na confiabilidade convencional. As redes neurais são utilizadas para identificar somente os estados de sucesso e, neste caso, evitar a realização da análise de adequação. Para os estados não classificados como sucesso, a análise de adequação é realizada normalmente (i.e. através de fluxo de potência e/ou otimização das medidas remediadoras). Novamente, as redes neurais não são utilizadas para estimar os índices diretamente, e sim para filtrar estados de sucesso, *bem definidos* a partir do conhecimento adquirido em simulações passadas. Este procedimento permite incorporar um aprendizado dinâmico à simulação Monte Carlo;

- A metodologia proposta foi capaz de estimar índices de perda de carga por barra ou área, pois, conforme mencionado no parágrafo anterior, a tendência é sempre analisar a adequação dos estados de falha através de fluxo de potência e/ou da otimização das medidas remediadoras. Utilizando uma estratégia análoga para estados marginais, também foi possível estimar índices de bem-estar por barra ou área, o que tornou esta metodologia ainda mais abrangente;
- A utilização combinada da redução da rede de transmissão e da incorporação de redes neurais no processo de avaliação da confiabilidade convencional e preventiva, propiciou reduções expressivas no custo computacional requerido. Como exemplo, foram obtidos *speedups* bastante elevados, principalmente para sistemas de grande porte. Se por um lado a redução da rede de transmissão restringe a dimensão do problema, tornando mais ágil a análise de adequação, por outro, a utilização de redes neurais reduz o número destas análises. Portanto, estas técnicas acabam sendo complementares, pois ambas atacam o problema através de caminhos distintos.

Finalmente, os testes realizados com sistemas reais de médio e grande porte mostraram o potencial da metodologia proposta para a avaliação da confiabilidade convencional e preventiva. Foi numericamente comprovado que o emprego das técnicas de redução da rede de transmissão e de utilização de redes neurais produz excelentes resultados, os quais são acompanhados de substanciais reduções no tempo de processamento.

6.3 PROPOSTA DE CONTINUIDADE DOS TRABALHOS

A partir da experiência obtida durante o desenvolvimento deste trabalho, algumas sugestões são propostas para trabalhos futuros:

- Desenvolver equivalentes mais inteligentes para definir a redução da rede de transmissão, capazes, por exemplo, de reter as barras de geração mais importantes da área externa. Neste caso, os impactos na área de interesse, advindos das saídas de elementos críticos da área externa, serão melhor representados, resultando em ajustes mais precisos das máximas injeções de potência nas barras de fronteira;
- Investigar a aplicação de outros tipos de redes neurais, e.g. máquina de vetor suporte, bem como a de sistemas inteligentes, e.g. regras *fuzzy*, na avaliação da confiabilidade preventiva. Ademais, outros conjuntos de variáveis de entrada com maior representatividade para treinamento e validação podem ser testados;
- Gerar, artificialmente, estados de falha para treinamento e validação das redes neurais, o que permite antecipar sua utilização no processo de avaliação da confiabilidade;
- Pesquisar a viabilidade da aplicação da simulação Monte Carlo cronológica para avaliar a confiabilidade preventiva de sistemas compostos;
- Incluir estudos de manutenção programada na avaliação da confiabilidade preventiva e verificar seu impacto nos índices de bem-estar;
- Desenvolver uma metodologia de planejamento da operação baseada na avaliação da confiabilidade preventiva. Informações relacionadas a listas de contingências, aos índices de bem-estar e aos estados marginais críticos e não-críticos devem ser consideradas dentro desta metodologia;
- Calcular os custos associados à ocorrência de estados marginais. Se um sistema reside em um estado marginal, o operador deverá modificar sua trajetória de operação tendo em vista conduzi-lo a um estado saudável. Para modificar esta

trajetória, algumas ações devem ser tomadas, o que pode incorrer em custos adicionais de operação;

- Utilizar o modelo de fluxo de potência ótimo com base reduzida. Neste caso, além de se obter um modelo matemático mais abrangente, estudos relacionados à segurança dinâmica poderão ser realizados. Também poderão ser identificadas as contingências críticas do ponto de vista da segurança (*security*).

6.4 PRODUÇÃO CIENTÍFICA

No âmbito desta tese, houve envolvimento em três projetos de pesquisa (2 no Brasil e 1 em Portugal) relativos ao planejamento de sistemas elétricos baseado em confiabilidade convencional e preventiva, o que gerou a publicação de 13 artigos, sendo: 2 em periódicos internacionais, 3 em congressos internacionais e 8 em congressos nacionais. Estes artigos são listados a seguir:

Periódicos Internacionais:

1. A.M. Leite da Silva, L.C. Resende, L.A.F. Manso, R. Billinton, “Well-Being Analysis for Composite Generation and Transmission Systems”, ***IEEE Trans. on Power Systems***, Vol. 19, No. 4, pp. 1763-1770, November 2004;
2. A.M. Leite da Silva, L.A.F. Manso, W.S. Sales, L.C. Resende, M.J.Q. Aguiar, M.A. Matos, J.A. Peças Lopes, V. Miranda, “Application of Monte Carlo Simulation to Generating System Well-Being Analysis Considering Renewable Sources”, ***European Transactions on Electrical Power***, aceito para publicação 2006.

Congressos Internacionais:

1. A.M. Leite da Silva, A.M. Cassula, L.C. Resende, R.M. Almeida, M.T. Yamasaki, G.M.F. Paula, “Reliability Evaluation of Distribution Systems Considering Automatic Reclosers”, *Proceedings of the 8th PMAPS'2004 - Probability Methods Applied to Power Systems*, Ames, USA, CD-ROM, 12-16/Sept./2004;
2. A.M. Leite da Silva, L.C. Resende, L.A.F. Manso, “Application of Monte Carlo Simulation to Well-Being Analysis of Large Composite Power Systems”,

Proceedings of the 9th PMAPS'2006 - Probability Methods Applied to Power Systems, Stockholm, Sweden, CD-ROM, 11-15/June/2006;

3. A.M. Leite da Silva, W.S. Sales, L.C. Resende, L.A.F. Manso, L.S. Rezende, “Evolution Strategies to Transmission Expansion Planning Considering Unreliability Costs”, *Proceedings of the 9th PMAPS'2006 - Probability Methods Applied to Power Systems*, Stockholm, Sweden, CD-ROM, 11-15/June/2006.

Congressos Nacionais:

1. L.A.F. Manso, W.S. Salles, A.M. Leite da Silva e L.C. Resende, “Confiabilidade Preventiva de Sistemas de Geração via Simulação Monte Carlo Não-Sequencial”, *Anais do V CLAGTEE – Congresso Latino Americano de Geração e Transmissão de Energia Elétrica*, São Pedro, SP, 16 -20 Novembro, 2003;
2. A.M. Leite da Silva, L.A.F. Manso, W.S. Salles, L.C. Resende, V. Miranda, M.J.Q. Aguiar, M.A. Matos, J.A. Peças Lopes, “Análise de Bem Estar de Sistemas com Elevada Penetração de Renováveis – O Caso Português”, *Anais do ENER'04 – Simpósio sobre Energias Renováveis*, Figueira da Foz, Portugal, 6-7 Maio, 2004, Vol. I, pp. 79-84;
3. L.A.F. Manso, A.M. Leite da Silva, L.C. Resende, W.S. Salles, R. Billinton, “Avaliação da Confiabilidade Preventiva em Sistemas Elétricos de Potência”, *Anais do IX SEPOPE – Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica*, Rio de Janeiro, RJ, 23 -27 Maio, 2004;
4. A.M. Cassula, A.M. Leite da Silva, L.C. Resende, R.M. Almeida, M.T. Yamasaki, G.M.F. Paula, “Impacto da Utilização de Religadores Automáticos na Confiabilidade de Sistemas de Distribuição”, *Anais da Transmission and*

Distribution IEEE/PES/T&D Latin America Conference, São Paulo, SP, Brasil, 8 a 11 de Novembro 2004;

5. M.A. Matos, A.M. Leite da Silva, M.J.Q. Aguiar, J.A. Peças Lopes, L.C. Resende, L.A.F. Manso, “Um Estudo Sobre a Segurança de Abastecimento de Eletricidade em Portugal”, *Anais do 1º Encontro Nacional de Riscos, Segurança e Fiabilidade, ESRA – European Safety and Reliability Associations, Lisboa, Portugal, 11 -13 Maio, 2005, Vol. I, pp. 201-211;*
6. A.M. Leite da Silva, W.S. Sales, L.C. Resende, L.A.F. Manso, V. Miranda, M.J.Q. Aguiar, M.A. Matos e J.A. Peças Lopes, “Análise de Bem-Estar de Sistemas de Geração com Elevada Penetração de Energia Renovável”, *Anais do XVIII SNTPEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica, Curitiba, Pr, artigo GPL-275, CD-ROM, 16 - 21 de Outubro, 2005;*
7. L.C. Resende, A.M. Leite da Silva, L.A.F. Manso e V. Miranda, “Avaliação da Confiabilidade Preventiva de Sistemas Elétricos Baseada em Técnicas de Reconhecimento de Padrões”, *Anais do X SEPOPE – Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, Florianópolis, SC, artigo SP-025,21 -25 Maio, 2006;*
8. L.S. Rezende, A.M. Leite da Silva, L.A.F. Manso, W.S. Sales e L.C. Resende, “Planejamento da Expansão da Transmissão de Sistemas de Potência Utilizando Colônia de Formigas”, *Artigo submetido e aceito para o XVI CBA – Congresso Brasileiro de Automática, Salvador, BA, 3 - 6 de Outubro, 2006.*

Atualmente, encontra-se em processo de submissão um novo artigo para o *IEEE Transactions on Power Systems*.

APÊNDICE A

TRANSIÇÃO DE ESTADO UM PASSO A FRENTE

A.1 INTRODUÇÃO

A demonstração do processo de transição de estado um passo a frente, apresentada nesta seção, é realizada para estimar o índice LOLF (*Loss of Load Frequency* – Frequência de Perda de Carga). No entanto, este estimador também pode ser utilizado para estimar os índices de confiabilidade preventiva (e.g. Freq(S) e Freq(M)).

Na Figura A.1, MT e MS indicam, respectivamente, o número de estados e o número de estados de sucesso que o sistema pode ingressar por meio de uma transição do estado de falha x^k .

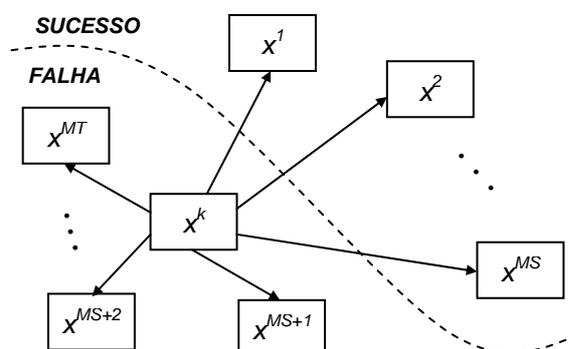


Figura A.1: Estado de Falha x^k e sua Vizinhança.

O processo de estimação proposto está relacionado com a identificação de uma transição possível de um estado amostrado de falha x^k para um estado vizinho x^m . A frequência de saída do estado x^k para o estado x^m , onde a única diferença entre estes dois estados é a mudança no estado operativo do componente j (por exemplo, um estado muda de $x_j = a$ para $x_j = b$ com taxa de transição λ_{ab} ou λ_{km}), é dada por:

$$f_{km} = P(x^k) \times \lambda_{ab} = P(x^k) \times \lambda_{km} \quad (\text{A.1})$$

A frequência de saída do estado x^k é dada por

$$f_k^{out} = P(x^k) \times \lambda_k^{out} \quad (\text{A.2})$$

onde λ_k^{out} é a soma de todas as taxas de transição entre o estado de falha x^k e qualquer estado diretamente conectado a ele.

A probabilidade da transição km , definida como a probabilidade do sistema ingressar no estado x^m partindo do estado x^k , é avaliada como a razão entre as frequências f_{km} e f_k^{out} , isto é

$$P_{km} = \frac{f_{km}}{f_k^{out}} = \frac{\lambda_{km}}{\lambda_k^{out}} = \frac{\lambda_{km}}{\sum_{i=1}^{MT} \lambda_{ki}} \quad (\text{A.3})$$

onde MT representa o número total de estados que o sistema pode entrar a partir de uma transição do estado x^k , como mostra a Figura A.1.

A Equação (A.3) fornece a base para a construção da função de distribuição de probabilidade associada às transições de saída de um estado de falha amostrado x^k . Baseado nesta função de distribuição, um estado vizinho x^m pode ser amostrado e a função teste proposta para o índice LOLF pode ser aplicada.

Considerando que a taxa de transição de um estado de falha x^k para um estado x^m é dada por

$$\lambda_{km} = P_{km} \times \lambda_k^{out} \quad (\text{A.4})$$

a soma das taxas de transição entre um estado de falha x^k e todos os estados de sucesso, $\Delta\lambda_k$, que podem ser alcançados a partir de x^k em uma transição é

$$\Delta\lambda_k = \sum_{i=1}^{MS} \lambda_{ki} = \sum_{i=1}^{MS} (P_{ki} \times \lambda_k^{out}) = \left(\sum_{i=1}^{MS} P_{ki} \right) \times \lambda_k^{out} \quad (\text{A.5})$$

onde MS representa o número de estados de sucesso que o sistema pode ingressar após deixar o estado x^k , como mostra a Figura A.1.

Observe que a probabilidade $\sum_{i=1}^{MS} P_{ki}$ é naturalmente amostrada através da simulação Monte Carlo não-seqüencial utilizando o processo de transição de estado um passo à frente. Portanto, a função teste da Equação (A.6) é equivalente à função teste da Equação (A.7):

$$F_{LOLF}(x^k) = \begin{cases} 0 & \text{se } x^k \in X_S \\ \lambda_k^{out} & \text{se } x^k \in X_F \text{ e } x^m \in X_S \\ 0 & \text{se } x^k \in X_F \text{ e } x^m \in X_F \end{cases} \quad (\text{A.6})$$

$$F_{LOLF}(x^k) = \begin{cases} 0 & \text{se } x^k \in X_S \\ \Delta\lambda_k & \text{se } x^k \in X_F \end{cases} \quad (\text{A.7})$$

A função teste dada pela Equação (A.7) é a mesma proposta em [MPL92], onde $\Delta\lambda_k$ é a soma das taxas de transição entre o estado de falha x^k e todos os estados de sucesso, que podem ser alcançados a partir de uma transição de x^k . Na próxima seção será apresentado um exemplo numérico para ilustrar esta equivalência.

A.2 EXEMPLO NUMÉRICO

Considere o sistema simples com 6 estados ilustrado na Figura A.2. Somente as transições de saída dos estados 4 e 5 são representadas.

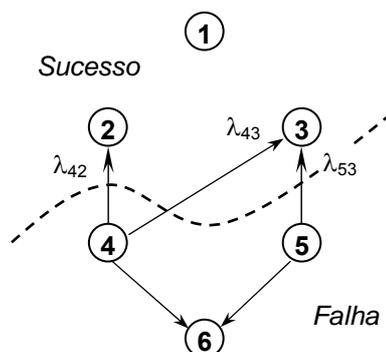


Figura A.2: Sistema Simples com 6 estados.

O índice LOLF é dado por

$$\begin{aligned}
 LOLF &= P_4 \times (\lambda_{42} + \lambda_{43}) + P_5 \times \lambda_{53} \\
 &= P_4 \times \lambda_4 \times \left(\frac{\lambda_{42}}{\lambda_4} \right) + P_4 \times \lambda_4 \times \left(\frac{\lambda_{43}}{\lambda_4} \right) + P_5 \times \lambda_5 \times \left(\frac{\lambda_{53}}{\lambda_5} \right)
 \end{aligned} \tag{A.8}$$

onde P_i representa a probabilidade do estado i e λ_i a soma de todas as taxas de transição entre o estado de falha i e qualquer estado diretamente conectado a ele.

Considerando $P_4 = 0,2$; $P_5 = 0,1$; $\frac{\lambda_{42}}{\lambda_4} = 0,25$; $\frac{\lambda_{43}}{\lambda_4} = 0,5$ e $\frac{\lambda_{53}}{\lambda_5} = 0,5$; uma amostragem perfeita, obtida a partir de 100 amostras, fornecerá 20 amostras do estado 4 e 10 do estado 5, então:

$$\begin{aligned}
 LOLF &= \frac{20}{100} \times \lambda_4 \times 0,25 + \frac{20}{100} \times \lambda_4 \times 0,5 + \frac{10}{100} \times \lambda_5 \times 0,5 \\
 &= \frac{5}{100} \times \lambda_4 + \frac{10}{100} \times \lambda_4 + \frac{5}{100} \times \lambda_5
 \end{aligned}$$

Nesta simulação Monte Carlo perfeita, o estado 4 será alcançado em 20 amostras, em 5 delas o sistema transita para o estado 2 e em 10 para o estado 3. Uma interpretação similar pode ser aplicada para o estado 5. Este resultado está de acordo com Expressão (A.8), e ilustra numericamente que as estimativas da função teste dada pela Equação (A.6) não são tendenciosas.

APÊNDICE B

O PRIMAL-DUAL DE PONTOS INTERIORES

B.1 INTRODUÇÃO

Desde 1940, a programação linear – que busca otimizar funções lineares sujeitas a restrições lineares – tem sido utilizada em muitas aplicações incluindo despacho de geração ótimo, fluxo de potência ótimo, etc. Em todas as aplicações, o algoritmo de programação linear, o chamado simplex, tem se mostrado muito satisfatório. No entanto, recentes avanços nas modelagens e nos algoritmos estão alterando a programação linear e uma nova classe de algoritmos está emergindo. Estes avanços têm dificultado a aplicação da programação linear para a resolução de problemas de grande porte e complexos.

A migração da resolução de programação linear para os métodos de pontos interiores teve início na década de 80 [AMLS92]. Os métodos de pontos interiores são fundamentalmente diferentes do método simplex clássico. A maneira mais fácil de verificar esta diferença é através da análise do polígono associado com o problema de programação linear, formado pelas restrições do problema. Como exemplo, podemos assumir um polígono no espaço tridimensional. Em cada iteração, o método simplex caminha ao longo dos vértices do polígono em questão. Por outro lado, os métodos de pontos interiores caminham por pontos internos do polígono, sem considerar as influências dos vértices.

Estes avanços, em conjunto com o desenvolvimento computacional, tornaram possíveis as resoluções de problemas de programação linear que, em anos anteriores, eram consideradas irrealizáveis.

Tendo em vista as considerações anteriores, esta seção apresenta uma abordagem linear do método Primal-Dual de Pontos Interiores, realizada de acordo com o referencial teórico apresentado em [A93, C97, C01].

B.2 ALGORITMO PRIMAL-DUAL DE PONTOS INTERIORES

Considere o seguinte problema de programação linear:

$$\begin{aligned}
 \text{Min} \quad & c^T x \\
 \text{s.a.} \quad & Ax \leq b \\
 & x \geq 0
 \end{aligned} \tag{B.1}$$

Onde, $c \in \mathbb{R}^n$
 $x \in \mathbb{R}^n$
 $b \in \mathbb{R}^m$
 $A \in \mathbb{R}^{m \times n}$

Através da utilização de variáveis de folga, $x_{n+1}, x_{n+2}, \dots, x_{n+m}$, as restrições de desigualdade podem ser transformadas em restrições de igualdade. Assim, o problema Primal pode ser reescrito da seguinte forma:

$$\begin{aligned}
 \text{Min} \quad & c^T x \\
 \text{s.a.} \quad & Ax = b \\
 & x \geq 0
 \end{aligned} \tag{B.2}$$

Onde, $c \in \mathbb{R}^{n+m}$
 $x \in \mathbb{R}^{n+m}$
 $b \in \mathbb{R}^m$
 $A \in \mathbb{R}^{m \times (n+m)}$

Com isto, tem-se o respectivo problema Dual:

$$\begin{aligned}
 \text{Max} \quad & b^T y \\
 \text{s.a.} \quad & A^T y + z = c \\
 & z \geq 0
 \end{aligned} \tag{B.3}$$

Onde, $y \in \mathbb{R}^m$
 $z \in \mathbb{R}^{n+m}$

Substituindo as condições de não-negatividade nas variáveis x e z pela justaposição de uma barreira logarítmica à função objetivo nos problemas Primal e Dual, as Equações (B.2) e (B.3) podem ser reescritas da seguinte forma, respectivamente:

$$\begin{aligned} \text{Min} \quad & c^T x - \mu \sum_{i=1}^{n+m} \ln(x_i) \\ \text{s.a.} \quad & Ax = b \\ & \mu > 0 \end{aligned} \tag{B.4}$$

Onde, $c \in \mathbb{R}^{n+m}$
 $x \in \mathbb{R}^{n+m}$
 $b \in \mathbb{R}^m$
 $A \in \mathbb{R}^{m \times (n+m)}$

e

$$\begin{aligned} \text{Max} \quad & b^T y + \mu \sum_{i=1}^{n+m} \ln(z_i) \\ \text{s.a.} \quad & A^T y + z = c \\ & \mu > 0 \end{aligned} \tag{B.5}$$

Onde, $y \in \mathbb{R}^m$
 $z \in \mathbb{R}^{n+m}$

Neste ponto, procedendo a inicialização conhecida como BigM descrita em [C97], a qual necessita de uma solução inicial factível, o problema de otimização dado pelas Equações (B.4) e (B.5) toma a seguinte forma matricial:

$$\begin{bmatrix} \mathbf{Z} & \mathbf{0} & \mathbf{X} \\ \mathbf{A} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{A}^T & \mathbf{I}_{n+m+2} \end{bmatrix} \begin{bmatrix} dx \\ dy \\ dz \end{bmatrix} = \begin{bmatrix} \mu e - XZe \\ 0 \\ 0 \end{bmatrix} \quad (\text{B.6})$$

Onde: I_{n+m+2} é o vetor de variáveis (com elementos unitários) de decisão adicionado às variáveis de folga e às variáveis artificiais, estas necessárias para a obtenção de uma solução factível;

Z é uma matriz diagonal formada pelos elementos do vetor z ;

X é uma matriz diagonal formada pelos elementos do vetor x ;

$e = [1, 1, \dots, 1]^T$;

dx , dy e dz são os passos que serão acrescentados às variáveis x , y e z , respectivamente.

Se uma solução inicial não factível for considerada, então a Equação matricial (B.6) apresentará um erro de factibilidade nos problemas Primal e Dual. No entanto, este pode ser levado em conta durante o processo iterativo e irá aparecer no vetor do lado direito do sistema ao invés dos elementos nulos. Portanto, neste caso, a equação matricial será:

$$\begin{bmatrix} \mathbf{Z} & \mathbf{0} & \mathbf{X} \\ \mathbf{A} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{A}^T & \mathbf{I}_{n+m} \end{bmatrix} \begin{bmatrix} dx \\ dy \\ dz \end{bmatrix} = \begin{bmatrix} me - XZe \\ b - \mathbf{A}x \\ c - \mathbf{A}^T y - z \end{bmatrix} \quad (\text{B.7})$$

Uma boa escolha para o cálculo do parâmetro barreira pode ser feita através do *gap* de dualidade [C97], como segue:

$$\mu = \sigma \frac{\sum_{i=1}^{n+m} x_i z_i}{n+m} \quad (\text{B.8})$$

onde $0 < \sigma < 1$.

Com esta escolha, pode-se definir:

$$v(\mu) = \mu e - XZe \quad (\text{B.9})$$

onde $v(\mu) \in \mathbb{R}^{n+m}$.

Com isto, pode-se reescrever o sistema matricial como:

$$Zdx + Xdz = \mu e - XZe = v(\mu) \quad (\text{B.10})$$

$$\mathbf{A}dx = b - \mathbf{A}x \quad (\text{B.11})$$

$$\mathbf{A}^T dy + dz = c - \mathbf{A}^T y - z \quad (\text{B.12})$$

Definindo-se os vetores:

$$V_1 = b - \mathbf{A}x \quad (\text{B.13})$$

$$V_2 = c - \mathbf{A}^T y - z \quad (\text{B.14})$$

Tem-se das equações (B.12) e (B.10) que:

$$dz = V_2 - \mathbf{A}^T dy \quad (\text{B.15})$$

$$dx = Z^{-1}[v(\mu) - Xdz] \quad (\text{B.16})$$

E com a substituição das equações (B.15) e (B.16) em (B.11):

$$\begin{aligned} \mathbf{A}dx &= \mathbf{A}Z^{-1}[v(\mu) - Xdz] = \mathbf{A}Z^{-1}[v(\mu) - X(V_2 - \mathbf{A}^T dy)] = \\ &= \mathbf{A}Z^{-1}v(\mu) - \mathbf{A}Z^{-1}XV_2 + \mathbf{A}Z^{-1}X\mathbf{A}^T dy = V_1 \end{aligned} \quad (\text{B.17})$$

ou

$$dy = D_1^{-1}V_3 \quad (\text{B.18})$$

Onde

$$D_1 = AD_2A^T \quad (\text{B.19})$$

$$V_3 = V_1 - AZ^{-1}v(\mu) + AD_2V_2 \quad (\text{B.20})$$

$$D_2 = Z^{-1}X \quad (\text{B.21})$$

A seguir atualizam-se as variáveis primais e duais:

$$x(k+1) = x(k) + \rho\alpha_p dx(k) \quad (\text{B.22})$$

$$y(k+1) = y(k) + \rho\alpha_D dy(k) \quad (\text{B.23})$$

$$z(k+1) = z(k) + \rho\alpha_D dz(k) \quad (\text{B.24})$$

onde, $0 < \rho < 1$; e

$$\alpha_p \equiv \min \left[-\frac{x_i(k)}{dx_i(k)} \mid \forall dx_i(k) < 0, 0 < i < n+m \right] \quad (\text{B.25})$$

$$\alpha_D \equiv \min \left[-\frac{z_i(k)}{dz_i(k)} \mid \forall dz_i(k) < 0, 0 < i < n+m \right] \quad (\text{B.26})$$

A última etapa é testar o critério de convergência (normalmente, o gap de dualidade). Se este for satisfeito, o processo estará terminado; caso contrário calcula-se um novo valor para o parâmetro barreira e realiza-se uma outra iteração.

APÊNDICE C

GMDH

C.1 INTRODUÇÃO

O método de grupo para manipulação de dados (GMDH – *Group Method of Data Handling*) foi proposto por Ivakhnenko em 1968. Este método pode ser interpretado como um modelo plástico de rede neural de camadas justapostas, sendo estas criadas uma por vez, a partir da camada de entrada, por meio da utilização de uma regra de aprendizado heurística [I71, F84].

O modelo do neurônio de uma rede GMDH é representado por uma função de ativação polinomial de segundo grau, sobre o seu conjunto de entrada, sendo a sua saída y obtida pela Equação:

$$y = A + Bx_i + Cx_j + Dx_i^2 + Ex_j^2 + Fx_ix_j \quad (\text{C.1})$$

Onde x_i e x_j são suas entradas e A , B , C , D , E e F são os coeficientes do polinômio, que equivalem aos pesos das conexões de uma outra rede neural cuja função de ativação é o combinador linear, conforme mostra a Figura C.1.

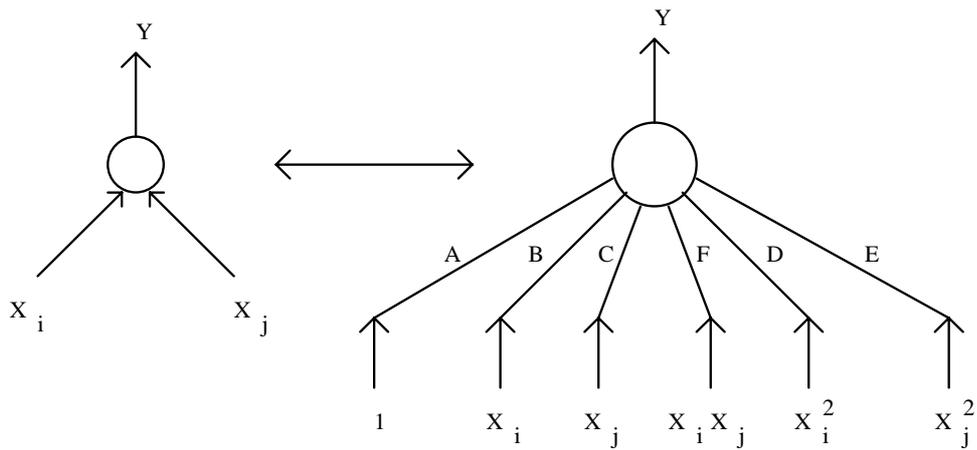


Figura C.1: Modelo do Neurônio.

O algoritmo GMDH permite criar as camadas da rede polinomial, uma por vez, a partir da camada de entrada. É necessário que se tenha n padrões de entrada-saída, divididos em dois conjuntos distintos, chamados de conjunto de treinamento e conjunto de teste, como mostra a Figura C.2. Para ilustrar a idéia, a rede terá m entradas e somente uma saída.

	Y	X				
		x_1	x_2	x_m		
CONJUNTO DE TREINAMENTO	y_1	x_{11}	x_{12}	• • •		x_{1m}
	y_2	x_{21}	x_{22}			x_{2m}
	•	•	•			•
	•	•	•			•
	y_{nt}	$x_{nt,1}$	$x_{nt,2}$			$x_{nt,m}$
CONJUNTO DE TESTE	•	•	•			•
	•	•	•			•
	•	•	•			•
	y_n	x_{n1}	x_{n2}			x_{nm}

Figura C.2: Padrões de Entrada-Saída.

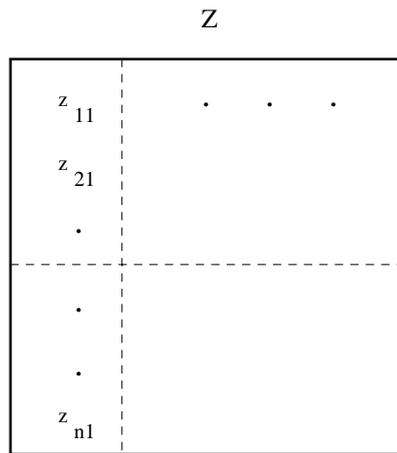


Figura C.3: Matriz Z.

iii) Escolher os neurônios que melhor representam os valores de Y.

Para cada coluna j de Z aplicar a seguinte equação:

$$reg_j^2 = \frac{\sum_{i=nt+1}^n (y_i - z_{ij})^2}{\sum_{i=nt+1}^n y_i^2} \quad j = 1, 2, \dots, \frac{m(m-1)}{2} \tag{C.4}$$

Também chamada de critério da regularidade [F84]. Ordenar as colunas de Z, em ordem crescente de reg_j^3 , de tal modo que a primeira coluna de Z corresponda ao menor valor de reg_j . Substituir então, as colunas de X pelas $(m + pi \cdot m)$ primeiras colunas de Z, obtendo-se assim, uma nova matriz X; o valor de pi deve ser $0 \leq pi \leq 1$.

iv) Armazenar o menor valor de reg_j na variável RMIN. A Figura C.4 mostra um exemplo típico de curva para RMIN em função do número de camadas criadas, ou iterações.

³ O critério da regularidade é, usualmente, representado pelo símbolo “r”. Nesta tese, foi utilizado o símbolo “reg” com a finalidade de diferenciar do símbolo do corte de carga, apresentado na Seção 3.3.

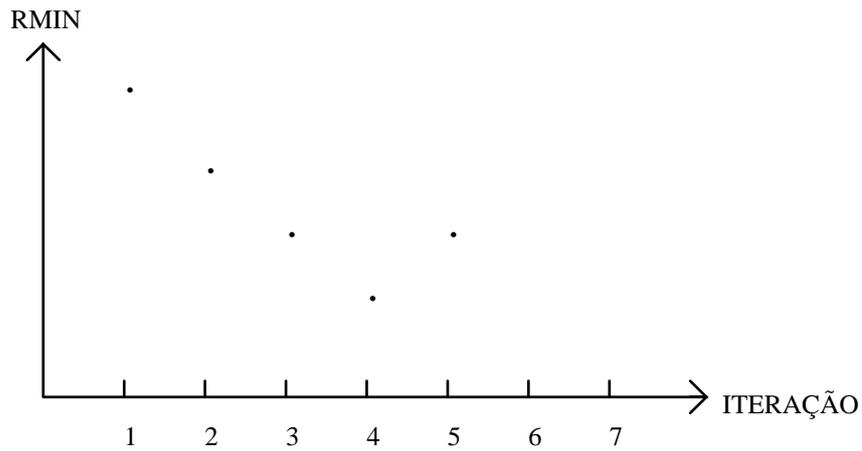


Figura C.4: Curva de RMIN.

Se o valor atual de RMIN é menor que o valor de RMIN da camada anterior, então, executar os passos "i" e "ii", criando-se assim, uma nova camada para a rede. Porém, se o valor atual de RMIN for maior, assumir que a curva de RMIN alcançou o seu valor mínimo na camada anterior. Portanto, devem-se utilizar os resultados gerados até a camada anterior e parar o processo de treinamento. A Figura C.5 mostra a arquitetura da rede criada.

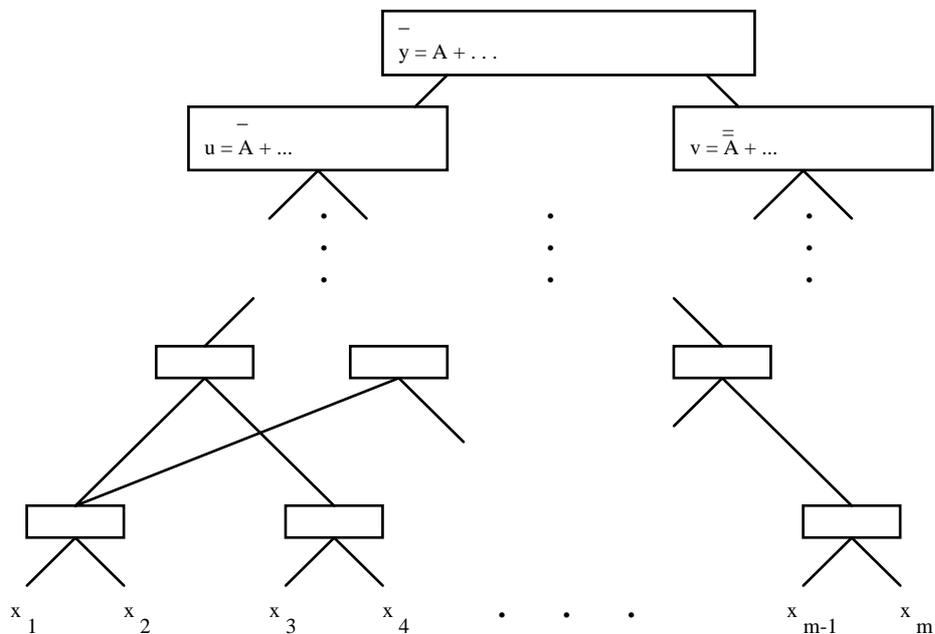


Figura C.5: Árvore de Polinômios.

Portanto, fazendo-se as substituições algébricas necessárias, chega-se a um polinômio da forma:

$$\bar{y} = a + \sum_{i=1}^m b_i x_i + \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m b_{ijk} x_i x_j x_k + \dots \quad (\text{C.5})$$

Conhecido como polinômio de Ivakhnenko.

APÊNDICE D

IEEE RELIABILITY TESTE SYSTEM

D.1 INTRODUÇÃO

O sistema IEEE-RTS (*IEEE Reliability Test System*) [APM79] possui 24 barras, 38 circuitos e 32 unidades geradoras distribuídas entre 14 usinas, perfazendo um total de 3405MW de potência instalada. O valor de pico anual da carga total do sistema atinge 2850MW. O diagrama deste sistema está ilustrado na Figura 3.1, apresentada na Seção 3.2.

D.2 DADOS DO SISTEMA

Através das tabelas dadas a seguir são apresentados os principais dados do sistema IEEE-RTS.

Tabela D.1: Dados de Classes de Usina.

CLASSE	NOME	ESTADOS	λ (1/ano)	MTTR (horas)
1	Classe 1	2	2,97959	60,00
2	Classe 2	2	19,46670	50,00
3	Classe 3	2	4,42424	20,00
4	Classe 4	2	4,46939	40,00
5	Classe 5	2	7,30000	50,00
6	Classe 6	2	9,12500	40,00
7	Classe 7	2	9,22105	50,00
8	Classe 8	2	7,61739	100,00
9	Classe 9	2	7,96364	150,00

Tabela D.2: Dados de Usina.

USINA	NOME	BARRA	UNIDADES	CLASSE	POT. ATIVA (MW)		POT. REATIVA (MVAr)	
					Min.	Max.	Min.	Max.
1	USINA-1	15	5	1	12,00	24,00	0,00	4,80
2	USINA-2	1	2	2	20,00	40,00	0,00	32,00
3	USINA-3	2	2	2	20,00	40,00	0,00	32,00
4	USINA-4	1	2	4	60,00	152,00	-50,00	30,40
5	USINA-5	2	2	4	60,00	152,00	-50,00	30,40
6	USINA-6	7	3	5	120,00	200,00	0,00	50,00
7	USINA-7	15	1	6	160,00	310,00	-100,00	108,60
8	USINA-8	16	1	6	160,00	310,00	-100,00	108,60
9	USINA-9	23	2	6	160,00	310,00	-100,00	108,60
10	USINA-10	13	3	7	160,00	394,00	0,00	137,80
11	USINA-11	23	1	8	300,00	700,00	-50,00	280,00
12	USINA-12	18	1	9	400,00	800,00	-100,00	200,00
13	USINA-13	21	1	9	400,00	800,00	-100,00	200,00
14	USINA-14	22	6	3	32,00	100,00	-20,00	10,00

Tabela D.3: Composição da Carga.

BARRA	CARGA		PARTICIPAÇÃO (%)		
	(MW)	(MVAr)	RES	COM	IND
1	216,6	44,00	20,0	40,0	40,0
2	193,8	39,40	30,0	70,0	0,0
3	359,0	73,00	20,0	10,0	70,0
4	148,2	30,00	20,0	80,0	0,0
5	142,6	29,00	10,0	20,0	70,0
6	273,6	55,60	30,0	10,0	60,0
7	250,8	51,00	20,0	10,0	70,0
8	342,0	69,40	50,0	50,0	0,0
9	347,8	70,60	20,0	30,0	50,0
10	387,6	78,80	20,0	10,0	70,0
13	530,0	107,60	10,0	20,0	70,0
14	387,6	78,80	20,0	20,0	60,0
15	632,6	128,40	10,0	30,0	60,0
16	199,6	40,60	20,0	40,0	40,0
18	667,0	135,40	10,0	10,0	80,0
19	364,8	74,00	20,0	10,0	70,0
20	256,6	52,00	20,0	20,0	60,0

Tabela D.4: Dados Determinísticos de Circuito.

DE	PARA	R (%)	X (%)	SUS (MVar)	CAPAC. (MVA)
1	2	0,26	1,39	46,11	175,00
1	3	5,46	21,12	5,72	175,00
1	5	2,18	8,45	2,29	175,00
2	4	3,28	12,67	3,43	175,00
2	6	4,97	19,20	5,20	175,00
3	9	3,08	11,90	3,22	175,00
3	24	0,23	8,39	0,00	400,00
4	9	2,68	10,37	2,81	175,00
5	10	2,28	8,83	2,39	175,00
6	10	1,39	6,05	245,90	175,00
7	8	1,59	6,14	1,66	175,00
8	9	4,27	16,51	4,47	175,00
8	10	4,27	16,51	4,47	175,00
9	11	0,23	8,39	0,00	400,00
9	12	0,23	8,39	0,00	400,00
10	11	0,23	8,39	0,00	400,00
10	12	0,23	8,39	0,00	400,00
11	13	0,61	4,76	9,99	500,00
11	14	0,54	4,18	8,79	500,00
12	13	0,61	4,76	9,99	500,00
12	23	1,24	9,66	20,30	500,00
13	23	1,11	8,65	18,18	500,00
14	16	0,50	3,89	8,18	500,00
15	16	0,22	1,73	3,64	500,00
15	21	0,63	4,90	10,30	500,00
15	21	0,63	4,90	10,30	500,00
15	24	0,67	5,19	10,91	500,00
16	17	0,33	2,59	5,45	500,00
16	19	0,30	2,31	4,85	500,00
17	18	0,18	1,44	3,03	500,00
17	22	1,35	10,53	22,12	500,00
18	21	0,33	2,59	5,45	500,00
18	21	0,33	2,59	5,45	500,00
19	20	0,51	3,96	8,33	500,00
19	20	0,51	3,96	8,33	500,00
20	23	0,28	2,16	4,55	500,00
20	23	0,28	2,16	4,55	500,00
21	22	0,87	6,78	14,24	500,00

Tabela D.5: Dados Estocásticos de Circuito.

DE	PARA	λ (1/ano)	MTTR (horas)
1	2	0,24	16,00
1	3	0,51	10,00
1	5	0,33	10,00
2	4	0,39	10,00
2	6	0,48	10,00
3	9	0,38	10,00
3	24	0,02	768,00
4	9	0,36	10,00
5	10	0,34	10,00
6	10	0,33	35,00
7	8	0,30	10,00
8	9	0,44	10,00
8	10	0,44	10,00
9	11	0,02	768,00
9	12	0,02	768,00
10	11	0,02	768,00
10	12	0,02	768,00
11	13	0,40	11,00
11	14	0,39	11,00
12	13	0,40	11,00
12	23	0,52	11,00
13	23	0,49	11,00
14	16	0,38	11,00
15	16	0,33	11,00
15	21	0,41	11,00
15	21	0,41	11,00
15	24	0,41	11,00
16	17	0,35	11,00
16	19	0,34	11,00
17	18	0,32	11,00
17	22	0,54	11,00
18	21	0,35	11,00
18	21	0,35	11,00
19	20	0,38	11,00
19	20	0,38	11,00
20	23	0,34	11,00
20	23	0,34	11,00
21	22	0,45	11,00

REFERÊNCIAS BIBLIOGRÁFICAS

- [A93] A. ARBEL, "Exploring Interior-Point Linear Programming: Algorithms and Software", London: The MIT Press, 1993.
- [AB89] R. N. Allan e R. Billinton, "Reliability Concepts of Composite Power Systems", IEEE Tutorial Course, 90EH0311-1-PWR, The Institute of Electrical and Electronic Engineers, New York, UEA, 1989.
- [ABBG94] R. N. Allan, R. Billinton, A. M. Breipohl e C. H. Grigg, "Bibliography on the Application of Probability Methods in Power System Reliability Evaluation, 1987-1991", *IEEE Trans. on Power Systems*, Vol. 9, No. 1, pp. 41-49, February 1994.
- [ABBG99] R. N. Allan, R. Billinton, A. M. Breipohl e C. H. Grigg, "Bibliography on the Application of Probability Methods in Power System Reliability Evaluation, 1992-1996", *IEEE Trans. on Power Systems*, Vol. 14, No. 1, pp. 51-57, February 1999.
- [AE00] K. Audomvongseree e B. Eua-Arporn, "Composite System Reliability Evaluation Using AC Equivalent Network", Proceedings. of the Int. Conf. on Power System Technology - PowerCon 2000, Vol. 2, pp. 751-756, Dec. 2000.
- [AHLM03] G.J. Anders, G. Hamoud, A.M. Leite da Silva e L.A.F. Manso, "Optimal Outage Scheduling - Example of Application to a Large Power System", *International Journal of Electrical Power & Energy Systems*, Vol. 25, No. 8, pp. 607-614, Oct. 2003.

- [AKRV89] I. Adler, N. Karmarkar; M. G. C. Resende, M. G. C. Veiga, "An Implementation of Karmarkar's Algorithm for Linear Programming", *Mathematical Programming*, Vol. 44, 1989.
- [AMLS92] G. Astfalk, I. Lustig, R. Marsten e D. Shanno, "The interior-point method for linear programming", *Software, IEEE*, Vol. 9, No. 4, pp. 61-68, July 1992.
- [APM79] IEEE Reliability Test system Task force of the Application of Probability Methods Subcommittee, "IEEE Reliability Test System", *IEEE Trans. on Power Apparatus and Systems*, Vol. PAS-99, pp. 2047-2054, November 1979.
- [APM99] IEEE APM Subcommittee, "IEEE Reliability Test System – 1996", *IEEE Trans. on Power Systems*, Vol. 14, No. 3, pp. 1010-1020, August, 1999.
- [B04] J. R. P. Barros, "Planejamento da Expansão da Transmissão Baseado em Custos Marginais de Confiabilidade", Tese de Doutorado, UNIFEI, 2004.
- [BA88] R. Billinton e R. N. Allan, "Reliability Assessment of Large Electric Power Systems", Kluwer Academic Publishers Massachusetts, UEA, 1988.
- [BA94] R. Billinton e R. N. Allan, "Reliability Evaluation of Power Systems", 2nd Edition, Plenum Press, New York, 1994.
- [BF94] R. Billinton e M. Fotuhi-Firuzabad, "A Basic Framework For Generating System Operating Health Analysis", *IEEE Trans. on Power Systems*, Vol.9, No. 3, pp.1610-1617, August 1994.
- [BFB01] R. Billinton, M. Fotuhi-Firuzabad e L. Bertling, "Bibliography on the Application of Probability Methods in Power System Reliability Evaluation, 1996-1999", *IEEE Trans. on Power Systems*, Vol. 16, No. 4, pp. 595-602, November 2001.

- [BFK98] R. Billinton, M. Fotuhi-Firuzabad e R. Karki, "A New Approach to Adequacy Assessment of Small Isolated Power Generating Systems", Proc. of EMPD, Vol. 2, pp. 625 -630, 1998.
- [BFMM01] C.L.T. Borges, D.M. Falcao, J.C.O. Mello e A.C.G. Melo, "Composite Reliability Evaluation by Sequential Monte Carlo Simulation on Parallel and Distributed Processing Environments", *IEEE Trans. on Power Systems*, Vol. 16, Issue 2, pp. 203-209, May 2001.
- [BG90] S. Burns e G. Gross, "Value of Service Reliability", *IEEE Trans. on Power Systems*, Vol. 5, No. 3, pp.825-834, August 1990.
- [BK92] R. Billinton e E. Khan "A Security Based Approach to Composite Power System Reliability Evolution", *IEEE Trans. on Power Systems*, Vol. PWRS-7, No. 1, pp. 65-71, February 1992.
- [BK99a] R. Billinton e R. Karki, "Capacity Reserve Assessment Using System Well-Being Analysis", *IEEE Trans. on Power Systems*, Vol. 14, No. 2, pp. 433-438, May 1999.
- [BK99b] R. Billinton e R. Karki, "Application of Monte Carlo Simulation to Generating System Well-Being Analysis", *IEEE Trans. on Power Systems*, Vol. 14, No. 3, pp. 1172-1177, August 1999.
- [BL93] R. Billinton e W. Li, "A System State Transition Sampling Method for Composite System Reliability Evaluation", *IEEE Trans. on Power Systems*, Vol. 8, No. 3, pp. 761-770, August 1993.
- [BL94] R. Billinton e G. Lian, "Composite Power System Health Analysis Using A Security Constrained Adequacy Evaluation Procedure", *IEEE Trans. on Power Systems*, Vol. 9, No. 2, pp. 936-941, May 1994.

- [BO88] R. Billinton e J. Oteng-Adjei, "Cost/Benefit Approach to Establish Optimum Adequacy Level for Generating System Planning", *IEEE Proc. Part C*, Vol. 135, pp. 81-87, 1988.
- [C01] E. D. Castronuovo, "Aplicação de Métodos de Pontos Interiores no Fluxo de Potência Ótimo Não-Linear com Utilização de Processamento de Alto Desempenho", Tese de Doutorado, UFSC, 2001.
- [C97] E. D. Castronuovo, "Solução do Fluxo de Potência Ótimo via Método de Pontos Interiores, com Aplicação de Computação de Alto Desempenho", Dissertação de Mestrado, UFSC, 1997.
- [D67] T.E. Dy Liacco, "The Adaptive Reliability Control System", *IEEE Trans. on Power Apparatus and Systems*, Vol. PAS-86, No. 5, pp. 517-531, May 1967.
- [DGF96] J. G. Dalton, D. L. Garrison e C.M. Fallon, "Value-Based Reliability Transmission Planning", *IEEE Trans. on Power Systems*, Vol. 11, No. 3, pp. 1400-1408, August 1996.
- [F84] S. J. Farlow, "Self-Organizing Methods in Modeling. GMDH Type Algorithm." Marcel Dekker. New York, Basel. 1984.
- [F98] C. Ferreira, "Modelagem dinâmica de cargas elétricas utilizando Redes Neurais Plásticas", Tese de Doutorado, UNIFEI, 1998.
- [FB97] M. Fotuhi-Firuzabad e R. Billinton, "An Energy Based Approach to Evaluate Optimum Interruptible Load Carrying Capability in Isolated and Interconnected Systems Including Well-Being Constraints", *IEEE Trans. on Power Systems*, Vol. 12, No. 4, pp. 1676-1681, November 1997.

- [FC78] L.H. Fink e K. Carlsen, "Operating Under Stress and Strain", *IEEE Spectrum*, pp. 48-53, March 1978.
- [FSMP95] R.N. Fontoura, M. Th. Schilling, J.C.O. Mello e J.L.R. Pereira, "Topological Reduction Considering Uncertainties", *IEEE Trans. on Power Systems*, Vol. 10, No. 2, pp. 739-744, May 1995.
- [G94] S. Granville, "Optimal Reactive Dispatch through Interior Point Methods", *IEEE Trans. on Power Systems*, Vol. 9, pp. 136-146, 1994.
- [GF99] L. Goel e C. Fenf, "Well-Being Framework for Composite Generation and Transmission System Reliability Evaluation", *IEE Proc. – Gener. Trans. Distrib.*, Vol. 146, No. 5, pp. 528-534, September 1999.
- [I71] A. G. Ivakhnenko, "Polynomial Theory of Complex Systems", *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. SMC-1, No. 4, pp. 364-378, October 1971.
- [KB88] S. Kumar e R. Billinton, "Adequacy Equivalents in Composite Power System Evaluation", *IEEE Trans. on Power Systems*, Vol. 3, No. 3, pp. 1167-1173, Aug. 1988.
- [LEW93] A. M. Leite da Silva, J. Endrenyi e L. Wang, "Integrated Treatment of Adequacy and Security in Bulk Power System Reliability Evaluations", *IEEE Trans. on Power Systems*, Vol. 8, No. 1, pp. 275-285, February 1993.
- [LMMB00] A. M. Leite da Silva, L. A. F. Manso, J. C. O. Mello, e R. Billinton "Pseudo-Chronological Simulation for Composite Reliability Analysis with Time Varying Loads", *IEEE Trans. on Power Systems*, Vol. 15, No. 1, pp. 73-80, February 2000.
- [LMSRAMLM04] A. M. Leite da Silva, L. A. F. Manso, W. S. Sales, L. C. Resende, M. J. Q. Aguiar, M. A. Matos, J. A. P. Lopes, V. Miranda, "Application of Monte Carlo

- Simulation to Generating System Well-Being Analysis Considering Renewable Sources”, *PMAAPS – Probabilistic Methods Applied to Power Systems*, pp. 439-444, September, 2004.
- [LPMM97] A. M. Leite da Silva, A. G. Perez, J. W. Marangon Lima e J. C. O. Mello, “Loss of Load Costs in Generation Capacity Reliability Evaluation”, *Int. Journal on Electric Power Systems Research*, Vol. 41, pp. 109-116, 1997.
- [LPS89] A. M. Leite da Silva, M. V. F. Pereira, M. Th. Schilling, “Power Systems Analysis under Uncertainties – Concepts and Techniques”, Artigo Convidado, II SEPOPE, São Paulo, 1989.
- [LRM06] A.M. Leite da Silva, L.C. Resende, L.A.F. Manso, “Application of Monte Carlo Simulation to Well-Being Analysis of Large Composite Power Systems”, *Proceedings of the 9th PMAAPS’2006 - Probability Methods Applied to Power Systems*, Stockholm, Sweden, CD-ROM, 11-15/June/2006;
- [LRMB04] A. M. Leite da Silva, L. C. Resende, L. A. F. Manso e R. Billinton, “Well-being Analysis for Composite Generation and Transmission Systems”, *IEEE Tran. on Power Systems*, Vol. 19, No. 4, pp. 1763-1770, November 2004.
- [LSP00] X. Luo, C. Singh e A.D. Patton, “Power System Reliability Evaluation Using Self Organizing Map”, *Power Engineering Society Winter Meeting*, Vol. 2, pp. 1103-1108, 23-27 Jan. 2000.
- [M83] A. J. Monticelli, “Fluxo de Carga em Redes de Energia Elétrica”, Edgard Blücher, São Paulo, 1983.
- [M94] J. C. O. Mello, “Determinação do Valor da Confiabilidade em Sistemas Compostos Geração e Transmissão”, Tese de Doutorado, PUC/RJ, 1994.

- [M99] L. A. F. Manso, "Um Ambiente para Planejamento de Sistemas de Geração e Transmissão Utilizando o Valor da Confiabilidade", Tese de Doutorado, UNIFEI, 1999.
- [MA99] H.A.M. Maghraby e R.N. Allan, "Application of DC Equivalents to the Reliability Evaluation of Composite Power Systems", *IEEE Trans. on Power Systems*, Vol. 14, No. 1, pp. 355-361, Feb. 1999.
- [MDGS79] A. Monticelli, S. Deckmann, A. Garcia e B. Stott, "Real-Time External Equivalents for Static Security Analysis", *IEEE Trans. On Power Systems*, Vol. 98, pp. 498-508, 1979.
- [ML02] L. A. F. Manso e A. M. Leite da Silva, "Modelagem de Cargas Variantes no Tempo na Avaliação de Confiabilidade Composta Via Simulação Monte Carlo Não-Seqüencial", Anais do XIV CBA – Congresso Brasileiro de Automática, Natal, RN, (CD-rom) pp. 2652-2657, Setembro, 2002.
- [ML04] L. A. F. Manso e A. M. Leite da Silva, "Avaliação da Confiabilidade Composta de Sistemas de Grande Porte", Anais do XV CBA - Congresso Brasileiro de Automática, Gramado, Brasil, Setembro, 2004.
- [MLM99a] L. A. F. Manso, A. M. Leite da Silva e J. C. O. Mello, "Avaliação da Confiabilidade de Sistemas de Geração e Transmissão Considerando Cargas Variantes no Tempo", XV SNPTEE, GPL11, Vol. 6, pp 43-50, outubro 1999.
- [MLM99b] L. A. F. Manso, A. M. Leite da Silva e J. C. O. Mello, "Comparison of Alternative Methods for Evaluating Loss of Load Costs in Generation and Transmission System", *Int. Journal on Electric Power Systems Research*, Vol. 50, pp. 107-114, 1999.
- [MLP97] J. C. O. Mello, A. M. Leite da Silva, M. V. F. Pereira, "Efficient Loss of Load Cost Evaluation by Combined Pseudo-Sequential and State Transition

- Simulation”, *IEE Proc. – Gener. Trans. Distrib.* , Vol. 144, No. 2, pp. 147-154, March 1997.
- [MLRSB04] L. A. F. Manso, A. M. Leite da Silva, L. C. Resende, W. S. Sales, R. Billinton, “Avaliação da Confiabilidade Preventiva de Sistemas de Potência”, Anais do IX SEPOPE - Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, Rio de Janeiro, (CD-ROM) - artigo SP-065, Maio, 2004.
- [MPL92] A. C. G. Melo, M. V. Pereira e A. M. Leite da Silva, “Frequency and Duration Calculations in Composite Generation and Transmission Reliability Evaluation”, *IEEE Trans. on Power Systems*, Vol. 7, No. 2, pp. 469-476, May 1992.
- [MPL93] A. C. G. Melo, M. V. Pereira e A. M. Leite da Silva, “A Conditional Probability Approach to the Calculation of Frequency and Duration Indices in Composite Reliability Evaluations”, *IEEE Trans. on Power Systems*, Vol. 8, No. 3, pp. 1118-1125, August 1993.
- [MPL94] A. C. G. Melo, M. V. Pereira e A. M. Leite da Silva, “Evaluation of Reliability Worth in Composite System Based on Pseudo-Sequential Monte Carlo Simulation”, *IEEE Trans. on Power Systems*, Vol. 9, No. 3, pp. 1318-1326, August 1994.
- [MPLM97] J. C. O. Mello, M. V. F. Pereira, A. M. Leite da Silva e A. C. G. Melo, “Application of Chronological Load Modeling in Composite Reliability Worth Evaluation”, *Int. Journal on Electric Power System Research*, Vol. 40, pp. 167-174, 1997.
- [PB92] M. V. F. Pereira e N. J. Balu, “Composite Generation/Transmission Reliability Evaluation”, *Proc. of the IEEE*, Vol. 80, No. 4, pp. 470-491, April 1992.

- [R02] L. C. Resende, “Avaliação da Confiabilidade Preventiva de Sistemas de Potência”, Dissertação de Mestrado, UNIFEI, 2002.
- [RLJM00] A. M. Rei, A. M. Leite da Silva, J. L. Jardim e J. C. O. Mello, “Static and Dynamic Aspects in Bulk Power System Reliability Evaluations”, *IEEE Trans. on Power Systems*, Vol. 15, No. 1, pp. 189-195, February 2000.
- [RLMM06] L. C. Resende, A. M. Leite da Silva, L. A. F. Manso; V. Miranda, “Avaliação da Confiabilidade Preventiva de Sistemas Elétricos via Técnica de Reconhecimento de Padrões”, Anais do X SEPOPE - Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, Florianópolis, (CD-ROM), artigo SP-025, Maio, 2006.
- [S96] J.C.S. Souza, “Depuração de Dados na Supervisão em Tempo-Real de Sistemas de Potência via Técnica de Reconhecimentos de Padrões”, Tese de Doutorado, PUC-RIO, 1996.
- [SB77] C. Singh e R. Billinton, “System Reliability Modeling and Evaluation”, Hutchinson, London, 1977.
- [SB85] B. S. da Silva Filho e O. G. P. Bravo, “Pesquisa Operacional”, Makron Books do Brasil, São Paulo, 1985.
- [SB95] A. Sankarakrishman e R. Billinton, “Sequential Monte Carlo Simulation for Composite Power System Reliability Analysis with Time Varying Loads”, *IEEE Trans. on Power Systems*, Vol. 10, pp. 1540-1545, 1995.
- [SBZ05] Y. Song, G. Bu e R. Zhang, “ A Fast Method Probabilistic Reliability Assessment of Bulk Power Systems Using FSOM Neural Network as System States Filters”, Transmission and Distribution Conference and Exhibition: Asia and Pacific, 2005 IEEE/PES, pp. 1-6, Aug. 2005.

- [SLA96] J.C.S. Souza, A.M. Leite da Silva e A.P. Alves da Silva, "Data Debugging for Real-Time Power System Monitoring Based on Pattern Analysis", *IEEE Transactions on Power Systems*, Vol. 11, issue 3, pp. 1592-1599, Aug. 1996.
- [SLA97a] J.C.S. Souza, A.M. Leite da Silva e A.P. Alves da Silva, "Online Topology Determination and Bad Data Suppression in Power System Operation Using Artificial Neural Networks", 20th International Conference on Power Industry Computer Applications, pp. 46-53, 11-16 May 1997.
- [SLA97b] J.C.S. Souza, A.M. Leite da Silva e A.P. Alves da Silva, "Data Visualization And Identification of Anomalies in Power System State Estimation Using Artificial Neural Networks", *IEE Proceedings – Generation, Transmission and Distribution*, Vol. 144, issue 5, pp. 445-455, Sept. 1997.
- [SM79] B. Stott, J. L. Marinho e O. Alsac, "Review Of Linear Programming Applied To Power System Rescheduling", *IEEE Conference Proc. Power, Industry Computer Applications Conference*, pp. 142-154, 1979.
- [SMP96] J. Tome Saraiva, V. Miranda e L.M.V.G. Pinto, "Generation/Transmission Power System Reliability Evaluation by Monte-Carlo Simulation Assuming a Fuzzy Load Description", *IEEE Trans. on Power Systems*, Vol. 11, no. 2, pp. 690-695, May 1996.
- [SPF93] C. Singh, T. Pravin Chander e J. Feng, "Convergence Characteristics of Two Monte Carlo Models for Reliability Evaluation of Interconnected Power Systems", *Int. Journal on Electric Power Systems Research*, Vol. 28, pp. 1-8, 1993.
- [UA94] J.R. Ubeda e R. N. Allan, "Reliability Assessment of Composite Hydrothermal Generation and Transmission Systems Using Sequential Simulation", *IEE Proc. – Gener. Trans. Distrib*, Vol. 141, No. 4, pp. 257-262, July 1994.

- [W49] J. B. Ward, "Equivalent Circuits for Power Flow Studies", *AIEE Transactions*, Vol. 98, pp. 498-508, 1949.
- [WB03] P. Wang e R. Billinton, "Reliability Assessment of a Restructured Power System Using Reliability Network Equivalent Techniques", *IEE Proc.-Gen., Transm and Dist.*, Vol. 150, No. 5, pp. 555-560, Sept. 2003.
- [WBG02] P. Wang, R. Billinton e L. Goel, "Unreliability Cost Assessment of an Electric Power System Using Reliability Network Equivalent Approaches", *IEEE Trans. on PWRs*, Vol. 17, No. 3, pp. 549-556, Aug. 2002.
- [WDM94] Y. Wu, A. S. Debs e R. E. Marsten, "A Direct Nonlinear Predictor Corrector Primal-Dual Interior Point Algorithm for Optimal Power Flows", *IEEE Trans. on Power Systems*, Vol. 9, pp. 876-883, 1994.