

UNIVERSIDADE ESTADUAL PAULISTA - UNESP  
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Lilian Yuli Isoda**

**Carlos Roberto Minussi**  
(Orientador)

**Análise da Estabilidade Estática de Tensão de  
Sistemas Elétricos de Potência Usando uma Rede Neural  
Baseada na Teoria da Ressonância Adaptativa**

Tese de Doutorado submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira – UNESP, como parte dos requisitos para a obtenção do título de *Doutor em Engenharia Elétrica*.

Ilha Solteira – SP, março de 2009.

## FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação  
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

I85a	<p>Isoda, Lilian Yuli. Análise da estabilidade estática de tensão de sistemas elétricos de potência usando uma rede neural baseada na teoria da ressonância adaptativa / Lilian Yuli Isoda. -- Ilha Solteira : [s n ], 2009 113 f. : il.</p> <p>Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2009</p> <p>Orientador: Carlos Roberto Minussi Bibliografia: p. 81-87</p> <p>1. Sistemas de energia elétrica - Estabilidade. 2. Redes neurais (Computação). 3. Teoria da ressonância adaptativa. 4. Lógica difusa.</p>
------	--



UNIVERSIDADE ESTADUAL PAULISTA

CAMPUS DE ILHA SOLTEIRA

FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

### CERTIFICADO DE APROVAÇÃO

**TÍTULO:** ANÁLISE DA ESTABILIDADE ESTÁTICA DE TENSÃO DE SISTEMAS ELÉTRICOS DE POTÊNCIA USANDO UMA REDE NEURAL BASEADA NA TEORIA DA RESSONÂNCIA ADAPTATIVA

**AUTORA:** LILIAN YULI ISODA

**ORIENTADOR:** Prof. Dr. CARLOS ROBERTO MINUSSI

Aprovada como parte das exigências para obtenção do Título de DOUTOR em ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:



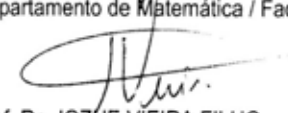
Prof. Dr. CARLOS ROBERTO MINUSSI

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. FRANCISCO VILLARREAL ALVARADO

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. JOZUE VIEIRA FILHO

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. OSVALDO RONALD SAAVEDRA MENDEZ

Departamento de Engenharia de Eletricidade / Universidade Federal do Maranhão



Prof. Dr. EDUARDO NOBUHIRO ASADA

Departamento de Engenharia Elétrica / Escola de Engenharia de São Carlos-USP

Data da realização: 13 de março de 2009.

Ao meu pai Yoshihisa,  
pelo grande homem que foi,  
e à minha mãe Tsutae,  
pela grande mulher que é.

## **Agradecimentos**

Ao Prof. Dr. Carlos Roberto Minussi, pelo empenho e dedicação na orientação do meu trabalho, pelas inúmeras conversas que tivemos sempre incentivando a alcançar o objetivo que traçamos juntos, pelo amigo que foi nos momentos difíceis que enfrentei durante o processo de titulação, meus profundos e sinceros agradecimentos.

Aos meus colegas e aos funcionários do Departamento de Matemática, pelo incentivo recebido. Em especial, ao Prof. Paulo, à Prof<sup>a</sup> Neusa e ao Prof. Villarreal, pelo apoio.

Aos técnicos do laboratório de computação do Departamento de Engenharia Elétrica, Deoclécio e José Roberto, pela assistência.

Aos funcionários da Seção de Pós-graduação, pela atenção com que sempre me atenderam.

Às colegas e amigas Prof<sup>a</sup> Anna Diva e Prof<sup>a</sup> Mara Lúcia pelas sugestões, críticas e discussões sobre o trabalho, e principalmente, pela amizade.

Aos meus pais, Yoshihisa e Tsutae, meus irmãos, Jorge, Madalena, Nelson e Ricardo, que mesmo longe sempre estiveram presente comigo.

ISODA, L. Y. *Análise de estabilidade estática de tensão de sistemas elétricos de potência usando uma rede neural baseada na teoria da ressonância adaptativa*. 2009. 113 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2009.

## Resumo

Nesta tese apresenta-se uma proposta para análise da estabilidade estática de tensão de sistemas de energia elétrica utilizando uma rede neural baseada na arquitetura ART (*Adaptive Resonance Theory*), designada rede neural ARTMAP *Fuzzy*. As redes neurais ART-descendentes apresentam as características de estabilidade e plasticidade, as quais são propriedades imprescindíveis para a realização do treinamento e execução da análise de forma rápida e confiável. A versão ARTMAP *Fuzzy* é uma rede neural supervisionada, ou seja, a extração do conhecimento se processa por estímulos de entrada e de saída. O problema da análise de estabilidade de tensão é formulado considerando-se o estímulo de entrada composto pelas potências ativa e reativa nodais. O estímulo de saída é adotado como sendo a margem de segurança, a qual representa a “distância” entre o ponto de operação do sistema e a fronteira da estabilidade estática de tensão. Esta margem de segurança é calculada, via análise de sensibilidade e álgebra matricial de Kronecker, a partir da função determinante da matriz jacobiana relativa ao problema do fluxo de potência de Newton-Raphson. A operacionalidade das redes neurais é constituída por três fases principais: treinamento (ou aprendizado), análise e treinamento continuado. A fase de treinamento requer uma grande quantidade de processamento, enquanto que a fase de análise é realizada, efetivamente, sem esforço computacional. Esta é, por conseguinte, a principal justificativa para o uso das redes neurais para a resolução de problemas complexos que exigem soluções rápidas, como é o caso de aplicações em tempo real. Na fase de treinamento, o perfil de geração e de carga do sistema elétrico é gerado empregando-se uma distribuição aleatória (ou pseudo-aleatória) e a respectiva saída (margem de segurança) calculada via execução de um programa de fluxo de

potência convencional, com as devidas adaptações. O procedimento aqui proposto é independente da forma com que se estabelece o despacho de geração e como evolui a carga do sistema. Esta abordagem é mais realista, se comparada à maioria das propostas disponibilizadas na literatura especializada, que considera o modelo de crescimento da carga de modo linear. Desta forma, com o uso da rede neural ARTMAP *Fuzzy*, bem como qualquer outra da família ART, pode-se obter, soluções com grande rapidez de resposta e com grande flexibilidade da inclusão de novos padrões, mudanças topológicas, etc., após concluída a fase de treinamento, sem a necessidade de reinicializar o treinamento, propriedade esta definida como sendo treinamento continuado (característica de plasticidade). O treinamento continuado constitui-se num procedimento que permite manter, de forma permanente, a aquisição do conhecimento a partir do treinamento realizado previamente de informações disponibilizadas pela operação do sistema. Para ilustrar a metodologia proposta, apresenta-se uma aplicação considerando-se dois sistemas elétricos de potência-exemplo.

Palavras-chaves: Engenharia Elétrica, Sistemas Elétricos de Potência, Estabilidade Estática de Tensão, Redes Neurais Artificiais, Teoria da Ressonância Adaptativa

ISODA, L. Y. *Static voltage stability analysis of electric power systems using a neural network based on adaptive resonance theory*. 2009. 113 f. Thesis (Electrical Engineering PhD) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2009.

## **Abstract**

This work develops a methodology to effectuate static voltage stability of electrical power systems by neural network. The neural network used is based on the ART (*Adaptive Resonance Theory*) architecture, named ARTMAP Fuzzy neural network. The ART descendent neural networks present the characteristics of stability and plasticity, which are important properties to execute the training and the analysis fast and reliable. The ARTMAP Fuzzy version is a supervised neural network, i.e. the extraction of the knowledge is processed by input/output stimulus. The voltage stability analysis problem is formulated considering the input stimulus composed by the active and reactive nodal power. The output stimulus is adopted as the security margin, which represents the distance with the operation point and the static voltage stability frontier. The security margin is calculated by sensitivity analysis and Kronecker algebra from the determinant function of the Jacobian matrix related to the power flow problem by Newton-Raphson. Neural Network operation is constituted by three principal phase: training (or learning), analysis and continuous training. The training phase needs great processing effort, while the analysis is effectuated without computational effort. This is the principal advantage to use neural networks to solve complex problems that need fast solutions as the real time applications. On the training phase, the generation and load profile is generated using a random (or pseudo random) distribution and the respective output (security margin) is calculated by executing a conventional power-flow with adequate adaptations. The procedure proposed is independent of how is defined the generation dispatch and how the system load evolves. This is a more realistic approach, when compared to the most of the proposals found on the specialized literature that considers the load increasing linearly.

Therefore, using Fuzzy ARTMAP neural network, as well as other ART family network, it is assured to obtain fast solutions (stability characteristics) and with flexibility to include new patterns like, topological changes, etc., after concluded the training phase without reinitializing the training, which characterizes the continuous training (plasticity). The continuous training is a procedure that maintains permanently the acquisition of the knowledge from the training effectuated previously and information from the system operation. To illustrate the proposed methodology two electrical systems were used.

Keywords: Electrical Engineering, Electrical Power Systems, Static Voltage Stability, Artificial Neural Network, Adaptive Resonance Theory.

## Lista de Figuras

3.2.1	Fluxograma do sistema neural proposto para realizar a análise de estabilidade	
	Tensão de sistemas elétricos de potência .....	30
4.2.1	Curva P–V .....	37
5.2.1	Rede neural ART <i>Fuzzy</i> .....	49
5.2.2	Fluxograma da rede neural ART <i>Fuzzy</i> .....	54
5.3.1	Fluxograma da rede neural ARTMAP <i>Fuzzy</i> .....	56
6.2.1	Sistema Composto por 3 Máquinas e 9 Barras .....	64
6.3.1	Representação do Sistema Sul-Brasileiro .....	73
A.2.1.1	Componentes de um neurônio .....	90
A.2.2.1.1	Modelo do neurônio de McCulloch-Pitts .....	91
A.2.2.2.1	Função relé .....	92
A.2.2.2.2	Função lógica <i>threshold</i> .....	92
A.2.2.2.3	Função sigmoide (1) .....	93
A.2.2.2.4	Função sigmoide (2) .....	93
A.3.1	Rede neural artificial .....	94

A.5.1	Treinamento supervisionado .....	96
A.5.2	Treinamento não-supervisionado .....	97
B.2.3.1	Funções de pertinência para a variável <i>tempertura</i> .....	101
B.2.4.1	Conjuntos Nebulosos <i>A</i> e <i>B</i> .....	102
B.2.4.2	Operador <i>AND</i> .....	102
B.2.4.3	Operador <i>OR</i> .....	103
B.2.4.4	Operador <i>NOT</i> .....	103
C.1.1	Sistema Anderson - Fouad .....	104
C.2.1	Sistema Sul-Brasileiro .....	107

## Lista de Tabelas

6.2.1. Comparação dos Métodos ARTMAP <i>Fuzzy</i> e Simul – Três Máquinas	
Síncronas .....	66
6.3.1. Comparação dos Métodos ARTMAP <i>Fuzzy</i> e Simul – Dez Máquinas	
Síncronas .....	73
C.1.1. Dados do sistema de transmissão (Sistema Anderson-Fouad) .....	105
C.1.2. Dados de barras (Sistema Anderson-Fouad) .....	105
C.1.3. Dados de máquinas (Sistema Anderson-Fouad) .....	106
C.2.1. Dados do sistema de transmissão (Sistema Sul-Brasileiro) .....	108
C.2.2. Dados das barras (Sistema Sul-Brasileiro) .....	111
C.2.3. Dados de máquinas síncronas (Sistema Sul-Brasileiro) .....	112

# Sumário

<b>1. Introdução .....</b>	<b>15</b>
<b>2. Estado da Arte .....</b>	<b>20</b>
2.1. Introdução .....	20
2.2. Metodologias de Análise de Estabilidade .....	20
2.3. Análise das Principais Referências Bibliográficas .....	23
2.4. Comentários .....	27
<b>3. Metodologia Proposta Para a Análise de Estabilidade Estática de Tensão</b>	<b>28</b>
3.1. Introdução .....	28
3.2. Esquema Proposto .....	29
3.3. Comentários .....	32
<b>4. Estabilidade de Tensão de Sistemas de Energia Elétrica .....</b>	<b>33</b>
4.1. Introdução .....	33
4.2. Mecanismo da Instabilidade de Tensão .....	34
4.3. Critério de Análise da Estabilidade Estática de Tensão .....	37
4.4. Comentários .....	47

<b>5. Redes Neurais ART <i>Fuzzy</i> e ARTMAP <i>Fuzzy</i> .....</b>	<b>48</b>
5.1. Introdução. ....	48
5.2. Rede Neural ART <i>Fuzzy</i> .....	49
5.3. Rede Neural ARTMAP <i>Fuzzy</i> .....	55
5.4. Estímulos de Entrada da Rede Neural ARTMAP <i>Fuzzy</i> .....	57
5.5. Estímulos de Saída da Rede Neural ARTMAP <i>Fuzzy</i> .....	60
5.6. Comentários .....	61
<b>6. Aplicações das Redes Neurais na Análise de Estabilidade de Tensão</b>	
<b>de Sistemas de Energia Elétrica .....</b>	<b>62</b>
6.1. Introdução .....	62
6.2. Sistema de Três Máquinas Síncronas .....	63
6.3. Sistema de Dez Máquinas Síncronas .....	72
6.4. Comentários e Considerações.....	77
<b>7. Conclusão e Sugestões para Trabalhos Futuros .....</b>	<b>78</b>
7.1. Conclusão .....	78
7.2. Sugestões para Trabalhos Futuros .....	80
<b>Referências .....</b>	<b>81</b>
<b>Apêndice A – Redes Neurais Artificiais .....</b>	<b>88</b>
A.1. Introdução .....	88
A.2. Estrutura de Rede Neural .....	89

A.2.1. Modelo Biológico .....	89
A.2.2. Neurônio Artificial .....	91
A.2.2.1. Neurônio de McCulloch-Pitts .....	91
A.2.2.2. Não-Linearidades .....	92
A.3. Estrutura da Rede Neural Artificial .....	94
A.4. Classificação das Redes Neurais .....	94
A.5. Tipos de Treinamento de Redes Neurais .....	95
<b>Apêndice B - Lógica <i>Fuzzy</i> ou Lógica Nebulosa .....</b>	<b>98</b>
B.1. Introdução .....	98
B.2. Conjuntos Nebulosos .....	99
B.2.1. Fundamentos .....	99
B.2.2. Variáveis Linguísticas .....	100
B.2.3 Funções de Pertinências .....	100
B.2.4. Operadores Lógicos .....	101
<b>Apêndice C – Dados dos Sistemas-Exemplo .....</b>	<b>104</b>
C.1. Dados do Sistema Anderson - Fouad .....	104
C.2. Dados do Sistema Sul - Brasileiro .....	107
<b>Apêndice D – Artigos Publicados e Submetidos Relacionados com a</b>	
<b>Pesquisa de Doutorado .....</b>	<b>113</b>

## Capítulo 1

### Introdução

A estabilidade de ângulo e de tensão constitui-se em importante procedimento de investigação em sistema elétricos de potência (VAN CUTSEM; VOURNAS, 1998; WEHENKEL, 1997). Através da sua análise é possível executar estratégias que visem garantir o suprimento de energia com qualidade e, ainda, evitar, ou pelo menos, minimizar a interrupção do fornecimento de energia aos consumidores. A estabilidade associada aos ângulos corresponde à estabilidade transitória, que consiste na avaliação dos efeitos oriundos de perturbações que causam grandes e indesejáveis oscilações nos ângulos das máquinas síncronas. A estabilidade de tensão refere-se à investigação sobre o comportamento do perfil de tensão nodal do sistema, em destaque, à observação e à identificação de deficiência de suporte de tensão em decorrência do aumento da potência consumida.

A estabilidade de tensão pode ser abordada sob dois pontos de vista: (1) estático e (2) dinâmico. O caráter dinâmico requer um tratamento como um fenômeno que pode ser modelado por um conjunto de equações diferenciais não-lineares (VU, et al. 1995). Trata-se de uma análise complexa e sofisticada, principalmente quando se aborda sistemas de grande porte. Uma forma mais simples, porém igualmente importante da estabilidade de tensão, refere-se à observação do comportamento das tensões nodais, considerando-se o aumento gradativo do perfil do carregamento do sistema, ou seja, a análise qualitativa do ponto de operação. Neste caso, a análise pode ser tratada como um problema linear. As

inferências sobre o sistema são baseadas na análise do comportamento do ponto de equilíbrio, mais especificamente, a partir da análise da matriz jacobiana ( $\mathbf{J}^0$ ) das equações de potências nodais do sistema, constituindo num problema incremental do fluxo de potência formulado via método de Newton-Raphson (ARYA; CHOUBE; SHRIVASTAVA, 2008; JIA; JEYASURYA, 2000; NAN, et al. 2000; SINHA; HAZARIKA, 2000; TIRANUCHIT; THOMAS, 1988; entre outras). Neste caso, o sobrescrito (o) indica que a matriz jacobiana  $\mathbf{J}$  é calculada no ponto de operação do sistema.

Deste modo, a partir da análise da matriz jacobiana  $\mathbf{J}^0$ , pode-se analisar a estabilidade do sistema. Esta análise pode ser realizada, por exemplo, usando a decomposição de autovalores e de autovetores da matriz jacobiana (TIRANUCHIT; THOMAS, 1988), vetor tangente (ZAMBRONI, 2000), entre outras técnicas. O comportamento do sistema, para pequenas perturbações, pode ser analisado através dos autovalores da matriz  $\mathbf{J}^0$ . Se todos os autovalores de  $\mathbf{J}^0$  forem reais e positivos, pode-se concluir que o sistema é estável para pequenas perturbações. Contudo, a instabilidade se caracteriza por haver, pelo menos, um autovalor com parte real negativa (TIRANUCHIT; THOMAS, 1988). O ponto limítrofe ocorre quando a matriz jacobiana  $\mathbf{J}^0$  torna-se singular, ou seja, o determinante da matriz jacobiana  $\mathbf{J}^0$  torna-se, também, nulo. Esta tem sido a forma abordada na maioria das referências bibliográficas pertinentes.

Nesta pesquisa, propõe-se o desenvolvimento de uma metodologia alternativa para a análise da estabilidade estática de tensão de sistemas elétricos de potência baseada no emprego de redes neurais artificiais (HAYKIN, 1994). Redes Neurais Artificiais são estruturas, implementadas em *hardware* e / ou *software*, fundamentadas no mecanismo de funcionamento do cérebro, sendo, por conseguinte, capazes de aprender com a experiência (HAYKIN, 1994; FOGEL, 1995). Para obter os resultados desejados, ou seja, que a rede apresente condições de efetuar diagnósticos complexos, tais redes devem ter configurações formadas por várias unidades de neurônios (ou elementos de processamento), dispostas em fileiras, compondo um arranjo complexo de interligações (WIDROW; LEHR, 1990). Estas interligações são formadas por pesos que devem ser ajustados por algum algoritmo adaptativo. O funcionamento das redes neurais é constituído por duas fases fundamentais: (1) treinamento e (2) análise. A fase de treinamento requer uma grande quantidade de processamento para a sua realização, enquanto que a fase de análise é efetivada, praticamente, sem esforço computacional. Esta é, portanto, a principal justificativa para o uso de redes neurais para resolução de problemas complexos que exigem soluções rápidas, como é o caso

aplicações em tempo real. A fase de treinamento da rede neural é realizada, na maioria das vezes, através da técnica retropropagação (WIDROW; LEHR, 1990), que é reconhecidamente muito lenta e, em muitos casos, não se observa convergência, principalmente quando se trabalha com grandes bases de dados. Novas estruturas neurais têm sido abordadas visando resolver a questão do excessivo tempo de processamento para a realização do treinamento. Neste contexto, destacam-se as redes neurais da família ART (*Adaptive Resonance Theory*) (CARPENTER, et al. 1992), que apresentam as características de estabilidade (sempre é garantida a obtenção de soluções) e plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões, sem perder a memória relacionada aos padrões anteriores).

Neste trabalho usa-se uma rede neural da família ART (ART-descendente) (CARPENTER, et al. 1992), mais especificamente, uma rede ARTMAP *Fuzzy* (CARPENTER, et al. 1992) com inclusões de melhorias visando torná-la, principalmente, mais precisa, se comparada à formulação original (CARPENTER, et al. 1992). Na literatura são encontradas algumas propostas que empregam redes neurais para a análise da estabilidade de tensão (PANDIT, et al. 2007; WAN; EKWUE, 2000) entre outras. Porém, a grande maioria é baseada em redes neurais com treinamento usando-se o algoritmo retropropagação, ou técnica similar, cujos problemas associados foram mencionados anteriormente (treinamento lento, instabilidade, ausência do mecanismo de treinamento continuado).

A rede neural, proposta nesta pesquisa, possui como critério de treinamento, um índice (margem) de segurança baseado na análise de sensibilidade da função determinante na matriz  $\mathcal{J}^o$ , calculada empregando-se o conceito da álgebra de Kronecker (BREWER, 1978; GEROMEL, 1987). Estes índices de segurança são gerados, formando uma base de dados para a execução da fase de treinamento da rede neural, via processamento do programa computacional Simul (SIMUL, 1990). Para a obtenção de tais índices, ao programa SIMUL, foram incluídas modificações necessárias para gerar combinações aleatórias (ou pseudo-aleatórias) de perfis de geração e de carga como forma de “simular” uma grande quantidade de situações operativas do sistema (FERREIRA, et al. 2006) e, conseqüentemente, a obtenção dos índices de segurança correspondentes. Este procedimento de obtenção de perfis (de geração / carga) aleatórios está sendo usado no sentido de tornar o processo de análise mais realista, se comparado ao procedimento comumente usado na literatura que emprega o critério de proporcionalidade dos referidos perfis.

Neste trabalho, por conseguinte, é apresentada a formulação de uma nova metodologia neural para análise da estabilidade de tensão de sistemas elétricos. Tendo em vista as características de desempenho desta metodologia (rapidez de treinamento, precisão dos resultados e flexibilidade de adaptação às diversidades topológicas da rede elétrica), a princípio, pode-se empregá-la para a análise de sistemas elétricos de potência reais.

Assim sendo, as principais contribuições desta pesquisa de doutorado podem ser resumidas nos seguintes itens:

1. desenvolvimento de uma metodologia neural para análise da estabilidade estática de tensão, baseada na rede neural ARTMAP *Fuzzy*. Esta arquitetura proporciona soluções rápidas, confiáveis e permite a inclusão do mecanismo de treinamento continuado, ou seja, sendo capaz de incrementar continuamente o conhecimento sobre o processo;
2. com a inclusão do mecanismo do treinamento continuado, pode-se formular, também, a análise de contingência, bem como extrair o conhecimento considerando-se as diversas configurações da rede elétrica;
3. o treinamento da rede neural é executado, cujo vetor padrão de entrada é constituído por perfis de geração e de carga gerados por um processo aleatório (ou pseudo-aleatório). Com este procedimento, pode-se realizar um treinamento que contempla um grande espectro de variação da geração e a evolução da carga da rede de eletricidade, constituindo-se numa estratégia mais realista, se comparada à prática da maioria das propostas disponibilizadas na literatura (crescimento linear da carga);
4. desenvolvimento de um índice de segurança alternativo para a análise da estabilidade estática de tensão via análise de sensibilidade (FRANK, 1978) e álgebra de Kronecker (BREWER, 1978; GEROMEL, 1987);
5. abre novas perspectivas de desenvolvimento de análise de tensão, considerando-se outros enfoques. Por exemplo, a análise da estabilidade dinâmica (VU, et al.1995) contemplando diversos mecanismos de instabilidade e estratégias de controle.

Após esta breve introdução, é descrita a seguir, também de forma breve, a organização do trabalho.

- Capítulo 2.* Apresenta-se a análise das principais propostas na literatura sobre o problema da análise de estabilidade estática de tensão (estado da arte).
- Capítulo 3.* Apresenta-se o diagrama esquemático da metodologia proposta para a análise estática da tensão.
- Capítulo 4.* É detalhado o procedimento de cálculo do índice (margem) de segurança de tensão.
- Capítulo 5.* Aborda-se a arquitetura neural ARTMAP *Fuzzy*.
- Capítulo 6.* É reservado para a apresentação e discussão dos resultados considerando-se aplicações em sistema de 9 barras (sistema Anderson & Fouad) (ANDERSON; FOUAD, 2003) e um sistema que uma versão da rede elétrica da região sul do Brasil.
- Capítulo 7.* É apresentada a conclusão.

*Referências bibliográficas.*

- Apêndice A.* Apresenta-se uma síntese dos principais conceitos e definições sobre redes neurais artificiais.
- Apêndice B* Apresentam-se, resumidamente, os principais conceitos e recursos sobre lógica *fuzzy*.
- Apêndice C.* Apresentam-se os diagramas unifilares e os dados dos dois sistemas elétricos, os quais são objetos de investigação neste trabalho.
- Apêndice D.* Artigos Publicados e Submetido Relacionados com a Pesquisa de Doutorado.

## Capítulo 2

### Estado da Arte

#### 2.1 Introdução

Neste capítulo, apresenta-se o estado da arte em relação ao problema da estabilidade de tensão (KUNDUR, 1994) de sistemas elétricos de potência. Neste contexto, são abordadas as publicações sobre métodos de análise baseados em várias técnicas usais na literatura especializada. Tratam-se da análise de sensibilidade, autoproblema (análise de autovalor e autovetor), bifurcação, método direto de Lyapunov, bem como métodos em que são usados conceitos da inteligência artificial (redes neurais, lógica *fuzzy*, etc.).

#### 2.2 Metodologias de Análise de Estabilidade

A análise de estabilidade de tensão, por via de regra, é tratada na literatura especializada sob dois enfoques principais: (1) dinâmico; (2) estático. Pode-se, ainda, agregar outros modelos que se caracterizam como quase-estáticos ou quase dinâmicos, tendo em vista a grande diversidade de procedimentos propostos na literatura especializada, ou seja, são

modelos em que a busca de uma solução é realizada por meio de sucessivas linearizações (*e.g.*, os métodos da continuação (SEYDEL, 1994)).

A estabilidade de caráter dinâmico ou estático refere-se à consideração de que a alteração o estado do sistema é causada, respectivamente, por grandes perturbações ou por pequenas perturbações. Ressalta-se que esta divisão é adotada, na literatura, com o propósito de facilitar os cálculos. Para haver estabilidade do ponto de vista dinâmico, é necessário que haja estabilidade estática. Ou seja, a estabilidade estática é uma condição necessária, porém não-suficiente para a observação da estabilidade dinâmica. Deste modo, a estabilidade estática pode ser interpretada apenas como um indicativo (ou estimativa) da estabilidade de tensão.

Nos modelos que descrevem a dinâmica dos sistemas elétricos são preservadas as não-linearidades, evidentemente, com as devidas adaptações ao fenômeno associado às tensões. Neste caso, podem, também, ser introduzidas algumas simplificações, desde que não comprometam por demais a qualidade das soluções. Enfim, vários estudos são realizados visando estabelecer modelos ajustados a cada aplicação e, muitas vezes, buscando-se adequar à técnica de solução a ser empregada. Por exemplo, se a preferência for pelo uso do método direto de Lyapunov (VIDYASAGAR, 2002), é do conhecimento que esta técnica é bastante útil neste tipo de problema. Todavia a sua aplicação fica condicionada a algumas restrições, *e.g.*, as funções não-lineares devem ser integráveis de forma independente do caminho de integração, mais apropriado aos sistemas hamiltonianos (VIDYASAGAR, 2002).

A dinâmica do sistema é descrita por equações diferenciais (equações de diferenças para modelagem discreta) não-lineares. Acrescentam-se ao modelo, equações algébricas não-lineares que contemplam as leis físicas da eletricidade (primeira e segunda lei de Kirchhoff, etc.). Para a obtenção das soluções, empregam-se as várias alternativas de análise de sistemas não-lineares disponibilizadas na literatura especializada, em destaque:

- a) uso de técnicas específicas para análise de sistemas não-lineares (métodos clássicos de resolução de equações diferenciais (quando possível empregá-los), método direto de Lyapunov, etc.);
- b) integração numérica das equações diferenciais conjuntamente com resolução das equações algébricas e interpretação da solução obtida. Este procedimento é empregado quando não for possível obter uma solução algébrica, que é o caso da maioria dos modelos algébrico-

diferenciais não-lineares associados aos problemas do estudo da estabilidade (de ângulo e de tensão) dos sistemas elétricos de potência;

- c) teoria da bifurcação (SEYDEL, 1994);
- d) métodos baseados na inteligência artificial (BENDER, 1996):
  - redes neurais artificiais (HAYKIN, 1994);
  - lógica *fuzzy* (KARTOLOPOULOS, 1996);
  - autômatos celulares (WOLFRAM, 2002);
  - sistemas imunológicos artificiais (DASGUPTA, 1998);
  - etc;
- e) outras metodologias.

No caso da estabilidade estática de tensão, os modelos são, também, não-lineares, porém a análise é focalizada para o ponto de operação do sistema, observando-se a “distância” entre o ponto de equilíbrio estável e a fronteira limítrofe da estabilidade. Esta distância é estabelecida tomando-se a máxima quantidade de carga (máximo carregamento) que pode ser atendida, considerando um ponto de operação particular. A fronteira limítrofe, por suposição, é definida como sendo o lugar geométrico em que se encontra o ponto de equilíbrio instável mais “próximo” ao ponto de operação estável. Por conseguinte, o processo de análise é, geralmente, realizado via sucessivas linearizações. As técnicas mais relevantes são:

- a) análise modal, correspondente ao cálculo e interpretação dos autovalores e dos autovetores das equações associadas à linearização do modelo não-linear do sistema;
- b) análise de sensibilidade (FRANK, 1978);
- c) perturbação singular (VIDYASAGAR, 2002);
- d) método direto de Lyapunov (VIDYASAGAR, 2002) ;
- e) cálculo do fluxo de potência via método de Newton (MONTICELLI, 1983);

- d) método da continuação (SEYDEL, 1994);
- e) método do vetor tangente (CAÑIZARES, 1999);
- f) técnicas baseadas na inteligência artificial (redes neurais, lógica *fuzzy*, sistemas imunológicos artificiais, etc.);
- g) etc.

Os modelos linearizados são desenvolvidos considerando-se a preservação da topologia da rede elétrica (modelo não-reduzido) e, em alguns casos, usam-se modelos reduzidos. Cada um destas abordagens (modelo não-reduzido ou modelo reduzido) apresenta vantagens e desvantagens. Este tema será discutido adiante neste capítulo.

Um estudo de grande contribuição, no contexto da estabilidade de tensão, encontra-se na referência VU et al. (1995). Trata-se de um completo exame dos mecanismos de instabilidade. Portanto, é, certamente, uma fonte de consulta relevante, tanto para a estabilidade estática, assim como para a estabilidade dinâmica.

## **2.3 Análise das Principais Referências Bibliográficas**

Considerando-se que, neste trabalho, será abordado o problema da estabilidade estática da tensão, esta análise restringirá às principais referências que fazem uso de conceitos e métodos associados a esta modalidade de estudo.

Tiranuchit e Thomas, (1988) propuseram uma abordagem que pode ser considerada uma das mais expressivas contribuições à compreensão do estudo da estabilidade estática da tensão baseada na análise modal e na análise de sensibilidade. Várias outras referências, com este enfoque, foram publicadas (NAN, et al. 2000; SINHA; HAZARIKA, 2000; VAN CUTSEM; VOURNAS, (1998); ZAMBRONI, 2000; entre outras). Na referência Van Cutsem (1991), a solução do problema de estabilidade é formulada com base no desenvolvimento de uma margem de estabilidade que traduz uma “distância” em que o

sistema se encontra em relação ao colapso de tensão. Outras referências, entre tantas, são: Jia e Jeyasurya (2000); Zambroni (2000), Chen, et al. (2002); Arya, et al. (2008).

Sauer e Pai (1990) apresentam uma metodologia fundamentada no modelo do fluxo de potência usando o método de Newton. Versões mais apropriadas à resolução da questão da estabilidade estática, baseadas no método de Newton, empregam o método da continuação, ou seja, são procedimentos iterativos de busca da chamada “ponta do nariz” (ponto extremo) da curva P-V (CHEN, et al. 2002). Outras tantas publicações foram disponibilizadas usando esta técnica (ZAMBRONI, 2000; CHEN, et al. 2002; ALVES, et al. 2003).

Em Iba et al. (1991) propuseram um procedimento usando um método da continuação via reformulação das equações do fluxo de potência com o propósito de tornar a matriz jacobiana bem comportada para qualquer condição de carga. Com isto a determinação de uma margem de segurança de tensão estática torna-se mais factível ao ser usado um método da continuação.

Ajjarapu e Christy (1992) propuseram o cálculo do fluxo de potência usando o método da continuação, chamado UWPFLOW, a partir do caso base de carregamento até encontrar o limite da estabilidade de tensão. Esta referência evidencia a capacidade do método da continuação na resolução de problemas em sistemas elétricos de potência. O método da continuação emprega um esquema preditor-corretor de busca do ponto extremo da curva P-V. Cañizares e Alvarado (1996) apresentam novos resultados baseados no uso do método UWPFLOW de Ajjarapu e Christy (1992). Chang (2002) propôs outro programa computacional, designado CPFLOW (*Continuation Power Flow*), visando melhorar o desempenho do *software* UWPFLOW. Foi desenvolvido um novo índice para a análise da estabilidade de tensão baseado no conceito de variedade central (*center manifold*) (GUCKENHEIMER; HOLMES, 1997). O CPFLOW gera as curvas P-P, Q-V e P-Q-V.

Outro artigo importante (CAÑIZARES, 1999) explora o conceito “Vetor Tangente”.

Van Cutsem (2000) apresentou um estudo sobre o mecanismo da instabilidade tensão, bem como sugeriu medidas preventivas contra a ocorrência do colapso de tensão. Trata-se de uma das mais importantes contribuições na literatura ao entendimento sobre o fenômeno da instabilidade de tensão em sistemas elétricos de potência. Este artigo foi

extraído, em grande parte, do livro de Van Cutsem e Vournas (1998) que por sua vez, é um excelente conteúdo sobre o tema “estabilidade de tensão”.

Alternativamente, a análise pode ser realizada via teoria da perturbação singular (VIDYASAGAR, 2002). Esta teoria pode ser interpretada como sendo uma extensão da análise de sensibilidade (FRANK, 1978), resguardadas as devidas particularidades de cada método. O método direto de Lyapunov (VIDYASAGAR, 2002) não tem sido usado, em regra, à análise de estabilidade estática, isto porque ele é mais afeito a aplicações a modelos não-lineares.

Flueck e Qiu (2004) propuseram uma nova técnica para investigar a análise de contingência referente à saída de operação de linha de transmissão, considerando a estabilidade de tensão.

Ayasun et al. (2004) propuseram um método de avaliação da estabilidade de tensão baseado na determinação do lugar geométrico em que ocorre a bifurcação no comportamento das equações algébrico-diferenciais que norteiam o fenômeno associado ao colapso de tensão. O ponto onde é observada a bifurcação indica o limite da estabilidade. Este enfoque está mais afeito ao problema da estabilidade dinâmica.

Em Echavarren et al. (2006), os autores propuseram um método usando o método da continuação e um algoritmo de otimização para detecção da singularidade da matriz jacobiana como critério da estabilidade de tensão. Este método requer grande quantidade de esforço computacional, tendo em vista que as equações do fluxo de potências são aumentadas em número, se comparadas ao procedimento usual.

Recentemente têm surgido as várias metodologias de análise da estabilidade estática, assim como da estabilidade dinâmica de tensão usando técnicas de inteligência artificial (redes neurais, lógica *fuzzy*, etc.). Algumas aplicações envolvendo redes neurais podem ser destacadas: Chauhan e Dave (1997), Wan e Ekwue (2000), Celli et al. (2002), Andrade et al. (2006), Devaraj et al. (2007), Kojima et al. (2007), Pandit et al. (2007), Kamalasadén et al. (2008); etc. No caso do emprego da lógica *fuzzy*, em regra, as metodologias propostas agregam redes neurais compondo um sistema neuro-*fuzzy* de análise (BERIZZI, et al. 2008), cujo objetivo é aumentar o desempenho (qualidade da solução e redução do tempo de processamento) do sistema de inferência.

Numa avaliação mais simplista dos métodos mencionados, observa-se que na maioria das metodologias propostas na literatura técnico-científica, as quais contemplam redes neurais em suas formulações, as redes neurais artificiais são arquiteturas *feedforwards* com treinamento realizado via algoritmo retropropagação (WERBOS, 1974), ainda que se encontram outras arquiteturas neurais: rede neural de Kohonen (CHAUHAN; DAVE, 1997); rede neural contrapropagação (PANDIT, et al. 2007), etc. A rede neural *feedforward* com treinamento realizado por aplicação do algoritmo retropropagação será designada aqui, por questão de simplicidade, “rede neural retropropagação”.

O algoritmo designado de retropropagação é considerado um *benchmark* em termos de precisão. Porém, apresenta limitações importantes, as quais, quase sempre, inviabilizam tratar de problemas de grandes dimensões (algo superior a 20 componentes de entrada) e/ou grande quantidade de dados, ou seja, este volume de dados torna a fase de treinamento bastante onerosa em termos do tempo dispensado ao processamento computacional, sendo que há vários casos em que se observa a não convergência deste processo. A não convergência é causada pelo uso do algoritmo retropropagação, que é uma compilação do MGD (Método do Gradiente Descendente) (WIDROW; LEHR, 1990). Sabe-se que o MGD, em problemas com multipontos de equilíbrio, pode produzir uma convergência para um ponto de equilíbrio mínimo local, ao invés de um ponto mínimo global, que é o objetivo-alvo da fase de treinamento (condição para que o treinamento seja considerado concluído). Além deste detalhe, na rede neural usam-se não-linearidades sigmoidais que, associadas ao uso de algoritmos baseado em derivadas (MGD), podem gerar um fenômeno denominado de paralisia (WIDROW; LEHR, 1990), que atua negativamente no processo de convergência. Uma análise detalhada destas limitações é apresentada por Lopes (2005), considerando o problema da previsão de carga em sistema elétricos de potência. Neste problema, o número de componentes de entrada é inferior a 20, saída simples (uma única unidade de saída correspondente à previsão da carga a uma hora à frente) e um conjunto de vetores padrões (par de entrada-saída) na ordem de 2000 exemplares. Na maioria dos casos simulados não houve convergência, mesmo promovendo-se uma série de ajustes e melhorias no algoritmo de retropropagação.

Deste modo, nos capítulos subsequentes será apresentada a proposta uma metodologia neural que é isenta das limitações inerentes à rede retropropagação (baixa convergência, elevado tempo de processamento e impossibilidade de implementação do

treinamento continuado). Trata-se de uma rede neural ART-descendente (CARPENTER; GROSSBERG, 1992).

## **2.4 Comentários**

Neste Capítulo foram apresentadas as técnicas mais relevantes de análise, assim como as referências que se consideram mais importantes para a realização do diagnóstico da estabilidade estática da tensão de sistemas elétricos de potência, não necessariamente as mais atuais, mas sim aquelas que efetivamente produziram saltos qualitativos nesta área de pesquisa. No Capítulo 3 será apresentado o esquema, proposto nesta pesquisa de doutorado, para a realização da análise da estabilidade estática de tensão, via rede neural artificial baseada na teoria da ressonância adaptativa.

## Capítulo 3

# Metodologia Proposta Para a Análise da Estabilidade Estática de Tensão

### 3.1 Introdução

Neste capítulo apresenta-se um esquema ilustrativo do sistema proposto para a análise da estabilidade estática de tensão de sistemas de energia elétrica, que será abordado nesta pesquisa de doutorado, usando-se uma rede neural baseada na teoria da ressonância adaptativa (CARPENTER; GROSSBERG, 1991). Trata-se da rede neural ARTMAP *Fuzzy* (CARPENTER, et al. 1992). Esta rede neural faz parte da família ART (*Adaptive Resonance Theory*) (CARPENTER; GROSSBERG, 1991), que apresenta a característica de estabilidade, plasticidade e custo computacional reduzidíssimo, se comparada à maioria das redes neurais disponíveis na literatura especializada. A estabilidade refere-se à propriedade de sempre garantir a obtenção de uma solução, enquanto que a plasticidade confere, à rede neural, a incorporação do treinamento continuado, não havendo necessidade de reiniciar o treinamento toda vez que houver necessidade de incorporar novos padrões de treinamento na matriz de pesos da rede neural, bastando, apenas, a execução de uma rotina simples. Deste modo, usando-se esta rede neural pode-se propor uma metodologia de análise bastante rápida, de grande confiabilidade e que seja susceptível de inclusão de novos conhecimento com o passar

do tempo, constituindo o aperfeiçoamento do conhecimento. O sistema de inferência é constituído por três módulos principais, ou seja, a geração de dados para o treinamento da rede neural, o treinamento da rede neural e, finalmente, a execução das análises.

## 3.2 Esquema Proposto

A Figura 3.2.1, apresenta-se o esquema proposto (sistema neural) para a realização da análise de estabilidade estática de tensão de sistemas elétricos de potência. O funcionamento das redes neurais é dividido, basicamente, em duas fases principais: (1) treinamento, ou aprendizado; (2) testes e análise. A rede neural usada, nesta pesquisa, é uma arquitetura ARTMAP *fuzzy* (CARPENTER et al., 1992). A fase de treinamento é realizada usando um “professor” representado por um simulador (programa computacional) (SIMUL, 1990) que realiza vários tipos de cálculo das redes elétricas: matrizes de rede, fluxo de potência e análise de estabilidade transitória. Este programa foi adaptado para executar, também, os cálculos associados à estabilidade estática de tensão, conforme o critério que será apresentado no Capítulo 4, e a base de dados, constituída por pares de padrões de entrada e de saída da rede neural, para a realização do treinamento neural. O fluxograma, da referida metodologia, é mostrado na Figura 3.2.1.

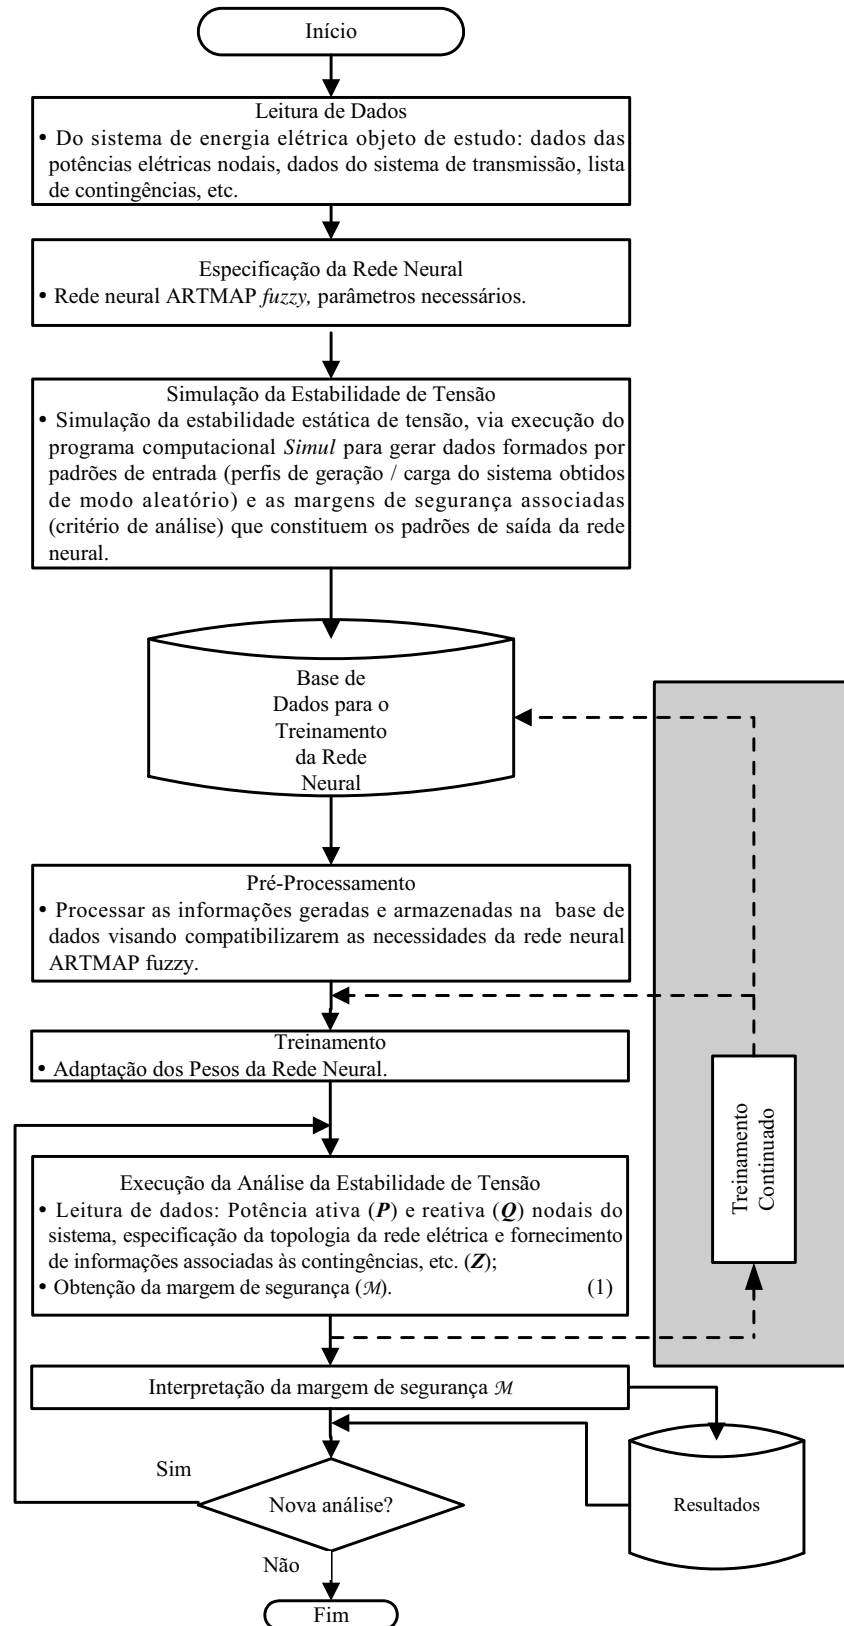


Figura 3.2.1 Fluxograma do sistema neural proposto para realizar a análise de estabilidade de tensão de sistemas elétricos de potência.

Este roteiro de cálculo ilustrado na Figura 3.2.1 é constituído pelos seguintes blocos:

1. Leitura dados e especificação da rede neural ARTMAP *Fuzzy*.
2. Simulação da estabilidade estática de tensão. Esta rotina compreende a construção da base de dados para a fase de treinamento da rede neural. Neste módulo são calculadas as margens de segurança associadas à estabilidade estática de tensão, considerando-se um conjunto de perfis de geração e carga do sistema. Estes perfis são gerados usando um procedimento de distribuição aleatória (pseudo-aleatória) da geração e da carga elétrica, que será apresentado na Seção 5.2 do Capítulo 5. O cálculo da margem de segurança será apresentado no Capítulo 4. Estas informações (perfis de geração / carga e as margens de segurança correspondentes) são armazenadas na base de dados.
3. Pré-processamento da base de dados para a execução do treinamento da rede neural. Trata-se da adequação das informações ao padrão exigido pela rede neural ARTMAP *Fuzzy*, conforme é discutido no Capítulo 5. O pré-processamento compreende, também, a preparação dos dados da saída da rede neural em codificação binária, a partir da margem de segurança que é um número real.
4. Treinamento da rede neural ARTMAP *Fuzzy* que será apresentado no Capítulo 5.
5. O bloco 1 é onde a análise da estabilidade de tensão é realizada, após ter sido concluída a fase de treinamento. A parte do fluxograma com linhas tracejadas refere-se ao módulo que executa o treinamento continuado. Ou seja, sempre que houver disponibilidade de dados de entrada para a execução da análise de estabilidade de tensão pela rede neural (bloco 1), se julgado como sendo um padrão ( $\mathbf{P}$ ,  $\mathbf{Q}$ ,  $\mathbf{Z}$ ) relevante, usa-se este vetor e a saída ( $\mathcal{M}$ ) associada para serem inseridos na base de dados, via adaptação dos pesos. O vetor  $\mathbf{Z}$  contém as informações binárias que codificam a topologia da rede elétrica, os dados das contingências, etc.

Enfim, as partes mais importantes do roteiro de cálculo ilustrado na Figura 3.2.1 são tratadas em capítulos específicos, como forma de facilitar a compreensão da metodologia proposta.

### 3.3 Comentários

Foi apresentado, neste capítulo, o esquema referente a metodologia proposta para a realização da análise de estabilidade estática de tensão de sistemas elétricos de potência. Nos Capítulos 4 e 5 será apresentado o detalhamento, respectivamente, do processo de cálculo do índice de estabilidade  $\mathcal{M}$  e da rede neural ARTMAP *Fuzzy*, bem como da geração do conjunto de padrões de entrada e de saída de rede neural para a fase de treinamento.

## Capítulo 4

# Estabilidade de Tensão de Sistemas de Energia Elétrica

### 4.1 Introdução

Apresenta-se, neste capítulo, o procedimento para o cálculo da margem de estabilidade estática de tensão ( $\mathcal{M}$ ) baseada na análise de sensibilidade da função determinante da matriz jacobiana  $\mathcal{J}^o$  das equações do fluxo de potência da rede elétrica. Esta margem é definida como uma medida da “distância” entre o estado de equilíbrio do sistema e a fronteira do limite de estabilidade estática de tensão. A margem de segurança  $\mathcal{M}$ , combinada com o treinamento da rede neural ARTMAP *Fuzzy* realizado considerando-se o conjunto de padrões de entrada gerados aleatório/pseudo-aleatoriamente, permite que a análise possa ser realizada de forma mais realista, se comparada à análise ultimada usando o critério baseado na proporcionalidade do aumento da carga, o qual tem sido usado na maioria dos casos abordados na literatura especializada. Inicialmente, serão apresentados os principais conceitos e definições sobre o problema da estabilidade de tensão de sistemas elétricos de potência, visando proporcionar os devidos subsídios ao desenvolvimento do critério de análise da estabilidade de tensão proposto nesta pesquisa, ou seja, a margem de estabilidade estática de tensão  $\mathcal{M}$ .

## 4.2 Mecanismo da Instabilidade de Tensão

O Grupo de Trabalho do IEEE (*The Institute of Electrical and Electronics Engineers*) (IEEE WORKING GROUP, 1990) tem elaborado um conjunto de definições e de técnicas de resolução associados ao problema da estabilidade de tensão de sistemas de energia elétrica. Trata-se de um documento que pode ser considerado um *benchmark* nesta área do conhecimento. Nele extrai-se a definição (definição 4.2.1) mais geral da instabilidade de tensão:

**Definição 4.2.1.** A Instabilidade de Tensão é originada como consequência da tentativa do sistema elétrico de potência em atender a carga elétrica além da capacidade conjunta da transmissão e da geração.

De outra forma, pode-se considerar que a instabilidade de tensão é um fenômeno que ocorre quando há um excesso de carga atendida pelo sistema, além do que ele pode suportar. Observa-se que a operação do sistema não possui o controle sobre a evolução da carga por ser um evento associado apenas à vontade do consumidor. Cabe ao sistema a obrigação de atender esta demanda. Evidentemente, quando esta situação for comprometer a integridade (segurança) do sistema, medidas preventivas ou emergenciais devem ser tomadas, *e.g.*, até mesmo a adoção de corte de carga (*load-shedding*), quando não houver outra alternativa plausível.

A instabilidade de tensão acontece quando há insuficiência de fontes de potência reativa para a manutenção dos níveis de tensão nodais. Por exemplo, quando a carga aumenta em um determinado barramento do sistema, a tensão deste barramento tende a diminuir até atingir o seu limite (condição limítrofe de tensão). A partir deste valor, se a carga aumentar ainda mais ocorrerá uma forte degeneração da tensão caracterizando a instabilidade do sistema. Ressalta-se que, quando isto é observado, haverá uma série de eventos interligados neste mecanismo, ou seja, havendo a deterioração do perfil de tensão, certamente haverá também os reflexos sobre os ângulos, entre outras implicações, cujo problema de instabilidade é mais crucial, pois o sistema pode evoluir para um cenário de blecaute.

Para evitar tais transtornos, há necessidade da realização uma série de estimativas sobre a segurança do sistema e o desenvolvimento de estratégias preventivas. É

neste sentido, que esta pesquisa irá atuar, culminando com o desenvolvimento de uma metodologia para a análise da estabilidade de tensão.

Por questões de conveniência, de modo geral, a estabilidade de tensão pode ser abordada sob dois pontos de vista: (1) estático e (2) dinâmico (VAN CUTSEN; VOURNAS, 1998). O caráter dinâmico requer uma abordagem mais precisa sobre o referido fenômeno, devendo ser modelado matematicamente por um conjunto de equações diferenciais não-lineares (VU, et al. 1995). Trata-se de uma análise complexa e sofisticada, principalmente quando se aborda sistemas de grande porte.

Uma forma mais simples, porém, igualmente importante da estabilidade de tensão, refere-se à observação do comportamento das tensões nodais, considerando-se o aumento gradativo do perfil do carregamento do sistema, ou seja, a análise qualitativa do ponto de operação. Neste caso, a análise pode ser tratada como um problema linear. Fazendo-se estimativas, sob o ponto de vista linear, corre-se o risco de obter soluções imprecisas. Contudo, tem-se observado, na literatura especializada, o uso bastante grande de técnicas enfocando a estabilidade de tensão como um problema de aproximação linear, cujos resultados têm sido relatados como “boas aproximações”. Via de regra, estas soluções são conservativas, ou seja, são observadas imprecisões, porém, estando à favor da segurança do sistema.

As cargas elétricas podem ser expressas, por meio das seguintes equações:

$$P = g(freq, V) \quad (4.2.1)$$

$$Q = h(freq, V) \quad (4.2.2)$$

sendo:

$P$  : potência ativa nodal;

$Q$  : potência reativa nodal;

$g$  e  $h$  : funções não-lineares;

$freq$  : frequência no sistema;

$V$  : tensão nodal.

As funções  $g$  e  $h$  dependem do tipo dos componentes da carga (*e.g.*, lâmpadas, motores, etc.) e de como tais componentes são usados em um determinado instante. Por exemplo, uma carga composta por 1 geladeira, que consome 1000 watts, e por 10 lâmpadas de 100 watts cada uma, terá um comportamento diferente de uma outra carga de mesma potência total, composta por 2 geladeiras, que consomem 1000 watts e 500 watts, respectivamente, e por 5 lâmpadas de 100 watts cada uma.

Deste modo, as cargas elétricas (ativa e reativa) são dependentes da frequência e da tensão. As cargas baseadas em motores são mais sensíveis à frequência, enquanto que as cargas resistivas (chuveiro, lâmpadas incandescentes, etc.) há uma maior influência da tensão. Nesta pesquisa, a análise da estabilidade de tensão será enfocada do ponto de vista estático. Neste caso, pode-se desconsiderar os efeitos da frequência, estabelecendo a inter-relação entre a carga e a tensão, em consonância aos procedimentos usuais adotados na literatura especializada.

Assim sendo, adiante apresenta-se a ilustração do comportamento da carga em relação à tensão. Trata-se da Figura 4.2.1, chamada curva P-V (TAYLOR, 1994). Ela mostra o comportamento da tensão em uma determinada barra em função do aumento da carga. Trata-se de um procedimento que visa ilustrar e determinar os valores críticos ( $P_{crítica}$  e  $V_{crítica}$ ) usando algum processo de busca. A grande maioria das propostas encontradas na literatura usa mecanismos (método da continuação, etc.) de busca baseados em sucessivas aproximações, a partir de pequenos acréscimos da potência ativa na barra sob análise até atingir o limite ( $P_{crítica}$ ). A diferença entre  $P_{crítica}$  e a potência ativa inicial ( $P_{inicial}$ ) é tomada como sendo o máximo acréscimo possível para a carga na referida barra e  $P_{crítica}$  corresponde ao máximo carregamento, ou seja, se a carga for superior a  $P_{crítica}$  tem-se um indicativo, se nenhuma providência for implementada, de que a tensão da barra evoluirá para o colapso. O ponto extremo N é designado como “nariz” da curva P-V. Ressalta-se que na Figura 4.2.1 não estão representados os detalhes que envolvem a análise de contingência. Este assunto será objeto de investigação em trabalhos futuros, ainda que não há grandes obstáculos de incluí-lo também à metodologia proposta.

Deste modo, qualquer metodologia a ser usada ou desenvolvida tem por objetivo encontrar o lugar geométrico correspondente ao ponto extremo N, ou um procedimento similar (equivalente).

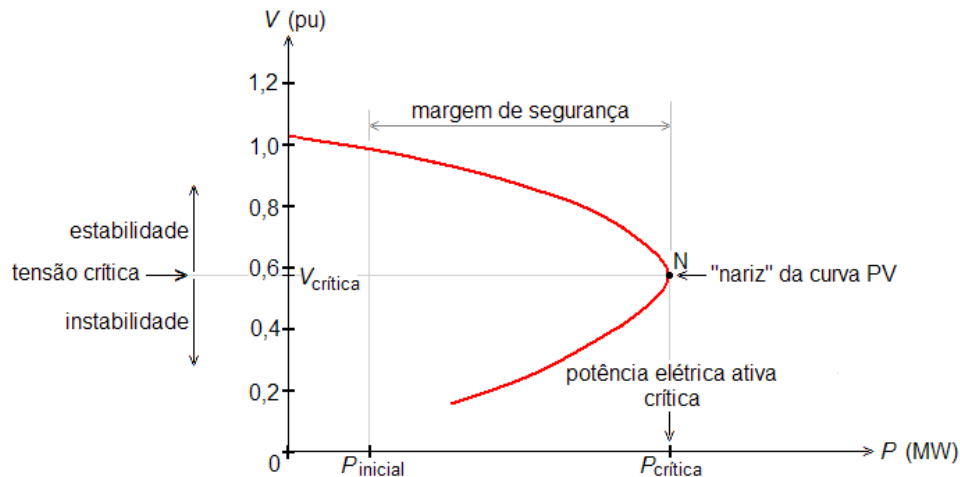


Figura 4.2.1. Curva P-V.

Por conseguinte, nesta pesquisa, a proposta apresentada está fundamentada na determinação de uma estimativa da “distância” em que o ponto de operação se encontra em relação ao limite de estabilidade. Esta distância é designada como sendo **margem de segurança de tensão**.

### 4.3 Critério de Análise da Estabilidade Estática de Tensão

Para o desenvolvimento do critério de análise proposto, considera-se que o sistema esteja operando em estado de equilíbrio estável ( $P_{inicial}$  na Figura 4.2.1), ou seja, são atendidos os balanços de potência (ativa e reativa) e não há perturbações significativas observadas no sistema, tanto de ângulo como de tensão. A partir deste cenário, busca-se determinar qual será o incremento máximo de carga (máximo carregamento) que o sistema pode suportar sem perder a sua estabilidade (de tensão). Este incremento de carga é considerado, neste trabalho, sem restrição à forma como evolui a carga. Por exemplo, não há necessidade de se impor que a carga cresça linearmente e com fator de potência constante, conforme tem sido tratado em vários artigos disponíveis na literatura. Assim, considerando-se um ponto de operação inicialmente estável, pode-se admitir que os autovalores da matriz jacobiana ( $J^0$ ) do fluxo de potência sejam todos positivos. Consequentemente, o determinante

desta matriz será um número positivo, isto porque a função determinante de uma matriz quadrada qualquer  $A$  ( $p \times p$ ) pode ser calculada por (BARNETT; STOREY, 1970):

$$\det(A) = \prod_{i=1}^p \lambda_i(A) \quad (4.3.1)$$

sendo:

$\lambda_i(A)$  :  $i$ -ésimo autovalor da matriz  $A$ .

Na medida em que há a aproximação, produzida pelo aumento da carga, de um ponto de equilíbrio (estável) à linha de transição entre a estabilidade e a instabilidade, pelo menos um dos autovalores se aproxima de zero e, naturalmente, a função determinante positiva também se aproximará de zero (em conformidade com a equação 4.3.1).

Pode-se, portanto, estimar a “distância” em que o ponto de equilíbrio estável se encontra em relação à instabilidade de tensão (linha de transição entre a estabilidade e a instabilidade) tomando-se a medida correspondente ao acréscimo da função determinante da matriz  $J^0$  torna-se nula, em função do aumento da demanda do sistema. Neste trabalho, o referido acréscimo do determinante será determinado via teoria da sensibilidade (FRANK, 1978), em especial empregando-se a álgebra matricial de Kronecker (BREWER, 1978; GEROMEL, 1987).

Deste modo, a análise de estabilidade estática de sistemas de energia pode ser ultimada alternativamente, por meio da investigação comportamental do modelo correspondente a soluções das equações linearizadas do fluxo de potência de Newton (TIRANUCHIT; THOMAS, 1988; SAUER; PAI, 1990):

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = [J^0] \begin{bmatrix} \Delta \theta \\ \Delta V \end{bmatrix} \quad (4.3.2)$$

sendo:

$\Delta P$  : vetor de potências ativas das barras PV e QP;

$\Delta Q$  : vetor de potências reativas das barras PQ;

$\Delta \theta$  : vetor de ângulos nas barras PV e PQ;

$\Delta V$  : vetor de tensões nodais das barras PQ;

$\mathbf{J}^0 \stackrel{\text{def}}{=} \text{matriz jacobiana}$

$$= \begin{bmatrix} \mathbf{H} & \mathbf{N} \\ \mathbf{M} & \mathbf{L} \end{bmatrix}.$$

As matrizes  $\mathbf{H}$ ,  $\mathbf{N}$ ,  $\mathbf{M}$  e  $\mathbf{L}$  são as submatrizes de  $\mathbf{J}^0$  correspondentes a  $\partial \mathbf{P} / \partial \boldsymbol{\theta}$ ,  $\partial \mathbf{P} / \partial \mathbf{V}$ ,  $\partial \mathbf{Q} / \partial \boldsymbol{\theta}$  e  $\partial \mathbf{Q} / \partial \mathbf{V}$ , respectivamente.

O problema do fluxo de potência pelo método de Newton (formulação e resolução) pode ser consultado em várias referências disponíveis na literatura, em destaque as referências Monticelli (1983), Monticelli, et al. (1990), Powell (2005), entre outras.

Neste trabalho, por conseguinte, estuda-se a questão da estabilidade estática de tensão, através da análise de sensibilidade, usando como função, para fins de análise, o determinante da matriz  $\mathbf{J}^0$ . Ressalta-se que o cálculo do determinante de uma matriz pode ser realizado de forma bastante rápida e eficiente (SU; CHANG, 1996), se comparado com os principais métodos comumente disponíveis na literatura, ainda que esta função não seja usada neste trabalho e sim a derivada (parcial) do determinante. Desta forma, através de expansão por série de Taylor, pode-se estimar a variação do determinante da matriz  $\mathbf{J}^0$  [ $\det(\mathbf{J}^0)$ ], em termos da sensibilidade da função  $\det(\mathbf{J}^0)$  e das variações da matriz jacobina  $\mathbf{J}^0$ , como mostra-se a seguir.

Considere  $f(\mathbf{J}) = \det(\mathbf{J})$ , sendo  $f$  uma função escalar. Se esta função for diferenciável, pode-se desenvolvê-la através da expansão por série de Taylor, produzindo (GEROMEL, 1987):

$$f(\mathbf{J}) = f(\mathbf{J}^0) + \varepsilon \text{Tr} \{ \mathbf{D}(\mathbf{J}^0)^T \Delta \mathbf{J} \} + o(\varepsilon), \quad \varepsilon \in \mathfrak{R} \quad (4.3.3)$$

sendo:

$$\mathbf{J} = \mathbf{J}^0 + \varepsilon \Delta \mathbf{J}$$

$$\mathbf{D}(\mathbf{J}^0) \stackrel{\text{def}}{=} \left. \frac{\partial \det(\mathbf{J})}{\partial \mathbf{J}} \right|_0$$

: derivada parcial da função escalar  $f$  em relação à matriz  $\mathbf{J}$ , calculada no ponto de operação do sistema "o");

Tr : traço de uma matriz;

$\phi(\varepsilon)$  : resíduo da expansão por série de Taylor (parte não-linear);

$\varepsilon$  : parâmetro de perturbação;

T : operação de transposição matricial.

A matriz  $\mathbf{D}(\mathbf{J}^0)$  representa a derivada de  $f$  (função escalar) em relação a matriz  $\mathbf{J}^0$ . A grande dificuldade se usar diretamente a equação (4.3.3) reside justamente na obtenção de  $\mathbf{D}(\mathbf{J}^0)$ . Uma forma alternativa mais "simples" de resolução deste problema consiste no uso de operações no contexto da teoria da álgebra de Kronecker (GEROMEL, 1987), ou seja:

$$f(\mathbf{J}) = f(\mathbf{J}^0) + \varepsilon \langle \psi\{\mathbf{D}(\mathbf{J}^0)\}, \psi\{\Delta\mathbf{J}\} \rangle + \phi(\varepsilon), \varepsilon \in \mathfrak{R} \quad (4.3.4)$$

sendo:

$\langle \mathbf{u}, \mathbf{v} \rangle$  : produto interno entre os vetores  $\mathbf{u}$  e  $\mathbf{v}$ ;

$$\begin{aligned} \Delta\mathbf{J} &= \begin{bmatrix} \Delta J_{11} & \dots & \Delta J_{1p} \\ \vdots & \vdots & \vdots \\ \Delta J_{p1} & \dots & \Delta J_{pp} \end{bmatrix} \\ &= \begin{bmatrix} \Delta\mathbf{J}_H & \Delta\mathbf{J}_N \\ \Delta\mathbf{J}_M & \Delta\mathbf{J}_L \end{bmatrix} \quad (\text{variação da matriz } \mathbf{J} \text{ associada ao problema (4.3.2)}) \end{aligned}$$

$$\psi(\mathbf{A}) \stackrel{\text{def}}{=} [A_{11} \dots A_{p1} \dots A_{1p} \dots A_{pp}]^T \quad (4.3.5)$$

$$\mathbf{A} = \begin{bmatrix} A_{11} & \dots & A_{1p} \\ \vdots & \vdots & \vdots \\ A_{p1} & \dots & A_{pp} \end{bmatrix}$$

Agora, a equação (4.3.4) contém uma única operação de produto interno de dois vetores. A operação matricial, definida pela expressão (4.3.5), constitui-se na vetorização de uma matriz tomando-se as colunas desta matriz colocadas de forma sequencial, da

esquerda para a direita. Assim,  $\psi\{D(J^0)\}$  e  $\psi\{\Delta J\}$  são dois vetores obtidos a partir das matrizes  $D(J^0)$  e de  $\Delta J$ , respectivamente.

A matriz  $J(J^0 + \varepsilon \Delta J)$  pode ser reescrita da seguinte forma, via pré-fatoração por  $J^0$ :

$$J = J^0 [I + \varepsilon (J^0)^{-1} \Delta J] \quad (4.3.6)$$

$$J^0 \in \mathfrak{R}^{p \times p}, J^0 : \text{matriz inversível}$$

sendo:

$I$  : matriz identidade ( $p \times p$ ).

A matriz  $J$  expressa pela equação (4.3.6) é representada pelo produto de duas matrizes  $J^0$  e  $[I + \varepsilon (J^0)^{-1} \Delta J]$ . Assim, como o determinante do produto de 2 matrizes quadradas é igual ao produto dos determinantes de cada matriz envolvida assim obtém-se:

$$\det(J) = \det(J^0) \det(I + \varepsilon (J^0)^{-1} \Delta J) \quad (4.3.7)$$

A operação  $\det\{I + \varepsilon (J^0)^{-1} \Delta J\}$  de (4.3.7), usando-se de propriedade de determinante (BARNETT; STOREY, 1970).

$$\det(I + \varepsilon (J^0)^{-1} \Delta J) = \prod_{i=1}^p \lambda_i [I + \varepsilon (J^0)^{-1} \Delta J] \quad (4.3.8)$$

sendo:

$\lambda_i$  :  $i$ -ésimo autovalor de  $[I + \varepsilon (J^0)^{-1} \Delta J]$ .

A equação (4.3.8), também, recorrendo-se as propriedades de determinantes (BARNETT; STOREY, 1970) pode ser expressa por:

$$\det(I + \varepsilon (J^0)^{-1} \Delta J) = \prod_{i=1}^p \{1 + \varepsilon \lambda_i [(J^0)^{-1} \Delta J]\} \quad (4.3.9)$$

sendo:

$\underline{\lambda}_i$  :  $i$ -ésimo autovalor de  $[(\mathbf{J}^0)^{-1} \Delta \mathbf{J}]$ .

Observa-se, portanto, que os autovalores  $\lambda_i$  e  $\underline{\lambda}_i$  estão relacionados da seguinte forma:

$$\lambda_i = 1 + \underline{\lambda}_i .$$

Deste modo, a equação (4.3.7), combinando com o resultado obtido na equação (4.3.9), pode ser reescrita por:

$$\det(\mathbf{J}) = \det(\mathbf{J}^0) \prod_{i=1}^p \{1 + \varepsilon \underline{\lambda}_i [(\mathbf{J}^0)^{-1} \Delta \mathbf{J}]\} + \phi(\varepsilon) \quad (4.3.10)$$

A equação (4.3.10), baseando-se das propriedades de determinante ((BARNETT; STOREY, 1970), pode ser expressa na seguinte forma:

$$\begin{aligned} \det(\mathbf{J}) &= \det(\mathbf{J}^0) \{1 + \varepsilon \text{Tr}\{(\mathbf{J}^0)^{-1} \Delta \mathbf{J}\} + \phi(\varepsilon) \\ &= \det(\mathbf{J}^0) + \varepsilon \text{Tr}\{\det(\mathbf{J}^0) (\mathbf{J}^0)^{-1} \Delta \mathbf{J}\} + \phi(\varepsilon) \end{aligned} \quad (4.3.11)$$

Como  $\det(\mathbf{J}^0) (\mathbf{J}^0)^{-1} = \text{adj}(\mathbf{J}^0)$ , então, a equação (4.3.11), usando-se as equações (4.3.3)–(4.3.5), pode ser expressa por:

$$\det(\mathbf{J}) = \det(\mathbf{J}^0) + \varepsilon \langle \psi\{\text{adj}(\mathbf{J}^0)^T\}, \psi\{\Delta \mathbf{J}\} \rangle + \phi(\varepsilon) \quad (4.3.12)$$

sendo:

$$\text{adj}(\mathbf{J}^0) = \{\text{cof}(\mathbf{J}^0)\}^T \text{ (matriz adjunta de } \mathbf{J}^0\text{)}.$$

A partir da equação (4.3.12), conclui-se que a sensibilidade da função  $\det(\mathbf{J})$  pode ser expressa por:

$$\frac{\partial \det(\mathbf{J})}{\partial \mathbf{J}} = \psi[\text{adj}(\mathbf{J})^T] \quad (4.3.13)$$

Dividindo-se a equação (4.3.12) por  $\det(\mathbf{J}^0)$ , obtém-se:

$$\tau = 1 + \Delta \tau + \phi(\varepsilon) \quad (4.3.14)$$

sendo:

$\tau$  : função determinante normalizada

$$\underline{\underline{\tau}} \stackrel{\text{def}}{=} \frac{\det(\mathbf{J})}{\det(\mathbf{J}^0)}$$

$$\Delta \tau = \varepsilon \langle \boldsymbol{\psi}\{[(\mathbf{J}^0)^{-1}]^T\}, \boldsymbol{\psi}(\Delta \mathbf{J}) \rangle \quad (4.3.15)$$

$$\varphi(\varepsilon) = \frac{\phi(\varepsilon)}{\det(\mathbf{J}^0)}.$$

Também, a partir da equação (4.3.14), conclui-se que:

$$\left. \frac{\partial f(\mathbf{J})}{\partial \mathbf{J}} \right|_0 \times \frac{1}{\det(\mathbf{J}^0)} = \boldsymbol{\psi}\{[(\mathbf{J}^0)^{-1}]^T\} \quad (4.3.16)$$

Ou seja, a equação (4.3.16) representa a sensibilidade da função determinante normalizada. Assim, fazendo-se:

$$\boldsymbol{\alpha} = \boldsymbol{\psi}\{((\mathbf{J}^0)^{-1})^T\}$$

$$\mathbf{C} \stackrel{\text{def}}{=} [(\mathbf{J}^0)^{-1}]^T$$

$$= \begin{bmatrix} C_{11} & \dots & C_{1p} \\ \vdots & \vdots & \vdots \\ C_{p1} & \dots & C_{pp} \end{bmatrix}$$

$$= \begin{bmatrix} \mathbf{C}_H & \mathbf{C}_N \\ \mathbf{C}_M & \mathbf{C}_L \end{bmatrix}$$

obtem-se a seguinte representação para  $\boldsymbol{\alpha}$ , que é a sensibilidade da função determinante normalizada, na forma vetorial:

$$\boldsymbol{\alpha} = [C_{11} \dots C_{p1} \dots C_{1p} \dots C_{pp}]^T. \quad (4.3.17)$$

A variação linear da função determinante normalizada  $\Delta \tau$  (Equação 4.3.15) pode ser expressa por:

$$\Delta \tau = \varepsilon \sum_{i=1}^p \sum_{j=1}^p C_{ij} \Delta J_{ij} \quad (4.3.18)$$

Deve-se observar que a matriz  $\Delta\mathbf{J}$  é uma estrutura esparsa, semelhante à esparsidade da matriz  $\mathbf{Y}$  barra (MONTICELLI, 1983). Assim, poucos são os elementos de  $\Delta\mathbf{J}$  que são diferentes de zero.

Desconsiderando-se os termos não-lineares ( $\varphi(\varepsilon)$ ), a partir da Equação (4.3.14), fazendo-se  $\tau = 0$  (determinante normalizado igual a zero) e  $\varepsilon = 1$ , obtém-se:

$$\langle \boldsymbol{\alpha}, \boldsymbol{\psi}(\Delta\mathbf{J}) \rangle = -1 \quad (4.3.19)$$

Nota-se que a adoção de  $\varepsilon = 1$  significa que a matriz jacobiana  $\mathbf{J}^0$  sofreu um acréscimo  $\Delta\mathbf{J}$ .

Observa-se que o objetivo da metodologia aqui proposta é determinar a distância compreendida entre o estado de operação do sistema e um lugar geométrico definido pela linha de transição entre a estabilidade e a instabilidade. Assim, fazendo-se  $\tau = 0$  está-se determinando uma estimativa da distância ou margem de segurança de tensão.

Assim, a equação (4.3.19) estabelece a relação entre os vetores  $\boldsymbol{\psi}\{((\mathbf{J}^0)^{-1})^T\}$  e  $\boldsymbol{\psi}(\Delta\mathbf{J})$  tais que reproduzem, considerando-se o modelo linear, um valor nulo para a função  $\det(\mathbf{J})$ , ou seja, uma condição limite para a estabilidade de tensão. Deste modo, a partir desta equação, pode-se estimar a distância euclidiana que corresponde à margem de segurança,  $\mathcal{M}$ , ou distância em que o ponto de operação do sistema encontra-se em relação à condição limítrofe de estabilidade estática. Esta margem pode ser calculada da seguinte forma (ISODA, et al. 2008):

$$\mathcal{M} = \sqrt{\frac{1}{\langle \boldsymbol{\alpha}, \boldsymbol{\alpha} \rangle}} \quad (4.3.20)$$

que corresponde a uma solução da Equação (4.3.19) para  $\boldsymbol{\psi}(\Delta\mathbf{J})$  (ISODA, et al. 2008):

$$\boldsymbol{\psi}(\Delta\mathbf{J}) = - \frac{\boldsymbol{\alpha}}{\langle \boldsymbol{\alpha}, \boldsymbol{\alpha} \rangle} \quad (4.3.21)$$

A margem de segurança  $\mathcal{M}$ , calculada através da equação (4.3.20) corresponde a uma solução de norma mínima (BARNETT; STOREY, 1970). Esta solução indica que a matriz jacobiana  $\mathbf{J}^0$  ao receber um acréscimo  $\Delta\mathbf{J}$  tal que os vetores  $\boldsymbol{\alpha}$  e  $\boldsymbol{\psi}(\Delta\mathbf{J})$  estiverem

alinhados, porém em oposição, o determinante de  $\mathbf{J}$  ( $\mathbf{J} = \mathbf{J}^0 + \Delta\mathbf{J}$ ) será nulo. Portanto, a margem  $\mathcal{M}$ , definida pela equação (4.3.20), caracteriza-se como uma estimativa da distância do ponto de operação em relação ao limite da estabilidade estática da tensão.

A escolha da representação dada pela Equação (4.3.16) tem sido importante, isto porque permite realizar as análises levando-se em conta a estrutura real do sistema (sem redução).

**Definição 4.3.1.** Autovalor Crítico. Autovalor crítico  $[\lambda_{\min}(\mathbf{J}^0)]$  é definido como sendo o menor autovalor positivo da matriz jacobiana  $\mathbf{J}^0$ .

O autovalor crítico corresponde ao autovalor de interesse para análise da estabilidade de tensão, tendo em vista que é aquele que se encontra mais próximo do colapso de tensão e, portanto, apresenta maior possibilidade de se tornar nulo à medida que houver o aumento da demanda de energia elétrica. O monitoramento de  $\lambda_{\min}(\mathbf{J}^0)$  constitui-se num importante instrumento de análise da estabilidade estática de sistemas de energia elétrica, como habitualmente empregado na literatura especializada (ARYA, et al. 2008; JI; JEYASURYA, 2000; NAN, et al. 2000; SINHA; HAZARIKA, 2000; TIRANUCHIT; THOMAS, 1988). Este parâmetro pode ser estimado como mostra-se a seguir.

As matrizes  $\mathbf{J}^0$  e  $(\mathbf{J}^0)^{-1}$  apresentam a seguinte relação entre autovalores, considerando-se que se a matriz  $\mathbf{J}^0 > 0$  (matriz definida positiva) implica que  $(\mathbf{J}^0)^{-1} > 0$  (GOLUB; VAN LOAN, 1990):

$$\lambda_{\min}(\mathbf{J}^0) = 1 / \lambda_{\max}((\mathbf{J}^0)^{-1}) \quad (4.3.22)$$

sendo:

$\lambda_{\max}((\mathbf{J}^0)^{-1})$  : máximo autovalor da matriz  $(\mathbf{J}^0)^{-1}$

$\lambda_{\min}(\mathbf{J}^0) > 0$

$\lambda_{\max}((\mathbf{J}^0)^{-1}) > 0$ .

A norma Euclidiana de  $\mathbf{J}^0$  pode ser expressa por (BARNET; STOREY, 1970):

$$\|\mathbf{J}^0\|_e \stackrel{\text{def}}{=} \{\text{Tr}[(\mathbf{J}^0)^{-1}]^T (\mathbf{J}^0)^{-1}\}^{1/2}$$

$$= \sqrt{\langle \boldsymbol{\alpha}, \boldsymbol{\alpha} \rangle} \quad (4.3.23)$$

Observa-se que o cálculo de autovalores de qualquer matriz quadrada  $A$  corresponde à solução da equação (BARNET; STOREY, 1970):

$$A \mathbf{x} = \lambda \mathbf{x} \quad (4.3.24)$$

sendo:

$\lambda$  : autovalor de  $A$

$\mathbf{x}$  : autovetor de  $A$  associado ao autovalor  $\lambda$ .

Aplicando as seguintes propriedades de normas de matrizes e vetores (BARNET; STOREY, 1970):

- $\|A \mathbf{x}\| \leq \|A\| \|\mathbf{x}\|, \mathbf{x} \neq \mathbf{0}$  e
- $\|\lambda \mathbf{x}\| = |\lambda| \|\mathbf{x}\|$  ( $\therefore |\lambda| = \|\mathbf{x}\|^{-1} \|A \mathbf{x}\|$ )

na Equação (4.3.24) e particularizando-se ao problema associado à matriz  $(J^0)^{-1}$  e à norma Euclidiana, obtém-se a seguinte relação (BARNET; STOREY, 1970):

$$|\lambda_i((J^0)^{-1})| \leq \|(J^0)^{-1}\|_e, \forall \lambda_i((J^0)^{-1}) \quad (4.3.25)$$

sendo:

- $\lambda_i((J^0)^{-1})$  : autovalor de  $(J^0)^{-1}$ ;
- $\|\cdot\|_e$  : norma Euclidiana definida na equação (4.3.23).

A inequação (4.3.25) pode ser aplicada, em particular, ao autovalor  $\lambda_{\max}[(J^0)^{-1}]$ :

$$|\lambda_{\max}((J^0)^{-1})| \leq \|(J^0)^{-1}\|_e \quad (4.3.26)$$

Levando-se em conta o resultado da inequação (4.3.26) nas Equações (4.3.22) e (4.3.23), conclui-se que:

$$\lambda_{\min}(\mathbf{J}^0) \geq \sqrt{\frac{1}{\langle \boldsymbol{\alpha}, \boldsymbol{\alpha} \rangle}} \quad (4.3.27)$$

ou seja:

$$\lambda_{\min}(\mathbf{J}^0) \geq \mathcal{M} \geq 0. \quad (4.3.28)$$

Deste modo, a margem de segurança  $\mathcal{M}$  representa uma estimativa pessimista (favorável à segurança do sistema) do parâmetro  $\lambda_{\min}(\mathbf{J}^0)$ . A estimativa de  $\lambda_{\min}(\mathbf{J}^0)$  pode ser calculada, de forma alternativa, aplicando-se a norma matricial à matriz inversa de  $\mathbf{J}^0$ .

## 4.4 Comentários

Foi apresentado, neste capítulo, um procedimento de cálculo alternativo do índice (margem) de segurança ( $\mathcal{M}$ ). Esta margem de segurança será, então, usada como critério de análise da estabilidade estática da tensão de sistemas elétricos de potência, via redes neurais. Esta margem de segurança será, posteriormente, transformada em classe, via codificação binária, com o propósito de conferir maior rapidez do treinamento da rede neural e melhorar a confiabilidade da análise. A margem de segurança  $\mathcal{M}$ , além de ser usada como critério de análise da estabilidade estática de tensão, possibilita a investigação de outros resultados, a serem explorados posteriormente, sobre o mecanismo da estabilidade tensão, a partir do estudo da equação (4.3.19), pois ela apresenta uma maior visibilidade por estar representando as variações reais do sistema. Por exemplo, ao invés de se adotar a solução para  $\boldsymbol{\psi}(\Delta\mathbf{J})$ , definida pela equação (4.3.21), pode-se observar e inferir o comportamento do produto interno  $\langle \boldsymbol{\alpha}, \boldsymbol{\psi}(\Delta\mathbf{J}) \rangle$  em função do crescimento da carga.

## Capítulo 5

### Redes Neurais ART *Fuzzy* e ARTMAP *Fuzzy*

#### 5.1 Introdução

A teoria de ressonância é um fenômeno bastante observado na natureza, em especial, é um dos principais mecanismos empregados pelo cérebro humano. Todo o processo de reconhecimento dar-se-á por um processo de observação de verossimilhança (ressonância). Com estas qualidades, as redes neurais da família ART se destacam em relação às demais redes disponíveis na literatura especializada. A estabilidade está associada à garantia da obtenção de soluções. A plasticidade, por sua vez, refere-se à capacidade de incluir novos padrões sem a necessidade de reiniciar todo o processo de treinamento, como é comumente observado na maioria das redes neurais disponíveis na literatura. Outra importante característica, refere-se à grande velocidade de realização do treinamento, e o diagnóstico correspondente, tornado-a um sistema adequado para aplicação em tempo real. A arquitetura neural ART *Fuzzy* (CARPENTE; GROSSBERG, 1992) foi projetada para manipular dados, tanto analógicos, assim como binários. Esta é uma configuração adequada para compor a metodologia proposta nesta pesquisa de doutorado. As redes neurais ART são não-supervisionadas. Neste trabalho, há necessidade de empregar as formas de treinamento: não-supervisionada e supervisionada. Assim, outra concepção ART-descendente foi proposta em CARPENTER e GROSSBERG (1992) com o propósito de operar no modo supervisionado.

Trata-se de um arranjo de duas redes neurais ART conectada, através de um módulo inter-ART. As duas redes neurais ART são responsáveis por receberem os estímulos de entrada e de saída, respectivamente. O módulo inter-ART desempenha a função de realizar o “casamento” entre os estímulos de entrada e de saída, ou seja, realizando um mapeamento entre entrada e saída (realização de uma função complexa). Esta rede é denominada ARTMAP (CARPENTER; GROSSBERG, 1992) ou, ARTMAP *Fuzzy*, quando incorporados os conceitos da lógica *fuzzy* (KARTALOPOULOS, 1996). Neste capítulo, serão, então, apresentadas as redes neurais ART *Fuzzy* e ARTMAP *Fuzzy*. Ressalta-se que a representação vetorial é adotada por linha e não como coluna (forma habitual). Trata-se da representação proposta pelos autores das redes neurais da família ART.

## 5.2 Rede Neural ART *Fuzzy*

Na Figura 5.2.1 ilustra-se a concepção básica da rede neural ART *Fuzzy*. Esta rede neural é composta por três camadas:  $F_0$  (camada de entrada),  $F_1$  (camada de comparação) e  $F_2$  (camada de reconhecimento que armazena as categorias (*clusters*)).




Figura 5.2.1. Rede neural ART *Fuzzy*.

As grandezas indicadas na Figura 5.2.1.,  $\mathbf{a}$ ,  $\mathbf{x}$ , ...,  $\mathbf{y}$ , serão definidas no algoritmo apresentado a seguir.

**Passo 1: Dados de Entrada**

Os dados de entrada são denotados pelo vetor  $\mathbf{a} = [ a_1 \ a_2 \ . \ . \ . \ a_M ]$   $M$ -dimensional. Este vetor é normalizado com o intuito adequá-lo ao padrão da lógica *fuzzy*. Assim:

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|} \quad (5.2.1)$$

sendo:

$\bar{\mathbf{a}}$  : vetor de entrada normalizado;

$$|\mathbf{a}| = \sum_i |a_i|. \quad (5.2.2)$$

**Passo 2: Codificação do vetor de entrada**

A codificação de complemento é realizada para preservar a amplitude da informação, ou seja:

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (5.2.3)$$

Assim sendo, o vetor de entrada será um vetor  $2M$ -dimensional, sendo denotado por:

$$\mathbf{I} = [ \bar{\mathbf{a}} \ \bar{\mathbf{a}}^c ]$$

em que:

$\bar{\mathbf{a}}^c$  : vetor complementar de entrada normalizado.

Assim,

$$\mathbf{I} = [\bar{a}_1 \ \bar{a}_2 \ \dots \ \bar{a}_M \ \bar{a}_1^c \ \bar{a}_2^c \ \dots \ \bar{a}_M^c] \quad (5.2.4)$$

$$|\mathbf{I}| = \sum_{i=1}^M \bar{a}_i + \sum_{i=1}^M \bar{a}_i^c$$

=  $M$  (todos os vetores com normalização e codificação complementada terão mesmo comprimento  $M$ ).

### Passo 3: Vetor de Atividade

O vetor de atividade de  $F_2$  é simbolizado por  $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_N]$ , sendo  $N$  o número de categorias criadas em  $F_2$ . Deste modo, tem-se:

$$\mathbf{y} = \begin{cases} 1, & \text{se o nó } J \text{ de } F_2 \text{ é ativo,} \\ 0, & \text{caso contrário.} \end{cases} \quad (5.2.5)$$

### Passo 4: Parâmetros da Rede Neural

Os parâmetros usados no processamento da rede ART *Fuzzy* são:

1. Parâmetro de escolha :  $\alpha > 0$ ;
2. Taxa de treinamento :  $\beta \in [0,1]$ ;
3. Parâmetro de vigilância :  $\rho \in [0,1]$ .

### Passo 5: Inicialização dos Pesos

Inicialmente todos os pesos possuem valor igual a 1, ou seja:

$$w_{j1}(0) = \dots = w_{j2M}(0) = 1 \quad (5.2.6)$$

indicando que não existe nenhuma categoria ativa.

### Passo 6: Escolha da Categoria

Dado o vetor de entrada  $I$  em  $F_1$ , para cada nó  $j$  em  $F_2$ , a função de escolha  $T_j$  é determinada por:

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (5.2.7)$$

sendo:

$\wedge$  : operador *AND fuzzy*, definido por:

$$(I \wedge w)_i = \min(I_i, w_i). \quad (5.2.8)$$

A categoria é escolhida como sendo o nó  $J$  ativo, *i.e.*:

$$J = \arg \max_{j=1, \dots, N} T_j \quad (5.2.9)$$

Usando-se a equação (5.2.9), se existir mais de uma categoria ativa, a categoria escolhida será aquela que possuir menor índice.

### Passo 7: Ressonância ou Reset

A ressonância ocorre se o critério de vigilância (10) for satisfeito:

$$\frac{|I \wedge w_J|}{|I|} \geq \rho \quad (5.2.10)$$

Caso o critério definido pela equação (10) não seja satisfeito, ocorre o *reset*.

No *reset*, o nó  $J$  de  $F_2$  é excluído do processo de busca dado por (5.2.10), ou seja,  $T_J = 0$ .

Então, é escolhida uma nova categoria através de (5.2.9) para o processo de ressonância. Este procedimento será realizado até que a rede encontre uma categoria que satisfaça a inequação (5.2.10).

### Passo 8: Atualização dos Pesos (Treinamento)

Após o vetor de entrada  $I$  ter completado o estado de ressonância, segue o processo de treinamento, no qual ocorre a modificação do vetor peso dado por:

$$w_J^{\text{nov}} = \beta (I \wedge w_J^{\text{vel}}) + (1 - \beta) w_J^{\text{vel}} \quad (5.2.11)$$

sendo:

$J$  : categoria ativa;

$w_J^{\text{nov}}$  : vetor peso atualizado;

$w_J^{\text{vel}}$  : vetor peso referente à atualização anterior.

Observa-se que  $\beta \in [0, 1]$ . Se  $\beta = 1$ , tem-se o treinamento rápido. Caso contrário, o treinamento se processa de modo convencional das redes neurais ART-descendentes.

A Figura 5.2.2 (LOPES, 2005) indica todos os procedimentos usados nos cálculos do algoritmo da rede neural ART *Fuzzy*.

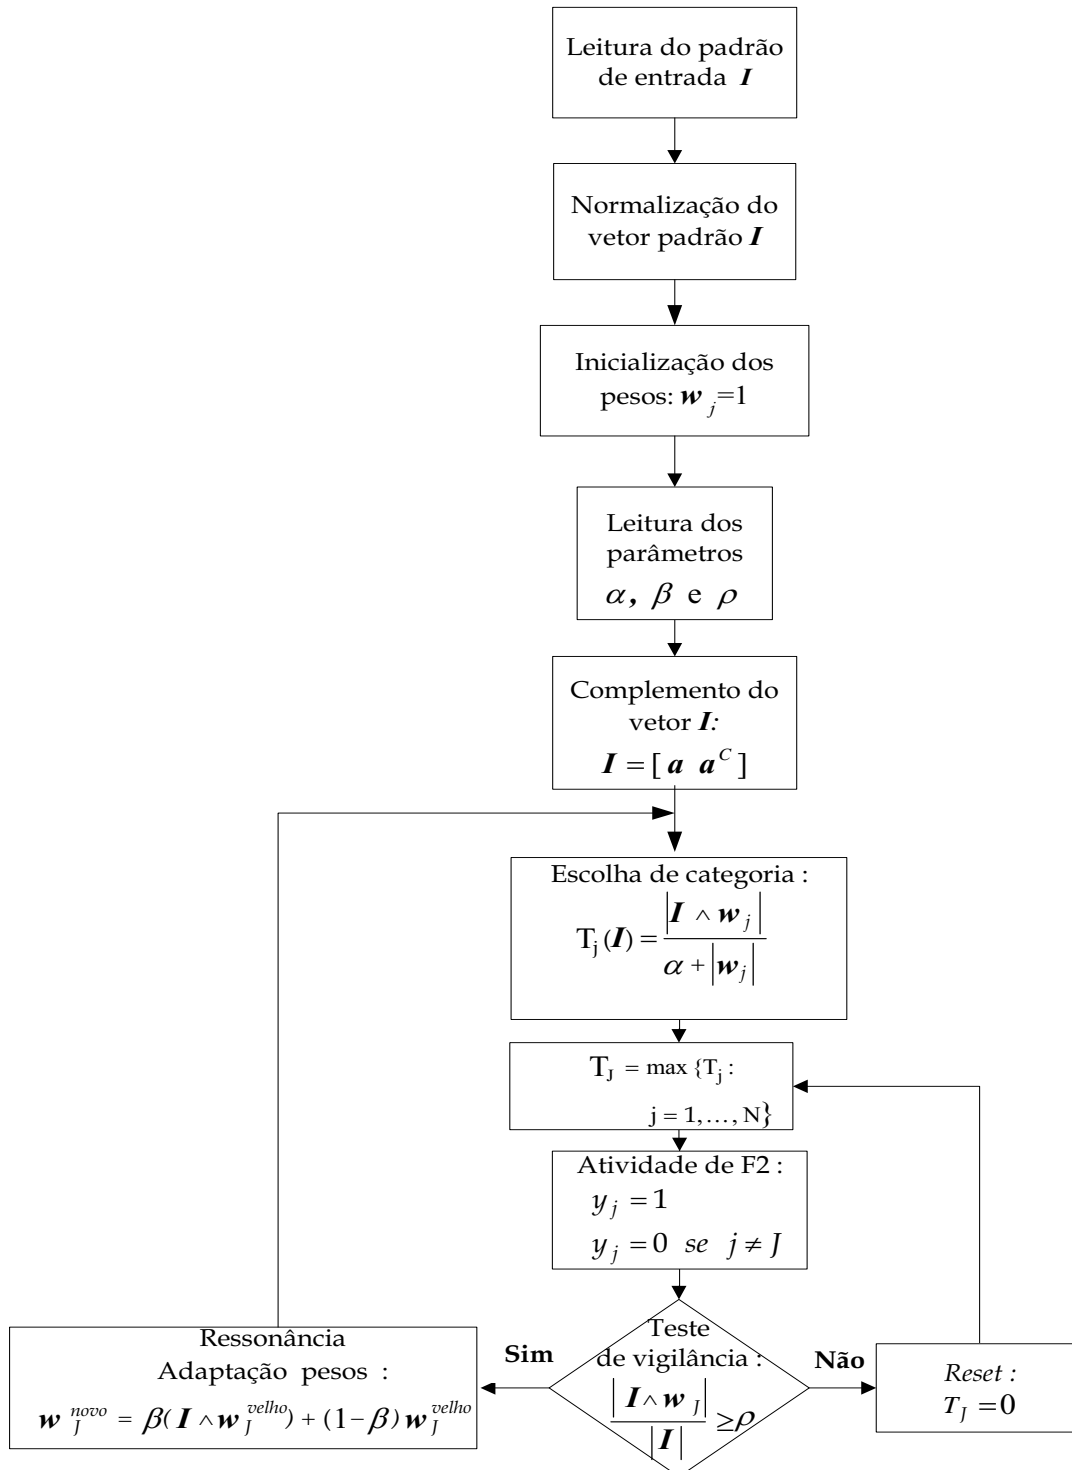


Fig. 5.2.2. Fluxograma da rede neural ART *Fuzzy*.

### 5.3 Rede Neural ARTMAP *Fuzzy*

A rede neural ARTMAP é uma arquitetura em que o treinamento é realizado de modo supervisionado e auto-organizável. Destinada-se à aproximação de funções não-lineares multidimensionais. Esta rede é composta por dois módulos ART<sub>a</sub> e ART<sub>b</sub>, que possuem a mesma estrutura da rede neural ART descrita anteriormente, exceto quando uma vigilância básica é usada para controlar o sistema. O módulo Inter-ART é responsável pela verificação se há casamento da entrada (ART<sub>a</sub>) e da saída (ART<sub>b</sub>). As matrizes pesos associadas aos módulos ART<sub>a</sub> ( $\mathbf{w}^a$ ) e ART<sub>b</sub> ( $\mathbf{w}^b$ ), assim como ao módulo Inter-ART ( $\mathbf{w}^{ab}$ ), são iniciadas com valores iguais a 1, *i.e.*, todas as atividades encontram-se inativas. Estas atividades são ativadas à medida que ocorre ressonância entre os padrões de entrada e de saída. Toda vez que os pares de entrada ( $\mathbf{a}$ ,  $\mathbf{b}$ ), associados aos módulos ART<sub>a</sub> e ART<sub>b</sub>, são confirmados (as entradas  $\mathbf{a}$  e  $\mathbf{b}$  referem-se às categorias  $J$  e  $K$  ativas, respectivamente), de acordo com o teste do *match tracking*:

$$|\mathbf{x}^{ab}|_i = \frac{|\mathbf{y}_i \wedge \mathbf{w}^{ab}_J|}{|\mathbf{y}_i|} \quad (5.3.1)$$

$|\mathbf{x}^{ab}|_i \geq \rho_{ab} \rightarrow \text{OK}$ , o par de treinamento deve ser confirmado nas matrizes de pesos com índices  $J$  e  $K$ .

$|\mathbf{x}^{ab}|_i < \rho_{ab} \rightarrow$  deve-se buscar um outro índice  $J$  (com relação aos vetores de entrada  $\mathbf{a}$ ) vetor, até que o critério seja satisfeito.

sendo:  $\rho_{ab}$  : parâmetro de vigilância do módulo Inter-ART.

Os pesos  $\mathbf{w}^a$ ,  $\mathbf{w}^b$  e  $\mathbf{w}^{ab}$  devem ser adaptados usando-se as equações (5.3.2):

$$\begin{aligned} \mathbf{w}^a_{J \text{ novo}} &= \beta (I \wedge \mathbf{w}^a_{J \text{ velho}}) + (1 - \beta) \mathbf{w}^a_{J \text{ velho}} \\ \mathbf{w}^b_{K \text{ novo}} &= \beta (I \wedge \mathbf{w}^b_{K \text{ velho}}) + (1 - \beta) \mathbf{w}^b_{K \text{ velho}} \\ \mathbf{w}^{ab}_{JK \text{ novo}} &= 1 \end{aligned} \quad (5.3.2)$$

O fluxograma apresentado na Figura 5.3.1 (LOPES, 2005) estabelece os procedimentos do algoritmo ARTMAP *Fuzzy* de uma forma simples.

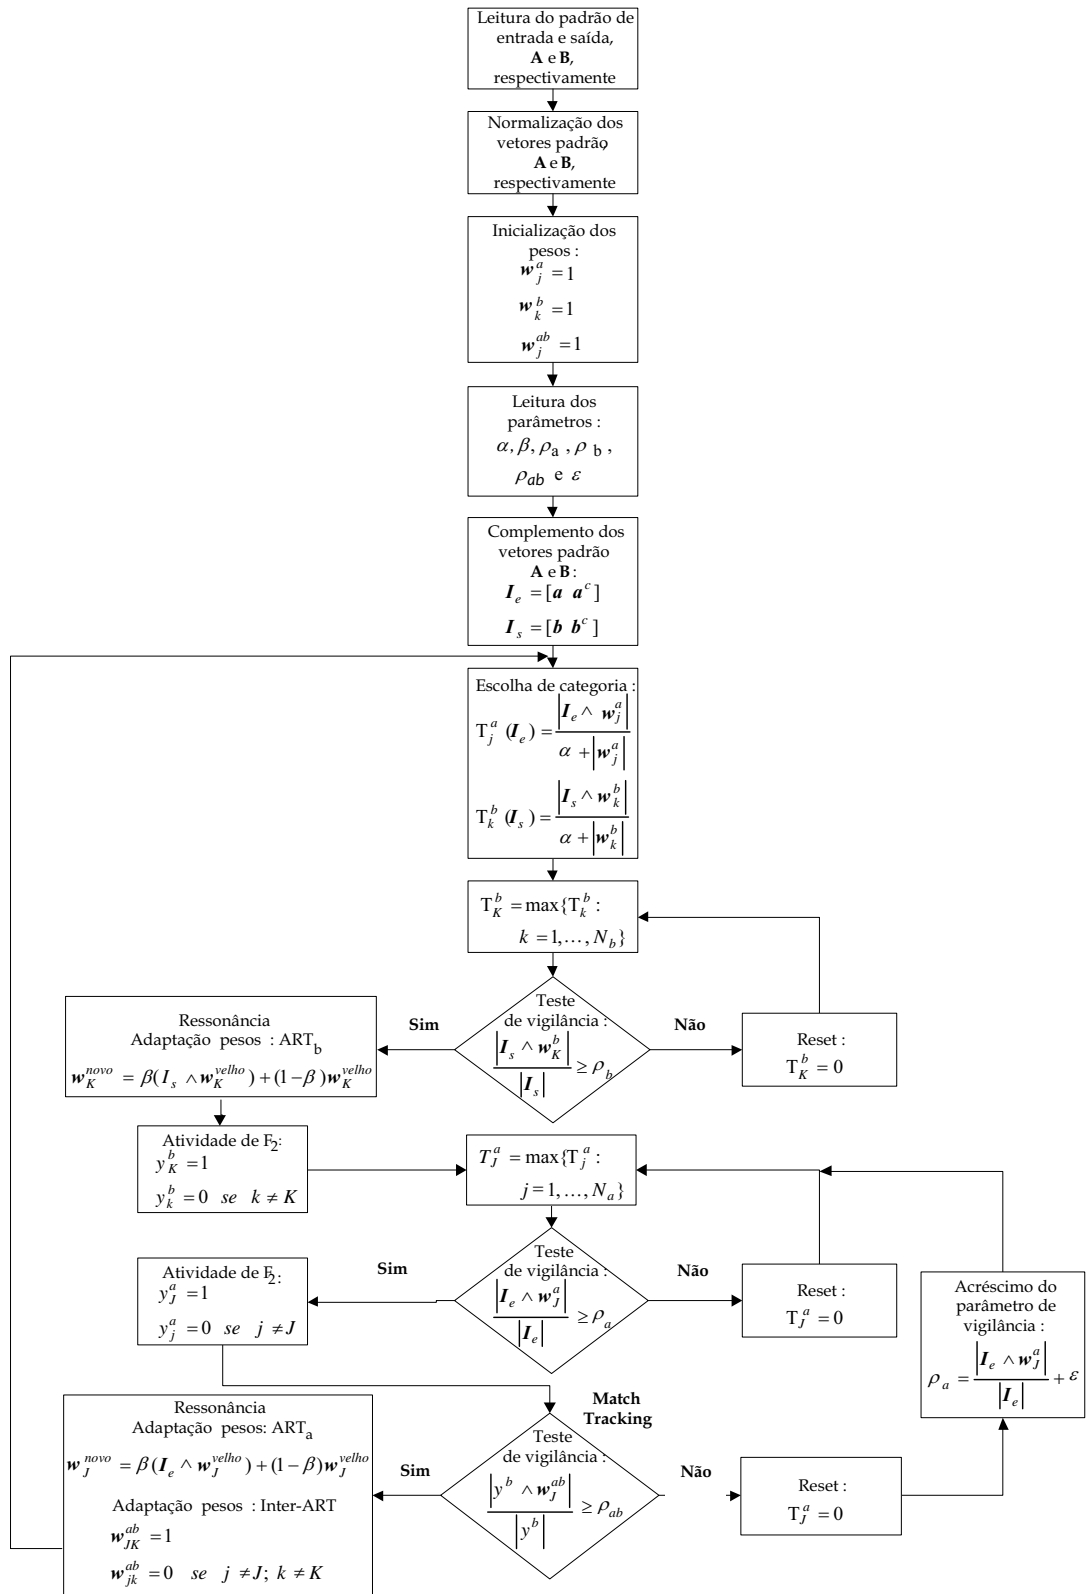


Fig. 5.3.1. Fluxograma da rede neural ARTMAP *Fuzzy*.

## 5.4 Estímulos de Entrada da Rede Neural ARTMAP *Fuzzy*

A estrutura neural proposta visa a análise de estabilidade transitória de sistemas de energia elétrica, que corresponde à determinação da margem de segurança, considerando-se defeitos de curto-circuito trifásico com saída de linha de transmissão. Os vetores padrões de entrada da rede neural são definidos como (SILVEIRA, 2003):

$$X = [P \ Q \ Z] \quad (5.4.1)$$

sendo:

$$P = [P_1 \ P_2 \ \dots \ P_n];$$

$$Q = [Q_1 \ Q_2 \ \dots \ Q_n];$$

$X$  : vetor padrão de entrada da rede neural;

$Z$  : vetor contendo as informações em código binário;

$P_i$  : potência ativa da  $i$ -ésima barra do sistema;

$Q_i$  : potência reativa da  $i$ -ésima barra do sistema;

$n$  : número de barras do sistema.

Para a realização do treinamento – extração do conhecimento baseado em estímulos de entrada / saída – deve-se proceder a apresentação de um conjunto de dados, no caso,  $X = [P \ Q \ Z]$  (entrada) e  $Y$  (saída), constituindo um conjunto de pares de treinamento. Trata-se de geração dos vetores  $P$  e  $Q$ , para a geração e para a carga do sistema por um procedimento de distribuição aleatória da geração (despacho aleatório para atender a demanda) e, também, de distribuição aleatória da carga (demanda aleatória), como mostrado a seguir (SILVEIRA, 2003). O vetor  $Z$  é formado por informações (em código binário) representado a topologia da rede elétrica, os dados das contingências, etc.

Considere um sistema com uma determinada topologia contendo  $NB$  barras, sendo que são  $NG$  barras de geração e as demais são barras de carga ( $NL = NB - NG$ ).

Considere, ainda, que se deseja realizar o despacho de geração para atender uma demanda variável, tomando-se como referência o caso base:  $PG^0$ ,  $QG^0$ ,  $PL^0$  e  $QL^0$ : sendo:

$PG^0$  : vetor de potência ativa dos geradores do caso base;

$QG^0$  : vetor de potência reativa dos geradores do caso base;

$PL^0$  : vetor de potência ativa das cargas do caso base;

$QL^0$  : vetor de potência reativa das cargas do caso base.

Para se gerar um grande espectro de variação da demanda, o critério a ser usado refere-se à distribuição aleatória da demanda e, conseqüentemente, da geração para atender a demanda, tomando-se variações percentuais da carga e da geração em torno do caso base (considerado como sendo o perfil de geração / carga de 100%). Por exemplo, arbitrando-se um percentual de 10%, pode-se realizar vários perfis de geração e de carga, realizando despachos de geração e definição da carga do sistema, distribuindo-se a geração e a carga de forma aleatória nas barras do sistema, respeitando-se o percentual arbitrado.

As potências ativas das barras de geração podem ser definidas por (SILVEIRA, 2003):

$$PG_i = PG_i^0 + \Delta PG_i \quad (5.4.2)$$

sendo:

$PG_i$  : potência ativa no  $i$ -ésimo gerador fixada aleatoriamente (ou pseudo-aleatoriamente);

$$\Delta PG_i = PG_{\text{total}}^0 \times Per \times AG_i / KG \quad (5.4.3)$$

$$PG_{\text{total}}^0 = \sum_{i \in \Omega(G)} PG_i^0 \quad (5.4.4)$$

$\Omega(G)$  : conjunto de barras de geração;

$Per$  : percentual de variação da demanda (valores positivos e negativos: por exemplo,  $Per = \pm 10\%$  correspondem a 90 e 110% do caso base, respectivamente);

$AG_i$  : número aleatório de uma sequência de  $NG$  números gerados a partir de uma semente dada. Variando-se a semente, ter-se-á uma sequência diferente de valores, cujo espectro de variação está compreendido entre 0 e 1:  $AG_i \in [0,1]$ ;

$$KG = 100 AG_{total} \quad (5.4.5)$$

$$AG_{total} = \sum_{i \in \Omega(G)} AG_i \quad (5.4.6)$$

As potências reativas das máquinas síncronas são determinadas na rotina referente ao cálculo do fluxo de potência (barras PV).

Com relação às cargas ativas, os perfis de variação (curva variável de demanda) podem ser, então, obtidos por (SILVEIRA, 2003):

$$PL_i = PL_i^0 + \Delta PL_i \quad (5.4.7)$$

sendo:

$PL_i$  : potência ativa na  $i$ -ésima carga fixada aleatoriamente;

$$\Delta PL_i = PL_{total}^0 \times Per \times AL_i / KL \quad (5.4.8)$$

$$PL_{total}^0 = \sum_{i \in \Omega(L)} PL_i^0 \quad (5.4.9)$$

$AL_i$  : número aleatório de uma sequência de  $NL$  números gerados a partir de uma semente dada,  $AL_i \in [0,1]$ .

$$KL = 100 AL_{total} \quad (5.4.10)$$

$$AL_{total} = \sum_{i \in \Omega(L)} AL_i. \quad (5.4.11)$$

$\Omega(L)$  : conjunto de barras de cargas.

As cargas reativas são fixadas considerando-se uma distribuição que preserva o fator de potência referente ao caso base. Este procedimento tenta estabelecer uma distribuição com um nível de inter-relação entre a potência ativa mais plausível, se comparado ao usado em (SILVEIRA, 2003). Contudo, pode-se buscar, também, outras formas de distribuição das cargas ativas que, em outras oportunidades, poder-se-ão investigar tal procedimento.

## 5.5 Estímulos de Saída da Rede Neural ARTMAP *Fuzzy*

Os estímulos de saída compreendem, nesta pesquisa, os valores da margem de segurança ( $M$ ) calculados conforme descrito no Capítulo 4. Ou seja, os padrões de treinamento correspondem aos parâmetros:

$$X_j = [ P_j \ Q_j \ Z ] \text{ (entradas)} \quad (5.5.1)$$

$$Y_j = [ \underline{M}_j ] \text{ (saídas)} \quad (5.5.2)$$

$$j = 1, 2, \dots, np.$$

sendo  $np$  o número de pares de padrões para a fase de treinamento.

A saída  $\underline{M}_j$  é codificada por classes (em código binário), sendo que cada classe expressa o grau de severidade das contingências e/ ou carregamento do sistema. Para uma representação, por exemplo, de 15 classes são necessários 4 *bits*. Como a saída da rede neural ARTMAP *fuzzy* é codificada considerando-se a inclusão do complemento do vetor, para representá-la são necessários 8 *bits*.

## 5.6 Comentários

Anteriormente apresentou-se a rede neural ARTMAP *Fuzzy* (ART descendente) que se constitui o módulo principal do procedimento proposto para a realização da análise de estabilidade estática de tensão. Trata-se de um esquema que busca emular o conceito da margem da segurança ( $M$ ) que foi desenvolvido no Capítulo 4. Foi apresentado, também, o processo de organização e extração do conjunto de padrões de entrada e de saída da rede neural para a fase de treinamento. No Capítulo subsequente, serão realizadas as aplicações considerando-se dois sistemas-exemplo.

## Capítulo 6

# Aplicações das Redes Neurais na Análise de Estabilidade de Tensão de Sistemas de Energia Elétrica

### 8.1 Introdução

Este capítulo destina-se à apresentação de testes computacionais. Primeiramente, apresenta-se os resultados obtidos considerando-se um sistema elétrico de potência composto por 9 barras e 3 máquinas síncronas (ANDERSON; FOUAD, 2003) e a seguir os resultados considerando-se um sistema baseado na configuração da região Sul do Brasil composto por 45 barras e 10 máquinas síncronas (FERREIRA, et al. 2006).

A rede neural possui, como critério de treinamento, um índice (margem) de segurança desenvolvido na análise de sensibilidade da função determinante da matriz jacobiana ( $J^0$ ), calculada empregando-se o conceito de álgebra de Kronecker (GEROMEL, 1987). Estes índices de segurança são gerados, formando uma base de dados para a execução da fase de treinamento da rede neural, via processamento do programa computacional Simul (SIMUL, 1990). Este *software* realiza os cálculos dos seguintes problemas: (1) fluxo de potência, via método de Newton desacoplado rápido (MONTICELLI, 1983) e (2) análise da estabilidade transitória de sistemas elétricos de potência baseada no método PEBS (*Potential Energy Boundary Surface*) (ATHAY, et al. 1979) por processo iterativo (FONSECA; DECKER, 1985). Para a obtenção de tais índices, ao programa Simul, foram incluídas

modificações necessárias para gerar combinações aleatórias (ou pseudo-aleatórias) de perfis de geração / carga como forma de simular uma grande quantidade de situações operativas dos sistemas e, conseqüentemente, a obtenção dos índices de segurança correspondentes. Ressalta-se que o cálculo do fluxo de potência pode ser realizado usando qualquer *software* disponível no mercado, desde que esteja disponível o código da linguagem computacional, pois há necessidade de incluir vários detalhes de cálculo, *e.g.*, a distribuição pseudo-aleatória da geração/carga. Por maior facilidade, usou-se o programa computacional Simul por estar totalmente aberto ao usuário.

Os resultados da análise, via rede neural (ARTMAP *Fuzzy*), são comparados com os resultados obtidos por simulação usando o programa SIMUL.

Ressalta-se que neste trabalho não será tratada a análise de contingências (modelada via vetor  $Z$ ). Contudo, este tema faz parte dos planos na sequência desta pesquisa.

## **6.2 Sistema de Três Máquinas Síncronas**

Apresentam-se a seguir, os resultados obtidos através do uso do método proposto neste trabalho. Trata-se de um sistema de transmissão composto por 3 máquinas síncronas e 9 barras (ANDERSON; FOUAD, 2003). Os dados das máquinas síncronas, bem como das linhas de transmissão e, das barras do sistema encontram-se listados no Apêndice C. O diagrama unifilar do sistema encontra-se ilustrado na Figura 6.2.1.




Figura 6.2.1. Sistema Composto por 3 Máquinas e 9 Barras.

O treinamento da rede neural foi realizado considerando-se um conjunto de 1003 perfis de geração / carga e respectivas margens de segurança  $\mathcal{M}$ . Cada perfil corresponde a um redespacho de geração em relação ao caso base, realizado de forma aleatório em cada barra.

O universo de variação de carga encontra-se correspondido entre 100% e 270%, em relação à carga total do sistema. Portanto, cada perfil é gerado considerando-se um percentual de variação em torno do estado nominal (caso base) e uma determinada semente para o processo de geração de seqüências aleatórias. Assim, para um mesmo percentual, diferentes sementes poderão gerar diferentes despachos de geração de diferentes perfis de carga.

Os resultados da análise são apresentados, nesta pesquisa de doutorado, na forma de classes de 1 a 15. Estas classes são adotadas visando constituir as saídas em código binário, *i.e.*, um modo mais adequado para se usar as redes neurais da família ART. Assim, adotou-se a seguinte definição das classes: 1, 2, ..., 15 (representação com 4 *bits*), que correspondem a  $0 \leq \mathcal{M} < 0,1$ ,  $0,1 \leq \mathcal{M} < 0,2$ , ...,  $1,4 \leq \mathcal{M} < 1,5$ , respectivamente. Assim, quanto menor for o número da classe, mais crítico é o ponto de operação do sistema, do ponto de vista da estabilidade estática de tensão. Com estas definições, podem-se estimar as

“distâncias” que cada perfil de geração e de carga se encontra em relação à fronteira da estabilidade de tensão. Tais intervalos, associados às classes, podem ser definidos, aumentando-os ou diminuindo-os de acordo com o interesse do usuário. Neste caso, deve-se ajustar o número de *bits* em função da maior ou da menor discretização usada.

Realizado o treinamento da rede neural, os testes (análise de estabilidade de tensão) podem ser efetivados, cujos resultados são mostrados na Tabela 6.2.1. Nesta Tabela, na coluna 1 estão alocados os percentuais comparativamente ao **caso base** (arbitrado como 100%). Deste modo, um percentual de 120% corresponde a um acréscimo de 20% em relação ao caso base. A carga total e a geração total terão um acréscimo de 20% distribuído pseudo-aleatoriamente em função da semente que consta na coluna 2. Assim, para um mesmo percentual de acréscimo (positivo ou negativo), diferentes sementes produzem diferentes realocações de geração e diferentes valores de cargas nos diversos barramentos do sistema. Deste modo, justifica-se o registro, na Tabela 6.2.1, do valor da semente usado em cada perfil de geração/carga. Observa-se que, aumentando-se este percentual, não necessariamente produzirá uma margem de segurança menor, pois isto depende da semente usada. Por exemplo, num cenário de geração/carga mais leve pode haver uma distribuição maior em barramentos mais críticos da rede, ocasionando uma margem de segurança menor que, a princípio, a expectativa era que fosse maior. Na coluna 3, constam os valores da margem de segurança ( $\mathcal{M}$ ) calculados pelo aplicativo Simul. Este programa é adotado, nesta pesquisa de doutorado, como uma referência de precisão, tendo em vista que os cálculos são executados observando o rigor necessário. Nas colunas 4 e 5, são relacionadas as classes ( $\underline{\mathcal{M}}$ ) associadas às margens de segurança, para fins de comparação entre os resultados produzidos pelo aplicativo Simul e pela rede neural ARTMAP *Fuzzy*, respectivamente. Então, uma classe 4 significa que a margem de segurança  $\mathcal{M}$  possui um valor entre 0,3 e 0,4.

Tabela 6.2.1. Comparação dos Métodos ARTMAP *Fuzzy* e Simul – Três Máquinas Síncronas.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\mathcal{M}$	
			Simul	ARTMAP <i>Fuzzy</i>
102,5	123	0,9166	10	10
102,5	6691	0,9162	10	10
107,5	4321	0,9116	10	10
107,5	201	0,9127	10	10
112,5	421	0,9058	10	10
112,5	74	0,9078	10	10
117,5	31	0,8989	9	9
117,5	9934	0,9014	10	10
127,5	221	0,8966	9	9
127,5	123	0,8852	9	9
132,5	6691	0,8822	9	9
132,5	123	0,8762	9	9
142,5	177	0,8689	9	9
142,5	31	0,8542	9	9
147,5	342	0,8408	9	9
147,5	1964	0,7999	8	9
152,5	1241	0,8352	9	9
152,5	1964	0,7757	8	9
152,5	31	0,8287	9	9

Tabela 6.2.1. Continuação.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\underline{\mathcal{M}}$	
			Simul	ARTMAP <i>Fuzzy</i>
157,5	123	0,8145	9	8
157,5	342	0,8114	9	9
162,5	123	0,7983	8	8
162,6	1241	0,8079	9	9
162,5	6691	0,8352	9	9
167,5	123	0,7806	8	8
167,5	1241	0,7925	8	9
167,5	6691	0,8258	9	8
167,5	1964	0,6846	7	9
172,5	221	0,8224	9	9
172,5	1241	0,7758	8	8
172,5	342	0,7529	8	9
177,5	6691	0,8036	9	8
177,5	314	0,8173	9	9
177,5	1241	0,7577	8	8
182,5	6691	0,7916	8	8
182,5	314	0,8075	9	8
182,5	123	0,7171	8	6
187,5	201	0,7827	8	9
187,5	1241	0,7159	8	8

Tabela 6.2.1. Continuação.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\underline{\mathcal{M}}$	
			Simul	ARTMAP <i>Fuzzy</i>
187,5	123	0,6918	7	6
192,5	201	0,7688	8	8
192,5	1241	0,6922	7	8
192,5	6691	0,7628	8	7
197,5	7116	0,6995	7	8
197,5	177	0,7339	8	8
197,5	201	0,7538	8	8
197,5	6691	0,7448	8	7
202,5	201	0,7377	8	8
202,5	921	0,7318	8	8
202,5	177	0,7139	8	8
202,5	6691	0,7238	8	7
207,5	421	0,6891	7	7
207,5	6691	0,6963	7	7
207,5	201	0,7193	8	8
212,5	201	0,6993	7	7
212,5	688	0,7402	8	8
212,5	101	0,6682	7	7
217,5	74	0,7296	8	8
217,5	667	0,6791	7	7

Tabela 6.2.1. Continuação.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\underline{\mathcal{M}}$	
			Simul	ARTMAP <i>Fuzzy</i>
217,5	1241	0,5213	6	6
217,5	221	0,7054	8	7
222,5	6692	0,4747	5	5
222,5	201	0,6547	7	7
222,5	1241	0,4710	5	5
222,5	68	0,6589	7	7
222,5	1965	0,7021	8	6
227,5	921	0,6239	7	7
227,5	741	0,4709	5	6
227,5	9934	0,6071	7	7
227,5	384	0,6489	7	7
232,5	145	0,5457	6	6
232,5	10	0,3950	4	4
232,5	741	0,4100	5	4
237,5	688	0,6492	7	7
237,5	9934	0,4985	5	5
237,5	8243	0,5873	6	7
237,5	68	0,5043	6	6
237,5	567	0,6184	7	5
242,5	1967	0,5851	6	6

Tabela 6.2.1. Continuação.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\underline{\mathcal{M}}$	
			Simul	ARTMAP <i>Fuzzy</i>
242,5	9934	0,4985	5	5
242,5	384	0,5961	6	7
242,5	667	0,5082	6	5
242,5	9934	0,4985	5	5
247,5	314	0,5882	6	6
247,5	567	0,5437	6	6
247,5	5100	0,4766	5	6
247,5	9934	0,4456	5	4
247,5	721	0,5542	6	5
247,5	421	0,2479	3	4
252,5	77	0,4573	5	5
252,5	3981	0,5026	6	6
252,5	921	0,3968	4	4
252,5	614	0,4016	5	5
252,5	5100	0,4239	5	5
252,5	201	0,3995	4	6
257,5	145	0,1172	2	2
257,5	921	0,2903	3	3
257,5	102	0,4030	5	3
257,5	2100	0,4764	5	5

Tabela 6.2.1. Continuação.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\underline{\mathcal{M}}$	
			Simul	ARTMAP <i>Fuzzy</i>
257,5	8243	0,3865	4	4
257,5	721	0,4655	5	5
262,5	314	0,4570	5	5
262,5	912	0,2342	3	3
262,5	721	0,3994	4	4
262,5	112	0,3451	4	4
262,5	582	0,2839	3	2
262,5	5223	0,3435	4	4
262,5	2123	0,4097	5	4
267,5	688	0,2836	3	3
267,5	761	0,2572	3	3
267,5	2123	0,2795	3	4
267,5	1135	0,3057	4	3
267,5	384	0,2096	3	2

Os acertos do sistema neural são superiores a 85%, considerando-se 1003 simulações realizadas. Os acertos são considerados quando há coincidência das classes indicadas pelo programa Simul e pela rede neural ARTMAP *Fuzzy*. Ressalta-se que a rede neural ARTMAP *Fuzzy* tende, por via de regra, optar por uma classe de numeração inferior, *i.e.*, se houver alternativa de seleção entre classes que produziram o mesmo valor da função escolha, por exemplo, classes 5 e 6, o indicativo ficará com a classe 5. Se houver relaxamento

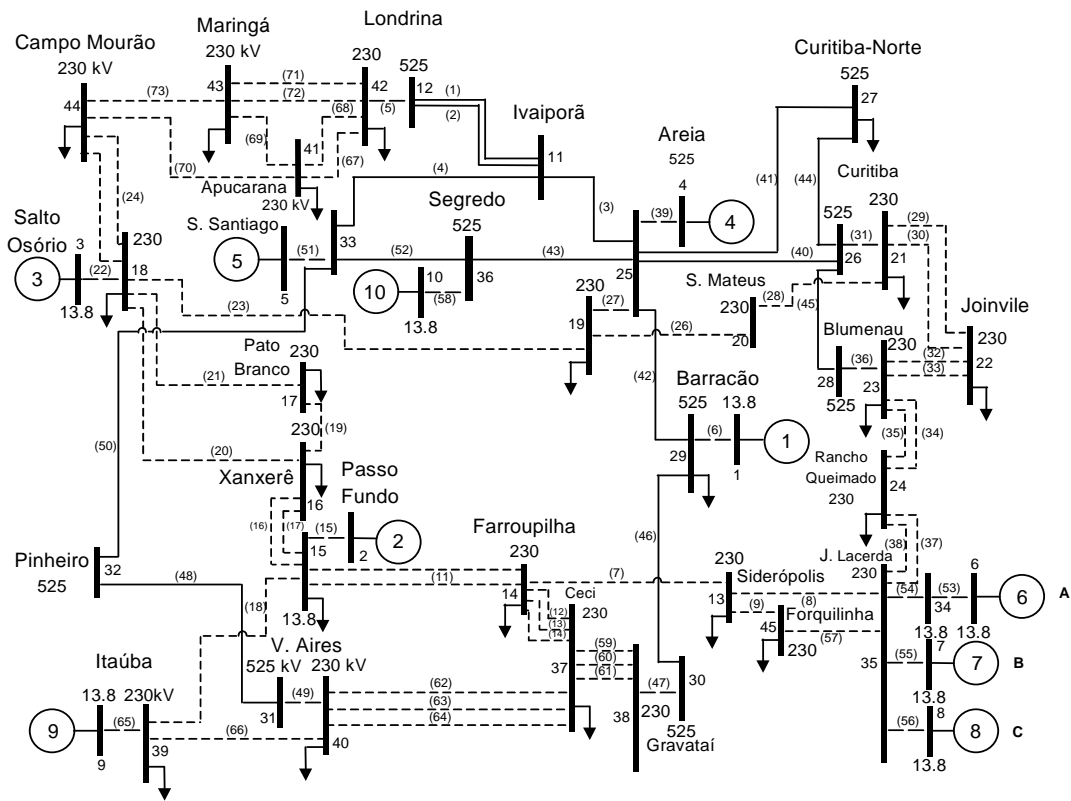
deste tipo de caso, (considera-o também como acerto), o percentual de acerto passa a ser superior a 95%. Este percentual, certamente irá aumentar, à medida que novos padrões forem incorporados à base de dados, através do processo referente ao treinamento continuado, e / ou usando-se outros tipos de geometria na rede neural ARTMAP *Fuzzy* (a qual emprega o conceito de hiper-retângulos (CARPENTER, et al. 1992)), *e.g.*, aproveitando melhor o desenvolvimento proposto por DAGHER, (2006), entre outras alternativas.

### **6.3 Sistema de Dez Máquinas Síncronas**

Nesta seção, apresentam-se alguns resultados obtidos, considerando-se um sistema real da região sul do Brasil composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão. O diagrama unifilar do sistema pode ser visto na Figura 6.3.1. Os dados das máquinas síncronas, do sistema de transmissão e das barras estão apresentados no Apêndice C.

Neste caso, o treinamento da rede foi realizado considerando-se um conjunto de 703 perfis de geração / carga e respectivas margens de segurança  $\mathcal{M}$ . Como no caso anterior, cada perfil corresponde a um redespecho de geração em relação ao caso base, realizado de forma aleatória para atender a demanda, também fixada de modo aleatório em cada barra. O universo de variação, neste caso, encontra-se correspondido entre 65 e 135%, em relação à carga total do sistema.

Realizado o treinamento da rede neural, os testes podem ser efetivados, cujos resultados são mostrados na Tabela 6.3.1. A definição de classes tem o mesmo significado da seção anterior. O mesmo padrão, usado na Tabela 6.2.1, vale também para a Tabela 6.3.1.



(--) Número das linhas de transmissão.

Figura 6.3.1. Representação do Sistema Sul-Brasileiro.

Tabela 6.3.1. Comparação dos Métodos ARTMAP *Fuzzy* e Simul – Dez Máquinas Síncronas.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\mathcal{M}$	
			Simul	ARTMAP <i>Fuzzy</i>
67,5	123	0,5994	6	6
67,5	689	0,6591	7	7
67,5	31	0,3274	4	2
67,5	9934	0,7642	8	8

Tabela 6.3.1. Continuação.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\mathcal{M}$	
			Simul	ARTMAP <i>Fuzzy</i>
72,5	123	0,6354	7	7
72,5	667	0,7226	8	8
72,5	31	0,4759	5	5
72,5	421	0,5882	6	6
72,5	51	0,7413	8	8
77,5	614	0,7096	8	8
77,5	123	0,6615	7	7
77,5	221	0,6435	7	7
77,5	68	0,7409	8	8
77,5	614	0,7096	8	8
82,5	123	0,6802	7	7
82,5	689	0,7090	8	8
82,5	201	0,6948	7	7
82,5	9934	0,7457	8	8
82,5	74	0,7278	8	8
87,5	31	0,6551	7	8
87,5	1964	0,5703	6	6
87,5	411	0,6982	7	8
87,5	820	0,7047	8	8
87,5	31	0,6551	7	7

Tabela 6.3.1. Continuação.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\underline{\mathcal{M}}$	
			Simul	ARTMAP <i>Fuzzy</i>
92,5	123	0,7003	8	7
92,5	31	0,6810	7	7
92,5	421	0,6939	7	7
92,5	7116	0,7354	8	8
92,5	721	0,7091	8	8
97,5	123	0,7018	8	8
97,5	221	0,7009	8	7
97,5	31	0,6961	7	7
97,5	7116	0,7134	8	8
97,5	264	0,7118	8	8
102,5	1241	0,6946	7	7
102,5	102	0,6897	7	7
102,5	31	0,7053	8	8
102,5	265	0,7017	8	8
117,5	31	0,6929	7	7
117,5	6691	0,6183	7	7
122,5	145	0,6055	7	6
122,5	123	0,6514	7	7
122,5	377	0,5662	6	6
122,5	221	0,6528	7	7

Tabela 6.3.1. Continuação.

%	Semente	Margem de Segurança $\mathcal{M}$ via Simul	Classe da Margem de Segurança $\underline{\mathcal{M}}$	
			Simul	ARTMAP <i>Fuzzy</i>
122,5	81	0,5992	6	7
127,5	123	0,6526	7	7
127,5	264	0,4855	5	5
127,5	177	0,5589	6	6
127,5	8555	0,5840	6	7
127,5	7116	0,4349	5	4
132,5	123	0,5873	6	6
132,5	145	0,4346	5	5
132,5	8555	0,5421	6	4
132,5	51	0,4631	5	5
132,5	4321	0,5487	6	6
132,5	421	0,5054	6	5

Ressalta-se que os acertos do neural são superiores a 85%, considerando-se 703 simulações realizadas.

## 6.4 Comentários e Considerações

Neste capítulo, foram apresentados os resultados das aplicações da metodologia proposta para análise de estabilidade estática de sistemas elétricos de potência multinodal, tomando-se dois sistemas testes: um sistema constituído por 3 máquinas síncronas, 9 barras e 9 linhas de transmissão e, o sistema baseado na configuração real da região Sul do Brasil composto por 10 máquinas, 43 barras e 73 linhas de transmissão. Trata-se de uma metodologia usando uma rede neural ARTMAP *Fuzzy*, cujo treinamento é realizado a partir de uma base de dados gerada via simulação (usando o programa computacional Simul): o cálculo de fluxo de potência, bem como outras grandezas que foram implementadas visando atender a necessidade da pesquisa proposta. Ressalta-se que os acertos do sistema neural, tanto no sistema composto por 3 máquinas quanto no sistema composto por 10 máquinas, são superiores a 85%, considerando-se 1003 e 703 simulações realizadas, respectivamente. Este acerto é superior a 95%, se houver o relaxamento no caso da indicação de uma classe vizinha, desde que corresponda uma classe mais crítica, ou seja, estando-se a favor da segurança do sistema. No sistema Anderson- Fouad, por exemplo, para o perfil de 247,5% (semente = 421) e para o perfil de 252,5% (semente = 201), os resultados obtidos foram otimistas, *i.e.*, a rede neural gerou classes menos críticas do que deveriam ser (classes corretas ou mais críticas). Estes são os casos que efetivamente devem ser considerados sem acerto.

## Capítulo 7

### Conclusão e Sugestões para Trabalhos Futuros

#### 7.1 Conclusão

Foi apresentada uma nova metodologia para análise de estabilidade de tensão estática de sistemas elétricos de potência multinodal. Trata-se de uma metodologia que emprega uma rede neural ARTMAP *Fuzzy*, cujo treinamento é realizado a partir de uma base de dados gerada via simulação computacional. Esta simulação realiza o cálculo das matrizes da rede elétrica, o cálculo de fluxo de potência, bem como outras grandezas que foram implementadas visando atender a necessidade do estudo proposto. A adoção da estratégia de obtenção desta base de dados (definição de perfis de geração e de carga de modo aleatório ou pseudo-aleatório) permitiu estabelecer um espectro de variação que “simule” os estados operativos reais. A arquitetura ARTMAP *Fuzzy*, tal como as demais redes da família ART, apresenta a característica de plasticidade (possibilita a implementação do treinamento continuado), o que se diferencia, de forma vantajosa, em relação às tradicionais redes neurais comumente usadas na literatura especializada.

Como ilustração da metodologia, foram apresentados os resultados da análise da estabilidade estática de tensão de sistemas de energia elétrica, via rede neural ARTMAP

*Fuzzy*, considerando-se dois sistemas elétricos de potência: um sistema Anderson-Fouad (ANDERSON & FOUAD, 2003) composto por 3 máquinas síncronas, 9 barras e 9 linhas de transmissão, e outro sistema Sul-Brasileiro (FERREIRA et al., 2006) composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão. Ressalta-se que o sistema Anderson-Fouad foi usado, inicialmente, com o propósito de proporcionar uma melhor compreensão dos fenômenos associados à instabilidade de tensão. Novas simulações estão sendo abordadas considerando-se sistema de maior porte (sistemas IEEE).

As simulações realizadas indicam um grande número de acertos e comprovam a rapidez de processamento da rede neural ARTMAP *Fuzzy*. O percentual de acerto foram superiores a 85%. Este percentual, certamente irá aumentar, à medida que novos padrões forem incorporados à base de dados, através do processamento referente ao treinamento continuado. Outra forma de melhorar a precisão consiste no desenvolvimento de outras arquiteturas ART descendentes usando-se outras geometrias nos módulos ART, *e.g.*, explorar todo o potencial do procedimento sugerido pelo Dagher (2006).

Tendo em vista as características de desempenho desta metodologia (rapidez de treinamento e flexibilidade de adaptação às diversidades topológicas da rede elétrica), a princípio, pode-se empregá-la para análise de estabilidade de sistemas elétricos de potências reais que necessitam de respostas imediatas, a fim de evitar, ou pelo menos, minimizar a interrupção do fornecimento de energia aos consumidores.

Ressalta-se que a rede neural ARTMAP *Fuzzy* apresenta algumas desvantagens, a saber: (1) necessidade de padronizar a base de dados (de entrada e de saída), ou seja, entradas e saídas devem ser grandezas positivas ( $\geq 0$ ) e inferiores a 1, justamente porque agregam-se os conceitos da lógica *fuzzy* à arquitetura ARTMAP. Há formas de contornar este problema. Por exemplo, usando uma rede neural ARTMAP Euclidiana que, a princípio, tem proporcionado melhorias do desempenho da rede neural; (2) as redes neurais ART-descendentes podem “modelar” funções complexas usando o conceito de formação de classes. Por exemplo, na arquitetura ART *fuzzy*, as classes são caracterizadas por hiper-retângulos. Aumentando-se ou diminuindo-se tais hiper-retângulos (via diminuição ou aumento do parâmetro de vigilância  $\rho$ ), pode-se determinar o “tamanho” de cada classe, *i.e.*, aumentando-se ou diminuindo-se a capacidade de generalização da rede neural. Este mecanismo de formação de classes pode produzir imprecisões nos resultados.

## 7.2 Sugestões para Trabalhos Futuros

Os resultados desta pesquisa podem ser considerados satisfatórios (no contexto da precisão e da rapidez na obtenção das soluções), conforme argumentado anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar esta metodologia mais eficiente e, ainda, propõem-se outros tipos de aplicações:

- 1) Desenvolvimento de estruturas neurais alternativas à rede ARTMAP *Fuzzy*, empregando, por exemplo, outras distâncias geométricas como propostas pelo Dagher (2006) e pelo Vuskovic e Du (2002). Tratam-se de procedimentos mais gerais que buscam estabelecer a formação de classes de forma mais precisas em comparação aos resultados aqui apresentados;
- 2) Implementação do mecanismo de treinamento continuado;
- 3) Desenvolver e aplicar a rede neural à análise da estabilidade estática de tensão, considerando-se as situações de contingências (saída de linhas de operação, etc.);
- 4) Desenvolver uma metodologia, baseada na arquitetura ART-descendente, à análise da estabilidade dinâmica de tensão de sistemas elétricos de potência, contemplando recentes modelos de mecanismos de instabilidade e estratégias de controle;
- 5) Desenvolver metodologias neurais ART-descendentes considerando-se as diversas topologias da rede elétrica.

## Referências

- ALVES, D. A.; LUIZ, C. P.; CASTRO, C. A.; COSTA, V. F. Alternative parameters for the continuation power flow method. *Electric Power Systems Research*, Lausanne, n 66, p.105-113, 2003.
- ANDERSON, P. M. ; FOUAD, A. A. *Power system control and stability*. 2.ed. New York: IEEE Series on Power Engineering, 2003.
- ANDRADE, A. C.; BARBOSA, F. P. M.; FIDALGO, J. N.; FERREIRA, J. R. Voltage stability assessment using a new FSQV method and artificial neural networks, electrotechnical conference, 2006. MELECON 2006. *IEEE Mediterranean*, New York, v.16, n.19, p.1003 – 1006, 2006.
- AJJARAPU, V.; CHRISTY, C. The Continuation power flow: a tool for steady state voltage stability analysis. *IEEE Transactions Power System*, New York, v. 7, n. 1, p. 304-311, 1992.
- ARYA, L.; CHOUBE, S. A.; SHRIVASTAVA, M. Technique for voltage stability assessment using newly developed line voltage stability index. *Energy Conversion and Management*, Oxford, v.49, n.2, p. 267-275, 2008.
- ATHAY, T.; SHERKET, V. R.; PODMORE, R.; VIRMANI, S.; PUECH, C. Transient energy stability analysis. In: CONFERENCE ON 'SYSTEM ENGINEERING FOR POWER', 1979, Davos, Switzerland. *Conference...* Davos: S.n., 1979.

AYASUN, S.; NWANKPA, C. O.; KWANTY, H. G. Computation of singular and singularity induced bifurcation points of differential-algebraic power system model. *IEEE Transaction On Circuits And System: Regular Papers*, New York, v. 51, n. 8, p. 1525-1538, 2004.

BARNETT, S.; STOREY, C. *Matrix methods in stability theory*. London: Thomas Nelson and Sons Ltd, 1970.

BENDER, E. A. *Mathematical methods in artificial intelligence*. Los Alamitos: IEEE Computer Society Press, 1996.

BERIZZI, A.; BOVO, C.; CIRIO, D.; DELFANTI, M.; MERLO, M.; POZZI, M. Online fuzzy voltage collapse risk quantification. *Electric Power Systems Reseach*, In Press, Corrected Proof, Available online 6 December 2008.

BREWER, J. W. Kronecker products and matrix calculus in system theory. *IEEE Transactions on Circuits and Systems*, New York, v. CAS-25, n. 9, p. 772-780, 1978.

CANIZARES, C.A. Voltage stability indices, voltage stability assessment, procedures and guides. *IEEE/PES PSS Subcommittee Special Publication*, Chapter 4. 1999

CARPENTER, G. A.; GROSSBERG, S. A Selfing-organizing neural network for supervised learning, recognition, and prediction. *IEEE Communications Magazine*, New York, v.30, p.38-49, 1992.

CARPENTER, G. A.; GROSSBERG, S. *Pattern recognition by self-organizing neural networks*. Massachusetts: The MIT Press, 1991.

CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, New York, v.3, n.5, p.698-713, 1992.

CELLI, G.; LODDO, M.; PILO, F.; USAI, M. *Voltage collapse prediction with locally recurrent neural networks*. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1043449&isnumber=22339>>. Acesso em: 15 dez. 2008.

CHAUHAN, S.; DAVE, M. P. Kohonen neural network classifier for voltage collapse margin estimation. *Electric Machines and Power Systems*, Washington, v.25, n.6, p. 607-619, 1997.

CHEN, K.; HUSSEIN, A.; WAN, H.B. On a class of new and practical performance indexes for approximation of fold bifurcations of nonlinear power flow equations. *Journal of Computational and Applied Mathematics*, Antwerpen, n.140, p. 119-141, 2002.

CHIANG, H. D. *CPFLOW for power tracer and voltage monitoring*: Ithaca: Cornell University/Power System Engineering Research Centre, 2002. (Final report, Power System Engineering Research Centre, 2002). Disponível em: <[http://www.pserc.wisc.edu/ecow/get/publicatio/2001public/chiang\\_report.pdf](http://www.pserc.wisc.edu/ecow/get/publicatio/2001public/chiang_report.pdf)>. Acesso em: 22 jan. 2009.

DAGHER, I. L-p Fuzzy ARTMAP neural network architecture. *Soft Computing - A Fusion of Foundations, Methodologies and Applications*, Berlin, v.10, n.8, p.649-656, 2006.

DASGUPTA, D. *Artificial immune systems and their applications*. New York: Springer-Verlag, 1998.

DEVARAJ, D.; ROSELYN, P. ; RANI, R.U. Artificial neural network model for voltage security based contingency ranking. *Applied Soft Computing*, London, v.7, n.3, p. 722-727, 2006.

ECHAVARREN, F. M.; LOBATO, E.; ROUCO, L. A power flow solvability identification and calculation algorithm. *Electric Power Systems Research*, Lausanne, n. 76 p. 242-250, 2006.

FERREIRA, W. P.; SILVEIRA, M. C.; LOTUFO, A. D.; MINUSSI, C.R. Transient stability analysis of electric energy systems via a fuzzy ART-ARTMAP neural network. *Electric Power Systems Research*, Lausanne, v.76, p.466-475, 2006.

FLUECK, A. J.; QIU, W. A new technique for evaluating the severity of branch outage contingencies based on two-parameter continuation. In: POWER ENGINEERING SOCIETY GENERAL MEETING, 2004, Denver. *Power...* Denver:IEEE, 2004. p.323-329.

FOGEL, D. B. *Evolutionary computation: toward a new philosophy of machine intelligence*. New York: IEEE Press, 1995.

FONSECA, L. G. S.; DECKER, I. C. Iterative algorithm for critical energy determination in transient stability of power system. In: IFAC - SYMPOSIUM PLANNING & OPERATION IN ELECTRIC ENERGY SYSTEM, Rio de Janeiro. **Symposium...** Rio de Janeiro: S.n., 1985. p. 483-489.

FRANK, P. K. *Introduction to system sensitivity theory*. New York: Academic Press, 1978.

GEROMEL, J. C. *Methods and techniques for decentralized control systems analysis and design*. Milano: Cooperativa Livraria Universitaria del Politecnico, 1987. 69p.

GOLUB, G. H. ; VAN LOAN, C. F. *Matrix computation*. 2.ed. London: The Johns Hopkins University Press, 1990.

GUCKENHEIMER, J.; HOLMES,P. Nonlinear oscillations, dynamical systems, and bifurcations of vector fields. *New York: Springer Verlag, 1997. (Applied Mathematical Sciences, 42)*

HAYKIN, S. *Neural networks: a comprehensive foundation*. New Jersey: Prentice Hall, 1994.

IBA, K.; SUZUKI, H.; EGAWA, M.; WATANABE, T. Calculation of critical loading condition with nose curve using homotopy continuation method. *IEEE Transactions Power System*, New York, v. 6, n. 2, p. 548-93, 1991.

IEEE WORKING GROUP ON VOLTAGE STABILITY. *Voltage stability of power system: concepts, analytical tools, and industry experience*. New York: IEEE, 1990. (IEEE Special Publication, 90TH0358-2-PWR).

ISODA, L. Y.; LOTUFO, A. D. P.; LOPES, M. L. M.; MINUSSI, C. R. Análise de estabilidade de tensão de sistemas elétricos usando uma rede neural ARTMAP fuzzy. *TEMA / Seleta - Tendência de Matemática Aplicada e Computacional*, São Carlos, v. 9, n. 2, 2008, p. 243-253, 2008.

JIA, Z. A. Contingency ranking for on-line voltage stability assessment. *IEEE Transactions on Power System* , New York, v.15, n.3, p. 1093-1097, 2000.

KAMALASADAN, S.; THUKARAM, D.; SRIVASTAVA, A.K. A new intelligent algorithm for online voltage stability. *International Journal of Electrical Power & Energy Systems*, Oxford, v.31, n.2/3, p.100-110, 2009.

KARTALOPOULOS, S. V. *Understanding neural networks and fuzzy logic: Basic concepts and applications*. Piscaway: IEEE Press, 1996.

KOJIMA, Y.; IZUI, Y.; KYOMOTO, S.; GODA, T. Voltage and reactive power control using recurrent neural networks. *Electrical Engineering in Japan*, New York, v.114, n.4, p.119-128, 2007.

KUNDUR, P. *Power system stability and control*. New York: McGraw - Hill, 1993.

LOPES, M. L. *Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica*. 2005. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

McCULLOCH, W. W.; PITTS, W. A logical calculus of the ideas imminent in nervous activity. *Bulletin of Mathematical Biophysics*, New York, v.5, p.114-133, 1943.

MONTICELLI, A. J. *Fluxo de carga em redes de energia elétrica*. São Paulo: Edgard Blücher Ltda., 1983.

MONTICELLI, A.; GARCIA, A.; SAAVEDRA, O. R. Fast decoupled load flow: hypothesis, derivations and testing. *IEEE Transactions on Power Systems*, New York, v. 5, n. 4, p. 1425-1431, 1990.

NAN, H.K.; KIM, Y.K.; SHIM, K. A.; LEE, K. Y. A new eigen-sensibility theory of augmented matrix and its applications to power systems stability analysis. *IEEE Transaction on Power Systems*, New York, v.15, n.1, p.363-369, 2000.

PANDIT, M.; SRIVASTAVA, L.; SINGH, V. A. Coherency-based fast voltage contingency ranking employing counterpropagation neural network. *Engineering Applications of Artificial Intelligence*, London, v.20, n.8, p.1133-1143, 2007.

POWELL, L. *Power system load flow analysis*. New York: McGraw-Hill Publisher, 2005.

- SAUER, P. W.; PAI, M. A. Power system steady-state stability and the load flow jacobian. *IEEE Transactions on Power Systems*, New York, v.PWRS-5, n.4, p.1374-1383, 1990.
- SEYDEL, R. *Practical bifurcation and stability analysis: from equilibrium to chaos*: New York: Springer-Verlag, 1994.
- SILVEIRA, M. C. *Análise de estabilidade transitória de sistemas elétricos por redes neurais ARTMAP nebulosa modulares*. 2003. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2003.
- SIMPSON, P. K. *Artificial neural systems: foundations, paradigms, applications and implementations*. New York: Pergamon Press, 1989.
- SINHA, A. A.; HAZARIKA, D. A Comparative study of voltage stability indices in a power system. *Electrical Power & Energy Systems*, Guildford, n.22, p. 589-596, 2000.
- SIMUL. *Programa computacional*. Ilha Solteira: Unesp/FEIS/Laboratório Computacional de Departamento de Engenharia Elétrica, 1990.
- SU, C.-T.; CHANG, F. C. Quick evaluation of determinants. *Applied Mathematics and Computation*, New York, n. 75, p.117-118, 1996.
- TAYLOR, C.W. *Power system voltage stability*. New York: McGraw-Hill, 1994.
- TIRANUCHIT, A. A.; THOMAS, R. J. A Posturing strategy against voltage instabilities in electric power systems. *IEEE Transactions on Power Systems*, New York, v.3, n.1, p. 87-93, 1988.
- VAN CUTSEM, T. A method to compute reactive stability margins with respect to voltage collapse. *IEEE Transactions on Power Systems*, New York, v.PWRS-6, n.1, p.145 – 156, 1991.
- VAN CUTSEM, T. Voltage instability: phenomena, countermeasures, and analysis methods. *Proceedings of the IEEE*, New York, v. 88, n. 2, p.208–227, 2000.
- VAN CUTSEM, T.; VOURNAS, C. *Voltage stability of electric power systems*. London: Kluwer Academic Publishers, 1998.

- VIDYASAGAR, M. *Nonlinear systems analysis*. 2.ed. Englewood Cliffs: Prentice Hall, 1978.
- VU, K.; LIU, C.C.; TAYLOR, C.W.; JIMMA, K. Voltage Instability: mechanisms and control strategies. *Proceeding of the IEEE*, New York, v.83, n.11, p. 1442-1455, 1995.
- VUSKOVIC, M.; DU, S. Simplified ARTMAP network based on mahalanobis distance. In: PROCEEDING OF THE 2002 INTERNATIONAL CONFERENCE ON MATHEMATICS AND ENGINEERING TECHNIQUES IN MEDICINE AND BIOLOGICAL SCIENCE, 2002, Las Vegas. *Proceedings of the...* Nevada: S.n., 2002.
- WAN, H. B.; EKWUE, A. O. Artificial neural network base contingency ranking method for voltage collapse. *Electrical Power & Energy Systems* , Guildford, v.22, p.349-354, 2000.
- WEHENKEL, L. Machine-learning approaches to power-system security assessment. *IEEE Expert Intelligent Systems & Their Applications* , New York, v.12, n.5, p.60-72, 1997.
- WERBOS, P. J. (1974). *Beyond regression: new tolls for prediciton and analysis in the behavioral sciences*. 1974. Thesis (PhD ) - Harvard University, Harvard, 1974.
- WIDROW, B. A.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. *Proceeding of the IEEE*, New York, v.78, n.9, p.1415-1442, 1990.
- WOLFRAM, S. *A New kind of science*. New York: MathWorld, 2002.
- ZADEH, L. A. Fuzzy logic. *Computer*, v.92. n.4, p. 83-93, 1988.
- ZADEH, L. A. Fuzzy sets. *Information and Control*, New York, v.8, p 338-353, 1965.
- ZAMBRONI A. C. S. Discussions on some voltage colapse indices. *Electric Power Systems Research*, Lausanne, v.53, n.1, p.53-58, 2000.

## Apêndice A

### Redes Neurais Artificiais

#### A.1 Introdução

Neste capítulo apresentam-se os principais conceitos e definições sobre redes neurais artificiais. O assunto “redes neurais artificiais” é demasiadamente longo. O número de textos (livros, artigos, etc.), disponibilizado na literatura, é bastante volumoso e diversificado. Assim, visando a objetividade, o conteúdo aqui apresentado constitui a medida justa, sem excesso ou falta, de informações necessárias à compreensão do sistema neuro-*fuzzy*, abordados no Capítulo 5, proposto para a realização da análise da estabilidade estática de tensão de sistemas elétricos de potência.

## **A.2 Estrutura de Rede Neural**

Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes. Elas possuem a capacidade computacional de adquirir o conhecimento através da experiência.

Inicialmente, apresenta-se um dos modelos de neurônio mais conhecido na literatura especializada: o neurônio de McCulloch e Pitts (McCULLOCH; PITTS, 1943). Ressalta-se que centenas de tipos de neurônios têm sido identificados, cada qual distinguindo-se dos demais pela forma do corpo celular. Estas diferenças morfológicas exibem especializações funcionais importantes. A identificação das funções dos vários tipos de neurônios representa um dos tópicos mais importantes dos estudos referentes à compreensão do cérebro humano. Os resultados destes estudos poderão orientar o desenvolvimento de redes neurais artificiais ainda mais eficientes, principalmente com relação à capacidade e velocidade do aprendizado.

### **A.2.1 Modelo Biológico**

O mais fascinante processador existente – o cérebro humano – é composto por aproximadamente 100 bilhões de componentes, chamados neurônios, que se encontram interligados numa complexa rede de comunicação. Os neurônios estão conectados uns aos outros através de sinapses e, juntos, formam uma grande rede, chamada Rede Neural ou Rede Neuronal (HAYKIN, 1994). Um neurônio recebe e transmite informações de muitos outros neurônios (aproximadamente 10 mil), além de armazenar estas informações.

Os modelos são formados, basicamente, pelas seguintes partes (Figura A.2.1.1):

- (a) *Corpo celular* (*Sôma*, do idioma grego, que significa corpo celular): Parte central do neurônio responsável pela recepção e geração dos impulsos nervosos.
- (b) *Sinapse*: Ponto de contato entre a terminação axônica de um neurônio e o dendrito do outro. Funcionam como válvulas, sendo capazes de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios. Esta capacidade é definida como sendo eficiência sináptica.
- (c) *Dendrito*: Os dendritos têm a função de receber as informações, ou impulsos nervosos de outros neurônios e conduzi-las ao corpo celular.
- (d) *Axônio*: Um axônio se distingue de um dendrito pelo seu tamanho (mede cerca de 0,1 milímetro podendo chegar a 1 metro). Sua função é conduzir os sinais, processados pelo corpo celular, para os demais neurônios. Próximo de seu final, o axônio divide-se em vários ramos (dendritos), que se interconectam com os demais neurônios através das sinapses.




Figura A.2.1.1. Componentes de um neurônio.

## A.2.2 Neurônio Artificial

Os modelos de neurônios artificiais são baseados no funcionamento dos neurônios biológicos. Vários modelos foram propostos na literatura. A seguir apresenta-se o modelo de McCulloch-Pitts, que é o mais empregado, principalmente em problemas de reconhecimento de padrão, que é a modalidade aqui abordada.

### A.2.2.1 Neurônio de McCulloch-Pitts

O modelo de McCulloch-Pitts (McCULLOCH; PITTS, 1943) foi desenvolvido em 1943, o qual descreve um neurônio (Figura A.2.2.1.1) cuja atividade  $s$  é a soma de  $n$  entradas ponderadas por seus respectivos pesos. Esta atividade alimenta uma função não-linear  $f(\cdot)$  que produz um sinal para ser enviado aos demais neurônios. As não-linearidades mais empregadas são: relé, lógica *threshold* e sigmoide, conforme mostra-se na Subseção (A.2.2.2). O neurônio de McCulloch-Pitts pode conter também um peso *bias*  $w_0$  alimentado por uma constante  $x_0 = +1$  (arbitrada) que desempenha o controle do nível de saída do neurônio.

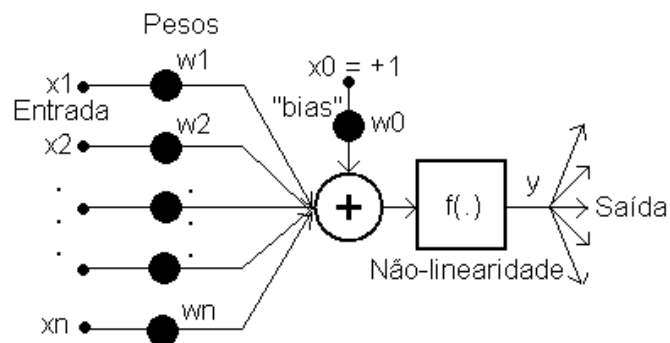


Figura A.2.2.1.1. Modelo do neurônio de McCulloch-Pitts.

### A.2.2.2 Não-Linearidades

O sinal  $s$  do neurônio é usualmente processado por uma função de ativação  $f(\cdot)$  que produz o sinal de saída do neurônio. As formas mais utilizadas desta função de ativação são as seguintes:

#### a) Relé




Figura A.2.2.2.1. Função relé.

sendo:

$$f(s) = \begin{cases} +1, & \text{se } s \geq 0 \\ -1, & \text{se } s < 0 \end{cases}$$

#### b) Lógica *Threshold*




Figura A.2.2.2.2. Função lógica *threshold*.

**c) Função Sigmoide (1)**




Figura A.2.2.2.3. Função sigmoide (1).

sendo que:

$$f(s) = (1 - e^{-\lambda s}) / (1 + e^{-\lambda s});$$

$\lambda$  : inclinação da curva.

**d) Função Sigmoide (2)**




Figura A.2.2.2.4. Função sigmoide (2).

sendo:

$$f(s) = 1 / (1 + e^{-\lambda s}).$$

Ressalta-se que há, na literatura, um número grande de tipos de não-linearidades usadas na realização de arquiteturas neurais. Contudo, as não-linearidades anteriormente relacionadas são as mais usuais.

### A.3 Estrutura de Rede Neural Artificial

Uma RNA consiste de elementos de processamento (neurônios) e suas conexões (sinapses) (Figura A.3.1). Cada neurônio pode ter várias entradas, porém, somente uma saída. Cada saída pode ser usada como entrada a vários neurônios (através de ramificações), assim como cada neurônio pode receber várias entradas procedentes de outros neurônios. Cada conexão entre neurônios possui um peso que determina sua contribuição na decisão de disparo (quando ultrapassa um determinado limiar predefinido), controlando, desta forma, os estímulos.




Figura A.3.1. Rede neural artificial.

### A.4 Classificações das Redes Neurais

As redes neurais podem ser classificadas em dois tipos quanto a sua estrutura: redes recorrentes e redes não-recorrentes (*feedforward*).

**Definição A.4.1.** Redes Neurais Recorrentes. Uma rede é definida como *recorrente* se ela contém laços de realimentação, ou seja, contém conexões das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores.

As entradas de um neurônio são as saídas dos demais neurônios da camada anterior. As redes que possuem esta estrutura desenvolvem uma memória a longo prazo nos neurônios internos. Nesta classe de redes neurais, *e.g.*, encontra-se a rede de Hopfield (SIMPSON, 1989).

**Definição A.4.2.** Redes Neurais Não-Recorrentes. Esta rede caracteriza-se estruturalmente por estar disposta em camadas. Nestas redes cada camada de neurônios recebe sinais somente das camadas anteriores, ou seja, elas não possuem laços de realimentação (HAYKIN, 2001; SIMPSON, 1989).

Redes não-recorrentes ou *feedforward* não possuem memória, sendo que sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos (HAYKIN, 2001; SIMPSON, 1989). A rede neural mostrada na Figura A.3.1 é não-recorrente.

## A.5 Tipos de Treinamento de Redes Neurais

A propriedade mais importante das redes neurais é a habilidade de aprender e, desta forma, melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicados a seus pesos que correspondem ao treinamento.

Denomina-se algoritmo de treinamento a um conjunto de regras bem definidas para a solução de um problema de treinamento. Existem muitos tipos de algoritmos de treinamento específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si, principalmente, pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto, existem, basicamente, os seguintes paradigmas de treinamento:

**Definição A.5.1.** Treinamento Supervisionado. Consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada (WIDROW; LEHR, 1990).

O treinamento supervisionado necessita de um de vetor de entrada e vetor-alvo representando a saída desejada. Juntos, eles são chamados de par treinado. Um dos algoritmos mais difundidos para treinamento deste tipo de rede é o algoritmo retropropagação. A Figura A.5.1 ilustra o treinamento supervisionado. Este algoritmo foi proposto por Werbos (1974).

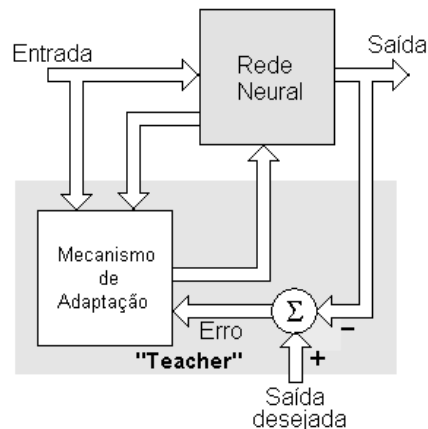


Figura A.5.1. Treinamento supervisionado.

**Definição A.5.2.** Treinamento Não-Supervisionado. Consiste no ajuste de pesos de uma rede neural, levando-se em conta somente o conjunto de padrões de entrada. É, por conseguinte, um procedimento de treinamento auto-organizado. O treinamento não-supervisionado é ilustrado na Figura A.5.2.

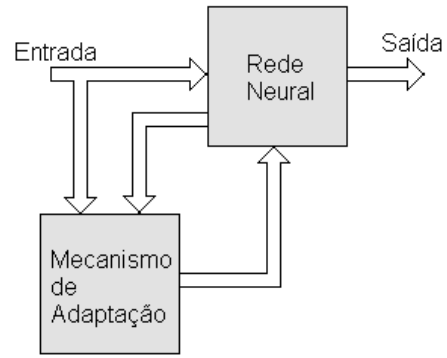


Figura A.5.2. Treinamento não-supervisionado.

## Apêndice B

### Lógica *Fuzzy* ou Lógica Nebulosa

#### B.1 Introdução

Os conceitos e princípios da lógica *fuzzy* (ou lógica nebulosa) foram introduzidos por Lotfi Zadeh, na década de 60 (ZADEH, 1965). Porém, já em 1920, um matemático polonês Jan Lukasiewicz desenvolvia as primeiras noções da lógica dos conceitos “vagos” formulando os conjuntos com graus de pertinência sendo 0, 1/2, e 1 e, mais tarde, expandiu para um número infinito de valores entre 0 e 1.

Na teoria clássica, os conjuntos são denominados *crisp* e um determinado elemento do universo (domínio) pertence ou não a um conjunto específico. Já na lógica *fuzzy*, presume-se que cada elemento de um universo possa possuir pertinência parcial a um determinado conjunto

A lógica nebulosa permite expressar conceitos imprecisos ou vagos e tomar decisões a partir do conhecimento inexato. Permite elaborar modelos sobre argumentos imprecisos que fazem parte da habilidade humana para tomar decisões em um ambiente de incerteza (ZADEH, 1988). É uma lógica multivalorada que permite que os valores intermediários sejam definidos entre as avaliações convencionais como, *sim/não*,

*verdadeiro/falso, frio/quente, baixo/alto*. Estas variáveis de linguísticas possuem uma representação melhor que os números (LOPES, 2005). As variáveis *fuzzy* são adjetivos que modificam a variável, de tal forma que noções como “bastante frio” ou “bastante morno” sejam formuladas matematicamente e processadas por computador.

A lógica *fuzzy* possui aplicações nas mais variadas áreas, como por exemplo: inteligência artificial, processamento de imagens, otimização, reconhecimento de padrão, tomada de decisões, avaliações por questionários, etc.

## B.2 Conjuntos Nebulosos

### B.2.1 Fundamentos

Na teoria clássica dos conjuntos, o conjunto de pertinência de um elemento a um conjunto fica bem definido. Dado um conjunto  $A$  em um universo  $X$ , os elementos deste universo simplesmente pertencem ou não àquele conjunto. Isto pode ser expresso pela função característica  $f_A$  definida da seguinte maneira:

$$f_A(x) = \begin{cases} 1, & \text{se e somente se } x \in A, \\ 0, & \text{se e somente se } x \notin A. \end{cases}$$

Já no conjunto nebuloso, a função característica, proposta por Zadeh, é generalizada de modo que ela possa assumir um número infinito de valores no intervalo  $[0, 1]$ . Um conjunto nebuloso  $A$  em um universo  $X$  é definido por uma função pertinência  $\lambda_A(x): X \rightarrow [0, 1]$ , representado por um conjunto de pares ordenados:

$$A = \{(x, \mu_A(x)), x \in X\},$$

sendo que  $\mu_A(x)$  representa o valor da função pertinência do conjunto nebuloso  $A$  correspondente ao elemento  $x$ , ou seja, o quanto  $x$  é compatível com o conjunto  $A$ .

## B.2.2 Variáveis Linguísticas

Na lógica nebulosa, *temperatura de um processo* ou *estatura de uma pessoa* são variáveis linguísticas que podem assumir valores como *baixa*, *média* e *alta*. Estes valores são descritos por intermédio de conjuntos nebulosos, representados por funções pertinência.

Os valores de uma variável linguística podem ser sentenças em uma linguagem especificada, construídas a partir de termos primários (alto, baixo, pequeno, médio, grande), de conectivos lógicos (*NOT*, *AND* e *OR*), de modificadores (muito, pouco, levemente, extremamente).

## B.2.3 Funções de Pertinências

A função de pertinência é uma representação gráfica da magnitude de participação de cada entrada. Ela associa um peso a cada entrada processada definindo uma superposição funcional entre entradas e determinando uma resposta de saída. As regras utilizam os valores de pertinência de entrada como fator peso para determinar sua influência na conclusão final de saída.

Existem diferentes tipos de funções de pertinências: triangular, trapezoidal, gaussiana, exponencial, entre outras. A mais comum é a função de pertinência triangular. A Figura B.2.3.1 mostra as características da função pertinência para a variável temperatura de um determinado processo, na qual a temperatura é normalizada entre os valores 0 e 1 (KARTALOPOULOS, 1996).

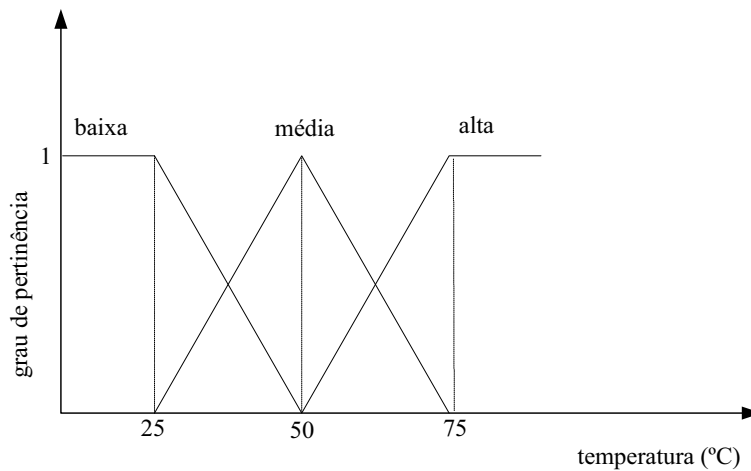


Figura B.2.3.1. Funções de pertinência para a variável *temperatura*.

O grau de pertinência é determinado pela projeção vertical do parâmetro de entrada do eixo horizontal no limite mais alto da função de pertinência, o qual tem valores entre 0 e 1.

## B.2.4 Operadores Lógicos

Apresentam-se aqui as mais relevantes operações envolvendo conjuntos nebulosos que são utilizados nesta pesquisa.

Supondo-se que  $A$  e  $B$  são dois conjuntos nebulosos com funções de pertinência designadas, respectivamente, por  $\mu_A(x)$  e  $\mu_B(x)$  (vide B.2.4.1), pode se introduzir os operadores *AND*, *OR* e *NOT* (KARTALOPOULOS, 1996).




Figura B.2.4.1. Conjuntos Nebulosos A e B.

**Definição B.2.4.1.** Operador AND ou interseção de dois conjuntos. A função de pertinência da interseção destes dois conjuntos nebulosos ( $C = A \cap B$ ) é definida por :

$$\mu_C(x) = \min \{ \mu_A(x), \mu_B(x) \}, x \in X$$

cuja representação gráfica pode ser vista na Figura B.2.4.2, sendo que a linha cheia nesta figura define a interseção do dois conjuntos nebulosos A e B.




Figura B.2.4.2. Operador AND.

**Definição B.2.4.2.** Operador OR ou união entre dois conjuntos. A função de pertinência da união destes conjuntos nebulosos ( $D = A \cup B$ ) é definida por :

$$\mu_D(x) = \max \{ \mu_A(x), \mu_B(x) \}, x \in X,$$

cuja representação gráfica pode ser vista na Figura B.2.4.3, sendo que a linha cheia nesta figura define a união entre dois conjuntos *fuzzy*  $A$  e  $B$ .




Figura B.2.4.3. Operador *OR*.

**Definição B.2.4.3.** Operador *NOT* ou o complemento de um conjunto nebuloso. A função de pertinência do complemento de  $A$ ,  $A'$  é definida por:

$$\mu_{A'}(x) = 1 - \mu_A(x), x \in X,$$

cuja representação gráfica pode ser vista na Figura B.2.4.4, sendo que a linha cheia nesta figura define o complemento do conjunto nebuloso  $A$ .




Figura B.2.4.4. Operador *NOT*.

## Apêndice C

### Dados dos Sistemas-Exemplo

Neste Apêndice, são relacionados os dados dos sistemas estudados nesta pesquisa. Trata-se dos sistemas de 3 máquinas e 9 barras (sistema Anderson-Fouad) (ANDERSON; FOUAD, 2003) e de 10 máquinas síncronas e 45 barras (uma versão do sistema da região sul-brasileira).

#### C.1. Dados do Sistema Anderson - Fouad

##### Diagrama do Sistema de Energia Elétrica Composto por três Máquinas




Figura C.1.1. Sistema Anderson - Fouad.

Tabela C.1.1. - Dados do sistema de transmissão (Sistema Anderson-Fouad).

Nº da LINHA	BARRA DE ORIGEM	BARRA DE DESTINO	IMPEDÂNCIA		SHUNT(%)	
			R(%)	X(%)		
1	1	4	0,0000	5,7600	0,0000	0,0000
2	4	5	1,0000	8,5000	0,0000	0,1760
3	4	6	1,7000	9,2000	0,0000	0,1580
4	5	7	3,2000	16,1000	0,0000	0,1530
5	6	9	3,9000	17,0000	0,0000	0,3580
6	2	7	0,0000	6,2500	0,0000	0,0000
7	7	8	0,8500	7,2000	0,0000	0,1490
8	8	9	1,1900	10,0800	0,0000	0,2090
9	3	9	0,0000	5,8600	0,0000	0,0000

sendo que:

R : resistência do elemento;

X : reatância do elemento;

SHUNT : admitância *shunt* do elemento da rede elétrica considerado.

Tabela C.1.2. – Dados de barras (Sistema Anderson-Fouad).

Nº	NOME	TENSÃO		MÓDULO	ARG(GRA)	POT. BARRA	
						ATIVA	REATIVA
1	Maria	1,0400	0,0000	1,0400	0,0000	0,7202	0,3320
2	Azul	1,0114	0,1665	1,0250	9,3482	1,6300	0,1516
3	Dumas	1,0216	0,0831	1,0250	4,6505	0,8500	-0,0789
4	Marrom	1,0216	-0,0399	1,0224	-2,2359	0,0000	0,0000
5	5	0,9845	-0,0689	0,9869	-4,0051	-1,2500	-0,5000
6	6	1,0073	-0,0653	1,0094	-3,7099	-0,9000	-0,3000
7	7	1,0184	0,0669	1,0206	3,7579	0,0000	0,0000
8	8	1,0120	0,0128	1,0121	0,7236	-1,0000	-0,3500
9	9	1,0301	0,0350	1,0307	1,9473	0,0000	0,0000

Tabela C.1.3. - Dados de máquinas (Sistema Anderson-Fouad).

MÁQUINA	XD	XDL	M	D
1	0,1460	0,0608	0,0507	0,0000
2	0,8958	0,1198	0,0177	0,0000
3	1,3125	0,1813	0,0125	0,0000

sendo:

XD : reatância do eixo direto da máquina síncrona (pu);

XLD : reatância transitória do eixo direto da máquina síncrona (pu);

M : momento de inércia da máquina síncrona

$$= \frac{2H}{2\pi f_0};$$

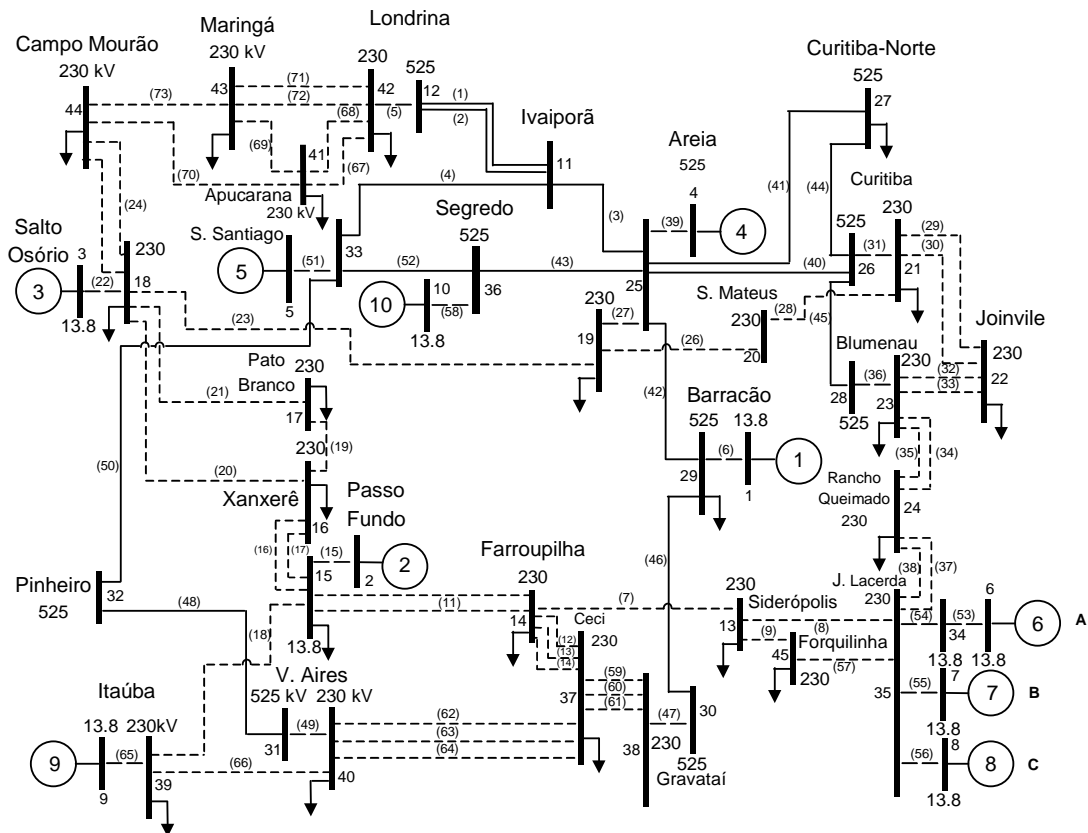
H : constante de inércia da máquina síncrona (s);

$f_0$  : frequência nominal da rede elétrica (60 Hz);

D : constante de amortecimento da máquina síncrona (pu).

## C.2. Dados do Sistema Sul-Brasileiro

### Diagrama Unifilar do Sistema Elétrico



(--) Número das linhas de transmissão.

Figura C.2.1. Sistema Sul-Brasileiro.

Tabela C.2.1. - Dados do sistema de transmissão (Sistema Sul-Brasileiro).

Nº da LINHA	BARRA DE ORIGEM	BARRA DE DESTINO	IMPEDÂNCIA	
			R(%)	X(%)
1	11	12	0,0700	1,4500
2	11	12	0,0700	1,4500
3	11	25	0,1800	2,2700
4	11	33	0,1400	2,0400
5	12	42	0,0000	0,6300
6	1	29	0,0000	1,3600
7	13	14	3,8600	19,8500
8	13	35	0,9600	4,9100
9	13	45	0,3300	1,6700
10	14	15	4,6300	23,7800
11	14	15	4,6300	23,7800
12	14	37	1,7700	9,1000
13	14	37	1,7700	9,1000
14	14	37	1,7700	9,1000
15	2	15	0,0000	4,6000
16	15	16	1,6300	8,3500
17	15	16	1,6300	8,3500
18	15	39	2,5000	15,4800
19	16	17	1,6300	8,3500
20	16	18	3,1600	16,2100
21	17	18	1,5300	8,6100
22	3	18	0,0000	1,1400
23	18	19	3,0600	15,2300
24	18	44	3,4400	17,6000
25	18	44	3,4400	17,6000
26	19	20	2,4500	12,5600
27	19	25	0,0000	3,0000
28	20	21	0,8800	4,1500
29	21	22	1,8200	9,3500
30	2	22	1,8200	9,3500
31	21	26	0,0000	0,6200
32	22	23	1,5400	7,7600
33	22	23	1,5400	7,7600

Tabela C.2.1. - Continuação.

Nº da LINHA	BARRA DE ORIGEM	BARRA DE DESTINO	IMPEDÂNCIA	
			R(%)	X(%)
34	23	24	2,1600	11,0500
35	23	24	2,1600	11,0500
36	23	28	0,0000	0,6200
37	24	35	1,8000	9,2000
38	24	35	1,8000	9,2000
39	4	25	0,0000	0,6700
40	25	26	0,1900	2,8000
41	25	27	0,1900	2,7400
42	25	29	0,1400	1,9500
43	25	36	0,0500	0,7000
44	26	27	0,0500	0,6900
45	26	28	0,1200	1,7500
46	29	30	0,2100	3,0900
47	30	38	0,0000	0,6200
48	31	32	0,2200	3,0000
49	31	40	0,0000	0,6200
50	32	33	0,1400	1,9500
51	5	33	0,0000	1,1400
52	33	36	0,0500	0,7000
53	6	34	0,0000	8,7100
54	34	35	0,0000	5,9000
55	7	35	0,0000	7,0100
56	8	35	0,0000	4,5000
57	35	45	1,2900	6,5700
58	10	36	0,0000	0,6800
59	37	38	0,2200	1,1100
60	37	38	0,2200	1,1100
61	37	38	0,2200	1,1100
62	37	40	2,0700	9,3300
63	37	40	2,0700	9,3300
64	37	40	2,0700	9,3300
65	9	39	0,0000	2,3600

Tabela C.2.1. - Continuação.

Nº da LINHA	BARRA de ORIGEM	BARRA de DESTINO	IMPEDÂNCIA	
			R(%)	X(%)
66	39	40	2,0200	11,2900
67	41	42	1,2500	6,4000
68	41	42	0,8900	4,6100
69	41	43	1,1000	11,8400
70	41	44	2,2900	11,7400
71	42	43	1,7200	8,8400
72	42	43	1,7200	8,8400
73	43	44	1,8100	9,2900

Tabela C.2.2 – Dados das Barras (Sistema Sul-Brasileiro).

Nº	NOME	TENSÃO		MÓDULO	ARG(GRA)	POT. BARRA	
						ATIVA	REATIVA
1	Ba13.8	0,9996	-0,2028	1,0200	-11,4690	6,5000	1,0529
2	PF13.8	0,9939	-0,3063	1,0400	-17,1294	2,1500	1,5051
3	SO13.8	1,0160	0,0900	1,0200	5,0642	10,5000	2,4560
4	FA13.8	1,0156	-0,1139	1,0220	-6,3968	11,1000	3,4209
5	SS13.8	1,0163	0,0582	1,0180	3,2795	13,2500	1,6814
6	LA13.8	0,8931	-0,5130	1,0300	-29,8743	0,9000	0,4581
7	LB13.8	0,9066	-0,4889	1,0300	-28,3346	1,2000	0,5518
8	LC13.8	0,9180	-0,4671	1,0300	-26,9706	2,4100	0,9105
9	It13.8	0,9603	-0,2790	1,0000	-16,1988	4,9000	1,3744
10	Se13.8	1,0200	0,0000	1,0200	0,0000	13,6426	2,0823
11	Iva525	0,9875	-0,1954	1,0066	-11,1905	0,0000	2,1300
12	Lon525	0,9676	-0,2326	0,9951	-13,5160	0,0000	0,0000
13	Sid230	0,7691	-0,5884	0,9684	-37,4176	-1,7700	-0,6800
14	Far230	0,7781	-0,5909	0,9770	-37,2143	-1,9100	-0,4200
15	PFo230	0,9023	-0,3775	0,9780	-22,7016	-1,7100	-0,1850
16	Xan230	0,8999	-0,2926	0,9462	-18,0143	-1,2600	-0,4700
17	PBr230	0,9360	-0,1801	0,9532	-10,8931	-0,4600	-0,1470
18	SOs230	0,9990	-0,0293	0,9995	-1,6771	-2,8100	-0,5650
19	Are230	0,9429	-0,2602	0,9782	-15,4299	-2,7900	-0,6070
20	SMa230	0,8914	-0,4461	0,9968	-26,5841	-1,3000	0,7060
21	Cur230	0,8844	-0,4456	0,9903	-26,7403	-4,2700	1,2500
22	Joi230	0,7921	-0,5263	0,9510	-33,6018	-3,1000	-0,4100
23	Blu230	0,8181	-0,5142	0,9663	-32,1511	-4,2400	0,0940
24	RQu230	0,7952	-0,5416	0,9621	-34,2577	-1,1700	-0,5310
25	Are525	0,9852	-0,1836	1,0022	-10,5568	0,0000	0,0000
26	Cur525	0,8981	-0,4058	0,9855	-24,3157	0,0000	1,4470
27	CNo525	0,9102	-0,3814	0,9869	-22,7354	-3,6800	0,7560
28	Blu525	0,8375	-0,4848	0,9677	-30,0675	0,0000	0,0000
29	Bar525	0,9687	-0,2848	1,0097	-16,3836	-1,7400	1,1380
30	Gra525	0,8471	-0,5635	1,0174	-33,6317	0,0000	1,5960
31	VAi525	0,9152	-0,4639	1,0261	-26,8820	0,0000	1,6030
32	Pin525	0,9879	-0,2440	1,0176	-13,8731	0,0000	1,6150
33	SSa525	1,0060	-0,0908	1,0101	-5,1601	0,0000	0,0000

Tabela C.2.2 - Continuação.

Nº	NOME	TENSÃO		MÓDULO	ARG(GRA)	POT. BARRA	
						ATIVA	REATIVA
34	JLa138	0,8217	-0,5597	0,9942	-34,2625	-1,2600	-0,3980
35	JLa230	0,8348	-0,5429	0,9958	-33,0349	0,0000	0,0000
36	Seg525	1,0061	-0,0910	1,0102	-5,1654	0,0000	0,0000
37	Cec230	0,8016	-0,6156	1,0107	-37,5267	-8,1300	-1,1000
38	Gra230	0,8190	-0,6153	1,0244	-36,9167	-6,1200	4,5500
39	Ita230	0,8969	-0,3809	0,9744	-23,0083	-4,0400	-1,3500
40	VAi230	0,8952	-0,5058	1,0282	-29,4689	-3,9300	1,1100
41	Apu230	0,9201	-0,3155	0,9727	-18,9277	-2,6200	-0,1320
42	Lon230	0,9519	-0,2657	0,9883	-15,5951	-2,2900	-0,8300
43	Mar230	0,9298	-0,3183	0,9828	-18,8984	-1,8400	0,3980
44	CMo230	0,9458	-0,2595	0,9808	-15,3426	-1,3900	0,4630
45	For230	0,7772	-0,5921	0,9771	-37,3020	-0,9010	0,4470

Tabela C.2.3. - Dados de máquinas síncronas (Sistema Sul-Brasileiro).

MÁQUINA	XD	XDL	M	D
1	0,0367	0,0367	0,1615	0,0000
2	0,1037	0,1037	0,0560	0,0000
3	0,0284	0,0284	0,2034	0,0000
4	0,0241	0,0241	0,3302	0,0000
5	0,0243	0,0243	0,2930	0,0000
6	0,1352	0,1352	0,0232	0,0000
7	0,1534	0,1534	0,0361	0,0000
8	0,0800	0,0800	0,0663	0,0000
9	0,0432	0,0432	0,1074	0,0000
10	0,0216	0,0216	0,3314	0,0000

## Apêndice D

### Artigos Publicados e Submetido Relacionados com a Pesquisa de Doutorado

1. **Isoda, L. Y.;** Lotufo, A. D. P.; Lopes, M. L. M. e Minussi, C. R. Análise de Estabilidade de Tensão de Sistemas Elétricos Usando uma Rede Neural ARTMAP *Fuzzy*, *TEMA / Seleta Tendência de Matemática Aplicada e Computacional*, São Carlos, v. 9, n. 2, 2008, p. 243-253, 2008.
2. **Isoda, L. Y.;** Lotufo, A. D. P.; Lopes, M. L. M. e Minussi, C. R. Métodos Matriciais no Estudo da Estabilidade de Tensão de Sistemas de Energia Elétrica, *68º Seminário Brasileiro de Análise*, São Paulo-SP, Art. 22, 12 p., 2008.
3. **Isoda, L. Y.,** Lotufo, A. D. P., Lopes, M. L. M. e Minussi, C. R. Desenvolvimento de uma Metodologia Neural Baseada na Teoria da Ressonância Adaptativa para a Análise da Estabilidade de Tensão de Sistemas de Energia Elétrica, *7-th Brazilian Conference on Dynamics, Control and Applications - DINCON'2008*, Presidente Prudente, p. 832 – 839, 2008.
4. **Isoda, L. Y.,** Lotufo, A. D. P.; Lopes, M. L. M. e Minussi, C. R. Voltage Stability Analysis of Electric Power Systems Using a Fuzzy ARTMAP Neural Network, *Artigo a ser submetido a um veículo científico internacional peer review da área de Engenharia Elétrica.*