

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

Análise de Estabilidade Transitória de Sistemas Elétricos por Redes Neurais ARTMAP Nebulosas Modulares

Maria do Carmo Gomes da Silveira

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, outubro de 2003.

À Deus.

Aos meus pais José e Maria.

Ao meu marido, Cicero José e
aos meus filhos, Jaqueline e Vinicius.

Agradecimento

Ao Prof. Dr. Carlos Roberto Minussi, pela dedicação, orientação e acima de tudo pela confiança no meu trabalho. Pelas vezes em que me incentivou a continuar crescendo profissionalmente e pessoalmente, sempre me orientando a seguir o caminho independente dos obstáculos.

A UNESP – Campus de Ilha Solteira, pela oportunidade de realizar este trabalho.

Ao apoio recebido pelo Serviço Técnico de Informática da FEIS, onde exerço minha atividade profissional.

À todos os professores e funcionários do Departamento de Engenharia Elétrica da FEIS que contribuíram para a realização deste trabalho. Em especial à Prof. Anna Diva Plasencia Lotufo pelas contribuições e pela amizade dedicada.

Às funcionárias da Seção de Pós-graduação, pela atenção com que sempre me atenderam.

Aos colegas do curso de pós-graduação, especialmente à Mara Lúcia Martins Lopes, pelas sugestões, contribuições e pela grande amizade que nasceu durante o nosso convívio.

Aos meus pais, José e Maria, pelos exemplos de perseverança que sempre me deram e continuam dando.

Aos meus irmãos, Eloiza e Waldivino pelo apoio recebido.

Ao meu marido, Cícero José, pelo apoio e pelas vezes em que exerceu o papel de mãe para com os nossos filhos, a fim de que este trabalho se realizasse.

Aos meus filhos, pela admiração e compreensão nas vezes em que estive ausente.

Finalmente, agradeço à Deus, que me trouxe ao mundo e que me permite realizações como esta.

RESUMO

Esta pesquisa apresenta uma metodologia para a análise de estabilidade transitória (de primeira oscilação) de sistema de energia elétrica usando uma rede neural baseada na arquitetura ART (*Adaptive Resonance Theory*), designada rede neural nebulosa ARTMAP modular para aplicações em tempo real. A margem de segurança é empregada como critério da análise de estabilidade transitória, considerando-se faltas tipo curto-circuito trifásico com saída de linha de operação. O funcionamento das redes neurais é constituído por duas fases fundamentais: treinamento e 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 a resolução de problemas complexos que exigem soluções rápidas, como é caso de aplicações em tempo real. As redes neurais ART, possuem como características primordiais, a plasticidade e a estabilidade, as quais são qualidades essenciais para a execução do treinamento e para a análise de modo eficiente. A rede neural ARTMAP nebulosa modular está sendo proposta visando proporcionar um desempenho superior, em termos de precisão e rapidez, se comparada à formulação ARTMAP convencional, muito maior ainda quando comparada ao emprego de redes neurais com treinamento realizado via técnica retropropagação (que é um *benchmark* em termos de precisão no contexto de redes neurais). O treinamento da rede neural será realizado usando como “professor” um método de energia para o cálculo das margens de segurança. A metodologia proposta nesta pesquisa é um procedimento que incorpora inovações em relação à literatura existente, em destaque: (1) desenvolvimento de um novo modelo apropriado para a resolução do problema da análise de estabilidade transitória por redes neurais; (2) desenvolvimento teórico-prático sobre a variável de saída da rede neural, representada nesta pesquisa pela variável *IMS* (Intervalo da Margem de Segurança) numa forma binária. Trata-se de uma representação conveniente para a abordagem da análise de estabilidade de sistema de energia elétrica; (3) proposição de uma metodologia de análise de estabilidade transitória de sistemas elétricos de potência por rede neural ARTMAP nebulosa modular, que proporciona soluções com precisão que pode ser considerada satisfatória e com grande rapidez, o que torna esta metodologia compatível com aplicações em tempo real. Visando ilustrar o método proposto, apresentam-se os resultados da análise, considerando-se um sistema composto por 10 máquinas síncronas, 72 linhas de transmissão e 45 barras.

ABSTRACT

This work presents a methodology for transient stability analysis (first swing) of electrical energy systems, using a neural network based on ART (adaptive resonance theory), called modular fuzzy ARTMAP neural network for applications in real time. The security margin is used as a criterion for transient stability analysis, considering three-phase short circuit with outage of a transmission line faults. The neural network functioning is composed of two fundamental phases: training and analysis. The training phase needs a great quantity of processing, while the test phase is realized almost without computational effort. Therefore, this is the principal reason for using neural networks to solve complex problems that demand fast solutions, as the real time applications. The ART neural networks have as prime characteristics the plasticity and the stability, which are essential qualities for the training execution and for analysis in an efficient way. The modular fuzzy ARTMAP neural network is proposed to provide a superior performance, in precision and velocity, when compared to the conventional ARTMAP formulation, and much faster when compared to the neural networks using backpropagation training (benchmark in precision in a neural network context). The neural network training is realized using as a “teacher” an energy method to calculate the security margin. The proposed methodology is a proceeding that incorporates innovations in relation to the existent literature emphasizing: (1) development of a new appropriated model for solving the transient stability analysis by neural networks; (2) theoretical-practical development of the neural network output variable, represented in this work by the *IMS* (security margin interval) variable in a binary way. It is a convenient representation for the transient stability analysis approach; (3) proposition of a methodology for transient stability analysis of the electrical power systems by a modular fuzzy ARTMAP neural network that provides solutions with a precision level that can be considered satisfactory and faster, being, therefore, compatible with applications in real time. To illustrate the proposed method, results are presented considering a system composed of 10 synchronous machines, 72 transmission lines and 45 buses.

NOTAÇÃO E SIMBOLOGIA

Letras em negrito, maiúsculas e minúsculas representam matrizes e vetores, respectivamente.

a = vetor padrão de entrada da rede neural;

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

AL_i = número aleatório de uma seqüência de NL números gerados a partir de uma semente dada, $AL_i \in [0,1]$;

ART = *Adaptive Resonance Theory*

B_{ij} = susceptância de transferência entre as máquinas síncronas i e j ;

CA = Centro de Ângulos;

$E(q,w) \triangleq$ energia total do sistema
 $= Ec(w) + Ep(q)$;

$Ec(w) \triangleq$ energia cinética
 $= \frac{1}{2} \sum_{i \in N} M_i w_i^2$;

$Ecrit_r$ = energia total crítica do sistema;

EDMS = Esforço de Deslocamento da Margem de Segurança;

Ee_r = energia total do sistema avaliada no instante de eliminação do defeito (te);

E_k = tensão interna da k -ésima máquina síncrona;

$Ep(q) \triangleq$ energia potencial

$$= - \sum_{i \in N} \int_{q_i^p}^{q_i} P_i(q) dq_i;$$

f	=	função não-linear desconhecida;
f_0	=	freqüência nominal do sistema (Hz);
$f_k(\mathbf{a})$	=	função não-linear desconhecida referente à k -ésima contingência;
G_{ij}	=	condutância de transferência entre as máquinas síncronas i e j ;
H_i	=	constante de inércia (s);
$\mathbf{I}$	=	$[\mathbf{Z} \ \mathbf{Z}^c]$ (vetor de entrada na representação de codificação complementar);
IMS_k	=	k -ésimo intervalo da margem de segurança;
M^A	=	valor da margem de segurança inicial do intervalo;
MA	$\triangleq$	número de neurônios em F_1
M^B	=	valor da margem de segurança final do intervalo;
MDL	=	Método Direto de Lyapunov;
M_i	=	$2 H_i / w_s$;
M_{min}	=	margem de segurança mínima preestabelecida;
M_r	=	margem de segurança da r -ésima contingência;
MT	=	$\sum_{j \in N} M_j$;
N	$\triangleq$	conjunto de índices das máquinas síncronas;
	=	$\{1, 2, \dots, ns\}$;
n	=	número de barras do sistema;
$nbits$	=	número de <i>bits</i> ;
NI	=	número de intervalos IMS 's;
ns	=	número de máquinas síncronas;
$\mathbf{P}$	=	$[P_1 \ P_2 \ \dots \ P_n \]$;
PCA	$\triangleq$	potência acelerante do CA;
	=	$\sum_{j \in N} (Pm_j - Pe_j)$;

$PEBS$	=	<i>Potential Energy Boundary Surface</i> (Superfície Limite de Energia Potencial);
Pe_i	=	potência elétrica de saída (pu);
Pm_i	=	potência mecânica de entrada (pu);
PER	=	percentual de variação da demanda (valores positivos e negativos: por exemplo, $PER = \pm 10\%$ correspondem a 90% e 110% do caso base, respectivamente);
PG^0	=	vetor de potência ativa dos geradores referente ao caso base;
PG_i	=	potência ativa no i -ésimo gerador fixada aleatoriamente (ou pseudoaleatório);
P_i	=	potência ativa da i -ésima barra do sistema;
$P_i(q)$	=	$Pm_i - Pe_i - (M_i PCA) / MT$;
PL^0	=	vetor de potência ativa das cargas do caso base;
Q	=	$[Q_1 \ Q_2 \ \dots \ Q_n]$;
QG^0	=	vetor de potência reativa dos geradores referente ao caso base;
QG_i	=	potência reativa no i -ésimo gerador fixada aleatoriamente (ou pseudoaleatório);
Q_i	=	potência reativa da i -ésima barra do sistema;
QL^0	=	vetor de potência reativa das cargas do caso base;
R_j	=	retângulo que corresponde à representação geométrica da categoria;
RNA	=	Redes Neurais Artificiais;
S	=	número de contingências a ser analisadas;
T_j	=	função escolha;
u_j	=	vértice do retângulo R_j ;
V	=	conjunto de variáveis conseqüentes (ângulos e tensões nodais, etc.);
v_j	=	vértice do retângulo R_j .
W	=	vetor de pesos da rede neural;

$\mathbf{x}$	=	vetor de entrada da rede neural;
$\mathbf{y}$	=	vetor de saída da rede neural;
y_k	=	saída da k -ésima contingência;
$\mathbf{Y}_{red}$	=	matriz de admitância reduzida às barras internas de geração;
$\mathbf{Z}$	=	$(\mathbf{a}) / \mathbf{a} $
$\mathbf{Z}$	=	$[Z_1 \ Z_2 \ \dots \ Z_m]$ (vetor de entrada normalizado);
Z_i^c	=	$1 - Z_i$;
$D(q)$	=	derivada direcional da energia potencial;
a	=	parâmetro de escolha;
b	=	parâmetro de treinamento;
d_0	=	$\sum_{j \in N} M_j d_j / MT$;
d_i	=	ângulo do rotor da i -ésima máquina síncrona medida com relação a uma máquina que gira à velocidade síncrona (rad. elét.);
P	=	conjunto de parâmetros;
$\mathbf{q}$	=	$[q_1 \ q_2 \ \dots \ q_{ns}]^T$;
q_i	=	ângulo do rotor da i -ésima máquina síncrona referida ao CA (rad. elét.)
	=	$d_i - d_0$;
r	=	parâmetro de vigilância;
$\mathbf{w}$	=	$[w_1 \ w_2 \ \dots \ w_{ns}]^T$;
w_s	$\triangleq$	velocidade síncrona (rad. elét./s)
	=	$2 p f_0$;
J	=	esforço de deslocamento da margem de segurança;
J_{esp}	=	valor de J especificado de acordo com o critério estabelecido.
L	=	conjunto de informações codificadas (código binário);
$\wedge$	=	operador nebuloso <i>AND</i> ;

$|\cdot|_e$ = norma euclidiana;

$$|\mathbf{p}| \triangleq \sum_{i=1}^L |p_i|$$

$W(G)$ = conjunto de barras de geração;

$W(L)$ = conjunto de barras de cargas;

$(\mathbf{p} \wedge \mathbf{q})_i \triangleq \min(p_i, q_i)$, (operador nebulosos *AND*) com $\mathbf{p}$ e $\mathbf{q} \in \Re^L$

$(\mathbf{p} \vee \mathbf{q})_i \triangleq \max(p_i, q_i)$ (operador nebuloso *OR*) com $\mathbf{p}$ e $\mathbf{q} \in \Re^L$

$|\cdot|$ = função norma;

$\langle \cdot, \cdot \rangle$ = produto interno de dois vetores n -dimensionais.

SUMÁRIO

1.	Introdução	01
2.	Esquematização do Problema da Análise da Estabilidade Transitória por Redes Neurais	07
2.1.	Introdução	07
2.2.	Representação Esquemática do Trabalho Proposto.	07
3.	Modelo do Sistema e Análise de Estabilidade Transitória de Sistemas de Energia Elétrica	11
3.1.	Introdução	11
3.2.	Modelo do Sistema	12
3.3.	Análise de Estabilidade Transitória.	15
4.	Redes Neurais Artificiais	17
4.1.	Introdução	17
4.2.	Neurônio Biológico e Artificial	19
4.3.	Princípios da Rede Neural Artificial	20
4.4.	Treinamento	23
4.5.	Rede Neural ART Nebulosa	25
4.6.	Algoritmo ART Nebuloso	28
4.7.	Rede Neural ARTMAP Nebulosa	31
4.8.	Concepção Básica da ARTMAP Nebulosa.	31
5.	Análise de Estabilidade Transitória via Redes Neurais	35
5.1.	Introdução	35

5.2.	Representação do Modelo do Sistema	35
5.3.	Estímulos de Entrada	38
5.4.	Estímulos de Saída	39
5.5.	Perfis de Geração e de Carga.	48
6.	Rede Neural ARTMAP Nebulosa Modular	51
6.1.	Introdução	51
6.2.	Rede Neural Modular	51
6.3.	Interpretação dos Resultados da Rede neural ART Nebulosa.	55
7.	Aplicação	61
7.1.	Introdução	61
7.2.	Resultados.	61
8.	Conclusão e Sugestões para Trabalhos Futuros	72
8.1.	Conclusão	72
8.2.	Sugestões para Trabalhos Futuros.	73
9.	Referências Bibliográficas	75
	Apêndice A – Implementação Computacional para a Determinação da Margem de Segurança	83
	Apêndice B – Dados do Sistema de Energia Elétrica	87
	Apêndice C – Artigos Publicados e Aceito para Publicação Relacionados com a Tese de Doutorado	92

CAPÍTULO 1

INTRODUÇÃO

Esta pesquisa visa desenvolver uma metodologia para análise de estabilidade transitória de sistemas de energia elétrica por redes neurais artificiais. A análise de estabilidade consiste na avaliação dos efeitos procedentes de perturbações que causam grandes e indesejáveis oscilações nos ângulos das máquinas síncronas. Esta análise pode ser realizada através das soluções das equações diferenciais não-lineares que descrevem o movimento do sistema – equação de oscilação da máquina síncrona – e, posteriormente, via análise da evolução da posição angular de cada máquina síncrona ao longo do tempo (simulação). As técnicas utilizadas para a simulação são precisas e não apresentam restrições quanto ao tipo de modelo empregado. Exigem, contudo, a participação de um especialista no processo, o que eleva consideravelmente o tempo de análise. Um procedimento alternativo consiste na obtenção da análise sem se resolver tais equações diferenciais. Neste contexto, encontra-se o Método Direto de Lyapunov (MDL) ([44]), cujos resultados são considerados satisfatórios, principalmente quando se emprega o modelo clássico ([1], [44], [47], [60]).

Tendo em vista a grande quantidade de defeitos a serem analisados, a complexidade e a grande dimensão dos atuais sistemas de energia elétrica, a simulação, assim como o método direto de Lyapunov, são alternativas que ainda não oferecem totais condições para aplicações em tempo-real. Novas metodologias de análise, baseadas na inteligência artificial, em especial as redes neurais ([27], [30], [48], [53], [59], [62], [63]), têm sido abordadas na literatura com o propósito de superar tais dificuldades. Assim sendo, este trabalho visa investigar a aplicação de Redes Neurais Artificiais (RNA) no diagnóstico da estabilidade transitória de Sistemas de Energia Elétrica.

A análise de estabilidade transitória, utilizando redes neurais, tem sido feita de forma geral via emprego de redes *feedforward*, com treinamento baseado no algoritmo retropropagação (*backpropagation*) ([62]). Esta técnica tem se mostrado eficiente, sendo considerada, pela literatura especializada, como um *benchmark* em termos de precisão.

Contudo, o tempo de processamento é relativamente alto.

Desta forma, pretende-se, neste trabalho, investigar o uso da rede neural ARTMAP nebulosa ([9]). A rede ARTMAP é uma arquitetura baseada no treinamento supervisionado para mapeamentos multidimensionais (multientradas/multisaídas) sendo composta por dois módulos ART (*Adaptive Resonance Theory*) ([8]) e um módulo inter-ART. As redes neurais da família ART possuem as características de estabilidade (capacidade de aprender através do ajuste dos seus pesos) e plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões sem perder a memória com relação aos padrões anteriores). Com tais características, esta rede deve apresentar um desempenho superior ao tradicional algoritmo retropropagação ([62]). A rede ARTMAP nebulosa será, então, usada para avaliação da estabilidade transitória, considerando-se contingências tipo curto-circuito. Neste contexto, será desenvolvido um arranjo para avaliação da estabilidade transitória baseado na informação de tempos críticos de chaveamento e/ou do cálculo da margem de segurança ([21], [44]) como um aproximador de funções complexas (análise qualitativa e quantitativa), ou, ainda, como um classificador de padrões (análise qualitativa). A margem de segurança, expressa em função de energia total, pode ser interpretada como uma medida de “distância” em relação à condição de instabilidade do sistema. O modelo dinâmico do sistema adotado, neste trabalho, será o modelo clássico, com o objetivo exclusivo de reduzir o custo computacional na geração dos dados para o treinamento. Ressalta-se, entretanto, que poderão ser utilizados, a princípio, modelos mais elaborados, sem a necessidade de se promover modificações significativas na arquitetura proposta.

Será dada uma atenção especial ao desenvolvimento da rede neural tendo em vista que ela deverá ser bastante útil, também, para a resolução de outros problemas de engenharia elétrica, assim como de outras áreas do conhecimento humano.

Ressalta-se que na literatura especializada encontram-se poucas referências que abordam o problema da análise de estabilidade através do emprego de redes neurais ([17], [37], [38], [40], [41], [45], [51], [54]). Em todas elas o problema da análise de estabilidade transitória é formulado visando a determinação dos tempos críticos para faltas de curtos-circuitos. As referências [40], [41], [45] e [54] utilizam redes neurais com treinamento realizado via uso do algoritmo retropropagação. Em [40] é utilizado o algoritmo retropropagação com controlador nebuloso ([2]), o qual ajusta a taxa de treinamento, com o propósito de reduzir o número de ciclos e o tempo de execução na fase de treinamento.

Na referência [45], a rede neural é composta por dois módulos: supervisionado e não-supervisionado executados por uma rede neural com ligação funcional, cuja finalidade é reduzir o tempo de treinamento. Há outras referências, em destaque, que abordam problemas associados aos sistemas elétricos de potência com redes neurais que empregam o conceito ART. Nas referências [37] e [38] são propostas a resolução do problema da análise de estabilidade transitória por rede neural ARTMAP nebulosa, considerando a variação da carga e geração por proporcionalidade; aliás, é esta a solução adotada pela maioria das referências disponíveis.

Nesta pesquisa, considera-se a análise de estabilidade de primeira oscilação onde se pode empregar o chamado modelo clássico ([1], [44], [47]). A opção pela abordagem de um modelo mais simples deve-se ao fato de que, para extrair o conhecimento deste problema, via redes neurais, é necessário impor uma rotina de dados que constitui a fase de treinamento da rede. Estes dados devem conter informações quantitativas e qualitativas de cada uma das contingências. Para efetivamente constituir uma boa capacidade de generalização (análise de situações não previstas nos casos simulados), faz-se necessária a utilização de um grande número de dados de entrada e de saída para a fase do treinamento da rede neural. Para atender estas características, no momento, salvo melhor julgamento, somente podem ser proporcionados quando se utiliza os métodos diretos de análise, mais especificamente, os métodos de energia ([4]). Estes métodos, embora tenham apresentado grande evolução nos últimos anos, ainda há carência de resultados práticos para modelos mais elaborados. Deve-se destacar que a simulação (resolução do sistema de equações algébricas/diferenciais não-lineares e exame das soluções obtidas) é considerada, pela literatura especializada, um *benchmark* de análise de transitórios eletromecânicos. Nesta metodologia pode-se simular qualquer modelo (qualquer que se seja a sua sofisticação). Contudo, o grande obstáculo reside na obtenção somente da análise qualitativa, ou seja, a informação se o *sistema é ou não estável* para uma contingência em particular. Não é possível, a princípio, a menos que se empregue o método de tentativa e erro, saber quanto estável ou instável é o sistema. Além disto, os métodos de simulação consomem grande quantidade de tempo para a análise, isto porque empregam, entre outras rotinas, métodos de integração numérica, registros das curvas de oscilação, e envolvem a participação de um especialista para a conclusão da análise, tudo isto efetuando uma simulação por vez.

Deve-se ressaltar que não há restrição quanto a adoção de modelos mais elaborados, inclusive via simulação, para a abordagem via redes neurais. Apenas é preciso evidenciar a necessidade de resultados mais completos (saber *quanto estável ou instável é o sistema* frente a uma certa perturbação). Se utilizada a simulação como gerador dos estímulos de entrada/saída, a informação que se poderia obter da rede neural seria apenas: *o sistema é estável*, ou *o sistema é instável* associado a cada contingência.

Assim sendo, nesta pesquisa, será desenvolvida uma versão da arquitetura ART, chamada ARTMAP nebulosa modular, cuja finalidade é tratar cada contingência de forma separada. Esta alternativa visa aumentar a precisão dos resultados pois, basicamente, trabalha-se somente com dados analógicos. Evita-se, portanto, a manipulação de dados analógicos e binários simultaneamente, que é uma situação que, via de regra, tem contribuído para uma má classificação das redes neurais, em especial, das redes neurais da família ART.

As principais contribuições desta pesquisa podem ser assim destacadas:

1. Desenvolvimento de um novo modelo que seja adequado para a resolução do problema de análise de estabilidade transitória baseado no uso somente das informações referentes às potências ativa e reativa nodais e aos dados das contingências, constituindo-se os dados de entrada e às margens de segurança (representadas pelos intervalos da margem de segurança), que correspondem aos dados de saída da rede neural. As variáveis correspondentes às potências ativa e reativa são analógicas, enquanto que os dados de contingências (barra sob curto-circuito e linha retirada de operação) são convertidos em dados binários. Trata-se de um modelo de tamanho bastante reduzido, se comparado ao modelo habitualmente usado na literatura especializada. Este modelo, então, deverá contribuir significativamente para a redução do esforço computacional para a execução do treinamento da rede neural;
2. Desenvolvimento teórico-prático sobre a variável de saída da rede neural, representada nesta pesquisa pela variável *IMS* (Intervalo da Margem de Segurança) numa forma binária. Trata-se de uma representação conveniente para a abordagem da análise de estabilidade de sistema de energia elétrica;
3. Desenvolvimento de um esquema para geração de perfis de geração e de carga do sistema para a fase de treinamento da rede neural, considerando um espectro de variação que atenda a curva de demanda diária. Este esquema é baseado numa

distribuição aleatória (ou pseudoaleatória) da potência em cada barra do sistema ([52]). Com este procedimento, evita-se a geração exaustiva de resoluções de problemas de previsão de carga e conseqüente determinação do despacho de geração, para atender a demanda, realizado, por exemplo, através de despacho econômico.

4. Proposição de uma metodologia de análise de estabilidade transitória de sistemas elétricos de potência por rede neural ARTMAP nebulosa modular. Considerando-se todos os resultados aqui desenvolvidos, estes permitirão à rede neural a execução do treinamento (maior parcela do esforço computacional) de forma bastante rápida, se comparada às demais redes neurais disponíveis na literatura especializada. Uma vez concluído o treinamento da rede neural, a análise pode ser realizada, a princípio, em tempo real. Cabe observar que as redes neurais de ascendência ART – que é o caso da rede proposta nesta pesquisa – são plásticas, permitindo, portanto, a realização do treinamento continuado sem destruir o conhecimento adquirido previamente. Com isto é possível desenvolver sistemas bastantes rápidos de análise da estabilidade transitória que ofereçam soluções mais precisas com o passar do tempo.

Este texto está organizado em capítulos e apêndices, cujos conteúdos são assim descritos:

- Capítulo 2* : É apresentada a formulação do problema de análise da estabilidade transitória por redes neurais.
- Capítulo 3* : São apresentados o modelo dinâmico do sistema e o método de energia (PEBS iterativo ([21])), com vistas à análise de estabilidade transitória de sistemas elétricos de potência, representado pelo modelo clássico.
- Capítulo 4* : São apresentados os principais conceitos sobre redes neurais artificiais, bem como as arquiteturas ART e ARTMAP nebulosas.
- Capítulo 5* : Análise de estabilidade transitória via redes neurais. São desenvolvidos os modelos para a geração dos dados de entrada e de saída da rede neural.
- Capítulo 6* : É apresentada a formulação da rede neural ARTMAP nebulosa modular.
- Capítulo 7* : São apresentados os resultados da análise da estabilidade transitória, através da rede neural ARTMAP nebulosa modular, considerando-se uma versão do sistema da região sul do Brasil, composta por 45 barras, 73 linhas de transmissão e 10 máquinas síncronas.

Capítulo 8 : São apresentadas as principais conclusões e sugestões para trabalhos futuros.

Capítulo 9 : Encontram-se relacionadas as referências bibliográficas.

Apêndice A : Apresenta-se o algoritmo passo a passo do método PEBS Iterativo ([21]).

Apêndice B : Contém os dados do sistema teste (versão do sistema elétrico de potência da região sul do Brasil).

Apêndice C : Contém os artigos publicados e aceitos para publicação relacionados com a tese.

CAPÍTULO 2

ESQUEMATIZAÇÃO DO PROBLEMA DA ANÁLISE DA ESTABILIDADE TRANSITÓRIA POR REDES NEURAIS

2.1. INTRODUÇÃO

Neste Capítulo apresenta-se o esquema básico de resolução do problema da análise de estabilidade transitória de sistemas de energia elétrica por redes neurais proposto nesta pesquisa. O modelo usado corresponde ao modelo clássico. A rede neural empregada corresponde a uma versão da rede neural da família ART chamada ARTMAP nebulosa modular. Trata-se de uma abordagem de análise para aplicações em tempo real. O funcionamento das redes neurais é constituído por duas fases fundamentais, que são o treinamento e a 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. Deste modo, o conteúdo apresentado neste capítulo tem por objetivo ilustrar as principais etapas da metodologia proposta. Em capítulos subseqüentes, cada parte aqui evidenciada será abordada de forma detalhada.

2.2. REPRESENTAÇÃO ESQUEMÁTICA DO TRABALHO PROPOSTO

A metodologia proposta nesta pesquisa para a análise de estabilidade transitória, basicamente, é constituída por 3 fases:

- (1) Fase 1. Geração de dados (de entrada e de saída) para uso no treinamento da rede neural.

Consiste na geração de um grande número de simulações de estabilidade transitória (de primeira oscilação) de sistemas de energia elétrica usando um programa computacional chamado *Simul* ([39]). É usado um conjunto extenso de perfis de geração e de carga, os quais são gerados, por processo aleatório (ou pseudoaleatório), com o objetivo de “simular” os níveis de geração

necessários para atender a demanda diária durante um período preestabelecido. Esta etapa será abordada nos Capítulos 3 (modelo do Sistema) e 5 (preparação dos dados de entrada e de saída).

(2) Fase 2. Treinamento da rede neural.

Usando-se os dados obtidos a partir das simulações realizadas (Fase 1), é preparado o conjunto de dados (de entrada e de saída) para a fase de treinamento da rede neural. Trata-se de um procedimento de extração do conhecimento através da experiência: os exemplos são apresentados à rede neural, correspondentes aos dados simulados. Este procedimento será abordado nos Capítulos 5 (análise de estabilidade transitória por redes neurais) e 6 (rede neural ARTMAP nebulosa modular). As Fases 1 e 2 são realizadas em *off-line*.

(3) Fase 3. Análise.

Uma vez concluído o treinamento da rede neural (ARTMAP nebulosa modular), pode-se executar a análise de estabilidade transitória. Esta fase (Fase 3) é realizada *on-line*. Os perfis de geração e de carga, nesta fase, correspondem aos casos reais que se deseja analisar, ou seja, não são idênticos aos dados empregados no treinamento. Deve-se observar que os dados de treinamento constituem os exemplos que servem para “ensinar” a rede neural.

Na Figura 1 mostram-se as principais rotinas que compõem a metodologia de análise de estabilidade transitória de sistemas elétricos de potência via redes neurais.

A rede neural assim proposta estará apta a realizar as análises. Contudo, pode-se incorporar outras rotinas visando tornar a metodologia mais eficiente. Neste sentido, o esquema pode conter um dispositivo que permita o treinamento continuado que deve estar agregado ao módulo de análise, ou seja, após o treinamento ter sido concluído. À medida em que são realizadas as análises, estas informações podem ser incorporadas nas “matrizes de memória” que são os pesos da rede neural, mediante mecanismo apropriado ([26]). Embora este recurso não seja abordado nesta pesquisa, faz parte dos itens que são sugeridos para futuros trabalhos.




Figura 1. Diagrama esquemático de análise de estabilidade transitória por redes neurais.

Pode-se, ainda, introduzir, se conveniente, dispositivos para testes entre os dados gerados pela rede neural e pelo programa de simulação, com o propósito de inferir sobre o grau de precisão da rede neural, estabelecendo-se, deste modo, a classe de confiabilidade da rede neural. Servindo, também, para detectar possíveis setores do sistema neural passíveis de serem melhorados. Enfim, constitui-se de um recurso importante para o diagnóstico sobre a qualidade das soluções obtidas.

CAPÍTULO 3

MODELO DO SISTEMA E ANÁLISE DE ESTABILIDADE TRANSITÓRIA DE SISTEMAS DE ENERGIA ELÉTRICA

3.1. INTRODUÇÃO

Esta pesquisa visa investigar o uso de redes neurais (ARTMAP nebulosa ([10], [11]) modular ([52])) para a análise da estabilidade transitória de sistemas de energia elétrica. Redes neurais são concepções que exibem capacidade de aprender com a experiência por aplicação de estímulos de entrada-saída e uso de um mecanismo de adaptação de pesos (treinamento). Com isto é possível efetuar diagnósticos complexos. No caso da análise de estabilidade transitória, estes estímulos podem ser definidos através de dados do sistema (entrada) e resposta (saída) determinada, por exemplo, via utilização do programa computacional como o Transdir®, Anatem®, Eurostag®, PSS/E®, etc. (que são os mais conhecidos no setor elétrico), ou um outro *software* disponível pelo usuário para esta finalidade. Estes *software* constituem-se num procedimento de simulação da dinâmica do sistema para todo tipo de modelo, desde o clássico até o mais elaborado, como o modelo completo de Park ([56]). As redes neurais podem efetuar análises, a princípio, considerando-se qualquer modelo, bastando apenas compor, adequadamente os referidos estímulos, ou seja, é necessário se dispor de um índice de medida do nível de segurança (índice de estabilidade). Neste Capítulo, então, será apresentado o modelo dinâmico do sistema correspondente ao modelo clássico ([1], [47]), como ponto de partida, tendo em vista, principalmente, a necessidade de se efetuar estudos e testes que possam orientar e/ou propor soluções alternativas para o diagnóstico e controle, em tempo real, de sistemas de energia elétrica. Será, também, apresentado o método para o cálculo da margem de segurança do sistema, com vistas à análise de estabilidade transitória que servirá para construir o conjunto de dados de entrada/saída da rede neural para a fase de treinamento. A margem de segurança representa uma medida da “distância” que o sistema se encontra, para uma contingência em particular, do seu limite de estabilidade.

3.2. MODELO DO SISTEMA

Considerando-se um sistema de energia elétrica composto por ns máquinas síncronas, o comportamento dinâmico da i -ésima máquina síncrona, relativo ao Centro de Ângulos (CA), é descrito pelas seguintes equações diferenciais e algébricas não-lineares ([1], [44], [47]):

$$M_i \frac{d^2 q_i}{dt^2} - P_i(q) = 0 \quad (3.2.1)$$

$$P_i(q) = Pm_i - Pe_i - (M_i PCA) / MT \quad (3.2.2)$$

$$i \hat{I} N.$$

sendo:

$$M_i = 2 H_i / \omega_s;$$

$$q = [q_1 \ q_2 \ \dots \ q_n]^T$$

$$\omega_s \triangleq \text{velocidade síncrona};$$

$$= 2p f_0;$$

$$H_i = \text{constante de inércia (s)};$$

$$f_0 = \text{frequência nominal do sistema (Hz)};$$

$$q_i \triangleq \text{ângulo do rotor da } i\text{-ésima máquina síncrona com relação ao Centro de Ângulos (radianos elétricos)};$$

$$= d_i - d_0;$$

$$d_i = \text{ângulo do rotor da } i\text{-máquina síncrona em relação a uma máquina que gira à velocidade síncrona (radianos elétricos)};$$

$$d_0 = \sum_{j \in N} M_j d_j / MT;$$

$$Pm_i = \text{potência mecânica de entrada (pu)};$$

$$Pe_i = \text{potência elétrica de saída (pu)};$$

$$PCA \triangleq \text{potência acelerante do centro de ângulos}$$

$$= \sum_{j \in N} (Pm_j - Pe_j);$$

$$MT = \sum_{j \in N} M_j;$$

$N \triangleq$ conjunto de índices das máquinas síncronas;

$$= \{1, 2, \dots, ns\}$$

ns = número de máquinas síncronas.

A formulação do modelo referido ao centro de ângulos, equações (3.2.1) e (3.2.2), apresenta as seguintes propriedades ([44]):

Propriedade 1. A potência acelerante do centro de ângulos, avaliada no ponto de equilíbrio estável, é nula ([44]).

Propriedade 2. O somatório do produto da posição angular q pela inércia de cada máquina do sistema é igual a zero ([44]):

$$\sum_{j \in N} M_j q_j = 0 \quad (3.2.3)$$

Propriedade 3. O somatório do produto da velocidade angular w pela inércia de cada máquina do sistema é igual a zero:

$$\sum_{j \in N} M_j w_j = 0 \quad (3.2.4)$$

A Propriedade 1 é estabelecida a partir da formulação do problema do fluxo de potência, que é determinado fazendo-se ($Pm - Pe = 0$) para todas as máquinas que compõem o sistema. Isto equivale à determinação de um ponto de operação (equilíbrio) do sistema ([42]). Desde modo, conclui-se que a PCA é nula quando avaliada em um ponto de operação estável do sistema. A PCA será diferente de zero sempre que houver

deslocamento do estado do sistema em torno do ponto de equilíbrio, ou seja, durante as oscilações eletromecânicas ([44]).

Da Propriedade 2 conclui-se que os ângulos θ_i 's são linearmente dependentes. O mesmo ocorre com as velocidades ω_i 's (Propriedade 3). Por conseguinte, o conhecimento de $(2n - 2)$ variáveis de estado do sistema permite o cálculo das duas variáveis restantes, utilizando-se as equações (3.2.3) e (3.2.4).

A potência elétrica (Pe), no modelo definido pelas equações (3.2.1) e (3.2.2), considerando-se o modelo da rede elétrica reduzida às barras internas de geração, pode ser expressa por ([1]):

$$Pe_i = \sum_{\substack{j=1 \\ j \neq i}}^{ns} (F_{ij} \sin q_{ij} + H_{ij} \cos q_{ij}) + E_i^2 G_{ii} \quad (3.2.5)$$

sendo:

$$F_{ij} = E_i E_j B_{ij} \quad (3.2.6)$$

$$H_{ij} = E_i E_j G_{ij} \quad (3.2.7)$$

E_k = tensão interna da k -ésima máquina síncrona.

Os parâmetros G_{ij} e B_{ij} são definidos como sendo condutância e susceptância de transferência, respectivamente. A matriz de admitância reduzida às barras internas de geração é por ([1]):

$$\mathbf{Y}_{RED} = \mathbf{Y}_{GG} - \mathbf{Y}_{GL} \{\mathbf{Y}_{LL}\}^{-1} \mathbf{Y}_{LG} \quad (3.2.8)$$

sendo:

$\mathbf{Y}_{GG}$, $\mathbf{Y}_{GL}$, $\mathbf{Y}_{LL}$ e $\mathbf{Y}_{LG}$ são sub-matrizes da matriz de admitância nodal do sistema, considerando-se as barras internas de geração e cargas transformadas em admitâncias constantes, definida por ([1]):

$$\mathbf{Y}_{AD} = \begin{bmatrix} \mathbf{Y}_{GG} & \mathbf{Y}_{GL} \\ \mathbf{Y}_{LG} & \mathbf{Y}_{LL} \end{bmatrix} \quad (3.2.9)$$

sendo que:

os subscritos G e L representam os índices relativos às barras de geração e cargas, respectivamente.

3.3. ANÁLISE DE ESTABILIDADE TRANSITÓRIA

A análise de estabilidade transitória de sistemas elétricos de potência, considerando uma contingência de índice r , pode ser realizada usando o critério da margem de segurança ([44]):

$$M_r = (E_{crit_r} - E_{e_r}) / E_{crit_r} \quad (3.3.1)$$

sendo:

M_r = margem de segurança do sistema referente à r -ésima contingência;

E_{crit_r} = energia total crítica do sistema;

E_{e_r} = energia total do sistema referente à r -ésima contingência calculada no tempo de eliminação da falta.

A energia crítica (E_{crit}) e o tempo crítico (t_{crit}) podem ser determinados usando uma série de soluções disponíveis na literatura especializada, por exemplo, o método PEBS (*Potential Energy Boundary Surface*) ([4], [21]). Observa-se que para a modelo clássico, o método PEBS produz os mesmos resultados da simulação ([21]). A energia total, relativa ao sistema (3.2.1) e (3.2.2), é dada por ([21], [44]):

$$E(q, w) = E_c(w) + E_p(q) \quad (3.3.2)$$

sendo:

$E_c(w)$ = energia cinética

$$= \frac{1}{2} \sum_{i \in N} M_i w_i^2; \quad (3.3.3)$$

$Ep(q)$ = energia potencial

$$= - \sum_{i \in N} \int_{q_i^p}^{q_i} P_i(q) dq_i. \quad (3.3.4)$$

Nesta pesquisa será usado o método PEBS iterativo ([21]), cujo algoritmo é apresentado no Apêndice A. Contudo, a metodologia a ser desenvolvida (por redes neurais ARTMAP nebulosa) não está atrelada ao método PEBS, podendo ser usado um outro método, desde que seja fornecido algum índice de estabilidade.

Então, a estabilidade transitória da r -ésima contingência pode ser inferida mediante o critério da margem de segurança da seguinte forma ([42], [44]):

- se $M_r \geq 0$, então, o sistema é considerado *estável*;
- se $M_r < 0$, então, o sistema é considerado *instável*.

Os termos *estável* e *instável*, nesta pesquisa, referem-se ao conceito de estabilidade transitória de primeira oscilação (*first swing*).

CAPÍTULO 4

REDES NEURAIS ARTIFICIAIS

4.1. INTRODUÇÃO

Os estudos de Redes Neurais Artificiais (RNA) constituem-se num dos maiores ramos da inteligência artificial. As RNA são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. O primeiro modelo de neurônio foi proposto por McCulloch e Pitts em 1943 ([27], [30], [59]). A saída do modelo assume valores iguais a um ou zero e, quando a entrada excede algum limiar predeterminado, os valores passam gradualmente de zero para um. No final de 1950 e início de 1960, Rosenblatt ([27]) desenvolveu o *perceptron*, que é uma das estruturas neurais mais empregadas na literatura especializada. Em 1982, Hopfield ([27], [53]) propôs um modelo de rede neural mutuamente conectada. Em 1974, Werbos ([62]) apresentou o algoritmo retropropagação (*backpropagation*) que possui a capacidade de treinar redes multicamadas. Na rede *perceptron*, o modelo de McCulloch-Pitts ([59]) foi substituído por um modelo diferenciável baseado em uma função sigmoideal, permitindo que todos os pesos da rede neural possam ser adaptados pelo algoritmo retropropagação. Portanto, estas redes são aplicáveis, também, para problemas não-lineares. Estes desenvolvimentos levaram as redes neurais a um novo estágio de pesquisa. Novos modelos estão sendo desenvolvidos: aplicações para classificação de padrões, modelagem de sistemas, controle de sistemas, problemas de otimização e predição estão sendo adotados, e vários sistemas baseados nas redes neurais estão atualmente em uso.

Uma das mais importantes características das redes neurais é a capacidade de generalização, ou seja, produzir respostas para padrões de entrada que são similares, mas não idênticos, aos padrões que a rede já conhece. As redes neurais artificiais são, especialmente, adequadas para tarefas que envolvem conjuntos de dados ou informações incompletas, com ruídos, problemas de difíceis soluções e mal definidos, onde geralmente o homem decide baseado na sua intuição. O uso das redes neurais artificiais tem obtido sucesso em várias aplicações. Algumas das mais importantes são:

Classificação

- Reconhecimento de padrão;
- Reconhecimento de som, voz e imagem;
- Identificação de alvos militares;
- Identificação de explosivos em malas de passageiros;
- Identificação de assinatura;
- Imagens médicas;
- Reconhecimento das ondas de eletrocardiogramas.

Previsão

- Tempos e tendências de mercados;
- Previsões de locais de exploração mineral;
- Previsões de cargas elétricas e térmicas.

Controle de Sistemas

- Controle adaptativo;
- Controle robótico.

Otimização e Tomada de Decisão

- Sistemas de Engenharia;
- Otimização linear e não-linear;
- Otimização combinatorial;
- Gerenciamento.

Etc.

Assim sendo, neste capítulo serão abordados os principais conceitos sobre a teoria de Redes Neurais Artificiais (RNA) ([8], [27], [30], [53], [59], [63]), com objetivo de auxiliar a compreensão da pesquisa proposta, que corresponde à análise de estabilidade transitória de sistemas de energia elétrica (assunto que será tratado no Capítulo 5).

Na sequência, apresentam-se os principais conceitos e o algoritmo computacional da rede neural ART (*Adaptive Resonance Theory*) ([8], [9], [10], [11], [12], [13], [14]), incluindo conceitos de lógica nebulosa ([30], [58]). Esta rede é conhecida como ART nebulosa ([10], [11]). A versão nebulosa da rede neural ART foi proposta pelos autores como forma de permitir a manipulação de dados analógicos e binários sem

necessidade do envolvimento de modificações sendo, portanto, uma única estrutura neural. Trata-se de uma rede neural não-supervisionada, ou seja, o treinamento é baseado na aplicação somente de estímulos de entrada constituindo num procedimento de extração do conhecimento auto-organizável.

Serão introduzidos, também, os conceitos da rede neural ARTMAP. A rede neural ARTMAP constitui-se numa rede supervisionada, ou seja, o treinamento é realizado baseado em estímulos de entrada e de saída, sendo formada por duas sub-redes neurais ART: ARTa e ARTb interligadas por um módulo inter-ART que executa a função de estabelecer o “casamento” entre a entrada e a saída da rede neural. A rede neural ARTMAP nebulosa possui uma arquitetura robusta tal como a rede ART com características de estabilidade e plasticidade. Ela é capaz de manusear vetores de entradas binárias e analógicas, os quais podem representar conjuntos de características nebulosas ou *crisp* (não-nebulosas). É uma arquitetura de rede neural capaz de aumentar o desempenho do treinamento supervisionado de reconhecimento de categorias e mapeamentos multidimensionais em resposta aos padrões de entrada binários, analógicos ou nebulosos em seqüências aleatórias. As redes ARTa e ARTb possuem a mesma estrutura da rede ART nebulosa, exceto que em ARTa existe uma vigilância básica usada para controlar o sistema.

4.2. NEURÔNIO BIOLÓGICO E ARTIFICIAL

No cérebro existe um fluxo de informações codificadas (neurotransmissão) da sinapse em direção ao axônio, através do qual a informação é transmitida para outros neurônios. Um neurônio recebe informações das sinapses de muitos outros neurônios, e cada neurônio pode receber informações de outros neurônios (aproximadamente 10 mil) ([29]). Os neurônios se agrupam formando sub-sistemas e a integração desses sub-sistemas forma o cérebro. Estima-se que o cérebro humano tenha por volta de 100 bilhões de neurônios conectados. Na Figura 2 são mostrados os principais componentes de um neurônio biológico mais conhecido. Nesta ilustração são mostrados 2 neurônios conectados, onde é evidenciada a conexão entre tais neurônios, através da sinapse.




Figura 2. Neurônio Biológico.

O modelo de um neurônio artificial (Figura 3) é baseado no neurônio biológico real. Uma rede neural artificial é um grupo de neurônios artificiais interconectados interagindo com outros de uma forma combinada. Neste sistema, um estímulo é aplicado na entrada da rede, e após algumas operações satisfatórias, encontra-se uma saída desejada. Na sinapse, existe um acúmulo de potencial, que no caso do neurônio artificial, é modelado como uma conexão de pesos. Esses pesos são continuamente modificados, baseados nas regras satisfatórias de aprendizagem.




Figura 3. Neurônio Artificial.

4.3. PRINCÍPIOS DA REDE NEURAL ARTIFICIAL

Redes neurais são modelos estatísticos adaptativos baseados na estrutura do cérebro. A rede neural artificial consiste de uma camada de entrada, algumas camadas ocultas e uma camada de saída. Desta forma simples, cada neurônio é conectado a outros neurônios da camada anterior, através dos pesos sinápticos. O conhecimento é geralmente

armazenado como um conjunto de pesos de conexão. Uma entrada é apresentada à rede junto com a saída desejada e os pesos são ajustados de modo que a rede tente reproduzir a saída desejada. A Figura 4 mostra como a informação é processada através de um único nó (neurônio). O neurônio recebe as ativações dos pesos dos outros neurônios através das suas conexões de entrada. Primeiramente, eles são somados e o resultado é passado por uma função de ativação, sendo o resultado a ativação do neurônio. Para cada conexão da saída, o valor da ativação é multiplicado por um peso específico e transferido para o próximo neurônio.




Figura 4. Processamento da informação.

Quando cada padrão é apresentado, a rede usa a entrada para produzir uma saída que é comparada com a saída desejada. Se existir uma diferença, a conexão dos pesos é alterada de forma que o erro tende a diminuir. Após a rede executar todos os padrões de entrada, se o erro ainda é maior que a tolerância máxima permitida, a rede executa novamente todos os padrões de entrada repetidamente até que todos os erros estejam dentro das tolerâncias preestabelecidas. Quando o treinamento atinge um nível satisfatório, a rede mantém os pesos constantes e, assim, ela está treinada para tomar decisões, identificar padrões ou definir associações em um novo conjunto de dados de entrada que não foram usados no treinamento.

Na Figura 5 mostra-se, um resumo sobre o que foi abordado até então de redes neurais: neurônio biológico, neurônio artificial (neurônio de McCulloch-Pitts) ([59]), que é um dos mais conhecidos na literatura especializada e a estrutura básica de uma rede neural.




Figura 5. Representação do neurônio biológico, neurônio artificial de McCulloch-Pitts e da estrutura básica de uma rede neural.

As redes neurais podem ser classificadas em *Recorrente* e *Não-Recorrente*, de acordo com as seguintes definições:

Definição 1. Rede Recorrente. É uma rede neural que contém laços de realimentação, ou seja, contém conexões através das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores ([27]).

Definição 2. Rede Não-recorrente ou *feedforward*. É uma rede neural que não contém laços de realimentação. Este tipo de rede não tem memória. Sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos (Figura 6) ([27], [53], [59]).




Figura 6. Rede não-recorrente.

4.4. TREINAMENTO

As redes neurais podem ter, também, dois tipos de treinamento: *Supervisionado e Não-supervisionado*, assim definidos:

Definição 3. Treinamento Supervisionado. Consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada, conforme é mostrado na Figura 7. Este treinamento necessita de um par de cada vetor de entrada com um vetor alvo representando a saída desejada. Este tipo de treinamento necessita de um “professor” para supervisionar a entrada e saída, informando à rede sobre o seu desempenho. Algumas redes apresentam este tipo de treinamento: *Madaline* ([63]), ARTMAP, ARTMAP Nebulosa ([8], [9], [10], [11], [12], [13], [14]), entre outras.




Figura 7. Treinamento supervisionado.

Definição 4. **Treinamento Não-supervisionado.** Consiste no mecanismo de ajuste de pesos de uma rede neural, levando-se em conta somente o conjunto de padrões de entrada (Figura 8). O treinamento não-supervisionado não necessita de um “professor”, ou seja, a rede é autônoma. As redes que possuem este tipo de treinamento são: Hopfield ([53]), Kohonen ([27]), ART ([8]) entre outras.




Figura 8. Treinamento não-supervisionado.

4.5. REDE NEURAL ART NEBULOSA

Apresentam-se, a seguir, os principais conceitos e o algoritmo computacional da rede neural ART (*Adaptive Resonance Theory*) ([8], [9], [10], [11], [12], [13], [14]), incluindo conceitos de lógica nebulosa ([30], [58]). *Adaptive* se refere à capacidade de aprendizagem da rede, *Resonance* se refere ao “casamento” auto-reforçado da camada de entrada com um vetor protótipo na segunda camada. Esta rede é conhecida como ART nebulosa ([10], [11]) e faz parte de um conjunto de propostas (ART, ART1, ART2, ARTMAP entre outras) ([8], [9], [10], [11], [12], [13], [14]) destinado à classificação de padrões binários e/ou analógicos com treinamento supervisionado e não-supervisionado. A versão nebulosa da rede neural ART foi proposta pelos autores como forma de permitir a manipulação de dados analógicos e binários sem necessidade do envolvimento de modificações sendo, portanto, uma única estrutura neural. Trata-se de uma rede neural não-supervisionada, ou seja, o treinamento é baseado na aplicação somente de estímulos de entrada constituindo num procedimento de extração do conhecimento auto-organizável. Este módulo é a base de formação da rede neural ARTMAP que é o sistema que será usado nesta pesquisa (assunto a ser abordado neste Capítulo).

A formulação da rede ART ([8]), através do uso da teoria de conjuntos nebulosos ([30], [58]), designada ART nebulosa ([10], [11]), tem conferido à formulação original ([8]) uma sensível redução do tempo necessário à execução do treinamento. A rede ART possui a característica de estabilidade (capacidade de aprender através do ajuste dos seus pesos) e plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões sem perder a memória relacionada aos padrões anteriores). Trata-se de uma rede neural para o reconhecimento de padrão em tempo-real em resposta a uma seqüência arbitrária de entradas, com modalidade de treinamento rápido ou lento. A rede ART é uma arquitetura baseada no treinamento não-supervisionado para mapeamentos multidimensionais (multientradas e multisaídas). Esta rede é composta, basicamente, por 3 níveis de atividades (campos): F_0 , F_1 e F_2 , como mostrados na Figura 9.




Figura 9. Rede neural ART nebulosa.

O vetor de entrada deve ser normalizado: $a \rightarrow Z$, sendo que a e $Z \in \hat{A}^m$, ou seja, este vetor é transformado, cujos componentes de Z devem satisfazer $Z_i \in [0, 1]$. No campo F_0 o vetor normalizado é convertido no vetor $I \in \hat{A}^{2m}$ chamado vetor complementar de Z . O campo F_1 contém neurônios, cada qual representa uma combinação particular de características sensoriais. F_2 contém os neurônios da rede que representam os códigos de reconhecimento que são seletivamente excitados por padrões de ativação através de F_1 . Este mecanismo constitui os procedimentos para o treinamento e, por consequência, o reconhecimento do processo sob abordagem. A rede é constituída por um conjunto de pesos referentes ao campo F_2 . Estes pesos (w) são responsáveis pelo armazenamento das informações através de um processo que envolve a escolha de categoria, critério de equalização e treinamento (rápido ou lento de acordo com a decisão do usuário). A ressonância e o *reset* são realizados através de um parâmetro denominado parâmetro de vigilância, r (r possui valor decimal compreendido entre 0 e 1), que determina a decisão do processo de classificação de categorias. Para um valor alto de r , a rede efetua boas distinções e, conseqüentemente, produz uma boa decisão de classificação, ou seja, pequenas variações nos padrões de entrada resultarão na criação de novas classes (categorias) e conduzirão o sistema a uma generalização pobre. Já um valor baixo de r causa uma decisão de classificação pequena, no qual, produzirá poucos tipos de classes ([31]).

Na Figura 10 mostram-se os detalhes sobre a formação dos pesos (vetor w) alocados entre as atividades F_1 e F_2 . Trata-se de uma conexão entre MA componentes de atividade correspondentes aos componentes do vetor x (em F_1) e NA neurônios na atividade F_2 . A escolha do número NA é arbitrária, porém, deve ser suficiente para abrigar todas as categorias formadas em F_2 . Assim sendo, costuma-se adotar o número NA igual ao número de vetores padrões a serem armazenados, ou seja, ter-se-iam NA categorias formadas, no máximo (uma para cada padrão que corresponde uma situação pouco plausível do ponto de vista prático). Outra alternativa que pode ser adotada é a criação contínua de novos neurônios à medida que novas categorias são formadas. Estas duas alternativas podem ser perfeitamente implementadas nas redes neurais ART. A segunda alternativa é mais interessante, visto que se trabalha com um número menor de neurônios, se comparada à primeira alternativa, sendo, portanto, mais rápida.




Figura 10. Detalhe sobre a formação do vetor peso que conecta as atividades F_1 e F_2 .

Na próxima Seção será apresentado o algoritmo básico da rede neural ART nebulosa. Ressalta-se que a notação vetorial usada, neste trabalho, segue a representação por linha e não por coluna. Esta representação, como já mencionada, torna mais simples a exposição da metodologia.

4.6. ALGORITMO ART NEBULOSO

O algoritmo da rede ART nebulosa consiste, basicamente, dos seguintes passos ([10], [11]):

Passo 1. Inicialização de Pesos e Escolha de Parâmetros

Inicialmente, os pesos são iguais a 1, informando assim que todas as categorias estão desativadas. Os pesos e demais parâmetros da rede neural ART nebulosa são arbitrados do seguinte modo:

$$w_{ij} = 1, \quad \forall i, j$$

$$r \in [0, 1], \quad a > 0, \quad e \quad b \in [0, 1];$$

sendo:

r = parâmetro de vigilância;

a = parâmetro de escolha;

b = parâmetro de treinamento.

Passo 2. Processo de Normalização

A proliferação de categoria é evitada na rede neural ART nebulosa se as entradas são normalizadas:

$$\mathbf{Z} = (\mathbf{a}) / \|\mathbf{a}\|$$

sendo:

$\mathbf{a}$ = vetor de entrada;

$\mathbf{Z} = [Z_1 \ Z_2 \ \dots \ Z_m]$ (normalizado);

$\|\cdot\|$ = função norma.

Passo 3. Codificação Complementar

Um novo padrão $\mathbf{Z}$, sendo que cada componente Z_i é um número real pertencente ao intervalo $[0,1]$, terá uma codificação complementar. Isto produz um vetor $\mathbf{I}$ de entrada com MA elementos, da seguinte forma:

$$\begin{aligned} \mathbf{I} &\triangleq [\mathbf{Z} \ \mathbf{Z}^c] \\ &= [Z_1 \ Z_2 \ \dots \ Z_m \ Z_1^c \ Z_2^c \ \dots \ Z_m^c] \end{aligned} \quad (4.6.1)$$

em que:

$$Z_i^c = 1 - Z_i.$$

$$\begin{aligned} MA &\triangleq \text{número de neurônios em } F_1 \\ &= 2m. \end{aligned}$$

Esta codificação complementar é uma regra de normalização que preserva a amplitude da informação ([10], [11]):

$$\begin{aligned} |\mathbf{I}| &= \sum_{i=1}^m Z_i + (m - \sum_{i=1}^m Z_i) \\ &= m. \end{aligned}$$

Passo 4. Escolha de Categorias

A função T_j é calculada para cada neurônio j usando-se a função escolha (na atividade F_2):

$$T_j = |\mathbf{I} \wedge \mathbf{w}_j| / (a + |\mathbf{w}_j|), \quad (4.6.2)$$

sendo:

$\wedge$ = operador nebuloso *AND* definido por ([30, 58]):

$$\begin{aligned} (\mathbf{p} \wedge \mathbf{q})_i &\triangleq \min(p_i, q_i), \text{ com } \mathbf{p} \text{ e } \mathbf{q} \in \mathfrak{R}^L, \\ |\mathbf{p}| &\triangleq \sum_{i=1}^L |p_i| \end{aligned} \quad (4.6.3)$$

A escolha da categoria é considerada quando pelo menos um neurônio em F_2 tornar-se ativo. A categoria escolhida é, então, indexada pelo índice J da seguinte forma:

$$T_J = \max \{T_j, j = 1, \dots, NA\}. \quad (4.6.4)$$

Se mais do que um T_j é máximo, a categoria j com o menor índice é escolhida. Em particular, os neurônios se tornam comprometidos em ordem $j = 1, 2, 3, \dots NA$.

Passo 5. Teste de Vigilância

A ressonância ocorre quando a função

$$| \mathbf{I} \wedge \mathbf{w}_J | / | \mathbf{I} |, \quad (4.6.5)$$

referente à categoria escolhida, satisfaz o critério de vigilância:

$$| \mathbf{I} \wedge \mathbf{w}_J | \geq r | \mathbf{I} |. \quad (4.6.6)$$

O treinamento, então, é realizado conforme instruções contidas no Passo 6. Do contrário, diz-se que o critério de vigilância falha, para a categoria escolhida. Neste caso, o valor da função de escolha T_j é posta igual a zero. Isto representa uma total exclusão do neurônio J no processo de competição para o vetor padrão corrente (aquele em que está sendo processado o treinamento associado). Assim, um novo índice J é escolhido usando a relação (4.6.4). O processo de busca continua até que o índice J satisfaça a Equação (4.6.6).

Passo 6. Adaptação de Pesos

Finalizado o processo de busca, o vetor de pesos $\mathbf{w}_J$ é adaptado de acordo com a seguinte equação: ([10], [11]):

$$\mathbf{w}_J^{novo} = b (\mathbf{I} \wedge \mathbf{w}_J^{velho}) + (1 - b) \mathbf{w}_J^{velho} \quad (4.6.7)$$

Deve-se observar que o treinamento rápido corresponde à adoção $b = 1$. Com $b < 1$ tem-se treinamento lento. Os vetores padrões devem ser apresentados à rede neural ART por ordem aleatória ([8]).

4.7. REDE NEURAL ARTMAP NEBULOSA

A seguir serão introduzidos os conceitos da rede neural ARTMAP. A rede neural ARTMAP constitui-se numa rede supervisionada, ou seja, o treinamento é realizado baseado em estímulos de entrada e de saída, sendo formada por duas sub-redes neurais ART: ARTa e ARTb interligadas por um módulo inter-ART que executa a função de estabelecer o “casamento” entre a entrada e a saída da rede neural. A rede neural ARTMAP nebulosa possui uma arquitetura robusta tal como a rede ART com características de estabilidade e plasticidade. Ela é capaz de manusear vetores de entradas binárias e analógicas, os quais podem representar conjuntos de características nebulosas ou *crisp* (não-nebulosas). É uma arquitetura de rede neural capaz de aumentar o desempenho do treinamento supervisionado de reconhecimento de categorias e mapeamentos multi-dimensionais em resposta aos padrões de entrada binários, analógicos ou nebulosos em seqüências aleatórias. Também realiza um novo aprendizado minimizando o erro predito e maximizando a generalização. Isto é obtido pelo processo *match tracking* que aumenta o parâmetro de vigilância por uma quantidade mínima necessária para corrigir o erro predito. As redes ARTa e ARTb possuem a mesma estrutura da rede ART nebulosa, exceto que em ARTa existe uma vigilância básica usada para controlar o sistema.

4.8. CONCEPÇÃO BÁSICA DA ARTMAP NEBULOSA

As matrizes pesos associadas aos módulos ARTa (w^a) e ARTb (w^b), assim como com relação ao módulo Inter-ART (w^{ab}), são iniciadas com valores iguais a 1, ou seja, todas as atividades encontram-se inativas. Estas atividades são ativadas à medida que ocorre ressonância entre os padrões de entrada e de saída.

Durante o treinamento supervisionado, a ARTa recebe um padrão de entrada a e ARTb recebe um padrão b , sendo que b é a predição correta de a . Quando uma predição em ARTa não é confirmada por ARTb, a memória associativa inibe o inter-ART, ativando o processo do *match tracking*. Este processo aumenta a vigilância em ARTa por uma quantidade mínima necessária para que o sistema ative outra categoria em ARTa que iguale a categoria em ARTb, ou para treinar uma nova categoria em ARTa. O mecanismo

de controle interno do ARTMAP cria reconhecimento de categorias estáveis de medida ótima por maximização da generalização preditiva em operações em tempo real. A rede neural ARTMAP (Figura 11) executa treinamento supervisionado como o retropropagação (*backpropagation*) ([62]). Diferentemente do algoritmo retropropagação, a rede ARTMAP nebulosa é auto-organizável, auto-estabilizável e apropriada para treinamento em tempo real ([10], [11]).




Figura 11. Rede neural ARTMAP nebulosa.

Toda vez que os pares de entrada (a , b), associados aos módulos ARTa e ARTb, são confirmados (as entradas a e b referem-se às categorias J e K ativas, respectivamente), os pesos w^a , w^b e w^{ab} devem ser adaptados da seguinte forma:

$$w_J^{a\ novo} = b (I \wedge w_J^{a\ velho}) + (1 - b) w_J^{a\ velho} \quad (4.8.1)$$

$$w_K^{b\ novo} = b (I \wedge w_K^{b\ velho}) + (1 - b) w_K^{b\ velho} \quad (4.8.2)$$

$$w_{JK}^{ab\ novo} = 1. \quad (4.8.3)$$

Baseando-se na observação de que o treinamento da rede neural ARTMAP leva a diferentes pesos adaptativos e diferentes categorias de reconhecimento para diferentes ordenações de um dado conjunto treinado, é introduzida a estratégia de votação ([10], [11]). A estratégia de votação usa um sistema ARTMAP que treina várias vezes com diferentes ordenações para o mesmo conjunto treinado. A predição final é dada pela solução mais freqüentemente gerada. Como o conjunto dos elementos que dá predições erradas varia de uma simulação para outra, esta estratégia cancela alguns dos erros.

Então, o funcionamento da rede neural ARTMAP consiste na aplicação, nas entradas dos módulos ARTa e ARTb, das informações referentes, respectivamente, de entrada e de saída. O módulo ARTb funciona de forma rigorosamente idêntica à rede neural ART nebulosa, como apresentado na Seção 4.5. O módulo ARTa também funciona da mesma maneira, porém, a confirmação da categoria (ativação do neurônio j) somente ocorrerá após terem sido satisfeitas as condições do mecanismo *match tracking*. Este mecanismo é formado por procedimento de aceitação ou rejeição do neurônio j inicialmente ativado em F_2 do módulo ARTa. Este mecanismo funciona, em última análise, como o responsável pelo “casamento” do par (a, b) ; diz-se que, neste caso, houve ressonância. É portanto, o realizador de funções: mapeamento $a \rightarrow b = f(a)$, $a \hat{I} \hat{A}^p$ e $b \hat{I} \hat{A}^q$. Quando ocorrer a ressonância entre a e b , tem-se como vencedores os neurônios J (em F_2 de ARTa) e K (em F_2 de ARTb). Para oficializar esta ressonância, deve-se adaptar (registrar este evento) nos pesos associados ao módulo Inter-ART.

Deve-se observar que no módulo ARTb a formação de classes é estabelecida pelo usuário através da arbitragem do parâmetro rb de acordo com a experiência, ou por um outro procedimento que possa ser implementado com esta finalidade. Porém, o parâmetro ra é determinado de forma automática, também realizada pelo mecanismo *match tracking*, ou seja, é estabelecida a máxima verossimilhança do par (a, b) .

Esta rede neural tem sido aplicada em uma série de problemas nas mais variadas áreas do conhecimento humano ([3], [12], [15], [18], [22], [23], [24], [31], [32], [33], [35], [36], [49], [50], [57], [61]) tendo em vista as suas qualidades de produzir soluções rápidas e com precisão satisfatória, além de permitir a incorporação do treinamento continuado, ou seja, produzir melhores diagnósticos com o passar do tempo.

No Capítulo 6 será desenvolvida uma versão da rede neural ART chamada ARTMAP nebulosa modular, cujo propósito é tratar cada contingência de forma separada.

Esta opção visa aumentar a precisão dos resultados pois, basicamente, trabalha-se somente com dados analógicos. Neste caso, busca-se evitar, portanto, a manipulação de dados analógicos e binários de forma simultânea (situação que, freqüentemente, é responsável por produzir imprecisões dos resultados, principalmente, quando se emprega as redes neurais da família ART).

CAPÍTULO 5

ANÁLISE DE ESTABILIDADE TRANSITÓRIA VIA REDES NEURAIS

5.1. INTRODUÇÃO

Neste Capítulo será abordada a formulação do problema da análise de estabilidade transitória de sistemas de energia elétrica com vistas à resolução por redes neurais. Para tanto, deverá ser desenvolvida uma série de resultados visando estabelecer a compatibilidade entre tais dados e a obtenção do máximo benefício que as redes neurais possam oferecer: aprender com a experiência, que uma vez concluída esta etapa de extração do conhecimento, a rede neural poderá, a princípio, realizar a análise em tempo-real. O desenvolvimento será feito com o propósito de empregar, para a análise, uma rede neural baseada na teoria da ressonância adaptativa (arquitetura da família ART nebulosa) ([8], [9], [10], [11], [12], [13], [14], [15], [16]), que foi tratada em capítulos anteriores. Será estabelecido um modelo do sistema referente ao mapeamento entre as variáveis de entrada e de saída. Tais variáveis serão separadas, convenientemente, entre dados analógicos e dados binários. Este procedimento visa, portanto, estabelecer uma melhor compatibilidade das informações e o aumento do desempenho da rede neural (maior rapidez e maior precisão). A saída, correspondente à margem de segurança, será formulada em uma versão binária, ou seja, subdivida em classes (categorias), baseada no uso do critério do esforço de deslocamento da margem de segurança ([39], [42]).

5.2. REPRESENTAÇÃO DO MODELO DO SISTEMA

As informações necessárias para resolver um grande número de problemas em sistemas de energia elétrica, em especial, para a análise da estabilidade transitória, podem ser agrupadas do seguinte modo ([41]):

- (1) *Variáveis causais;*
- (2) *Variáveis Conseqüentes; e*
- (3) *Parâmetros.*

Com esta divisão, é possível expressar o seguinte modelo para resolver tais problemas:

$$\mathbf{y} = \mathbf{f}(\mathbf{a}, \mathbf{V}, P) \quad (5.2.1)$$

sendo:

$\mathbf{y}$ = conjunto de variáveis de saída;

$\mathbf{f}$ = função não-linear desconhecida;

$\mathbf{a}$ = conjunto de variáveis causais;

$\mathbf{V}$ = conjunto de variáveis conseqüentes;

P = conjunto de parâmetros.

As variáveis causais $\mathbf{a}$ – consideradas, nesta pesquisa, para a análise de estabilidade transitória – correspondem às potências ativa e reativa nodais do sistema. As variáveis conseqüentes $\mathbf{V}$, dependendo do problema a ser tratado, podem ser agrupadas de várias formas. Por exemplo, no caso da análise de estabilidade transitória de primeira oscilação, o conjunto $\mathbf{V}$ pode ser definido como sendo composto pelos ângulos e tensões nodais, os quais são a solução de um problema de fluxo de potência, processado considerando-se as condições pré e pós-falta. Fazem parte de $\mathbf{V}$, também, as potências elétricas entre máquinas síncronas, velocidades, etc., obtidas a partir da resolução de um conjunto de equações diferenciais e ordinárias não-lineares. Enfim, são todas as grandezas que são envolvidas no processo de cálculo.

Contudo, as redes neurais produzem soluções baseadas num processo de treinamento, no qual é realizada a extração do conhecimento (pretende-se, por conseguinte, modelar a função desconhecida $\mathbf{f}$), através de estímulos convenientemente aplicados na entrada e na saída da rede neural. Assim, pode-se estabelecer um modelo alternativo à equação (5.2.1) em que as variáveis conseqüentes e os parâmetros passam a ser considerados como um conjunto implícito de informações, não necessitando ser fornecido à rede neural, bastando apenas dispor das variáveis causais e demais informações representadas por código (*e.g.*, código binário), ou seja ([41]):

$$\mathbf{y} = \mathbf{f}(\mathbf{a}, L) \quad (5.2.2)$$

sendo:

L = conjunto de informações codificadas (código binário).

Observa-se que o número de variáveis de entrada da rede neural, usando-se o modelo definido pela equação (5.2.2), é bastante reduzido, se comparado ao uso da forma convencional (equação (5.2.1)), que é a alternativa adotada pela maioria das referências ([45], [46], [54]).

Deste modo, as variáveis do sistema são divididas da seguinte forma:

- (1) variáveis analógicas de entrada $\mathbf{a}$ (vetor);
- (2) variáveis binárias de entrada L (vetor);
- (3) variável de saída y (vetor).

As variáveis de entrada $\mathbf{a}$ são representadas pelos valores de potências ativa e reativa nodais, enquanto que L corresponde ao dados referentes às contingências. Por exemplo, tem-se uma contingência de número 5 que corresponde a uma falta de curto-circuito na barra 10 com saída de linha de transmissão entre as barras 10 e 25, a representação binária de L em 4 bits (por exemplo) corresponde [0 0 1 1]. As demais contingências seguem este mesmo procedimento. A saída y será representada tomando-se como base as margens de segurança. Deve-se ressaltar que, através da aplicação de estímulos de entrada e saída da rede neural, o modelo (5.2.2) será estabelecido, ou seja, será determinada a função não-linear f desconhecida. Neste caso, estará concluído o treinamento da rede neural. Se realizada com sucesso, a rede neural estará apta a generalizar (realização das análises).

Assim sendo, nesta Seção serão estabelecidas as entradas e saídas da rede neural, de acordo com o modelo definido pela equação (5.2.2). Estas informações são fornecidas por um programa computacional de análise de estabilidade transitória (Simul), utilizado por [39], [43], que, a partir dos dados da rede elétrica, considerando-se uma lista de contingências (curto-circuito trifásico com saída de linha de transmissão), provêm os valores das margens de segurança associadas. O programa Simul é uma implementação computacional baseada na integração numérica das equações diferenciais (3.2.1) e no método PEBS ([4], [21]), versão para microcomputador. Na seqüência, procedem-se a escolha e o pré-processamento das informações que serão usadas no treinamento da rede neural, compondo os estímulos de

entrada/saída. A entrada é constituída por dados analógicos (potências ativa e reativa nodais) e a saída é formada pelos intervalos da margem de segurança (*IMS*'s) representados por código binário.

Na Figura 12 é mostrado um sistema neural visando a realização do mapeamento não-linear $y = f(a, L)$.




Figura 12. Rede neural para mapeamento de $y = f(a, L)$, como estabelecido na equação (5.2.2).

5.3. ESTÍMULOS DE ENTRADA

A estrutura neural proposta visa a análise de estabilidade transitória de SEE, que corresponde à determinação da margem de segurança, considerando-se faltas de curto-circuito trifásico com saída de linha de transmissão. Os vetores padrões de entrada da rede neural são definidos como:

$$a = [P \ Q] \quad (5.3.1)$$

sendo:

a = vetor padrão de entrada da rede neural;

$$\mathbf{P} = [P_1 \ P_2 \ \dots \ P_n];$$

$$\mathbf{Q} = [Q_1 \ Q_2 \ \dots \ Q_n];$$

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.

Deve-se ressaltar que os elementos das grandezas vetoriais estão dispostos por linha e não por coluna. Esta convenção é adotada com o propósito de facilitar o tratamento da informação com as redes neurais de ascendência ART.

O vetor L estará implicitamente representado, através da adoção de uma rede neural modular, em que cada módulo deverá executar as rotinas associadas a cada contingência, assunto este que será tratado no Capítulo 6.

5.4. ESTÍMULOS DE SAÍDA

Os estímulos de entrada a serem aplicadas no módulo ARTb da rede neural ARTMAP são as margens de segurança correspondentes aos vetores padrões de entrada do módulo ARTa, os quais são as saídas binárias referentes ao módulo ART (formação de categorias). A estratégia usada, neste trabalho, é empregar os intervalos das margens de segurança onde as contingências se encontram. Por exemplo, uma determinada contingência, tendo como margem de segurança igual a 0,5, pode ser arbitrada como pertencente ao intervalo (0,4 a 0,6). Isto permite que as margens de segurança possam ser expressas em código binário reduzindo, assim, o número de classes no módulo ARTb, que é a forma mais adequada para trabalhar com a rede neural ARTMAP, executando o treinamento mais rápido e a análise mais confiável (existe sempre a garantia de obtenção de soluções). Deve-se destacar que este procedimento, desde que observados os devidos cuidados, é pertinente, pois para os centros de controle não há grande necessidade de dispor de números com grande precisão, e sim, a informação de quanto estável ou instável é o sistema frente à ocorrência de determinada contingência. Tais intervalos serão estabelecidos baseados no uso do conceito de EDMS (Esforço de Deslocamento da Margem de Segurança) ([39], [42]) (Definição 5).

Definição 5. Esforço de Deslocamento da Margem de Segurança ([42]) é definido como sendo uma função que relaciona a margem de segurança inicial e final, da seguinte forma:

$$J = (1 - M^A) / (1 - M^B) - 1 \quad (5.4.1)$$

sendo:

J = esforço de deslocamento da margem de segurança;

M^A = valor inferior da margem de segurança do intervalo considerado;

M^B = valor superior da margem de segurança do intervalo considerado.

Nota-se que J é definido no intervalo $[0, +\infty)$ e possui crescimento significativo à medida que M^B se aproxima de 1.

Conforme argumentado na referência [38], o conceito de EDMS foi empregado nas referências [39] e [43] com o propósito de resolver o problema de controle de segurança que corresponde à determinação de um perfil de geração que atenda a carga do sistema, de forma segura, do ponto de vista da estabilidade transitória. A correção a ser efetuada no sistema, a partir de um estado inseguro ($M < 0$), é determinada através de vários passos até atingir um resultado desejado ($M \geq M_{min}$, sendo M_{min} a margem de segurança mínima preestabelecida). Estes passos são idealizados via sucessivas linearizações do modelo de um sistema não-linear bastante complexo (conjunto de equações algébricas e diferenciais não-lineares). Atribuindo-se um valor fixo para J , os intervalos de linearizações podem ser inferidos, ou seja, o erro em cada segmento se mantém na mesma ordem de grandeza. Portanto, o EDMS serve como um parâmetro para estabelecer a validade das linearizações e, conseqüentemente, estimar a região no espaço de estado em que se pode resolver o referido problema, através de um modelo linear, sem que haja comprometimento da precisão dos resultados ([43]). O esforço da margem de segurança pode ser atribuído, com segurança, até o valor igual a 1,5 ([43]), *i.e.*, o erro a ser observado, via de regra, é relativamente pequeno.

Com esta representação, por exemplo, com 4 *bits* pode-se usar até 15 classes de saída, independentemente do número de contingências. Esta alternativa de solução é bastante vantajosa para o treinamento da rede e, principalmente, para a atividade do treinamento continuado, pois facilmente poderão ser inseridas novas informações com o objetivo de tornar a extração do conhecimento mais efetiva ([37], [38]). Ainda que as magnitudes dos intervalos

sejam diferentes entre si, ou seja, tornam-se menores à medida que há aproximação da margem de segurança unitária, as “distâncias”, em termos de energia, são equivalentes. Para exemplificar, considerando-se $J = 0,35$ a quantidade de potência redespachada no sistema que produz uma alteração na margem de segurança de -3 para $-1,9630$, resultaria em uma alteração da margem de segurança de $0,6374$ para $0,7314$. Pode-se estender esta observação, também, aos demais intervalos. Estes resultados têm sido observados nas simulações apresentadas nas referências [39] e [43]. Deve-se observar que nesta pesquisa não se aplica o redespacho de geração ou qualquer outra ação corretiva. O exemplo abordado é apenas ilustrativo, e serve unicamente para evidenciar a coerência de seu uso para a determinação dos referidos intervalos. Este procedimento, aqui adotado, é empírico, porém, tem proporcionado resultados com precisão satisfatória (erro inferior a 5%) ([37], [38]).

Assim, a partir da equação (5.4.1), pode-se estabelecer a seguinte equação de recorrência (equação de diferença):

$$M(k+1) = g M(k) + h \quad (5.4.2)$$

sendo:

$$g \triangleq 1 / (1 + J_{esp})$$

$$h = 1 - g$$

J_{esp} = valor de J especificado de acordo com o critério estabelecido.

A equação (5.4.2) é obtida a partir de (5.4.1) via substituição de M^A e M^B por $M(k)$ e $M(k+1)$, respectivamente. Fazendo-se a variação do tempo discreto k entre 0 e ∞ , obtém-se uma curva discreta compreendida entre o valor inicial da margem de segurança $M(0)$ (valor de partida) e a margem de segurança final $M(\infty) = 1$.

Desta forma, o intervalo, em função do conceito da margem de segurança, pode ser definido como:

$$IMS(k) \triangleq (M_{inferior}(k), M_{superior}(k)) \quad (5.4.3)$$

para $k = 1, 2, 3, \dots, NI$

sendo:

$IMS(k)$ = k -ésimo intervalo da margem de segurança;

NI = número de intervalos das IMS 's.

Os valores de $M_{inferior}(k)$ e $M_{superior}(k)$ correspondem a dois pontos subseqüentes da curva definida pela equação (5.4.2), ou seja, $M(k)$ e $M(k+1)$, respectivamente. A solução da equação (5.4.2) pode ser obtida, através de processo de identificação de coeficientes, usando-se uma função exponencial da forma ([6]):

$$M(k+1) = 1 - n \exp(-f k) \quad (5.4.4)$$

$$k = 1, 2, \dots, \infty$$

sendo que n e f são dois parâmetros a serem identificados. Supondo-se que se deseja identificar a curva definida pela equação (5.4.4), as equações que definem $M_{superior}(k)$ e $M_{inferior}(k)$ podem ser expressas, respectivamente, por:

$$M_{superior}(k) = 1 - n_s \exp(-f k) \quad (5.4.5)$$

$$M_{inferior}(k+1) = 1 - n_i \exp(-f k). \quad (5.4.6)$$

$$\triangleq M_{superior}(k)$$

ou $M_{inferior}(k) = M_{superior}(k-1)$

A partir das equações (5.4.2) e (5.4.4), pode-se, então determinar os parâmetros n_s e f do seguinte modo:

$$M(1) = g M(0) + h = 1 - n_s \exp(0)$$

$$M(2) = g M(1) + h = 1 - n_s \exp(f)$$

donde obtém-se:

$$\begin{aligned} n_s &= 1 - g M(0) - h \\ n_s &= \{1 - M(0)\} / (1 + J_{esp}) \end{aligned} \quad (5.4.7)$$

$$f = -\ln(1 + J_{esp}) \quad (5.4.8)$$

sendo:

$\ln$ = logaritmo neperiano.

O parâmetro n_i pode ser determinado a partir da seguinte relação:

$$M_{inferior}(2) = 1 - n_i \exp(f) = g M(0) + h$$

obtendo-se finalmente:

$$n_i = n_s (1 + J_{esp}) \quad (5.4.9)$$

A curva relativa aos pontos centrais dos intervalos IMS 's é regida pela seguinte equação:

$$M_m(k) = 1 - n_m \exp(f k) \quad (5.4.10)$$

sendo:

$$n_m = \frac{1}{2} n_s \{2 + J_{esp}\} \quad (5.4.11)$$

A equação de $M_m(k)$ (5.4.10) serve para estimar um valor médio da margem de segurança correspondente a $IMS(k)$ prevista pela rede neural na fase de análise.

O número de intervalos NI determina o número de *bits* necessários para a representação dos valores da saída da rede neural. Por exemplo, se desejarmos NI entre 8 e 15, serão necessários 4 *bits*.

Atribui-se $-\infty$ a $M_{inferior}(1)$, apenas para constar, visto que em situações práticas são raras as condições operativas do sistema que representem margem de segurança inferior a -10 . Contingências com margens de segurança inferiores a -3 e superiores a $0,9$ podem ser consideradas *muito instáveis* e *muito estáveis*, respectivamente ([42]). Na Figura 13 ilustra-se a distribuição dos intervalos da margem de segurança. Deve-se observar que o conjunto central composto por $(NI-2)$ IMS 's corresponde à situação mais plausível de ocorrência. $IMS(1)$ e $IMS(NI)$ indicam contingências muito instáveis e muito estáveis, respectivamente.




Figura 13. Representação das IMS 's no intervalo $(-\infty, 1]$.

A relação entre o número do intervalo k da margem de segurança IMS e o parâmetro J (esforço de deslocamento da margem de segurança) pode ser obtida como mostrado a seguir. Tomando-se dois valores discretos de $M_{superior}(k)$ dado pela equação (5.4.5):

$$M_{superior}(1) = 1 - n_s \exp(f) = M(0) \quad (5.4.12)$$

$$M_{superior}(k) = 1 - n_s \exp(f \cdot k) \quad (5.4.13)$$

A partir destas equações, obtém-se:

$$n_s \exp(f) = (1 - M(0)) \quad (5.4.14)$$

$$n_s \exp(f \cdot k) = (1 - M_{superior}(k)) \quad (5.4.15)$$

Dividindo-se (5.4.15) por (5.4.14), resulta em:

$$\exp\{f \cdot (k - 1)\} = (1 - M_{superior}(k)) / (1 - M(0)) \quad (5.4.16)$$

como $f = -\ln(1 + J)$, então, obtém-se:

$$\ln(1 + J) \cdot (k - 1) = -\ln\{(1 - M_{superior}(k)) / (1 - M(0))\}$$

ou:

$$J = \{G(k)\}^{y(k)} - 1 \quad (5.4.17)$$

sendo:

$$G(k) \triangleq \{(1 - M_{superior}(k)) / \{1 - M(0)\}\} \quad (5.4.18)$$

$$y(k) \triangleq -1 / (k - 1). \quad (5.4.19)$$

Se desejarmos determinar o parâmetro J , considerando k correspondente ao penúltimo IMS , ou seja, $k = NI - 1$, basta substituir este valor na equação (5.4.17) e nas equações (5.4.18) e (5.4.19) que definem os parâmetros associados:

$$Jesp = \{G(NI - 1)\}^{y(NI-1)} - 1 \quad (5.4.20)$$

sendo:

$$G(NI - 1) \triangleq \{(1 - M_{superior}(NI - 1)) / \{1 - M(0)\} \quad (5.4.21)$$

$$y(NI - 1) \triangleq -1 / (NI - 2) \quad (5.4.22)$$

para $k = 1, 2, 3, \dots, NI$.

Deve-se observar que a relação entre número de intervalos NI e número de *bits* pode ser expresso por:

$$NI = 2^{(nbits)} - 1 \quad (5.4.23)$$

sendo:

$nbits$ = número de *bits* usado na representação da variável de saída (*IMS*).

Como será mostrado no Capítulo 6, os intervalos *IMS*'s guardam grande correlação com o parâmetro de vigilância (r) das redes neurais da arquitetura ART. Esta propriedade, portanto, caracteriza-se como um resultado bastante importante no trato com redes neurais ARTMAP, principalmente ao se adotar a representação binária da saída como forma de representar uma grandeza analógica. O controle sobre a qualidade das soluções é estabelecido pelo parâmetro *Jesp*, estando-se, também, exercendo o controle implícito do parâmetro de vigilância r , ou seja, as classes formar-se-ão com maior qualidade. Deve-se observar que uma representação com 6 *bits* (até 63 intervalos), tomando-se o primeiro intervalo definido por $(-\infty, -10]$, a “curva” *IMS* entre -10 e 1 (ou na proximidade de 1) apresenta um comportamento que se aproxima muito de uma curva analógica:

$$IMS(k) \cong M_{superior}(k) \cong M_{inferior}(k) \cong M_m(k). \quad (5.4.24)$$

Considerando-se os resultados aqui explicitados, deve-se, portanto, priorizar a atenção para valores de M compreendidos entre -3 e $0,9$. Uma boa alternativa prática é a adoção de 15 intervalos ($NI = 15$), ou seja, a saída é representada por 4 *bits*. Considerando-se $M(0) = -3$, $M_{superior}(14) = 0,9191$ e usando-se as equações (5.4.15) a (5.4.17), obtém-se $Jesp = 0,35$. Esta representação é ilustrada na Figura 14.




Figura 14. Gráfico de IMS e de M considerando a margem de segurança $\in (-\infty, 1]$, $J_{esp} = 0,35$ e $M(0) = -3$.

A escolha de $J = 0,35$, contudo, é bastante conveniente, tendo em vista que forma um grupo de intervalos que cobre todo o espectro de variação da margem de segurança mais importante e com um número razoável de segmentação. Deve-se destacar, ainda, que este número pode ser arbitrado livremente, sem necessidade de efetuar alterações substanciais na rede neural. O que muda é apenas o número de *bits* na representação binária da contingência. Para uma maior precisão da margem de segurança, maior deverá ser o número de intervalos. Como ilustração, considerando-se 4, 5, 6 e 7 *bits* pode-se trabalhar com 15, 31, 63 e 127 intervalos, respectivamente. Nas Figuras 15 e 16 mostram-se o comportamento da margem de segurança (M) para representações com 4 e 7 *bits*, respectivamente. Estas duas curvas são determinadas usando os valores de J_{esp} (calculados usando as Equações (5.4.20) a (5.4.23)) iguais a 0,4452 e 0,039, respectivamente. Os IMS 's nestas curvas correspondem aos intervalos entre dois valores subseqüentes de M .




Figura 15. Gráfico de IMS e de M considerando-se a representação de 4 bits e $M(0) = -5$.




Figura 16. Gráfico de IMS e de M considerando-se a representação de 7 bits e $M(0) = -5$.

5.5. PERFIS DE GERAÇÃO E DE CARGA

Para a realização do treinamento – extração do conhecimento baseado em estímulos de entrada e de saída – deve-se proceder a apresentação de um conjunto de dados, no nosso caso, $e = [a \ L]$ (entrada) e I (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 ([52]).

Suponha que um sistema com uma determinada topologia contendo NB barras, sendo que são NG barras de geração e as demais são barras de carga ($NL = NB - NG$). Suponha, 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 e de 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. Com este procedimento, pode gerar perfis de geração e de carga entre, por exemplo, 75% e 130% do caso base.

As potências ativa e reativa das barras de geração podem ser definidas como em ([64]):

$$PG_i = PG_i^0 + PG_{total}^0 \times PER \times AG_i / KG \quad (5.5.1)$$

$$QG_i = QG_i^0 + PG_{total}^0 \times PER \times AG_i / KG \quad (5.5.2)$$

$$i \in W(G)$$

sendo:

PG_i = potência ativa no i -ésimo gerador fixada pseudo aleatoriamente;

QG_i = potência reativa no i -ésimo gerador fixada pseudo aleatoriamente;

$$PG_{total}^0 = \sum_{i \in W(G)} PG_i^0$$

$$QG_{total}^0 = \sum_{i \in W(G)} QG_i^0$$

$W(G)$ = 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 seqüência de NG , números gerados a partir de uma semente dada. Variando-se a semente, ter-se-á uma seqüência diferente de valores, cujo espectro de variação está compreendido entre 0 e 1: $AG_i \in [0,1]$.

$$KG = 100 AG_{total}$$

$$AG_{total} = \sum_{i \in W(G)} AG_i.$$

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

$$PL_i = PL_i^0 + PL_{total}^0 \times PER \times AL_i / KL \quad (5.5.3)$$

$$QL_i = QL_i^0 + PL_{total}^0 \times PER \times AL_i / KL \quad (5.5.4)$$

sendo:

PL_i = potência ativa na i -ésima carga fixada aleatoriamente;

QL_i = potência reativa na i -ésima carga fixada aleatoriamente;

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

$$QL_{total}^0 = \sum_{i \in W(L)} QL_i^0$$

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

$$KL = 100 AL_{total}$$

$$AL_{total} = \sum_{i \in W(L)} AL_i.$$

$W(L)$ = conjunto de barras de cargas.

Deve-se notar que o perfil de geração definido pelas equações (5.5.1) e (5.5.2) busca atender a demanda total do sistema (definida pelas equações (5.5.3) e (5.5.4)), evidentemente, desconsiderando-se o acréscimo de perda associada ao sistema que será absorvido pela máquina de referência.

CAPÍTULO 6

REDE NEURAL ARTMAP NEBULOSA MODULAR

6.1. INTRODUÇÃO

Apresenta-se neste Capítulo uma rede neural ARTMAP nebulosa modular. Esta rede é constituída por vários módulos ARTMAP, sendo que cada módulo é responsável pela realização de somente uma contingência. Todos os módulos possuem entradas comuns que são os vetores de potências ativa e reativa nodais do sistema. Na saída de cada módulo ARTMAP nebuloso são aplicados os valores correspondentes aos índices associados às contingências (no caso desta pesquisa são usadas as margens de segurança), através da expressão do *IMS* (Intervalo da Margem de Segurança). Esta concepção modular está sendo proposta como forma de evitar falsas análises (que podem ocorrer em consequência do uso concomitante de dados analógicos e binários) e tornar o sistema neural mais rápido, se comparado à rede neural não modular. Será abordada a interpretação dos resultados produzidos pelas redes neurais ART nebulosa, com o propósito de fundamentar o uso dos *IMS's* como instrumento de análise, via redes neurais ARTMAP nebulosas.

6.2. REDE NEURAL MODULAR

O objetivo desta pesquisa é a realização da análise de estabilidade transitória (estabilidade de primeira oscilação), através de uma rede neural ARTMAP nebulosa. Então, o modelo do sistema pode ser expresso da seguinte forma (desenvolvido no Capítulo 5):

$$y = f(a, L) \quad (6.2.1)$$

sendo:

$\mathbf{a}$ = conjunto de variáveis de entrada;
 $\mathbf{y}$ = conjunto de variáveis de saída;
 f = função não-linear desconhecida;
 L = conjunto de informações codificadas (código binário).

As variáveis de entrada correspondem aos vetores de potências ativa e reativa nodais:

$$\mathbf{a} = [\mathbf{P} \ \mathbf{Q}] \quad (6.2.2)$$

sendo:

$\mathbf{a}$ = vetor padrão de entrada da rede neural;
 $\mathbf{P} = [P_1 \ P_2 \ \dots \ P_n]$;
 $\mathbf{Q} = [Q_1 \ Q_2 \ \dots \ Q_n]$;
 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.

Esta notação vetorial por linha segue a orientação adotada nas redes da família ART, como abordada anteriormente.

A saída ($\mathbf{y}$) corresponde à margem de segurança associada à k -ésima contingência, é representada por código binário:

$$\mathbf{y}_k = \text{representação binária de } \{IMS(k)\} \quad (6.2.3)$$

sendo:

$IMS(k) \triangleq k$ -ésimo intervalo da margem de segurança.
 $= (M_{inferior}(k), M_{superior}(k)]$

As funções $M_{inferior}(k)$ e $M_{superior}(k)$ são calculadas usando-se as expressões (5.4.5) e (5.4.6):

$$\begin{aligned} M_{superior}(k) &= 1 - n_s \exp(f \cdot k) \\ M_{superior}(1) &= M(0) \\ M_{inferior}(k) &= 1 - n_i \exp(f \cdot k), \\ M_{inferior}(1) &= -\infty \text{ (valor arbitrário)} \\ \text{para } k &= 2, 3, \dots, NI \end{aligned}$$

sendo:

$$\begin{aligned} NI &= \text{número de intervalos;} \\ f &= -\ln(1 + J_{esp}) \\ n_s &= \{1 - M(0)\} / (1 + J_{esp}); \\ n_i &= n_s (1 + J_{esp}); \\ J_{esp} &= \{G(NI - 1)\}^{y(NI-1)} - 1 \\ G(NI - 1) &\triangleq \{(1 - M_{superior}(NI - 1))\} / \{1 - M(0)\}; \\ y(NI - 1) &\triangleq -1 / (NI - 2); \\ \ln &= \text{logaritmo neperiano.} \end{aligned}$$

O tamanho do vetor y_k é dependente do número de intervalos adotados para representar os intervalos IMS 's. Deve-se observar que os intervalos $(NI - 2)$ e $(NI - 1)$ correspondem, respectivamente, ao antepenúltimo e penúltimo intervalos no espectro de variação da margem de segurança, conforme ilustrado na Figura 14. $M(0)$ é a margem de segurança superior do primeiro IMS , ou seja, $M_{superior}(1)$.

Os dados de entrada da rede podem, então, ser estabelecidos considerando os vetores $\mathbf{a}$ (dados analógicos) e L (dados binários representando as informações das contingências). Este procedimento emprega, portanto, dados analógicos binários simultâneos que, eventualmente, poderão contribuir para a má classificação de padrões pela rede neural. Visando evitar tal problema, neste trabalho propõe-se o uso de uma rede neural ARTMAP nebulosa modular. Cada módulo executará a análise para uma única

contingência. Assim, ter-se-ão tantos módulos quantas forem as contingências consideradas, ou seja, tem-se:

$$\begin{aligned} y_k &= f_k(\mathbf{a}) \\ k &= 1, 2, \dots, S \end{aligned} \tag{6.2.4}$$

sendo:

y_k = saída da k -ésima contingência;

$f_k(\mathbf{a})$ = função não-linear desconhecida referente à k -ésima contingência;

S = número de contingências a serem analisadas.

A Figura 17 ilustra a estrutura desta rede neural. Deve-se ressaltar que o treinamento desta rede neural modular é mais rápido, se comparado à realização da Equação (6.2.1). Contudo, há uma maior necessidade de memória para armazenar as matrizes de pesos da rede neural modular composta por S -Redes Neurais Nebulosas ARTMAP ($RNN-ARTMAP$'s). O pré-processamento é empregado nesta rede visando obter uma máxima redução do esforço computacional necessário para realizar o treinamento dos módulos ARTa's, visto que, como mencionado anteriormente, a entrada ($\mathbf{a} = [\mathbf{P} \ \mathbf{Q}]$) destes módulos são comuns para todas as contingências. Então, a maior diversidade de processamento ocorre nos módulos ARTb's. Deve-se observar, porém, que a organização nos módulos de saída é consideravelmente mais simples do que os de entrada, pois a dimensão do vetor de saída será em torno de 4 (4 *bits* que corresponde a 15 classes), chegando, no máximo a 6 (6 *bits* para realizar 63 classes) e, também, porque os intervalos, definidos como propostos nesta pesquisa, possuem um comportamento bastante favorável (seguindo uma função exponencial). A auto-organização dos módulos ARTb é alcançada com extrema velocidade. Daí, então, a razão da maior rapidez desta rede; contudo, como já mencionado, há maior necessidade de armazenamento de pesos, embora não muito porque em cada módulo o número de conexões é bem menor se comparado ao caso em que uma única rede neural ARTMAP é empregada para realizar todas as contingências. Portanto, este acréscimo não é significativo.




Figure 17. Rede neural modular ARTMAP nebulosa.

6.3. INTERPRETAÇÃO DOS RESULTADOS DA REDE NEURAL ART NEBULOSA

A seguir será ilustrada a concepção básica de funcionamento da rede neural ART nebulosa (componentes básicos da rede neural ARTMAP nebulosa modular). Evidencia-se o funcionamento do módulo ARTb da rede neural ARTMAP nebulosa, que é justamente onde são processadas as informações de saída da rede, mais especificamente, dos dados referentes aos intervalos IMS 's. Considera-se, para fins de simplicidade, o vetor de entrada contendo duas dimensões. Neste caso, cada categoria j possui uma interpretação geométrica como sendo um retângulo R_j (Fig. 18), a partir de dois vetores $\mathbf{p}$ e $\mathbf{q}$, cujos vértices estão identificados na Figura 18. Dois vértices deste retângulo correspondem aos vetores $\mathbf{p}$ e $\mathbf{q}$, e os outros dois são obtidos por operações nebulosas sobre $\mathbf{p}$ e $\mathbf{q}$: operadores AND e OR , definidos da seguinte forma, respectivamente ([30, 58]):

$$(\mathbf{p} \wedge \mathbf{q})_i \triangleq \min(p_i, q_i) \text{ (operador nebuloso } AND) \quad (6.3.1)$$

$$(\mathbf{p} \vee \mathbf{q})_i \triangleq \max(p_i, q_i) \text{ (operador nebuloso } OR). \quad (6.3.2)$$




Figura 18. Representação gráfica do retângulo referente à categoria j .

A ressonância depende do grau que o vetor $\mathbf{I}$ é um subconjunto de $\mathbf{w}_j$. Em particular, se a categoria j é um subconjunto nebuloso escolhido (satisfeita a equação (4.6.6)), então, a função *match* é dada por:

$$|\mathbf{I} \wedge \mathbf{w}_j| / |\mathbf{I}| = |\mathbf{w}_j| / |\mathbf{I}| \quad (6.3.3)$$

Assim, a escolha do índice J que maximize $|\mathbf{w}_j|$, entre os subconjuntos nebulosos escolhidos, também maximiza a oportunidade de atendimento da expressão de ressonância:

$$|\mathbf{I} \wedge \mathbf{w}_J| / |\mathbf{I}| \geq r. \quad (6.3.4)$$

Suponha que se tenha um vetor $\mathbf{a} = [a_1 \ a_2]$, sendo que os componentes a_1 e a_2 satisfazem a restrição $a_i \in [0, 1]$, não há necessidade de realizar a normalização. O vetor $\mathbf{I}$ é definido por:

$$\begin{aligned}
\mathbf{I} &= [a_1 \ a_2 \ (1-a_1) \ (1-a_2)]. \\
&= [\mathbf{a} \ \mathbf{a}^c].
\end{aligned}
\tag{6.3.5}$$




Figura 19. Ilustração da conexão de pesos de uma rede neural para entrada bi-dimensional.

A distribuição dos pesos está ilustrada na Figura 19. São destacados o neurônio j e o neurônio J (vencedor). Os vetores pesos, respectivamente, correspondem a $\mathbf{w}_j$ e $\mathbf{w}_J$. Supondo-se ainda, representar o vetor peso $\mathbf{w}_j$ (conexão entre os componentes de entrada e os neurônios de F2), particionado da seguinte forma (representação por codificação complementar):

$$\mathbf{w}_j = [\mathbf{u}_j \ \mathbf{v}_j] \tag{6.3.6}$$

sendo:

$$\mathbf{v}_j = \mathbf{u}_j^c.$$

Os vetores $\mathbf{u}_j$ e $\mathbf{v}_j$ encontram-se ilustrados na Figura 20 (a), sendo $\mathbf{u}_j$ e $\mathbf{v}_j$ vetores bi-dimensionais. Neste caso, cada categoria j possui uma representação geométrica que corresponde ao retângulo $\mathbf{R}j$. Os vetores $\mathbf{u}_j$ e $\mathbf{v}_j$ estão situados em vértices opostos do retângulo $\mathbf{R}j$. O tamanho (magnitude) deste retângulo pode ser expresso por ([10]):

$$|\mathbf{R}j| \triangleq |\mathbf{v}_j - \mathbf{u}_j|$$

$$\begin{aligned}
&= | (v_{1j} - u_{1j}) (v_{2j} - u_{2j}) | \\
&= | (v_{1j} - u_{1j}) | + | (v_{2j} - u_{2j}) | \quad (6.3.7) \\
&\quad \text{base do} \quad \text{altura do} \\
&\quad \text{retângulo} \quad \text{retângulo}
\end{aligned}$$

sendo:

$$\mathbf{v}_j = [v_{1j} \ v_{2j}]$$

$$\mathbf{u}_j = [u_{1j} \ u_{2j}].$$

que é igual a altura mais a largura de $\mathbf{R}_j$.

Considerando-se o caso de treinamento rápido ($b = 1$), os pesos da rede neural ART nebulosa, após ter sido confirmada a escolha do neurônio vencedor (neurônio J), são atualizados da seguinte forma (usando a equação (4.6.7)):


$$\begin{aligned}
\mathbf{w}_J^{novo} &= \mathbf{I} \\
&= [\mathbf{a} \ \mathbf{a}^c]. \quad (6.2.8)
\end{aligned}$$

Os novos vértices de $\mathbf{R}_J$ (designado como $\mathbf{R}_J^{novo}$) (Figura 20 (b)) serão dados por $\mathbf{a}$ e $(\mathbf{a}^c)^c = \mathbf{a}$. Deste modo, $\mathbf{R}_J^{novo}$ é justamente o ponto $\mathbf{a}$. Durante cada execução de treinamento rápido, o retângulo $\mathbf{R}_J$ é expandido para $\mathbf{R}_J \oplus \mathbf{a}$ contendo $\mathbf{R}_J$ e o vetor $\mathbf{a}$. Os vértices opostos de $\mathbf{R}_J \oplus \mathbf{a}$ são dados por $(\mathbf{a} \wedge \mathbf{u}_J)$ e $(\mathbf{a} \vee \mathbf{v}_J)$. A magnitude de $\mathbf{R}_J \oplus \mathbf{a}$ é, então, dada por ([10]):


$$|\mathbf{R}_J \oplus \mathbf{a}| \triangleq |(\mathbf{a} \wedge \mathbf{u}_J) - (\mathbf{a} \vee \mathbf{v}_J)| \quad (6.3.9)$$

O dispositivo *reset* deverá promover uma outra escolha da categoria (busca de um novo neurônio vencedor), se $|\mathbf{R}_J \oplus \mathbf{a}|$ for muito grande. Em resumo, com o treinamento rápido, cada $\mathbf{R}_j$ é igual ao menor retângulo que abriga todos os vetores $\mathbf{a}$ que tiveram como escolha a categoria j , sob a restrição ([10]):

$$|R_J| \leq 2(1-r). \quad (6.3.10)$$



(a)



(b)

Figura 20. Representação dos pesos da rede neural ART.

Para o caso do vetor a (multidimensional), pode-se chegar a resultado semelhante usando esta mesma idéia ([10]):

$$|R_J| \leq (1-r) M \quad (6.3.11)$$

A grandeza R_j , neste caso, é chamada hiper-retângulo contendo os dois vértices $(\wedge_j \mathbf{a})$ e $(\vee_j \mathbf{a})$. Observa-se que o parâmetro r para valores pequenos ($r \cong 0$) e grandes ($r \cong 1$) produzem hiper-retângulos R_j grandes e pequenos, respectivamente. Se $0 \leq r < 1$, o número de categorias é limitado se, evidentemente, o número de exemplares for limitado.

Para ilustrar os resultados com diferentes valores do parâmetro de vigilância, toma-se como exemplo uma coleção de figuras composta por triângulos, quadrados e círculos ([38]). Deseja-se identificar objetos (figuras) semelhantes. Com um ajuste adequado do parâmetro de vigilância r pode-se perfeitamente agrupar triângulos, quadrados e círculos em três classes. Cada classe deverá estar contida em um hiper-retângulo associado. Se atribuirmos um determinado valor para r , os agrupamentos poderão ser formados, por exemplo, em que um deles conterá os círculos e o outro quadrados e triângulos. Se diminuirmos ainda mais o parâmetro r , haverá um único agrupamento contendo todas as figuras que poderiam ser chamadas coletivamente apenas de “figuras geométricas planas”. Neste caso, não há condições de fazer distinções sobre tais objetos. Pode-se, então, concluir que ([38]), à medida que r diminui, haverá um aumento da generalização e um decréscimo da precisão. No sentido inverso, aumentando-se o parâmetro de vigilância, diminuir-se-á a generalização e aumentar-se-á a precisão dos resultados.

Comparando estes resultados com os resultados desenvolvidos no Capítulo 5, percebe-se que os hiper-retângulos mantêm fortes correlações com relação às *IMS's*, ou seja, a auto-organização do módulo ARTb nebuloso está em consonância com o parâmetro de vigilância. Quanto maior (menor) for o parâmetro de vigilância r , menores (maiores) serão os hiper-retângulos. Os intervalos *IMS's*, definidos como propostos nesta pesquisa, já são apresentados à sub-rede neural ARTb de forma organizada. Assim, a auto-organização deste módulo é alcançada com extrema velocidade. A maior parcela do esforço computacional é empregada para realizar o treinamento (auto-organização) do módulo ARTa, envolvendo o ajuste de pesos e funcionamento do mecanismo *match tracking*. Daí, então, a razão da maior rapidez desta rede.

CAPÍTULO 7

APLICAÇÃO

7.1. INTRODUÇÃO

Apresentam-se neste Capítulo os resultados obtidos através do método proposto (rede neural ARTMAP nebulosa modular), para um sistema composto por 10 máquinas síncronas, 45 barras e 72 linhas de transmissão, que corresponde a uma possível configuração do sistema sul-brasileiro. São apresentados, então, os resultados obtidos por redes neurais e comparados com resultados produzidos por simulação (metodologia híbrida: método PEBS iterativo ([21])), que é um referencial em termos de precisão, considerando-se o modelo clássico.

7.2. RESULTADOS

Apresentam-se, a seguir, os resultados obtidos através do método proposto, considerando-se um sistema composto por 10 máquinas síncronas, 45 barras e 72 linhas de transmissão, como mostrado na Figura 21. Nestes estudos consideram-se faltas tipo curto-circuito trifásico com tempo de eliminação (t_{ch}) igual a 9 ciclos (0,15s) com saída de linha de transmissão.

O treinamento da rede é realizado usando-se um conjunto de perfis de geração e de carga e respectivas margens de segurança associadas a um conjunto de contingências. Cada perfil corresponde a um despacho de geração, em relação ao caso base, realizado de forma aleatória para atender a demanda, também estabelecida randomicamente em cada barra do sistema, conforme procedimento proposto na Seção 5.5. O universo de variação da geração e da carga está compreendido entre 75% e 130% em relação ao caso base do sistema. Portanto, cada perfil é gerado considerando uma

variação percentual em torno do estado nominal (caso base) e uma determinada semente para o processo de geração da sequência randômica. Assim, para um mesmo percentual, diferentes sementes geram diferentes despachos de geração e diferentes perfis de carga. Este procedimento gera, a princípio, um conjunto adequado de padrões para a fase de treinamento. A análise comparativa entre os resultados obtidos por redes neurais e por simulação híbrida (de acordo com o método apresentado no Apêndice A) é satisfatória. São considerados diferentes perfis de geração de cargas (obtidos com diferentes percentuais e diferentes sementes), se comparados aos dados usados na fase de treinamento. O conjunto de contingências é mostrado na Tabela 1. São consideradas 15 contingências, escolhidas arbitrariamente, visando ilustrar a metodologia proposta. Entretanto, este número pode ser aumentado, de acordo com as necessidades do usuário, sem nenhum problema quanto a sua formulação. Na Tabela 2 são apresentados os intervalos da margem de segurança (*IMS's*), adotando-se uma representação por 4 *bits*, ou seja, com $J_{esp} = 0,35$ totalizando 15 intervalos.




Figura 21. Diagrama unifilar do sistema elétrico de potência.

O treinamento da rede neural é realizado considerando um conjunto em torno de 3.000 perfis (em média 200 por contingência) de geração e de carga e as margens de segurança associadas para as 15 contingências.

Tabela 1. Conjunto de Contingências.

No. da Falta	Falta		
	Curto-circuito	Saída da Linha de Transmissão	
		Barra Inicial	Barra Final
1	15	14	15
2	18	16	18
3	18	18	44
4	29	29	30
5	39	39	40
6	15	16	16
7	16	16	18
8	17	16	17
9	17	17	18
10	33	33	36
11	44	18	44
12	16	15	16
13	44	41	44
14	35	13	35
15	44	43	44

Tabela 2 Intervalos da margem de segurança.

No. Do Intervalo	Intervalo da Margem de Segurança (<i>IMS</i>)
1	$(-\infty; -3]$
2	$(-3; -1,9630]$
3	$(-1,9630; -1,1948]$
4	$(-1,1948; -0,6258]$
5	$(-0,6258; -0,2043]$
6	$(-0,2043; 0,10790]$
7	$(0,10790; 0,33920]$
8	$(0,33920; 0,51050]$
9	$(0,51050; 0,63740]$
10	$(0,63740; 0,73140]$
11	$(0,73140; 0,80110]$
12	$(0,80110; 0,85260]$
13	$(0,85260; 0,89080]$
14	$(0,89080; 0,91910]$
15	$(0,9191; 1]$

Na Tabela 3 são apresentados os parâmetros usados para a fase de treinamento da rede neural ARTMAP nebulosa modular.

Tabela 3. Especificação dos parâmetros da rede neural.

Item	Valor
Parâmetro de vigilância : ra	0,99
rb	0,97
rab	0,90
Taxa de treinamento : b	1 (treinamento rápido)
Parâmetro de escolha : a	0,1

Após a realização da fase de treinamento, a análise de estabilidade transitória pode ser realizada, cujos resultados são mostrados na Tabela 4. Os resultados da análise, via rede neural (ARTMAP nebulosa modular), são comparados com os resultados obtidos por simulação usando o programa *Simul* (método PEBS iterativo ([21])). Observa-se que os resultados pelo método PEBS iterativo são exatos, considerado o modelo clássico, como observado em [21]. São considerados diferentes perfis de geração e de carga (diferentes percentuais e diferentes sementes). Os percentuais e as sementes usadas são mostrados nas colunas 2 e 3 da Tabela 4, respectivamente. Os intervalos *IMS*'s, indicados pela rede neural ARTMAP nebulosa modular, correspondem ao emprego da *estratégia de votação* ([10]), ou seja, a rede neural é treinada por várias vezes (por exemplo, 5 vezes), com diferentes ordenações (ordenações randômicas ou pseudo-randômicas) para o mesmo conjunto de dados do treinamento. A predição final é dada pela maior frequência das soluções geradas. Pode-se observar que os resultados produzidos pelas duas metodologias são bastantes próximos.

Tabela 4. Resultados da análise de estabilidade transitória obtidos por simulação (resultados de referência) e por redes neurais ARTMAP nebulosa modular.

Número da Falta	Perfil de Geração / Carga		Intervalo da Margem da Segurança (<i>IMS</i>)	
	% do caso base	Semente	Correto	Rede Neural
1	75	123	15	15
2	75	289	7	7
3	75	73	9	9
4	75	190	15	15
5	75	391	13	13
1	80	381	15	14
2	80	73	9	9
3	80	1	12	12
4	80	355	15	15
5	80	999	12	12
1	85	24	12	12

Tabela 4. (Continuação 1).

Número da Falta	Perfil de Geração / Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Correto	Rede Neural
2	85	257	8	7
3	85	191	9	8
4	85	309	15	15
5	85	60	8	8
1	90	71	12	12
2	90	137	5	5
3	90	19	5	5
4	90	244	15	15
5	90	60	8	8
6	90	458	15	15
7	90	711	12	12
8	90	711	13	12
9	90	597	11	12
10	90	597	12	11
11	90	458	13	13
12	90	273	12	12
13	90	597	13	14
14	90	597	15	15
15	90	458	15	15
1	95	200	12	12
2	95	28	6	5
3	95	163	5	5
4	95	131	14	12
5	95	2	6	6
6	95	749	12	13
7	95	391	12	12
8	95	321	12	12
9	95	497	13	13
10	95	749	11	12

Tabela 4. (Continuação 2).

Número da Falta	Perfil de Geração / Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Correto	Rede Neural
11	95	123	14	14
12	95	123	14	14
13	95	321	14	14
14	95	321	15	15
15	95	458	15	15
1	100	–	12	12
2	100	–	5	5
3	100	–	5	5
4	100	–	15	15
5	100	–	7	6
6	100	–	12	12
7	100	–	12	12
8	100	–	12	12
9	100	–	12	13
10	100	–	12	12
11	100	–	13	14
12	100	–	13	14
13	100	–	14	14
14	100	–	12	12
15	100	–	15	14
1	105	100	11	11
2	105	389	4	4
3	105	275	5	5
4	105	380	15	15
5	105	77	7	7
6	105	109	12	12
7	105	613	11	11
8	105	931	11	12
9	105	371	12	13

Tabela 4. (Continuação 3).

Número da Falta	Perfil de Geração / Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Correto	Rede Neural
10	105	61	11	12
11	105	613	12	11
12	105	371	13	13
13	105	371	14	14
14	105	613	8	8
15	105	371	15	14
1	110	121	11	11
2	110	320	4	4
3	110	11	5	5
4	110	220	14	14
5	110	55	7	7
6	110	206	9	9
7	110	365	11	12
8	110	180	12	12
9	110	439	9	10
10	110	51	11	12
11	110	365	11	11
12	110	365	12	13
13	110	180	14	14
14	110	365	6	6
15	110	439	15	14
6	130	403	5	5
6	125	30	6	5
6	115	412	6	5
6	110	206	9	9
6	90	458	15	15
7	130	403	9	8
7	125	30	9	8
7	120	611	8	8

Tabela 4. (Continuação 4).

Número da Falta	Perfil de Geração / Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Correto	Rede Neural
7	115	350	8	8
7	110	519	11	11
8	130	121	8	9
8	127,5	288	13	13
8	122,5	240	12	11
8	117,5	163	13	13
8	112,5	360	12	12
9	130	3	6	7
9	127,5	288	12	12
9	122,5	240	11	11
9	117,5	805	12	12
9	112,5	71	10	10
10	130	832	10	11
10	127,5	77	9	9
10	122,5	425	10	11
10	117,5	819	9	9
10	112,5	71	9	9
11	130	220	11	12
11	127,5	190	11	8
11	122,5	867	9	8
11	117,5	515	10	10
11	112,5	500	11	11
12	130	121	9	9
12	127,5	288	10	9
12	122,5	333	11	11
12	117,5	515	10	9
12	112,5	360	12	13
13	130	121	9	8
13	127,5	77	13	13

Tabela 4. (Continuação 5).

Número da Falta	Perfil de Geração / Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Correto	Rede Neural
13	122,5	380	12	13
13	117,5	131	12	13
13	112,5	500	13	13
14	130	3	1	1
14	127,5	349	1	1
14	122,5	240	1	1
14	117,5	163	1	1
14	112,5	383	6	6
15	130	365	15	14
15	127,5	77	15	13
15	122,5	603	15	13
15	117,5	251	15	14
15	112,5	385	15	14

Considerando-se os resultados apresentados anteriormente, pode-se observar os seguintes pontos:

- (1) A carga total do sistema correspondente ao caso base (100% do carregamento do sistema) é de 6.655 MW. Assim, a geração e a carga correspondem a um espectro de variação de 5.324 MW a 8.651,5 MW;
- (2) Deve-se ressaltar que a fase de análise é realizada com extrema rapidez (inferior a 0,1s). Há, portanto, compatibilidade para aplicações em tempo real. A fase de treinamento (atividade realizada *off-line*) consome grande parte do tempo de processamento. Porém, este tempo é muitíssimo inferior (cerca 1%), se comparado com as demais redes neurais disponíveis na literatura especializada;
- (3) O treinamento da rede neural foi realizado para as 15 contingências, tomando-se aproximadamente 3.000 pares de vetores padrões (entrada / saída), em torno de 1 minuto (4 s por contingência) usando um microcomputador Pentium III de 500MHz.

Não está sendo incluído o tempo destinado para a leitura e impressão das informações. Ressalta-se que o pré-processamento dos dados, para o treinamento da rede neural, é realizado por um módulo agregado ao programa *Simul*. Portanto, o tempo de execução do programa *Simul* e do pré-processamento não estão sendo considerados;

- (4) O tempo de processamento para cada análise é da ordem de centésimos de segundo;
- (5) Na Tabela 4 constam 138 análises de estabilidade transitórias, considerando-se as mesmas contingências usadas na fase de treinamento, porém, com geração e cargas diferentes, cuja distribuição é realizada de modo pseudoaleatório, buscando-se, assim, simular possíveis casos reais da operação. Se o treinamento estiver adequadamente realizado, a análise de casos reais, a princípio, deverá ser confiável;
- (6) Os resultados obtidos podem ser considerados satisfatórios. Contudo, foram observadas algumas imprecisões. Tais imprecisões não são suficientes para invalidar as análises. O erro, na maioria das vezes, é pessimista, ou seja, é encontrada um *IMS* inferior ao intervalo real. Isto ocorre, muito provável, em consequência do critério de escolha do algoritmo nebuloso (função *T* do Passo 4 da Seção 4.6)): quando houver empate na escolha do neurônio vencedor, a opção é feita tomando-se o neurônio de menor índice.

CAPÍTULO 8

CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS

8.1. CONCLUSÃO

Foi desenvolvido, neste trabalho, um procedimento de análise de estabilidade transitória de sistemas de energia elétrica multimáquinas, através de uma rede neural ARTMAP nebulosa modulares. Com esta arquitetura pode-se desenvolver um procedimento de análise de estabilidade transitória de sistemas elétricos de potência. Os estímulos de entrada da rede neural são constituídos pelos vetores de potências ativa e reativa nodais (dados analógicos) e pelos dados das contingências (dados binários). As saídas correspondem às margens de segurança do sistema, representadas por intervalos compreendidos entre os valores mínimo e máximo. Deste modo, foi possível representar as saídas em código binário (saídas binárias), que é uma representação que, via de regra, oferece melhores condições de produzir resultados mais precisos, pois trabalha-se com números menos sensíveis a ruídos. Como ilustração da metodologia foram apresentados os resultados da análise de estabilidade transitória, via rede neural ARTMAP nebulosa modular ([52]), considerando-se um sistema elétrico de potência correspondente a um sistema (uma versão do sistema sul-brasileiro) composto por 45 barras, 72 linhas de transmissão/transformadores e 10 máquinas síncronas. O treinamento foi realizado considerando-se 15 contingências do tipo curto-circuito trifásico sólido com saída de linha de transmissão. As contingências foram arbitradas como incidentes em vários pontos da rede elétrica (15 localizações). Foram considerados níveis de carregamentos arbitrados de forma aleatória dentro de um universo compreendido entre 75% e 130% da carga total do sistema. Os resultados obtidos podem ser considerados satisfatórios, ou seja, atingiram os objetivos propostos. Estes objetivos foram: investigar a aplicação de redes neurais para execução de diagnósticos da estabilidade transitória de sistemas elétricos de potência. A rede neural ARTMAP tem proporcionado a obtenção de soluções bastantes rápidas (cerca de centésimos de segundo), utilizando um microcomputador Pentium III de 500 MHz. A qualidade das soluções foram adequadas. Contudo, foram observadas algumas imprecisões. Estas imprecisões são geradas em parte pela própria concepção das redes neurais da

família ART, que necessitam ser continuamente melhoradas, e pelo uso de um conjunto de treinamento não suficientemente completo. A precisão dos resultados é dependente do volume de dados usado no treinamento e, também, do número de segmentos de saída (intervalos *IMS*). Um maior número de segmentos pode ser obtido tomando-se valores menores para o parâmetro J . Contudo, para aumentar o número de intervalos será necessário utilizar um grande conjunto de pares de treinamento (número de exemplos) para reduzir as possibilidades de existência de intervalos vazios. Intervalos vazios (não ocorrência de valores de margem de segurança em determinados intervalos, considerando-se os dados de treinamento) não oferecem oportunidades de aprendizado e, conseqüentemente, introduzem os indesejáveis focos de ruídos no treinamento. Maior segmentação requer maior número de vetores padrões na fase de treinamento. Concluindo-se, a rede neural ARTMAP nebulosa obtém respostas com grande rapidez (há compatibilidade com as aplicações *on-line*) e a precisão é dependente da implementação de um esquema adequado de treinamento, adotando-se um volume de dados de entrada e de saída bem elaborado (em quantidade e qualidade suficientes). Deve-se ressaltar que a questão referente ao volume de dados pode ser resolvida através de um treinamento realizado, como proposto nesta pesquisa, e a incorporação de um módulo de treinamento continuado. O que se espera é que a rede neural, com esta concepção, proporcione melhores soluções com o passar do tempo.

A rede neural ARTMAP aqui usada caracteriza-se como um sistema viável para análise de estabilidade transitória de sistemas elétricos de potência, que pode ser ainda mais aperfeiçoada (visando proporcionar maior rapidez e precisão das soluções) com a inclusão de melhorias, através da proposição de novas arquiteturas, a exemplo das referências [20] (onde foi proposta uma nova arquitetura de rede neural ART chamada ART&ARTMAP nebulosa) e [5], [7], [13], [14], [15], [16], [25], [26], [28], [34], [55] em que foram introduzidos aperfeiçoamentos importantes, aproveitando-se da característica de maleabilidade das redes neurais ART ascendentes. Novas proposições podem ser ainda implementadas, dependendo da criatividade dos pesquisadores.

8.2. SUGESTÕES PARA TRABALHOS FUTUROS

Os resultados desta pesquisa podem ser considerados satisfatórios (do ponto de vista da precisão e rapidez na obtenção das soluções), conforme argumentado

anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar a análise, através da rede neural ARTMAP nebulosa, ainda mais eficiente:

- 1) introduzir novos dispositivos e procedimentos à rede neural desenvolvida, visando a melhoria das soluções. Por exemplo, incluir novos mecanismos para geração de classes e a sintonia (*match tracking*) entre a entrada e a saída da rede neural, empregar técnicas estocásticas em que se determinam probabilidades das inferências, ou seja, a informação de que uma determinada contingência possui a probabilidade p de estar contida no intervalo I_k que é uma forma interessante de abordagem;
- 2) desenvolver estratégias de implementação do treinamento continuado;
- 3) propor novas arquiteturas de redes neurais da família ART, a exemplo do que foi proposto na pesquisa apresentada na referência [20] (posteriormente aplicado para resolver o problema de análise de estabilidade transitória de sistemas de energia elétrica ([19])). Trata-se de uma concepção que busca trabalhar com uma rede neural da família ART que manipula dados analógicos (P e Q) e binários separadamente (dados de topologia e de contingências). Com isto, é possível aumentar a precisão e a rapidez;
- 4) empregar a rede neural ARTMAP nebulosa para o diagnóstico da estabilidade transitória para modelos mais elaborados do que o modelo clássico, *e.g.*, o modelo completo de Park ([56]). Neste sentido, sugere-se o uso combinado dos resultados de simulações, considerando-se o modelo de Park (modelo completo) e o índice proposto nesta pesquisa (uso do conceito de intervalo da margem de segurança). Neste caso, tem-se nas simulações resultados realistas, porém, sem, ainda, à disposição de um índice de segurança, enquanto que com o uso do modelo clássico há disponibilidade de um índice, porém, é um modelo simplificado. O desafio é, então, propor um índice, via redes neurais, para análise de estabilidade transitória em tempo real, cujos modelos traduzem de forma mais realista o comportamento do sistema.

CAPÍTULO 9

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ANDERSON, P. M.; FOUAD, A. A. “Power System Control and Stability”, *IEEE Series on Power Engineering*, USA, Second Edition, 2003.
- [2] ARABSHAHI, P.; CHOI, J. J.; MARKS II, R. J.; CAUDELL, T. P. “Fuzzy Parameter Adaptation in Optimization”, **IEEE Computational Science & Engineering**, Spring, 1996, pp.57-65.
- [3] ASSADI, H.; TAN, A.; ETEZADI-AMOLI, M.; EGBERT, D.; FADALI, M. S. “Application of the ARTMAP Neural Network to Power System Stability Studies”, **IEEE – International Conference on Systems, Man and Cybernetics**, v.2, 1992, pp.1080-1085,
- [4] ATHAY, T.; SHERKET, V. R.; PODMORE, R.; VIRMANI, S.; PUECH, C. “Transient Energy Stability Analysis”, **Conference on ‘System Engineering For Power’**, Davos, Switzerland, 1979.
- [5] BARTFAI, G. “On the Match Tracking Anomaly of the ARTMAP Neural Network”, **Neural Networks**, v.9, n.2, 1996, pp.295-308.
- [6] BENDER, C. M.; ORSZAG, S.A. “Advanced Mathematical methods For Scientists And Engineers”, **McGraw-Hill**, New York, 1978.
- [7] BLUME, M.; ESENER, S. C. “An Efficient Mapping of Fuzzy ART onto a Neural Architecture”, **Neural Networks**, v.10, n.3, 1997, pp.409-411.
- [8] CARPENTER, G. A.; GROSSBERG, D. “Pattern Recognition by Self-Organizing Neural Networks”, **The MIT Press**, Cambridge, Massachusetts, USA, 1991.

- [9] CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. "ARTMAP: Supervised Real-Time Learning and Classification of Nonstationary Data by a Self-Organizing Neural Network", **Neural Networks**, n. 4, 1991, pp.503-544.
- [10] 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**, v.3, n.5, September 1992, pp.698-713.
- [11] CARPENTER, G. A.; GROSSBERG, S. "A Self-Organizing Neural Network for Supervised Learning, Recognition, and Prediction", **IEEE Communications Magazine**, September 1992, pp.38-49.
- [12] CARPENTER, G. A. "Distributed Learning, Recognition, and Prediction by ART and ARTMAP Neural Networks", **Neural Networks**, v.10, 1997, pp.1473-1494.
- [13] CARPENTER, G. A.; MILENOVA, B. L.; NOESKE, B. W. "Distributed ARTMAP: a Neural Network for Fast Distributed Supervised Learning", **Neural Networks**, n.11, 1998, pp.793-813.
- [14] CARPENTER, G. A.; MARKUZON, N. "ARTMAP-IC and Medical Diagnosis: Instance Counting and Inconsistent Cases", **Neural Networks**, n.11, 1998, pp.323-336.
- [15] CARPENTER, G. A.; GOPAL, S.; MACOMBER, S.; MARTENS, S.; WOODCOCK, C. E. "A Neural Network Method for Mixture Estimation for Vegetation Mapping", **Remote Sens. Environment**, n.70, 1999, pp.138-152.
- [16] CARPENTER, G. A.; GOPAL, S.; MACOMBER, S.; MARTENS, S.; WOODCOCK, C. E.; FRANKLIN, J. "A Neural Network Method for Efficient Vegetation Mapping", **Remote Sensing Environment**, n.70, 1999, pp.326-338.
- [17] CARVALHO, L. M. R.; MINUSSI, C. R. "Estabilidade Transitória de Sistemas de Energia Elétrica: Uma Abordagem de Análise via Rede Neural de Kohonen", **XIV**

Congresso Brasileiro de Automática (CBA 2002), Natal-RN, setembro-2002, pp.3178-3184.

- [18] DISTANTE, C.; SICILIANO, P; VASANELLI, L. “Odor Discrimination Using Adaptive Resonance Theory”, **Sensors and Actuators**, B 69, 2000, pp.248-252.
- [19] FERREIRA, W.P.; SILVEIRA, M.C.G.; LOTUFO, A.D.P. e MINUSSI, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Por Rede Neural Baseada na Teoria da Ressonância Adaptativa”, *5th Latin American Congress on Electricity, Generation and Transmission*, São Pedro-SP, Novembro-2003. (Artigo B-135 aceito para apresentação e publicação).
- [20] FERREIRA, W. P. “Análise de Segurança de Sistemas de Energia Elétrica Por Redes Neurais Baseadas na Teoria de Ressonância Adaptativa”, **Exame de Qualificação de Doutorado, Programa de Pós-graduação em Engenharia Elétrica–UNESP – Ilha Solteira-SP**, Agosto-2003.
- [21] FONSECA, L. G.; DECKER, I. C. “Iterative Algorithm For Critical Energy Determination in Transient Stability of Power System”, **IFAC – Symposium Planning and Operation in Electric Energy System**, RJ-Brazil, 1985, pp.483-489.
- [22] FOUAD, A. A.; VITTAL, V. “Power System Transient Stability Analysis Using the Transient Energy Function Method”, **Prentice Hall**, Englewood Cliffs, New Jersey, 1992.
- [23] GARDNER, J. W.; SHIN, H. W.; HINES, E. L.; DOW, C. S. “An Electronics Nose System For Monitoring the Quality of Potable Water”, **Sensors and Actuators**, B 69, 2000, pp.336-341.
- [24] GEORGIOPOULOS, M.; FERNLUND, H.; BEBIS, G.; HEILEMAN, G. L. “Order of Search in Fuzzy ART and Fuzzy ARTMAP: Effect of the Choice Parameter”, **Neural Networks**, v.9, n.9, 1996, pp.1541-1559.

- [25] GEORGIOPOULOS, M.; DAGHER, I.; HEILEMAN, G. L.; BEBIS, G. “Properties of Learning of a Fuzzy ART Variant”, **Neural Networks**, n.12, 1999, pp.837-850.
- [26] GRANGER, E.; RUBIN, M. A.; GROSSBERG, S.; LAVOIE, P. A “What-And-Where Fusion Neural Network for Recognition and Tracking of Multiple Radar Emitters”, **Neural Networks**, n.14, 2001, pp.325-344.
- [27] HAYKIN, S. “Neural Networks: a Comprehensive Foundation”, **Prentice Hall**, Upper Saddle River, New Jersey-USA, 1994.
- [28] ISQUIERDO, J. M. C.; DIMITRIADIS, Y. A.; SÁNCHEZ, E. G.; CORONADO, J. L. “Learning From Noisy Information in FastArt and FasBack Neuro-Fuzzy Systems”, **Neural networks**, n.14, 2001, pp.407-425.
- [29] KALOGIROU, S. A. “Applications of Artificial Neural-Networks For Energy Systems”, **Applied Energy**, n.67, 2000, pp.17-35.
- [30] KARTALOPOULOS, S. V. “Understanding Neural Networks and Fuzzy Logic”, **IEEE Press**, New York, 1996.
- [31] KEYVAN, S.; SONG, X.; KELLY, M. “Nuclear Fuel Pellet Inspection Using Artificial Neural Networks”, **Journal of Nuclear Materials**, n.264, 1999, pp.141-154.
- [32] LIM, C. P.; HARRISON, R. F.; KENNEDY, R. L. “Application of Autonomous Neural Network Systems to Medical Pattern Classification Tasks”, **Artificial Intelligence in Medicine**, v.n.11, pp.215-239, 2000.
- [33] LIM, C. P.; HARRISON, R. F. “An Incremental Adaptive Network For On-Line Supervised Learning and Probability Estimation”, **Neural Networks**, v.10, n.5, pp.925-939, 1997.

- [34] LIM, C. P.; HARRISON, R. F. “Modified Fuzzy ARTMAP Approaches Bayes Optimal Classification Rates: an Empirical Demonstration”, **Neural Networks**, v.10, n.4, pp.755-774, 1997.
- [35] LINDSEY, C. S.; LINDBLAD, T. “Unsupervised Learning With ART on the CNAPS”, **Nuclear Instruments and Methods in Physics Research**, A 389, pp.237-239, 1997.
- [36] LLOBET, E.; HINES, E. L.; GARDNER, J. W.; BARTLETT, P. N.; MOTTRAM, T. T. “Fuzzy ARTMAP Based Electronics Nose Data Analysis”, **Sensors and Actuators**, B 61, pp.183-190, 1999.
- [37] MARCHIORI, S.; MINUSSI, C. R.; LOTUFO, A. D. P. “Rede Neural ARTMAP Nebulosa Para Análise de Estabilidade Transitória de Sistemas de Energia Elétrica”, **Learning and Nonlinear Models**, n.1, v.1, pp.61-78, 2002.
- [38] MARCHIORI, S. C. “Estabilidade Transitória de Sistemas de Energia Elétrica: Uma Metodologia de Análise Via Rede Neural ARTMAP Nebulosa”, **Dissertação de Mestrado**, Universidade Estadual Paulista (UNESP), Programa de Pós-graduação em Engenharia Elétrica – Campus de Ilha Solteira – São Paulo-SP, Agosto-2001.
- [39] MINUSSI, C. R.; FREITAS FILHO, W. “Sensitivity Analysis For Transient Stability”, **IEE Proceedings on Generation, Transmission And Distribution**, v.145, n.6, pp.669-674, 1998.
- [40] MINUSSI, C. R.; RAMOS, L. M.; MARCHIORI, S. C.; LOPES, M. L. M.; LOTUFO, A. D. P. “Neural Networks to Transient Stability Analysis of Electrical Power Systems”, **Proceedings of the V Brazilian Conference on Neural Networks**, PUC, Rio de Janeiro-RJ, pp. 31-36, April-2-5, 2001.
- [41] MINUSSI, C. R.; SILVEIRA, M. C. G. “Transient Stability Analysis of Electric Power Systems by Neural Networks”, **38rd Midwest Symposium on Circuits And Systems**, Rio de Janeiro-RJ, pp.1305-1308, 1995.

- [42] MINUSSI, C. R. “Controle de Segurança Dinâmica de Sistemas de Energia Elétrica”, **Tese DSc.**, UFSC, Brasil, Novembro 1990.
- [43] MINUSSI, C. R.; PEREIRA, M. “Um Programa Computacional Para o Ensino de Análise de Estabilidade Transitória de Sistemas de Energia Elétrica”, **19º Congresso Brasileiro de Ensino de Engenharia**, João Pessoa, v.1, pp.113-122.
- [44] PAI, M. A. “Power System Stability: Analysis by the Direct Method of Lyapunov”, **North-Holland Control Series**, New York, North-Holland Publishing Company, 1981.
- [45] PAO, Y. H.; SOBAJIC, D. J. “Combined use of Unsupervised and Supervised Learning for Dynamic Security Assessment”, **IEEE PICA-91**, pp.278-284.
- [46] PARK, Y. M.; KIN, G. W.; CHO, H. S.; LEE, Y. N. “A New Algorithm For Kohonen Layer Learning With Application to Power System Stability Analysis”, **IEEE Transactions on Systems, Man, And Cybernetics**, v. 27, n. 6, pp.1030-1033, December 1997.
- [47] PAVELLA, M.; ERNST, D.; RUIZ-VEGA, D. “Transient Stability of Power Systems: A Unified Approach to Assessment and Control”, London: Klüwer Academic Publishers, 2000.
- [48] PIERRE, S.; SAID, H., PROBST, W. G. “Routing in Computer Networks Using Artificial Neural Networks”, **Artificial Intelligence in Engineering**, n.14, pp.295-305, 2000.
- [49] PHAM, D. T.; SUKKAR, M. F. A. “Predictor Based on Adaptive Resonance Theory”, **Artificial Intelligence in Engineering**, n.12, pp.219-228, 1998.
- [50] RAVEENDRAN, P.; PALANIAPPAN, R.; OMATU, S. “Fuzzy ARTMAP Classification of Invariant Features Derived Using Angle of Rotation From a Neural Network”, **Information Sciences**, n.130, pp.67-84, 2000.

- [51] SILVEIRA, M. C. G.; MARCHIORI, S. C.; FERREIRA, W. P.; MINUSSI, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Usando Uma Rede Neural ARTMAP Nebulosa”, **XIV Congresso Brasileiro de Automática (CBA 2002)**, Natal-RN, pp.3171-3177, setembro-2002.
- [52] SILVEIRA, M. C. G.; LOTUFO, A. D. P. and MINUSSI, C. R. “Transient Stability Analysis of Electrical Power Systems Using a Neural Network Based on Fuzzy ARTMAP”, **IEEE Bologna Power Tech 2003 Conference**, Bologna, Italy, Paper 43, June-2003.
- [53] SIMPSON, P. K. “Artificial Neural Systems: Foundations Paradigms, Applications and Implementations”, **Pergamon Press**, New York, 1989.
- [54] SOBAJIC, D. J.; PAO, Y. H. “Artificial Neural-Net Based Dynamic Security Assessment For Electric Power Systems”, **IEEE Transactions on Power Systems**, v.4, n.1, pp.220-227, February 1989.
- [55] SRINIVASA, N. “Learning And Generalization of Noisy Mappings Using a Modified PROBART Neural Network”, **IEEE Transactions on Signal Processing**, v.45, n.10, pp.533-2550, October 1997.
- [56] STOTT, B. “Power System Dynamic Response Calculations”, **Proceedings of the IEEE**, v.67, n.2, pp. 219 – 241, January-1979.
- [57] SU, M. C.; CHANG, H. T. “Application of Neural Networks Incorporated With Real-Valued Genetic Algorithms in Knowledge Acquisition”, **Fuzzy Sets and Systems**, n.112, pp.85-97, 2000.
- [58] TERANO, T.; ASAI, K.; SUGENO, M. “Fuzzy Systems Theory And its Application”, **Academic Press**, New York, 1987.
- [59] WASSERMAN, P. D. “Neural Computing – Theory And Practice”, **Van Nostrand Reinhold**, New York-USA, 1989.

- [60] WEHENKEL, L. "Machine-Learning Approaches to Power-System Security Assessment", **IEEE Expert Intelligent Systems & Their Applications**, pp.60-72, September/October 1997.

- [61] WEENINK, D. "Category ART: A Variation on Adaptive Resonance Theory Neural Networks", **Institute of Phonetic Sciences, University o Amsterdam, Proceedings**, n.21, pp.117-129, 1997.

- [62] WERBOS, P. J. "Beyond Regression: New Tools For Prediction And Analysis in the Behavioral Sciences", **Master Thesis**, Harvard University, 1974.

- [63] WIDROW, B.; LEHR, M. A. "30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation", **Proceedings of the IEEE**, v.78, n.9, pp.1415-1442.

- [64] WILLIAMSON, J. R. "Gaussian ARTMAP: A Neural Network For Fast Incremental Learning of Noisy Multidimensional Maps", **Neural Networks**, v.9, n.5, pp.881-897, July 1996.

APÊNDICE A

IMPLEMENTAÇÃO COMPUTACIONAL PARA A DETERMINAÇÃO DA MARGEM DE SEGURANÇA

A análise de estabilidade transitória de sistemas de energia elétrica será efetuada combinando-se o Método Direto de Lyapunov e a resolução das equações diferenciais (metodologia híbrida), considerando-se defeitos tipo curto-circuito com saída de operação de linha de transmissão ([39]). Esta combinação é empregada como forma de se obter maior precisão, se comparada ao Método Direto de Liapunov. A função de Liapunov adotada será do tipo energia. Neste caso, a análise da estabilidade é efetuada comparando-se a energia adquirida durante o transitório com uma energia crítica. A energia crítica corresponde à máxima energia que o sistema pode acumular de tal modo que sua estabilidade seja preservada. A energia crítica e, conseqüentemente, o tempo crítico serão determinados baseados no conceito PEBS (*Potencial Energy Boundary Surface* ([4])) iterativo ([21]), cujo algoritmo empregado corresponde ao apresentado na referência [43]. Este algoritmo tem sido adotado, tendo em vista a precisão comparável à simulação, com custo computacional consideravelmente inferior ([21]).

O conceito energia para o diagnóstico da estabilidade transitória, pode ser empregado mediante o critério da margem de segurança ([4], [21], [42], [44]):

$$M_r = (E_{crit_r} - E_{e_r}) / E_{crit_r} \quad (A.1)$$

sendo:

r = índice da falta sob análise;

$E(q,w) \triangleq$ energia total do sistema (A.2)

$$= E_c(w) + E_p(q);$$

E_{crit_r} = energia crítica do sistema;

E_{e_r} = energia total correspondente ao tempo de eliminação de defeito;

$E_c(w)$ $\triangleq$ energia cinética;

$$= \frac{1}{2} \sum_{i \in N} M_i w_i^2; \quad (A.3)$$

$E_p(q)$ $\triangleq$ energia potencial

$$= - \sum_{i \in N} \int_{q_i^p}^{q_i} P_i(q) dq_i; \quad (A.4)$$

Então, pode-se concluir sobre a estabilidade do sistema, mediante o seguinte critério ([4], [21], [42], [44]):

- Se $M_r > (\leq) 0$, o sistema associado à i -ésima contingência é considerado estável (instável) do ponto de vista da estabilidade transitória.

A derivada direcional da energia potencial pode ser expressa de modo similar ao apresentado nas referências [4] e [21], por:

$$D(q) = - \langle g(q)^T, (q - q^p) \rangle / \|q - q^p\|_e \quad (A.5)$$

sendo:

$$g(q) = [g_1(q) \ g_2(q) \ \dots \ g_{ns}(q)]$$

$$g_i(q) = Pm_i - Pe_i - (M_i PCA) / MT \quad (A.6)$$

$\langle ., . \rangle$ = produto interno de dois vetores n -dimensionais.

A derivada direcional $D(q)$ possui a propriedade de se manter sempre positiva para trajetórias (soluções das equações diferenciais) estáveis ([4],[21]). Os pontos $q \hat{=} \hat{A}^n$ correspondentes aos zeros da derivada direcional, que primeiro são lançados quando se

percorre uma direção radial, a partir da origem, determinam uma superfície definida como sendo Superfície Limite de Energia Potencial ou PEBS ([21], [42]). Por conseguinte, o procedimento de determinação da energia e tempo crítico apresentado na referência [21] consiste na busca de um ponto na trajetória sob falta, por processo iterativo, tal que a evolução pós-falta, que começa neste ponto, encontre a máxima aproximação da PEBS. Considerando-se, então, os resultados apresentados anteriormente, pode-se descrever o algoritmo através dos seguintes passos ([43]):

Passo 1. Ler os dados.

Passo 2. Determinar o fluxo de potência do sistema pré-falta, através do método desacoplado rápido.

Passo 3. Iniciar o contador de contingências:
 $r = 1$.

Passo 4. Contador de contingências:
 $r = r + 1$.

Passo 5. Calcular as matrizes reduzidas às barras internas de geração para as configurações de falta e pós-falta.

Passo 6. Calcular o ponto de equilíbrio pós-defeito. Emprega-se, neste caso, o método de Newton, considerando a topologia da rede reduzida às barras internas de geração.

Passo 7. O ponto de equilíbrio pós-defeito é estável? Se verdadeiro, ir ao passo 8. Do contrário, emitir mensagem que a contingência não possui ponto de equilíbrio e, conseqüentemente, o sistema é considerado instável para a contingência analisada e retornar ao passo 4.

Passo 8. Determinar o tempo crítico e a energia crítica:

- (a) o cálculo das trajetórias sob falta e pós-falta é determinado através do método Runge-Kutta de segunda ordem (integração numérica das equações diferenciais (2.2.1) e (2.2.2));
- (b) energia e tempo crítico são determinados utilizando-se o algoritmo proposto na referência [21]. A função de Liapunov tipo energia é avaliada de acordo com as expressões (A.2), (A.3) e (A.4).

Passo 9. Última contingência? Se verdadeiro, ir ao passo 10. Do contrário, retornar ao passo 4.

Passo 10. Emitir relatório em forma de tabelas contendo os principais dados e resultados (tempo crítico, energia crítica, energia correspondente ao instante de eliminação de defeito, margem de segurança, etc.).

Passo 11. Finalizar o processo de cálculo.

APÊNDICE B

DADOS DO SISTEMA DE ENERGIA ELÉTRICA

A seguir apresenta-se os dados ([38]) referentes a uma configuração baseada no sistema sul-brasileiro composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão (Figura 21). Os dados referem-se a uma base de 100 MVA.

Tabela 5. Dados de barras do sistema sul-brasileiro (10 máquinas).

IDENTIFICAÇÃO		TENSÃO		CARGA		GERAÇÃO	
Nº	NOME	MÓD.	ÂNG.	Ativa (pu)	Reativa (pu)	Ativa (pu)	Reativa (pu)
1	Barracão 13,8	1,020	-11,430	0,000	0,000	6,500	1,007
2	P. Fundo 13,8	1,040	-17,100	0,000	0,000	2,150	1,496
3	S. Osório 13,8	1,020	5,080	0,000	0,000	10,500	2,450
4	F. Areia 13,8	1,022	-6,380	0,000	0,000	11,100	3,377
5	S. Santiago 13,8	1,018	3,290	0,000	0,000	13,250	1,651
6	J. Lacerda A 13,8	1,030	-29,920	0,000	0,000	0,900	0,465
7	J. Lacerda B 13,8	1,030	-28,380	0,000	0,000	1,200	0,548
8	J. Lacerda C 13,8	1,030	-27,020	0,000	0,000	2,410	0,905
9	Itaúba 13,8	1,000	-16,150	0,000	0,000	4,900	1,365
10	Segredo 13,8	1,020	0,000	0,000	0,000	13,640	2,051
11	Ivaiporã 525	1,007	-11,180	0,000	-2,130	0,000	0,000
12	Londrina 525	0,995	-13,510	0,000	0,000	0,000	0,000
13	Siderópolis 230	0,969	-37,470	1,770	0,680	0,000	0,000
14	Farroupilha 230	0,978	-37,240	1,910	0,420	0,000	0,000
15	P. Fundo 230	0,978	-22,680	1,710	0,185	0,000	0,000
16	Xanxerê 230	0,946	-17,990	1,260	0,470	0,000	0,000
17	Pato Branco 230	0,954	-10,870	0,460	0,147	0,000	0,000
18	S. Osório 230	0,999	-1,660	2,810	0,565	0,000	0,000
19	Areia 230	0,978	-15,420	2,790	0,607	0,000	0,000

Tabela 5. Continuação 1.

IDENTIFICAÇÃO		TENSÃO		CARGA		GERAÇÃO	
Nº	NOME	MÓD.	ÂNG.	Ativa (pu)	Reativa (pu)	Ativa (pu)	Reativa (pu)
20	S. Mateus 230	0,997	-26,600	1,300	-0,706	0,000	0,000
21	Curitiba 230	0,991	-26,760	4,270	-1,250	0,000	0,000
22	Joinville 230	0,952	-33,640	3,100	0,410	0,000	0,000
23	Blumenau 230	0,967	-32,190	4,240	0,094	0,000	0,000
24	R. Queimado 230	0,963	-34,310	1,170	0,531	0,000	0,000
25	Areia 525	1,003	-10,550	0,000	0,000	0,000	0,000
26	Curitiba 525	0,986	-24,330	0,000	-1,447	0,000	0,000
27	Cur. Norte 525	0,988	-22,750	3,680	-0,756	0,000	0,000
28	Blumenau 525	0,968	-30,100	0,000	0,000	0,000	0,000
29	Barracão 525	1,010	-16,350	1,740	-1,138	0,000	0,000
30	Gravataí 525	1,019	-33,630	0,000	-1,596	0,000	0,000
31	V. Aires 525	1,027	-26,790	0,000	-1,603	0,000	0,000
32	Pinheiro 525	1,018	-13,680	0,000	-1,615	0,000	0,000
33	S. Santiago 525	1,010	-5,150	0,000	0,000	0,000	0,000
34	J. Lacerda 138	0,994	-34,310	1,260	0,398	0,000	0,000
35	J. Lacerda 230	0,996	-33,090	0,000	0,000	0,000	0,000
36	Segredo 525	1,010	-5,160	0,000	0,000	0,000	0,000
37	Ceci 230	1,012	-37,550	8,130	1,100	0,000	0,000
38	Gravataí 230	1,026	-36,940	6,120	-4,550	0,000	0,000
39	Itaúba 230	0,975	-22,960	4,040	1,350	0,000	0,000
40	V. Aires 230	1,029	-29,400	3,930	-1,110	0,000	0,000
41	Apucarana 230	0,973	-18,930	2,620	0,132	0,000	0,000
42	Londrina 230	0,989	-15,600	2,290	0,830	0,000	0,000
43	Maringá 230	0,983	-18,900	1,840	-0,398	0,000	0,000
44	C. Mourão 230	0,981	-15,340	1,390	-0,463	0,000	0,000
45	Forquilha 230	0,977	-37,360	0,901	-0,447	0,000	0,000

Tabela 6. Dados do sistema de transmissão.

Nº	BARRA DE ORIGEM	BARRA DE DESTINO	IMPEDÂNCIA	
			R(%)	X(%)
1	Ivaiporã 525	Londrina 525	0,07	1,45
2	Ivaiporã 525	Londrina 525	0,07	1,45
3	Ivaiporã 525	Areia 525	0,18	2,27
4	Ivaiporã 525	S. Santiago 525	0,14	2,04
5	Londrina 525	Londrina 230	0,00	0,63
6	Barracão 13,8	Barracão 525	0,00	1,36
7	Siderópolis 230	Farroupilha 230	3,86	19,85
8	Siderópolis 230	J. Lacerda 230	0,96	4,91
9	Siderópolis 230	Forquilha 230	0,33	1,67
10	Farroupilha 230	P. Fundo 230	4,63	23,78
11	Farroupilha 230	P. Fundo 230	4,63	23,78
12	Farroupilha 230	Ceci 230	1,77	9,10
13	Farroupilha 230	Ceci 230	1,77	9,10
14	Farroupilha 230	Ceci 230	1,77	9,10
15	P. Fundo 13,8	P. Fundo 230	0,00	4,60
16	P. Fundo 230	Xanxerê 230	1,63	8,35
17	P. Fundo 230	Xanxerê 230	1,63	8,35
18	P. Fundo 230	Itaúba 230	2,50	15,48
19	Xanxerê 230	P. Branco 230	1,63	8,35
20	Xanxerê 230	S. Osório 230	3,16	16,21
21	P. Branco 230	S. Osório 230	1,53	8,61
22	S. Osório 13,8	S. Osório 230	0,00	1,14
23	S. Osório 230	Areia 230	3,06	15,23
24	S. Osório 230	C. Mourão 230	3,44	17,60
25	S. Osório 230	C. Mourão 230	3,44	17,60
26	Areia 230	S. Mateus 230	2,45	12,56
27	Areia 230	Areia 525	0,00	3,00
28	S. Mateus 230	Curitiba 230	0,88	4,15
29	Curitiba 230	Joinville 230	1,82	9,35
30	Curitiba 230	Joinville 230	1,82	9,35

Tabela 6. Continuação 1.

Nº	BARRA DE ORIGEM	BARRA DE DESTINO	IMPEDÂNCIA	
			R(%)	X(%)
31	Curitiba 230	Curitiba 525	0,00	0,62
32	Joinville 230	Blumenau 230	1,54	7,76
33	Joinville 230	Blumenau 230	1,54	7,76
34	Blumenau 230	R. Queimado 230	2,16	11,05
35	Blumenau 230	R. Queimado 230	2,16	11,05
36	Blumenau 230	Blumenau 525	0,00	0,62
37	R. Queimado 230	J. Lacerda 230	1,80	9,20
38	R. Queimado 230	J. Lacerda 230	1,80	9,20
39	F. Areia 13,8	Areia 525	0,00	0,67
40	Areia 525	Curitiba 525	0,19	2,80
41	Areia 525	Cur. Norte 425	0,19	2,74
42	Areia 525	Barracão 525	0,14	1,95
43	Areia 525	Segredo 525	0,05	0,70
44	Curitiba 525	Cur. Norte 525	0,05	0,69
45	Curitiba 525	Blumenau 525	0,12	1,75
46	Barracão 525	Gravataí 525	0,21	3,09
47	Gravataí 525	Gravataí 230	0,00	0,62
48	V. Aires 525	Pinheiro 525	0,22	3,00
49	V. Aires 525	V. Aires 230	0,00	0,62
50	Pinheiro 525	S. Santiago 525	0,14	1,95
51	S. Santiago 13,8	S. Santiago 525	0,00	1,14
52	S. Santiago 525	Segredo 525	0,05	0,70
53	J. Lacerda A 13,8	J. Lacerda 13,8	0,00	8,71
54	J. Lacerda 13,8	J. Lacerda 230	0,00	5,90
55	J. Lacerda B 13,8	J. Lacerda 230	0,00	7,01
56	J. Lacerda C 13,8	J. Lacerda 230	0,00	4,50
57	J. Lacerda 230	Forquilha 230	1,29	6,57
58	Segredo 13,8	Segredo 525	0,00	0,68
59	Ceci 230	Gravataí 230	0,22	1,11
60	Ceci 230	Gravataí 230	0,22	1,11

Tabela 6. Continuação 2.

Nº	BARRA DE ORIGEM	BARRA DE DESTINO	IMPEDÂNCIA	
			R(%)	X(%)
61	Ceci 230	Gravataí 230	0,22	1,11
62	Ceci 230	V. Aires 230	2,07	9,33
63	Ceci 230	V. Aires 230	2,07	9,33
64	Ceci 230	V. Aires 230	2,07	9,33
65	Itaúba 13,8	Itaúba 230	0,00	2,36
66	Itaúba 230	V. Aires 230	2,02	11,29
67	Apucarana 230	Londrina 230	1,25	6,40
68	Apucarana 230	Londrina 230	0,89	4,61
69	Apucarana 230	Maringá 230	1,10	11,84
70	Apucarana 230	C. Mourão 230	2,29	11,74
71	Londrina 230	Maringá 230	1,72	8,84
72	Londrina 230	Maringá 230	1,72	8,84
73	Maringá 230	C. Mourão 230	1,81	9,29

Tabela 7. Dados das máquinas síncronas.

Nº MÁQUINA	X'd (%)	H(s)	POTÊNCIA MECÂNICA (pu)
1	3,67	30,44	6,50
2	10,37	10,56	2,15
3	2,84	38,34	10,50
4	2,41	62,25	11,10
5	2,43	55,24	13,25
6	13,52	4,37	0,90
7	15,34	6,80	1,20
8	8,00	12,50	2,41
9	4,32	20,24	4,90
10	2,16	62,46	Referência

APÊNDICE C

ARTIGOS PUBLICADOS E ACEITO PARA PUBLICAÇÃO RELACIONADOS COM A TESE DE DOUTORADO

De acordo com as exigências do Regulamento do PPGE (Programa de Pós-graduação em Engenharia Elétrica) da Faculdade de Engenharia de Ilha Solteira – UNESP, Art. 45, Parágrafo único, o aluno do Doutorado deverá ter publicado ou ter sido aceito para publicação, no mínimo, dois artigos completos, relacionados com a pesquisa da tese, em periódicos, congressos ou eventos similares que possuem corpo técnico de revisores de competência reconhecida pela comunidade científica. Assim sendo, neste Apêndice são apresentados os artigos que foram publicados e aceito para publicação relacionados com a pesquisa de doutorado:

1. **Silveira, M. C. G.**; Marchiori, S. C.; Ferreira, W. P. e Minussi, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Usando Uma Rede Neural ARTMAP Nebulosa”, *XIV Congresso Brasileiro de Automática (CBA 2002)*, Natal-RN, pp.3171-3177, setembro-2002.
2. **Silveira, M. C. G.**; Lotufo, A. D. P. and Minussi, C. R. “Transient Stability Analysis of Electrical Power Systems Using a Neural Network Based on Fuzzy ARTMAP”, *IEEE Bologna Power Tech 2003 Conference*, Bologna, Italy, Paper 43, June-2003.
3. Ferreira, W.P.; **Silveira, M.C.G.**; Lotufo, A.D.P. e Minussi, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Por Rede Neural Baseada na Teoria da Ressonância Adaptativa”, *5th Latin American Congress on Electricity, Generation and Transmission*, São Pedro-SP, Novembro-2003. (Artigo aceito para apresentação e publicação).