

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

Desenvolvimento de um Sistema para Análise da
Estabilidade Transitória de Sistemas de Energia
Elétrica via Redes Neurais

Sandra Cristina Marchiori

Carlos Roberto Minussi

(Orientador)

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, fevereiro de 2006.

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

FICHA CATALOGRÁFICA

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

M317d Marchiori, Sandra Cristina
Desenvolvimento de um sistema para análise da estabilidade transitória de sistemas de energia elétrica via redes neurais / Sandra Cristina Marchiori. -- Ilha Solteira : [s.n.], 2006 xvii, 110 p.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2006

Orientador: Carlos Roberto Minussi
Bibliografia: p. 96-102

1. Sistemas de energia elétrica - Estabilidade. 2. Transitórios (Eletricidade). 3. Redes neurais (Computação).



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: DESENVOLVIMENTO DE UM SISTEMA PARA ANÁLISE DA ESTABILIDADE TRANSITÓRIA DE SISTEMAS DE ENERGIA ELÉTRICA VIA REDES NEURAIS

AUTORA: SANDRA CRISTINA MARCHIORI
ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

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

Prof. Dr. CARLOS ROBERTO MINUSSI
DEE / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. ANTONIO PADILHA FELTRIN
DEE / Faculdade de Engenharia de Ilha Solteira

Profa. Dra. MARIA DO CARMO G DA SILVEIRA
Serviço Técnico de Informática / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. JOÃO ONOFRE PEREIRA PINTO
DEE/ Universidade Federal de Mato Grosso do Sul, Campo Grande, MS

Prof. Dr. ARLAN LUIZ BETTIOL
UNIVALI, Florianópolis, SC

Data da realização: 15 de fevereiro de 2006.

Presidente da Comissão Examinadora
Prof. Dr. CARLOS ROBERTO MINUSSI

Esta tese de doutorado foi desenvolvida com o apoio (bolsa de estudo e reserva técnica) da Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, processo nº 01/10689-9.

Aos meus pais Norival e Odilir.

Ao meu marido, Wesley.

Agradecimentos

Ao Prof. Dr. Carlos Roberto Minussi, pela orientação precisa, pela confiança e tolerância demonstradas, que foram fundamentais para a conclusão deste trabalho.

Aos professores do curso de pós-graduação do departamento de engenharia elétrica, especificamente àqueles com os quais convivi ao longo do curso, pela experiência e conceitos transmitidos, que contribuíram para a execução deste trabalho. Em particular, agradeço a Prof. Dra. Anna Diva pela presteza e apoio sempre que solicitado.

Aos membros da banca de avaliação desta tese (João Onofre Pereira Pinto, Arlan Luiz Bettiol, Antonio Padilha Feltrin, Maria do Carmo Gomes da Silveira), pelas valiosas críticas e sugestões que enriqueceram o conteúdo.

Aos colegas da pós-graduação pelos momentos importantes que compartilhamos.

Aos funcionários da seção de pós-graduação, pela atenção e dedicação.

Aos funcionários do Departamento de Engenharia Elétrica – DEE, com atenção especial para o setor de informática e para a secretaria.

Aos meus pais, Norival e Odelir, e a meus irmãos, Selma e Paulo, por sempre estarem presente em minha vida, apoiando-me e incentivando-me em todos os momentos.

Ao meu marido, Wesley, pelo carinho e compreensão nos momentos mais difíceis, expressei meus melhores sentimentos.

Àqueles que não foram citados, mas que de alguma forma, contribuíram para a realização deste trabalho.

Agradecimento Especial

À Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, pelo auxílio financeiro dado a esta pesquisa (bolsa de estudo e reserva técnica, processo nº 01/10689-9).

Biografia da Autora

- Nascida em 04 de janeiro de 1977, em Guararapes, estado de São Paulo.
- Graduada em Matemática pela Universidade Federal de Mato Grosso do Sul – UFMS, em 1998.
- Mestre em Engenharia Elétrica pela Universidade Estadual Paulista – UNESP, em 2001.
- Autora e co-autora de 05 trabalhos publicados na área de Estabilidade Transitória de Sistemas de Energia Elétrica.

Resumo

Esta pesquisa apresenta uma metodologia para a análise da estabilidade transitória de primeira oscilação de sistemas de energia elétrica usando uma rede neural baseada na arquitetura ART (*Adaptive Resonance Theory*), designada rede neural ARTMAP Euclidiana. A margem de segurança (método da energia) é empregada como critério de análise de estabilidade transitória, considerando-se, na forma preliminar, o modelo clássico e defeitos tipo curto-circuito trifásico com saída de linha de transmissão. A metodologia proposta está concebida, ainda, com a possibilidade de se considerar modelos mais elaborados (e.g., o modelo de Park), se comparados ao modelo clássico. Esta alternativa pode se tornar exeqüível, por meio do uso de um segundo módulo neural e de um índice, para fins de treinamento, gerado considerando-se uma combinação, por exemplo, da margem de segurança (análise quantitativa / qualitativa com média precisão) e de informações fornecidas por processo de simulação (análise qualitativa com alta precisão). As arquiteturas ART apresentam as características de estabilidade e plasticidade, as quais são imprescindíveis para a realização do treinamento e execução da análise de forma rápida. A versão ARTMAP Euclidiana proporciona soluções mais precisas e mais rápidas, se comparada à configuração ARTMAP nebulosa. O funcionamento da rede é constituído por três fases principais: treinamento (ou aprendizado), análise e treinamento continuado. A realização da fase de treinamento requer uma grande quantidade de processamento, 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 o caso de aplicações em tempo real. O treinamento continuado constitui-se de um procedimento que permite manter, permanentemente, a extração do conhecimento do problema da análise de estabilidade transitória a partir do treinamento realizado e informações disponibilizadas na operação do sistema: resultados das análises via simulação, etc. Por conseguinte, nesta pesquisa será, também, formulada a rotina referente ao treinamento continuado. A rede neural proposta permite abordar, simultaneamente, várias topologias da rede elétrica, constituindo, deste modo, uma alternativa de análise da estabilidade transitória de sistemas reais em tempo real. Como forma de ilustrar a estrutura neural proposta, apresenta-se uma aplicação considerando-se um sistema elétrico (multimáquinas) composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão.

Abstract

This work presents a methodology for transient stability analysis of first swing of electrical energy systems, using a neural network based on ART (Adaptive Resonance Theory), named Euclidean ARTMAP neural network. The security margin (energy method) is used as a criterion for transient stability analysis, considering, in the preliminary form, the classical model and faults like three-phase short-circuit with outage of a transmission line. The proposed methodology is conceived, even that, with the possibility to consider more elaborated models (e.g., the Park model), when compared to the classical model. This alternative can become executable, through the use of a second neural module and an index for training, generated considering a combination, for example, the security margin (quantitative / qualitative analysis with precision average) and information provided by simulation process (qualitative analysis with precision high). The ART neural network presents stability and plasticity characteristics, which are very important for realization of the training and analysis, executed in a very fast way. The Euclidean ARTMAP version gives more accurate solutions and more fast, when compared to the Fuzzy ARTMAP. The performance of neural network is constituted of three principal phases: training (or learning), analysis and continuous training. The training phase needs a great quantity of processing time for the realization, whereas the analysis phase is effectuated almost without computational effort. Therefore, this is the principal justification to use neural network for solving complex problems that need fast solutions, as the case of real time applications. The continuous training is constituted of a procedure that allows to maintain, permanently, the extraction of the knowledge from the problem of the transient stability analysis starting from the accomplished training and available information in the operation of the system: analysis results through simulation, etc. Consequently, in this work it will also be formulated the routine referring to continuous training. The proposed neural network permits to treat, concomitantly, various topologies of the electrical power system, constituting, this way, an alternative to transient stability analysis of systems in real time. To illustrate the proposed neural framing, an application is presented considering an electric system (multimachine) composed of 10 synchronous machines, 45 buses, and 73 transmission lines.

Notação e Simbologia

Letras no estilo negrito, maiúsculas e minúsculas, representam matrizes e vetores, respectivamente. Os vetores seguem a representação por linha, ao invés por coluna como comumente adotada na literatura. Esta opção torna-se mais atrativa quando se empregam redes neurais, baseadas na Teoria da Ressonância Adaptativa, que se constituem a base do desenvolvimento desta tese.

MDL	=	Método Direto de Lyapunov
SEE	=	Sistemas de Energia Elétrica
RNA	=	Redes Neurais Artificiais
ART	=	<i>Adaptive Resonance Theory</i> (Teoria da Ressonância Adaptativa)
CA	=	Centro de Ângulos
<i>ng</i>	=	número de máquinas síncronas
<i>PT_i</i>	=	potência mecânica do eixo da turbina
<i>PG_i</i>	=	potência elétrica gerada
<i>Wcin_i</i>	\triangleq	energia cinética total do gerador mais turbina
<i>f_s⁰</i>	=	freqüência nominal do sistema
<i>Pd_i</i>	=	potência referente às perdas elétricas
<i>Wcin_i⁰</i>	=	energia cinética da <i>i</i> -ésima máquina síncrona medida na freqüência nominal
<i>δ_i</i>	=	posição angular do rotor em relação a uma referência que gira de modo síncrono

D_i	=	um parâmetro positivo da máquina síncrona denominado constante de amortecimento do rotor
H_i	\triangleq	constante de inércia definida por:
Pm_i	\triangleq	potência mecânica de entrada (pu)
Pe_i	\triangleq	potência elétrica de saída (pu)
Pr_i	=	potência nominal total da i -ésima máquina síncrona
ω_s	\triangleq	velocidade síncrona (rad. elét./s)
θ_i	\triangleq	ângulo do rotor da i -ésima máquina síncrona referida ao CA (rad. elét.)
δ_i	=	ângulo do rotor da i -ésima máquina síncrona medida com relação a uma máquina que gira à velocidade síncrona (rad. elét.)
$PCOA$	\triangleq	potência acelerante do Centro de Ângulos
NG	\triangleq	conjunto de índices das máquinas que compõem o sistema
M_r	=	margem de segurança
$Ecrit_r$	=	energia total crítica do sistema
Ee_r	=	energia total do sistema avaliada no instante de eliminação do defeito (te)
r	=	número de contingências
$E(\theta, \omega)$	=	energia total do sistema
$Ec(\omega)$	\triangleq	energia cinética
$Ep(\theta)$	\triangleq	energia potencial
p	=	ponto de equilíbrio pós-falta
PEBS	=	<i>Potential Energy Boundary Surface</i> (Superfície Limite de Energia Potencial)

$D(\theta)$	=	derivada direcional da Energia Potencial
$\langle \cdot, \cdot \rangle$	=	produto interno de dois vetores n -dimensionais;
$\ \bullet \ _e$	=	norma euclidiana
LTM	=	<i>Long Term Memory</i> (Memória de Longo Prazo)
STM	=	<i>Short Term Memory</i> (Memória de Curto Prazo)
F_0	=	campo de pré-processamento de neurônios
F_1	=	campo de neurônios que processa os dados de entrada
F_2	=	campo de neurônios que agrupa os padrões de treinamento em categorias de reconhecimento
ρ	=	parâmetro de vigilância
α	=	parâmetro de escolha
β	=	taxa de treinamento
a_i	=	padrão de entrada para a rede ART nebulosa
T_j	\triangleq	função escolha
w_j	=	vetor de pesos
\wedge	=	operador nebuloso <i>AND</i>
\cap	=	operador de interseção <i>crisp</i>
T_J	=	$\max\{T_j : j = 1, \dots, M\}$
J	=	índice da categoria escolhida
$w_J^{(novo)}$	\triangleq	atualização do vetor de pesos
$ R_j $	\triangleq	tamanho do retângulo R_j

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

\mathbf{v}_j = vetor bi-dimensional pertencente ao vértice de R_j

\mathbf{u}_j = vetor bi-dimensional pertencente ao vértice de R_j

T_0 = ativação do neurônio “vazio” (categoria de reconhecimento sem a presença de nenhum padrão de entrada)

\mathbf{X}_r \triangleq vetor padrão de entrada da rede neural ARTMAP Euclidiana (entrada do módulo ARTa) correspondente à r -ésima contingência

P_i = potência elétrica ativa da i -ésima barra do sistema

Q_i = potência elétrica reativa da i -ésima barra do sistema

\mathbf{A}_r = vetor que contém os índices das contingências e informação sobre a topologia do sistema, representado em código binário [0,+1]

ns = número de barras do sistema

nc = número de *bits* correspondente ao número (índice) da contingência e configuração do sistema

\mathbf{PG}^0 = vetor de potência ativa dos geradores do caso base

\mathbf{QG}^0 = vetor de potência reativa dos geradores do caso base

\mathbf{PL}^0 = vetor de potência ativa das cargas do caso base

\mathbf{QL}^0 = vetor de potência reativa das cargas do caso base

PG_i = potência ativa no i -ésimo gerador, fixada aleatoriamente (ou pseudo-aleatoriamente)

$\Omega(G)$ = conjunto de barras de geração

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

- AG_i = número aleatório de uma 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: $AG_i \in [0, 1]$
- PL_i = potência ativa na i -ésima carga fixada aleatoriamente
- AL_i = número aleatório de uma seqüência de NL números gerados a partir de uma semente dada, $AL_i \in [0, 1]$
- $\Omega(L)$ = conjunto de barras de cargas
- \mathcal{G} = esforço de deslocamento da margem de segurança
- M^A = valor da margem de segurança inicial do intervalo
- M^B = valor da margem de segurança final do intervalo
- IMS $\underline{\Delta}$ intervalo da margem de segurança
- k = índice que indica o k -ésimo intervalo
- $Mmin$ = margem de segurança mínima preestabelecida
- $Mmax$ = margem de segurança máxima preestabelecida
- Y $\underline{\Delta}$ vetor saída da rede neural ARTMAP Euclidiana (entrada do módulo ARTb)
- IMS_k = vetor correspondente ao k -ésimo intervalo da margem de segurança associada à contingência representada em código binário
- $Ncmin$ = número mínimo de membros que uma categoria, formada na fase de treinamento, deve conter para ser considerada eficiente para realizar uma boa predição
- $Nmin$ = número mínimo de membros que uma categoria indexada como “indeterminada” deve conter para ser definida como “novidade”

N_{max} = número máximo de iterações que uma categoria indexada como “indeterminada”, sem ter atingido N_{min} , deve aguardar para ser rejeitada como nova informação e eliminada do processo.

Sumário

1	Introdução	1
2	Modelo do Sistema	6
2.1	Introdução	6
2.2	Modelo da Máquina Síncrona	8
2.3	Modelo do Sistema Referido ao Centro de Ângulos	12
2.4	Conclusão	15
3	Análise de Estabilidade Transitória	16
3.1	Introdução	16
3.2	Margem de Segurança	17
3.3	Critério e Algoritmo de Análise da Estabilidade Transitória	19
3.4	Conclusão	21
4	Redes Neurais Artificiais	22
4.1	Introdução	22
4.2	Inspiração Biológica	23
4.3	Histórico	25
4.4	Modelo Artificial	26
4.5	Características Gerais das Redes Neurais	29
4.5.1	Estrutura da Rede Neural	30
4.5.2	Treinamento da Rede Neural	31
4.6	Regras de Adaptação dos Pesos	33
4.6.1	Aprendizagem pela Regra de Hebb	34
4.6.2	Aprendizagem pela Regra de Delta	35
4.6.3	Aprendizagem Competitiva	35

4.7	Conclusão	36
5	Teoria da Ressonância Adaptativa.....	37
5.1	Introdução.....	37
5.2	Redes Baseadas na Teoria da Ressonância Adaptativa.....	38
5.3	Características Básicas dos Sistemas ART.....	40
5.4	Algoritmo ART Nebuloso	44
5.5	Representação Geométrica do Algoritmo ART Nebuloso	47
5.6	Algoritmo ARTMAP Nebuloso	51
5.7	Conclusão	53
6	Rede Neural ARTMAP Baseada na Distância Euclidiana.....	54
6.1	Introdução.....	54
6.2	ARTMAP Euclidiana	55
6.3	Conclusão	60
7	Análise de Estabilidade Transitória: Solução Proposta via Rede	61
	Neural ARTMAP Euclidiana	
7.1	Introdução.....	61
7.2	Estímulos de Entrada.....	62
7.3	Estímulos de Saída	65
7.4	Representação Esquemática do Trabalho Proposto.....	70
7.5	Conclusão	74
8	Algoritmo de Execução do Treinamento Continuado	75
8.1	Introdução.....	75
8.2	Algoritmo de Execução do Treinamento Continuado	75
	8.2.1 Critério para inclusão e rejeição dos dados	76
8.3	Conclusão	78
9	Aplicação.....	79

9.1	Introdução.....	79
9.2	Configuração do Sistema.....	79
9.3	Resultados Considerando o Treinamento Continuado	89
9.3	Conclusão	92
10	Conclusão e Sugestões Para Trabalhos Futuros	93
10.1	Conclusão	93
10.2	Sugestões para Trabalhos Futuros	94
11	Referências Bibliográficas.....	96
Apêndice A	Algoritmo Computacional para a Determinação da Margem de Segurança	103
Apêndice B	Dados do Sistema de Energia Elétrica.....	105
Apêndice C	Artigos Publicados Relacionados com a Pesquisa de..... Doutorado	110

Capítulo 1

Introdução

A análise de estabilidade (de ângulo e de tensão) constitui-se num importante procedimento de investigação em sistemas elétricos de potência. Ela tem por objetivo analisar e executar estratégias que visem garantir o suprimento de energia com qualidade e, ainda, evitar, ou pelo menos, minimizar a interrupção do fornecimento de energia aos consumidores. A estabilidade associadas aos ângulos corresponde à estabilidade transitória que consiste na avaliação dos efeitos procedentes de perturbações que causam grandes e indesejáveis oscilações nos ângulos das máquinas síncronas [Pai, 1981]. Esta análise pode ser realizada através das soluções das equações diferenciais não-lineares que descrevem a dinâmica 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, constituindo-se na rotina conhecida como simulação [Stott, 1979]. As técnicas utilizadas para a simulação são precisas e não apresentam restrições quanto ao tipo de modelo empregado. Porém, demandam um tempo de CPU considerável, tendo em vista que envolve cálculos complexos. Também, via de regra, fornece somente a informação qualitativa, ou seja, o sistema é estável ou é instável para uma determinada contingência. Este tipo de informação nem sempre é útil à operação, principalmente nos casos instáveis em que se faz necessária a adoção de medidas preventivas (realocação de geração, corte de carga, etc.), as quais são quantificadas em função do conhecimento de quanto (informação quantitativa) é instável o sistema.

Um procedimento alternativo consiste na obtenção da análise sem resolver tais equações diferenciais. Neste contexto, encontra-se o Método Direto de Lyapunov (MDL), cujos resultados são considerados satisfatórios quando se emprega, principalmente, o modelo clássico [Pai, 1981].

Tendo em vista a grande quantidade de defeitos a serem analisados, a complexidade e a grande dimensão dos atuais Sistemas de Energia Elétrica (SEE), a simulação, assim como o método direto de Lyapunov, são alternativas que ainda não

oferecem totais condições para aplicações em tempo-real. Novas abordagens de análise, baseadas na inteligência artificial, em especial as redes neurais, 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) na análise da estabilidade transitória de SEE. As contingências consideradas neste trabalho são defeitos de curto-circuito trifásico equilibrado com saída de linha de transmissão. Esta proposta permite, ainda, considerar várias topologias da rede elétrica que, certamente, é um cenário mais plausível, do ponto de vista da operação, se comparado a uma única topologia como comumente é adotado na literatura. Trata-se, por conseguinte, de um procedimento inovador, no contexto de aplicações de redes neurais, se comparado às demais propostas atualmente disponíveis.

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*). 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. Ressalta-se que na literatura especializada encontram-se poucas referências que abordam o problema da análise de estabilidade através do emprego de redes neurais [Marchiori et al., 2002; Minussi et al., 2001; Pao & Sobajic, 1991; Silveira et al., 2003], entre outras referências.

Desta forma, pretende-se investigar o uso da rede neural ARTMAP Euclidiana [Vuskovic & Du, 2002a]. Esta rede faz parte de um conjunto de propostas (ART, ART1, ART2 e ARTMAP) [Carpenter et al., 1992] destinadas à classificação de padrões binários e/ou analógicos, com treinamento supervisionado ou não-supervisionado. A rede ARTMAP é uma arquitetura baseada no treinamento supervisionado para mapeamentos multientradas e multisaídas. A rede ART (*Adaptive Resonance Theory*) [Carpenter et al., 1992] 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 com relação aos padrões anteriores). A rede ARTMAP Euclidiana foi proposta na literatura como alternativa para superar algumas dificuldades operacionais encontradas nas redes neurais da família ART. Os dados de entrada para a rede, diferente da rede neural ARTMAP, não são necessariamente normalizados e codificados, o que reduz, à metade, a dimensão do vetor de entrada e diminui o tempo de execução do treinamento e análise. A precisão dos resultados também é melhorada com essa concepção, pois a representação geométrica das categorias da rede neural, que antes era de hiper-retângulos, passa a ser

representada por círculos, que, em muitos casos, pode ser a melhor forma para agrupar dados. Outra vantagem do emprego desta estrutura neural, refere-se à propriedade de realização do treinamento de forma continuada. Com este recurso, a rede neural pode ser treinada de modo *off-line*, considerando um conjunto de pares treinados gerado por um programa computacional “professor”, e permanentemente atualizado o treinamento, a partir de bases de dados ou dados simulados junto as empresas do setor elétrico. Este procedimento, a princípio pode ser implementado, via redes neurais da família ART, tendo em vista que é uma arquitetura plástica e de funcionamento (treinamento, treinamento continuado e análise) com tempo de execução baixíssimo, sendo, portanto, compatível com aplicações *on-line*. Visando ilustrar o método proposto apresentam-se os resultados considerando-se um sistema multimáquinas.

Nesta tese de doutorado será dada uma atenção especial ao desenvolvimento da rede neural, como anteriormente esboçada, 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. Assim sendo, as principais contribuições desta pesquisa podem ser resumidas nos seguintes itens:

1. desenvolvimento de uma metodologia neural para análise de estabilidade transitória, baseada na rede neural ARTMAP Euclidiana. Esta arquitetura tem proporcionado a obtenção de resultados mais precisos e mais rápidos, em comparação à arquitetura ARTMAP nebulosa [Silveira, 2003]. A maior rapidez se observa por usar vetores padrões de entrada de dimensão equivalente a 50% da dimensão de tais vetores usados na versão ARTMAP nebulosa, ou seja, não há necessidade de duplicação da dimensão como estabelecida na rotina “codificação complementar” da família ART nebulosa;
2. são consideradas as análises de sistemas para diferentes topologias e diferentes perfis de geração / carga do sistema. Esta representação possibilita a análise de sistemas de forma mais realista, em comparação aos habituais procedimentos adotados na literatura especializada;
3. é proposto, também, um esquema que permite contemplar o treinamento continuado, ou seja, o treinamento é realizado considerando-se um pequeno conjunto de dados, o suficiente para que a rede neural tenha atingido o aprendizado de forma satisfatória. Posteriormente, durante o processo de análise, a intensificação do treinamento será efetivada, através de um mecanismo similar à adaptação de pesos na fase de treinamento,

toda vez que o algoritmo “julgar” importante a inclusão de novos padrões na base de dados sinápticos (memória neural). Acredita-se que este mecanismo permitirá realizar a análise de estabilidade transitória em tempo real considerando-se modelos mais elaborados, se comparados ao modelo clássico, por exemplo, o modelo completo de Park [Anderson & Fouad, 2003]. Com isto poderá ser possível gerar funções complexas (índices de estabilidade), também, por meio de uma segunda rede neural, que contemple a composição da informação quantitativa (algum índice baseado na margem de segurança) e da informação qualitativa fornecida, por exemplo, por processo de simulação. Na simulação, a informação produzida constitui-se na indicação de que certa contingência, associada à determinada topologia, perfil de geração e carga, é estável ou é instável. Daí decorre o fato de ser uma técnica de análise qualitativa.

Assim sendo, este texto está organizado em capítulos e apêndices, cujos conteúdos são assim descritos:

- Capítulo 2.* Apresentar-se-á o modelo dinâmico, com vistas à análise de estabilidade transitória de sistemas elétricos de potência, representado pelo modelo clássico.
- Capítulo 3.* Será apresentado o critério de análise da estabilidade transitória baseado no conceito de energia total do sistema.
- Capítulo 4.* Serão apresentados os principais conceitos sobre redes neurais artificiais.
- Capítulo 5.* Serão abordados os principais conceitos sobre as redes neurais baseadas na teoria da ressonância adaptativa.
- Capítulo 6.* Será apresentada a formulação da rede neural ARTMAP baseada na distância Euclidiana que constitui o conteúdo principal desta pesquisa.
- Capítulo 7.* Serão estabelecidas as entradas e saídas que serão usadas no treinamento da rede neural ARTMAP Euclidiana.
- Capítulo 8.* Será apresentada uma proposta para a realização do treinamento continuado, baseado no conceito de detecção de novidade, bem como de anomalia, no contexto das redes neurais ART descendentes.

Capítulo 9. Apresentar-se-ão os resultados da análise da estabilidade transitória, através da rede neural ARTMAP Euclidiana, considerando-se uma versão do sistema da região sul do Brasil, composta por 45 barras, 73 linhas de transmissão e 10 máquinas síncronas.

Capítulo 10. Serão apresentadas as conclusões.

Capítulo 11. Encontram-se relacionadas as referências bibliográficas.

Apêndice A. É apresentado o algoritmo computacional para o cálculo da margem de segurança.

Apêndice B. Dados do Sistema Teste (versão do sistema elétrico de potência da região sul do Brasil).

Apêndice C. Trabalhos completos publicados que estão relacionados com a pesquisa de doutorado.

Capítulo 2

Modelo do Sistema

2.1 Introdução

Apresenta-se, neste capítulo, o modelo que descreve a dinâmica do sistema de energia elétrica, considerando-se as grandes oscilações (grande aumento de carga, perda de equipamento elétrico, curto-circuito, etc.). Trata-se do modelo da máquina síncrona e sua integração ao sistema. Este modelo é representado por equações algébricas e diferenciais não-lineares. A análise deste modelo permite inferir sobre a estabilidade do sistema. Os defeitos a serem considerados são curtos-circuitos trifásicos combinados com a saída das linhas sob defeito. Esta idealização é baseada na observação de que um curto-circuito causado por descarga atmosférica, que incide sobre o sistema de transmissão, ocorre em linha exposta, visto que os demais equipamentos encontram-se protegidos. Deste modo, quando ocorrer este evento, para fins de simplificação, transfere-se o defeito para o barramento mais próximo. A eliminação do defeito consiste, então, na retirada de operação, via proteção do sistema, da linha onde ocorreu a descarga atmosférica que rompeu o isolamento e provocou o curto-circuito. O curto-circuito trifásico é adotado por ser o mais severo, ainda que a sua ocorrência seja a mais rara entre todos os tipos de curtos-circuitos. Considerando-se o caso mais severo, permite efetuar a análise para a situação mais crítica.

O objetivo desta pesquisa é investigar a aplicação de redes neurais artificiais (rede neural da família ART [Carpenter et al., 1992]) para a realização da análise de estabilidade transitória, mais especificamente, a rede neural ARTMAP Euclidiana [Vuskovic & Du, 2002a]. Considera-se a análise de estabilidade de primeira oscilação onde se pode empregar o chamado modelo clássico [Anderson & Fouad, 2003; Pai, 1981; Fouad & Vittal, 1992; Pavella et al., 2000]. A opção por esta abordagem mais simples de modelo 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 utilizam os métodos diretos de análise, mais especificamente, os métodos de energia [EPRI, 1981; Pai, 1981; Fouad & Vittal, 1992]. 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 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, etc., tudo isto efetuando uma simulação por vez.

Em vista disto, nesta pesquisa, será abordado o problema da análise de estabilidade transitória através de redes neurais, levando-se em conta o modelo clássico. Os dados de entrada e de saída serão fornecidos por um programa computacional que foi implementado baseado na proposta apresentada na referência [Fonseca & Decker., 1985], que é uma metodologia que emprega a resolução das equações diferenciais (método indireto) e o método da energia (método direto). Este método é, portanto, híbrido e iterativo pois fornece o cálculo da margem de segurança (e o tempo crítico) do sistema para uma lista preestabelecida de contingências. Os resultados são bastante precisos, cujos erros observados são apenas procedentes de arredondamentos e da tolerância adotada.

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.

Quando se emprega o modelo clássico e um método de análise fundamentado na função energia do sistema, a representação dos ângulos das máquinas síncronas, referidas ao Centro de Ângulos (CA) [Epri, 1981; Pai, 1981; Fouad & Vittal, 1992], constitui a melhor opção [Athay et al., 1979], visto que as perdas elétricas, que são o grande obstáculo para a aplicação dos métodos da energia, podem ser mais facilmente incorporadas no modelo. Esta será, então, a alternativa a ser seguida nesta pesquisa.

2.2 Modelo da Máquina Síncrona

Consideração 1. Defeito. Considera-se, nesta pesquisa, defeito como sendo um curto-circuito trifásico, equilibrado, metálico e incidente em um barramento do sistema, cuja extinção dar-se-á com a retirada definitiva de operação de uma linha de transmissão (ou seja, não retornando mais à operação), por meio da atuação do sistema de proteção com a abertura de relés.

Assim sendo, as equações que descrevem o comportamento dos geradores são conhecidas como equações de oscilação. São equações diferenciais que consideram, por exemplo, as posições angulares das máquinas, a velocidade de resposta ao distúrbio, se este for equilibrado ou desequilibrado [Elgerd, 1971].

Considere, portanto, um sistema composto de ng máquinas síncronas, sendo que PT_i é a potência mecânica do eixo da turbina e PG_i é a potência elétrica gerada. Se estas duas potências forem iguais, desprezadas as perdas, o gerador estará funcionando com velocidade síncrona constante [Elgerd, 1971]. Caso contrário, se existir uma diferença, esta diferença será usada para mudar a energia cinética ou a velocidade e dominar o conjugado de amortecimento nos enrolamentos de amortecimento.

A equação matemática de acordo com as referências [Elgerd, 1971], [Kundur, 1994] e [Venikov, 1970] pode ser expressa como:

$$PT_i - PG_i = \frac{d}{dt}(Wcin_i) + Pd_i \quad (2.2.1)$$

sendo:

$Wcin_i$ \triangleq energia cinética total do gerador mais turbina

$$= \left(\frac{f_i}{f^0} \right)^2 Wcin_i^0; \quad (2.2.2)$$

f^0 = frequência nominal do sistema;

Pd_i = potência referente às perdas;

$Wcin_i^0$ = energia cinética da i -ésima máquina síncrona medida na frequência nominal.

A frequência f_i pode ser expressa, considerando-se as variações em torno da frequência nominal, da seguinte forma:

$$f_i = f^0 + \Delta f_i. \quad (2.2.3)$$

Então:

$$\begin{aligned} Wcin_i &= \left(\frac{f^0 + \Delta f_i}{f^0} \right)^2 Wcin_i^0 \quad (2.2.4) \\ &= \left\{ 1 + 2 \frac{\Delta f_i}{f^0} + \left(\frac{\Delta f_i}{f^0} \right)^2 \right\} Wcin_i^0. \end{aligned}$$

Como as variações de frequência Δf_i são pequenas, pode-se usar a seguinte aproximação:

$$Wcin_i \cong \left\{ 1 + 2 \frac{\Delta f_i}{f^0} \right\} Wcin_i^0. \quad (2.2.5)$$

A derivada temporal da energia cinética total da i -ésima máquina síncrona pode ser expressa por [Elgerd, 1971]:

$$\frac{d}{dt}(Wcin_i) = \frac{2Wcin_i^0}{f^0} \frac{d}{dt} \Delta f_i. \quad (2.2.6)$$

Como [Elgerd, 1971]:

$$\Delta f_i = \frac{1}{2\pi} \frac{d}{dt} (\Delta \delta_i) \quad (2.2.7)$$

então:

$$\frac{d}{dt} \Delta f_i = \frac{d^2}{dt^2} \left\{ \frac{1}{2\pi} \Delta \delta_i \right\} \quad (2.2.8)$$

$$= \frac{1}{2\pi} \frac{d^2 \delta_i}{dt^2} \quad (2.2.9)$$

sendo:

δ_i = posição angular do rotor em relação a uma referência que gira de modo síncrono.

Substituindo (2.2.9) em (2.2.6), obtém-se:

$$\frac{d}{dt}(Wcin_i) = \frac{Wcin_i^0}{\pi f^0} \frac{d^2 \delta_i}{dt^2}. \quad (2.2.10)$$

Deve-se observar que, havendo desvios da velocidade do rotor em relação à velocidade síncrona, haverá a indução de correntes nos enrolamentos de amortecimento do rotor, as quais causam forças que tendem a impedir os movimentos. Este conjugado tende a crescer com a velocidade relativa $\frac{d\delta_i}{dt}$, de tal forma que [Elgerd, 1971]:

$$Pd_i \approx D_i \frac{d\delta_i}{dt} \quad (2.2.11)$$

sendo:

D_i = um parâmetro positivo da máquina, denominado constante de amortecimento do rotor.

Considerando as equações (2.2.10) e (2.2.11), a equação (2.2.1) pode ser escrita da seguinte forma:

$$PT_i - PG_i = \frac{Wcin_i^0}{\pi f^0} \frac{d^2\delta_i}{dt^2} + D_i \frac{d\delta_i}{dt}. \quad (2.2.12)$$

Colocando a equação (2.2.12) em pu (por unidade), uma vez que é dada em MW, cuja base adotada é a potência nominal da i -ésima máquina síncrona, tem-se [Elgerd, 1971]:

$$Pm_i - Pe_i = \frac{H_i}{\pi f^0} \frac{d^2\delta_i}{dt^2} + D_i \frac{d\delta_i}{dt} \quad (2.2.13)$$

sendo:

H_i \triangleq constante de inércia definida por:

$$= \frac{Wcin_i^0}{Pr_i}; \quad (2.2.14)$$

Pm_i \triangleq potência mecânica de entrada (pu)

$$= \frac{PT_i}{Pr_i}; \quad (2.2.15)$$

Pe_i \triangleq potência elétrica de saída (pu)

$$= \frac{PG_i}{Pr_i};$$

Pr_i = potência nominal total da i -ésima máquina síncrona.

Adaptando-se estas equações ao modelo clássico, e desconsiderando o amortecimento, tem-se as seguintes equações, apresentadas na Seção 2.3, que descrevem o comportamento dinâmico das máquinas síncronas referidas ao Centro de Ângulos.

2.3 Modelo do Sistema Referido ao Centro de Ângulos

O comportamento dinâmico da i -ésima máquina pode ser descrito pela seguinte equação diferencial (equação de oscilação da máquina síncrona) [Anderson & Fouad, 2003; Pai, 1981]:

$$M_i \frac{d^2 \theta_i}{dt^2} - g_i(\boldsymbol{\theta}) = 0, \quad i \in NG \quad (2.3.1)$$

sendo:

$$g_i(\boldsymbol{\theta}) = Pm_i - Pe_i - (M_i PCOA) / MT; \quad (2.3.2)$$

$$M_i = \frac{2H_i}{\omega_s};$$

$$\omega_s \triangleq \text{velocidade síncrona (rad. elét./s)}$$

$$= 2\pi f^0;$$

$$\theta_i \triangleq \text{ângulo do rotor da } i\text{-ésima máquina síncrona referida ao CA (rad. elét.)}$$

$$= \delta_i - \delta^0;$$

$$\delta_i = \text{ângulo do rotor da } i\text{-ésima máquina síncrona medida com relação a uma máquina que gira à velocidade síncrona (rad. elét.);}$$

$$\delta^0 = \sum_{j \in NG} M_j \delta_j;$$

$PCOA \triangleq$ potência acelerante do CA

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

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

$$NG \triangleq \{1, 2, \dots, ng\}$$

= conjunto de índices das máquinas que compõem o sistema;

ng = número de máquinas síncronas.

A potência elétrica usada na equação (2.3.2), considerando-se as simplificações introduzidas no modelo clássico, pode ser calculada de várias formas. Uma delas e mais comum consiste em realizar o cálculo, a partir da matriz de admitância reduzida às barras internas de geração, como proposto em [Anderson & Fouad, 2003; Pai, 1981]. Trata-se de um procedimento rápido do cálculo da potência elétrica, principalmente, quando esta se refere à condição de defeito (período de permanência do curto-circuito) e pós- defeito (eliminação do defeito com saída da linha de transmissão), empregando o método proposto na referência [Minussi & Freitas Filho, 1998].

O modelo do sistema referido ao centro de ângulos (equação (2.3.1)) apresenta as seguintes propriedades:

Propriedade 1. A potência acelerante do centro de ângulos, quando calculada no ponto de equilíbrio estável, é nula [Pai, 1981; Minussi, 1990].

Propriedade 2. O somatório do produto da posição angular θ pela inércia de cada máquina síncrona do sistema é igual a zero, ou seja [Pai, 1981; Minussi, 1990]:

$$\sum_{j \in NG} M_j \theta_j = 0. \quad (2.3.3)$$

Propriedade 3. O somatório do produto da velocidade angular ω pela inércia de cada máquina síncrona do sistema é igual a zero, ou seja [Pai, 1981; Minussi, 1990]:

$$\sum_{j \in NG} M_j \omega_j = 0. \quad (2.3.4)$$

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 representa a obtenção de um ponto de operação (equilíbrio). Deste modo, conclui-se que a *PCOA* é nula quando avaliada em um ponto de operação estável do sistema. A *PCOA* será diferente de zero sempre que houver deslocamento do estado em torno do ponto de equilíbrio, ou seja, durante as oscilações eletromecânicas.

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 $(ns - 2)$ variáveis de estado do sistema permite o cálculo das duas variáveis restantes utilizando-se as equações (2.3.3) e (2.3.4).

Estas propriedades serão úteis na determinação da função energia total do sistema, como será abordada no Capítulo 3.

Outras definições e termos utilizados em problemas de estabilidade de sistemas de energia elétrica podem ser encontrados na referência [IEEE Task Force, 1982]. Trata-se de um importante texto de referência nesta área de conhecimento.

2.4 Conclusão

Foi apresentado, neste capítulo, o modelo clássico que representa a dinâmica das máquinas síncronas em sistemas interligados. Este modelo visa inferir sobre a análise de estabilidade transitória de sistemas elétricos de potência no período conhecido como de primeira oscilação. Este modelo encontra-se referido ao centro de ângulos que é uma forma bastante adequada e pertinente, quando se emprega metodologia de análise via métodos diretos (ou similares), pois permite a inclusão dos efeitos das perdas. No modelo clássico, com redução às barras internas de geração, estas perdas representam as perdas procedentes dos equipamentos elétricos, principalmente da transmissão, e de uma parcela importante referente às cargas. Neste caso, não considerá-las resultarão em erros significativos a ponto de prejudicar ou invalidar as análises. Portanto, a inclusão destas perdas é um item de grande importância.

Este modelo será utilizado nos próximos capítulos em que será apresentado o método de análise e serão realizadas as simulações, com o propósito de gerar as informações de entrada e saída para a execução do treinamento da rede neural.

Capítulo 3

Análise de Estabilidade Transitória

3.1 Introdução

A análise de estabilidade transitória de sistemas de energia elétrica tem como objetivo verificar o comportamento destes sistemas, após a ocorrência de uma perturbação do tipo curto-circuito, desligamento de linha de transmissão, perda de unidades geradoras, etc. Esta análise pode ser realizada, por exemplo, via simulação passo a passo no domínio do tempo, o que requer a solução de dois conjuntos de equações provenientes da modelagem dos diversos componentes do sistema: um conjunto de equações diferenciais que descrevem basicamente os geradores síncronos e seus controles; e um conjunto de equações algébricas que representam os estatores das máquinas síncronas, rede de transmissão e cargas.

Atualmente, a simulação através da integração numérica é a melhor ferramenta disponível, por permitir a representação de modelos mais abrangentes e fornecer resultados confiáveis. As limitações ficam por conta do esforço computacional envolvido e pela ausência de resultados que informem o grau de estabilidade ou instabilidade.

Outras alternativas de análise são os métodos diretos de resolução, que exigem menor custo computacional, mas por outro lado, têm como desvantagem a dificuldade de modelar os vários componentes do sistema.

Neste capítulo, apresenta-se o conceito de margem de segurança, que é um índice que aponta o grau de estabilidade ou instabilidade do sistema após a ocorrência de uma falha, o critério e algoritmo para a análise de estabilidade transitória, baseada em uma metodologia híbrida que combina o Método Direto de Lyapunov (MDL) e a resolução das equações diferenciais, considerando defeito correspondente a um curto-circuito com saída de operação de linha de transmissão.

3.2 Margem de Segurança

O diagnóstico da estabilidade transitória de Sistemas de Energia Elétrica, considerando-se uma contingência de índice r , pode ser efetuado através do emprego do conceito da margem de segurança definida por [Fonseca & Decker, 1985; Fouad & Vittal, 1992]:

$$M_r = \frac{E_{crit_r} - Ee_r}{E_{crit_r}} \quad (3.2.1)$$

sendo:

E_{crit_r} = energia total crítica do sistema;

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

A margem de segurança pode ser interpretada como uma “medida de distância” em relação à situação de instabilidade do sistema [Freitas Filho, 1996]. A estabilidade do sistema para a r -ésima contingência pode ser avaliada, mediante o emprego do conceito da margem de segurança, através do seguinte critério [Athay et al., 1979; Fonseca & Decker, 1985; Freitas Filho, 1996; Minussi, 1990; Minussi & Freitas Filho, 1998]:

- $M_r < 0$, o sistema é *instável* do ponto de vista da estabilidade transitória;
- $M_r \geq 0$, o sistema é *estável* do ponto de vista da estabilidade transitória.

Ressalta-se que, quando são consideradas as condutâncias de transferência, a expressão (2.3.2) não se caracteriza como força potencial [Minussi, 1990], conseqüentemente, não é possível determinar uma função energia potencial do sistema – representada pela primeira integral do movimento – que se constitui dependente do caminho de integração, descaracterizando-a como energia potencial. Porém, por abuso de linguagem, nesta pesquisa,

o termo energia total do sistema será utilizado sempre que houver referência à função tipo energia. Por conseguinte, a energia total relativa ao sistema (2.3.1) é dada por [Athay et al., 1979; Pai, 1981; Fonseca & Decker, 1985; Minussi, 1990; Freitas Filho, 1996; Minussi & Freitas Filho, 1998]:

$$E(\boldsymbol{\theta}, \boldsymbol{\omega}) = E_c(\boldsymbol{\omega}) + E_p(\boldsymbol{\theta}) \quad (3.2.2)$$

sendo:

$E_c(\boldsymbol{\omega}) \triangleq$ energia cinética

$$= \frac{1}{2} \sum_{i \in NG} M_i \omega_i^2 ; \quad (3.2.3)$$

$E_p(\boldsymbol{\theta}) \triangleq$ energia potencial

$$= - \sum_{i \in NG} \int_{\theta_i^p}^{\theta_i} g_i(\boldsymbol{\theta}) d\theta_i . \quad (3.2.4)$$

O superescrito (p) refere-se ao ponto de equilíbrio pós-defeito e $g_i(\boldsymbol{\theta})$ é dada pela equação (2.3.2).

Desenvolvendo a expressão referente a energia potencial, obtém-se [Minussi, 1990; Freitas Filho, 1996]:

$$E_p(\boldsymbol{\theta}) = - \sum_{i \in NG} \int_{\theta_i^p}^{\theta_i} P m_i d\theta_i + \sum_{i \in NG} \int_{\theta_i^p}^{\theta_i} P e_i d\theta_i + \sum_{i \in NG} \int_{\theta_i^p}^{\theta_i} (M_i / MT) PCOA d\theta_i . \quad (3.2.5)$$

Como a potência mecânica é considerada constante (desconsidera-se a ação do regulador de velocidade) e utilizando-se da Propriedade 3 (o terceiro membro de (3.2.5) torna-se nulo) a energia total do sistema é dada por [Athay, 1979; Fonseca & Decker, 1985; Pai, 1981; Minussi, 1990]:

$$E(\boldsymbol{\theta}, \boldsymbol{\omega}) = \frac{1}{2} \sum_{i \in NG} M_i d\theta_i + \sum_{i \in NG} P m_i (\theta_i - \theta_i^p) d\theta_i + \sum_{i \in NG} \int_{\theta_i^p}^{\theta_i} P e_i d\theta_i . \quad (3.2.6)$$

Observa-se que, em função da consideração das condutâncias de transferência, a função energia total do sistema (equação (3.2.6)) é dependente do caminho de integração [Fonseca & Decker, 1985; Pai, 1981; Minussi, 1990]. Para solucionar este problema, será tomada a seguinte medida: avaliar-se-á a integral à medida que se conhece a evolução dos ângulos das máquinas. Portanto, o caminho de integração entre dois pontos quaisquer é conhecido, assim a integral é facilmente determinada. Esta formulação não introduz erros significativos e a integral é avaliada fazendo-se uso da regra trapezoidal [Fonseca & Decker, 1985].

3.3 Critério e Algoritmo de Análise da Estabilidade Transitória

A energia crítica, energia máxima que o sistema pode acumular para que a sua estabilidade seja preservada, assim como o tempo crítico, são determinados, nesta pesquisa, baseados no algoritmo PEBS (*Potential Energy Boundary Surface*) Iterativo [Athay, 1979, Fonseca & Decker, 1985]. Para efetuar esta metodologia é necessário algum indicativo para que se possa identificar a PEBS como discutido a seguir.

Definição 1. *Derivada Direcional da Energia Potencial* é definida como sendo [Athay, 1979, Fonseca & Decker, 1985]:

$$D(\boldsymbol{\theta}) = -\frac{\langle \mathbf{g}(\boldsymbol{\theta}), (\boldsymbol{\theta} - \boldsymbol{\theta}^P) \rangle}{\|\boldsymbol{\theta} - \boldsymbol{\theta}^P\|_e} \quad (3.3.1)$$

sendo:

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

$$\mathbf{g}(\boldsymbol{\theta}) = [g_1(\boldsymbol{\theta}) \quad g_2(\boldsymbol{\theta}) \quad \dots \quad g_n(\boldsymbol{\theta})];$$

$$g_i(\boldsymbol{\theta}) \triangleq Pm_i - Pe_i - \frac{M_i}{MT} PCOA;$$

$\| \cdot \|_e$ = norma euclidiana.

Definição 2. *Superfície Limite de Energia Potencial* (PEBS em inglês) [Athay, 1979, Fonseca & Decker, 1985] é definida como os pontos correspondentes aos zeros da derivada direcional (3.3.1), excetuando o ponto de equilíbrio estável do sistema.

A PEBS representa, portanto, os pontos dos máximos direcionais da energia potencial, os quais circundam o ponto de equilíbrio estável do sistema [Minussi, 1990].

Propriedade 4. A derivada direcional $D(\theta)$ possui a propriedade de se manter sempre positiva para trajetórias estáveis [Athay, 1979].

A análise de estabilidade transitória, utilizando-se o conceito da PEBS, consiste na determinação de um ponto sobre a trajetória de defeito, por processo iterativo, de tal modo que a evolução da trajetória pós-defeito, que começa neste ponto, encontre a máxima aproximação da superfície limite de energia potencial.

O programa computacional deste método encontra-se implementado no LC (Laboratório Computacional) do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira – UNESP. Trata-se de um programa em linguagem Fortran, versão para microcomputador. Este algoritmo refere-se ao apresentado na referência Fonseca & Decker, 1985. No Apêndice A é apresentado este algoritmo passo a passo.

Deve-se ressaltar que a opção pelo método PEBS, na qualidade de “professor” para o processo de treinamento da rede neural, como será abordado em capítulos subseqüentes, foi motivada por ser uma técnica que se encontra disponível no Laboratório Computacional, é precisa (equiparável à simulação, quando se emprega o modelo clássico) e

rápida. Contudo, a rede neural desenvolvida, nesta pesquisa, não mantém relação de compromisso com o método PEBS. Qualquer outro procedimento pode ser perfeitamente usado para este fim, ficando, apenas a exigência, de pelo menos, ser preciso e que gere um índice qualitativo / quantitativo similar ao associado à margem de segurança como aqui adotado.

3.4 Conclusão

Neste capítulo foi apresentado o critério utilizado como indicativo da estabilidade transitória, fornecendo o conceito de margem de segurança, sendo que, esta fornece-nos uma idéia de quanto o sistema se encontra estável ou instável. Também foram apresentados a metodologia PEBS Iterativa [Fonseca & Decker, 1985] e respectivo algoritmo computacional. Este algoritmo está sendo utilizado com o intuito de obter os estímulos de entrada e saída para o treinamento e diagnóstico da rede neural (rede neural ARTMAP Euclidiana [Vuskovic & Du, 2002a]), que é a metodologia de análise de estabilidade transitória de sistemas de energia elétrica proposta nesta pesquisa.

Capítulo 4

Redes Neurais Artificiais

4.1 Introdução

A simulação de capacidades cognitivas de um ser humano tem sido uma área de pesquisa amplamente investigada. Projetam-se máquinas capazes de exibir um comportamento inteligente, como se fossem reações humanas. A inteligência humana é a mais avançada dentro do universo das criaturas. Essa inteligência, dentro do corpo humano, está localizada no cérebro. As entidades básicas são os neurônios, interconectados em redes o que permitem a troca de informação entre eles, criando a inteligência biológica. Uma ambição óbvia, que surge dessas observações, é a tentativa de copiar a estrutura e o funcionamento do cérebro em um ambiente técnico. Isso significa que a pesquisa tenta entender o funcionamento da inteligência residente nos neurônios e mapeá-la para uma estrutura artificial, por exemplo uma combinação de *hardware* e de *software*, assim transformando as redes neurais biológicas em redes neurais artificiais.

Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência [Simpson, 1989; Wasserman, 1989; Widrow & Lehr, 1990; Kung, 1993; Haykin, 1994; Kartalopoulos, 1996; Jain et al., 1996; Mendes Filho & Carvalho, 1997; King, 1998].

A proliferação, nos últimos anos, de modelos de redes neurais artificiais é bastante significativa. Hoje, a quantidade de modelos inspirados, sob o paradigma neural, é de ordem de dezenas. Sabe-se, entretanto, que os modelos artificiais têm pouco em comum com as redes neurais reais. Por outro lado, existem paralelos entre os dois mundos que prometem que as redes neurais artificiais sejam uma aproximação apropriada para resolver problemas cognitivos complexos.

As redes neurais vêm sendo usadas, com sucesso, na solução de problemas de reconhecimento de padrão, otimização combinatorial, modelagem de sistemas, representação de conhecimento, aproximação de funções, diagnóstico e classificação, monitoramento e controle, processamento de voz e imagem, recuperação de informações, previsão, diagnósticos médicos, composição musical, etc.

Neste capítulo, serão apresentados os principais conceitos sobre a teoria de redes neurais artificiais, com o objetivo de auxiliar a compreensão da metodologia proposta, a ser apresentada nos próximos capítulos, a qual refere-se à análise de estabilidade transitória de sistemas de energia elétrica por redes neurais baseadas na teoria da ressonância adaptativa [Carpenter & Grossberg, 1991c].

4.2 Inspiração Biológica

As mais importantes características do cérebro humano, que o capacitam de um comportamento inteligente, que são especialmente atrativas de serem simuladas em uma rede neural artificial, podem ser resumidas como:

- *Robustez e tolerância a falhas*: a eliminação de alguns neurônios não afeta a funcionalidade global.
- *Capacidade de aprendizagem*: o cérebro é capaz de aprender novas tarefas que nunca foram executadas antes.
- *Processamento de informação incerta*: mesmo que a informação fornecida esteja incompleta, afetada por ruído ou parcialmente contraditória, um raciocínio correto é possível.
- *Paralelismo*: um imenso número de neurônios está ativo ao mesmo tempo. Não existe a restrição de um processador que obrigatoriamente trabalhe uma instrução após a outra.

Uma rede neural artificial é um mecanismo (implementação em *hardware* e/ou *software*) que emula o modo como o cérebro realiza uma tarefa particular ou função de interesse [Haykin, 1994]. A rede neural artificial assemelha-se com o cérebro em dois aspectos: o conhecimento é adquirido pela rede, através de um processo de treinamento ou aprendizado; e as conexões entre os neurônios, conhecidos como pesos sinápticos, são usados para armazenar o conhecimento.

O sistema nervoso é formado por um conjunto bastante complexo de células, os neurônios. Estes neurônios possuem um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio [Haykin, 1994].

O processamento local de informação no cérebro efetua-se em cerca de 100 bilhões de unidades (os neurônios) que possuem uma estrutura relativamente simples. O neurônio é uma célula com *núcleo* e *corpo celular* (*sôma* do idioma grego) em que reações químicas e elétricas representam o processamento de informação. A saída da informação do corpo celular é realizada por impulsos elétricos que se propagam através do *axônio*. No final do axônio existem inúmeras ramificações que distribuem a informação para outros neurônios vizinhos. A ligação com os outros neurônios é realizada através de *sinapses* que estão conectadas a um *dendrito* do neurônio receptor. A sinapse dispara uma substância química quando for excitada pelo impulso do axônio. A substância se transmite entre sinapse e dendrito realizando a conexão entre dois neurônios vizinhos. Conforme as excitações (ou inibições) que células vizinhas transmitem para a célula em consideração ela processa a informação novamente e a transmite via seu axônio [Simpson, 1989; Haykin, 1994; Mendes Filho & Carvalho, 1997]. Na Figura 4.1 apresenta-se o modelo simplificado de um único neurônio biológico e as partes que o compõem. Ressalta-se que, vários tipos de neurônios têm sido identificados, cada qual se distingue dos demais pela forma do corpo celular. Estas diferenças morfológicas exibem especializações funcionais importantes.

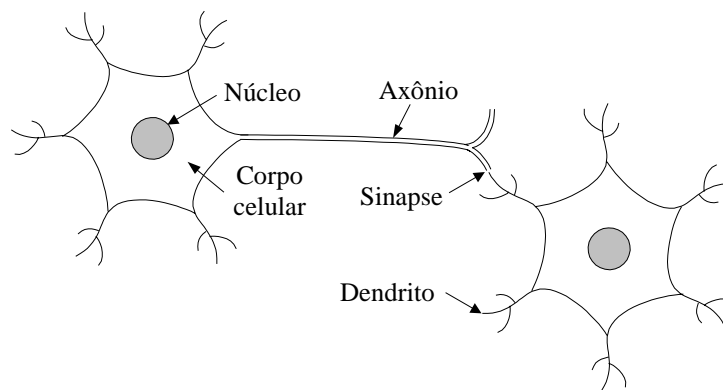


Figura 4.1 – Componentes de um neurônio biológico.

4.3 Histórico

Os estudos de RNA constituem-se num dos maiores ramos da inteligência artificial. O primeiro modelo de neurônio artificial foi formulado pelo neurofisiologista McCulloch e pelo matemático Pitts, em 1943, cujo trabalho fazia uma analogia entre células vivas e o processo eletrônico, simulando o comportamento do neurônio natural, em que o neurônio possuía apenas uma saída, que era uma função de entrada (*threshold*) da soma do valor de suas diversas saídas [Haykin, 1994; Mendes Filho & Carvalho, 1997]. Em 1949 o psicólogo Donald Hebb, demonstrou que a capacidade da aprendizagem em redes neurais vem da alteração da eficiência sináptica, i.e., a conexão somente é reforçada, se tanto as células pré-sinápticas quanto as pós-sinápticas estiverem excitadas [Tutorial, 2005]. Hebb foi o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios, servindo de inspiração para que muitos outros pesquisadores perseguissem a mesma idéia.

Em 1958 Roseblatt desenvolveu o *perceptron*, que é uma das estruturas neurais mais empregadas na literatura especializada. Nesse modelo, os neurônios estão organizados em camada de entrada e saída, em que os pesos das conexões são adaptados a fim de se atingir a eficiência sináptica [Tutorial, 2005]. No ano de 1960 surgiu a rede *ADALINE* (*ADaptive Linear NEtwork*) e a rede *MADALINE* (*Many ADALINE*), proposta por Widrow e Hoff. Na rede *MADALINE* foram usadas saídas analógicas em uma arquitetura de três camadas [Widrow & Lehr, 1990].

Entre as décadas de 60 e 70, poucas pesquisas foram publicadas pelo fato de pouca credibilidade ter sido dada aos estudos desta área, marcada por um entusiasmo exagerado de muitos pesquisadores, que passaram a publicar muitos artigos e livros que faziam uma previsão pouco confiável para a época, sobre máquinas tão poderosas quanto o cérebro humano que surgiriam em um curto espaço de tempo. Porém, alguns pesquisadores que realizaram importantes trabalhos nesse período sobre modelos de redes neurais em visão, memória, controle e auto-organização devem ser citados: Amari, Anderson, Cooper, Cowan, Fukushima, Grossberg, Kohonen e Von der Malsburg.

Em 1974, Werbos apresentou o algoritmo retropropagação (*backpropagation*) que possui a capacidade de treinar redes multicamadas [Werbos, 1974]. Em 1982, o físico e biólogo Hopfield relatou a utilização de redes simétricas para otimização, através de um algoritmo de aprendizagem que estabilizava uma rede binária simétrica com realimentação. Na rede *perceptron*, o modelo de McCulloch-Pitts 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 neurais são aplicáveis, também, para problemas não-lineares, levando as redes neurais a um novo estágio de pesquisa.

Os estudos sobre redes neurais sofreram uma grande revolução a partir dos anos 80. A partir daí, cada vez mais, esta área de estudos tem se destacado, seja pelas promissoras características apresentadas pelos modelos de redes neurais propostos, ou pelas condições tecnológicas atuais de implementação, que permitem desenvolver arrojadas arquiteturas neurais paralelas em *hardware* dedicados, obtendo assim ótimos desempenhos destes sistemas, bastante superiores aos sistemas convencionais.

4.4 Modelo Artificial

Assim como o sistema nervoso (de humanos) é composto por bilhões de células nervosas, a rede neural artificial, também, deve ser formada por unidades que nada mais são que pequenos módulos que simulam o funcionamento de um neurônio biológico. Estes

módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações.

Na Figura 4.2 mostra-se o modelo de um neurônio artificial de McCulloch e Pitts [Haykin, 1994], que foi o primeiro modelo a ser formulado. Este modelo tenta simular as realidades biológicas que ocorrem dentro de uma célula do sistema nervoso (compare com a Figura 4.1). A informação fornecida por outros neurônios consiste em n entradas, x_j , para o neurônio processador. Cada entrada está associada a um peso, w_j , que reflete a importância da entrada x_j . Seu processamento consiste na soma ponderada dos valores de suas entradas, resultando no chamado potencial de ativação. Neste primeiro processamento, os pesos multiplicativos, associados às entradas, emulam o efeito da intensidade das sinapses. Se o peso é positivo diz-se que a conexão é excitatória, caso contrário, ela é dita inibitória [Haykin, 1994; Mendes Filho & Carvalho, 1997]. Quando o potencial de ativação tem valor superior a um limiar de disparo preestabelecido, μ , o neurônio produz um sinal de saída de valor igual a 1. Se a ativação é inferior ao limiar, então a saída gerada tem valor 0. Essa saída será enviada aos demais neurônios.

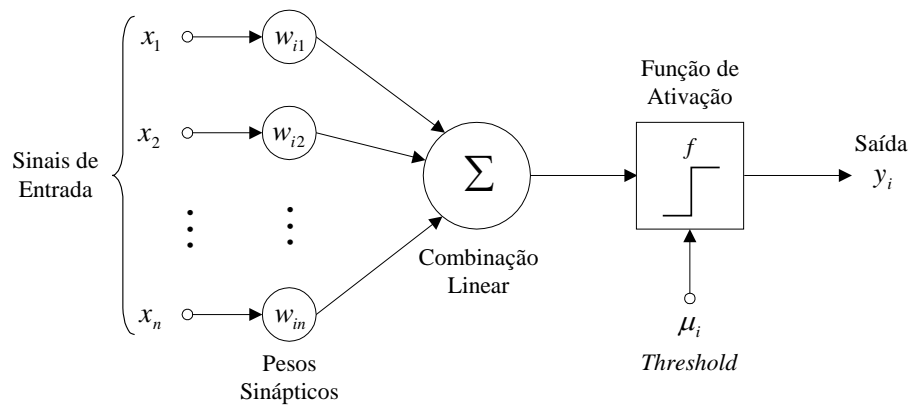


Figura 4.2 – Diagrama esquemático de um neurônio artificial de McCulloch-Pitts.

A saída do i -ésimo neurônio, segundo esse modelo, é expressa como [Kartalopoulos, 1996]:

$$y_i(t+1) = f \left(\sum_{j=1}^n w_{ij} x_j(t) - \mu_i \right) \quad (4.4.1)$$

sendo:

t = instante de tempo em que são observadas as entradas;

w_{ij} = peso da conexão da saída da célula j a entrada desta célula;

x_j = valor da saída da célula j ;

μ_i = limiar de disparo desta célula;

f = função de ativação degrau definida por [Kung, 1993; Kartalopoulos, 1996]:

$$f(a) = \begin{cases} 1, & \text{se } a \geq 0 \\ 0, & \text{se } a < 0 \end{cases} \quad (4.4.2)$$

A unidade de McCulloch-Pitts é o mais popular modelo de neurônio artificial. Mas, assim como existem diversos tipos de neurônios biológicos especializados, de acordo com o tipo de processamento a que se dedicam, também existem diferentes modelos de neurônios artificiais, cada um adequado a um tipo de problema específico.

Uma das modificações mais comuns do neurônio artificial de McCulloch-Pitts é o uso de outras funções de ativação. A função de ativação define a saída de um neurônio, em termos do nível de atividade da sua entrada. A Figura 4.3 mostra alguns exemplos de funções de ativação [Mendes Filho & Carvalho, 1997].

As funções do tipo relé são apropriadas para dados binários, enquanto que as funções sigmoidais podem ser empregadas tanto para dados analógicos como binários. Além disso, as funções sigmoidais apresentam adicionalmente a vantagem de serem diferenciáveis em todos os pontos [Kartalopoulos, 1996].




Figura 4.3 – Exemplos de funções de ativação: (a) Linear por partes; (b) Relé; (c) Sigmoidal.

sendo:

k = constante qualquer;

λ = inclinação da função sigmoidal.

Definiu-se uma entidade de processamento relativamente simples que calcula uma função de saída y , a partir de entradas x_j e dos pesos w_j , com uma função de ativação predefinida. O potencial e flexibilidade do cálculo, baseado em redes neurais, vêm da criação de conjuntos de neurônios que estão interligados entre si. Esse paralelismo de elementos, com processamento local, cria a “inteligência” global da rede. Um elemento da rede recebe um estímulo nas suas entradas, processa esse sinal e emite um novo sinal de saída que, por sua vez, é recebido pelos outros elementos.

4.5 Características Gerais das Redes Neurais

Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior. Usualmente as camadas são

classificadas em três grupos: *camada de entrada*, onde os padrões são apresentados à rede; *camadas intermediárias* ou *escondidas*, onde é feita a maior parte do processamento através das conexões ponderadas; e *camada de saída*, onde o resultado final é concluído e apresentado [Haykin, 1994].

Uma rede neural é especificada, principalmente, pela sua topologia, características dos nós e regras de treinamento. A seguir, será analisada a classificação das redes neurais de acordo com sua estrutura e processos de treinamento.

4.5.1 Estrutura da Rede Neural

As redes neurais podem ser classificadas em dois tipos quanto a sua estrutura, que se refere ao método de propagação da informação recebida [Simpson, 1989; Wasserman, 1989; Haykin, 1994; Kartalopoulos, 1996; Mendes Filho & Carvalho, 1997]:

- *Redes Neurais Recorrentes*. Uma rede é definida como *recorrente* se ela contém laços de realimentação, ou seja, contém conexões das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores.
- *Redes Neurais Não-recorrentes*. Esta rede se caracteriza estruturalmente por estar disposta em camadas. Nestas redes cada camada de neurônios recebe sinais somente das camadas anteriores, ou seja, elas não possuem laços de realimentação.

As redes que possuem uma estrutura recorrente desenvolvem uma memória nos neurônios internos. As redes não-recorrentes ou *feedforward* não possuem memória, sendo que, sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos. A Figura 4.4 ilustra os dois tipos de redes descritos.




Figura 4.4 – Principais topologias de redes neurais artificiais: (a) Rede neural não-recorrente; (b) Rede neural recorrente.

4.5.2 Treinamento da Rede Neural

Uma vez definida a rede neural, essa tem de ser treinada. A propriedade mais importante das redes neurais é a habilidade de aprender e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos que corresponde o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

A maioria dos modelos de redes neurais possui alguma *regra de treinamento*, em que os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos. A rede neural passa por um processo de treinamento a partir de casos reais conhecidos, adquirindo a sistemática necessária para executar adequadamente o processamento desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, em que é necessário um conjunto de regras pré-fixadas e algoritmos.

O processo de treinamento da rede pode ser entendido como um problema de atualização dos pesos de conexão tal que ela possa realizar eficientemente uma tarefa específica. Existem muitos tipos de algoritmos de treinamento específicos para determinados

modelos de redes neurais. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto existem, basicamente, os seguintes paradigmas de treinamento [Kung, 1993; Haykin, 1994]:

- *Treinamento Supervisionado*. Consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada.
- *Treinamento Não-supervisionado*. Consiste no ajuste de pesos de uma rede neural levando-se em conta somente o conjunto de padrões de entrada.
- *Treinamento Híbrido*. Combina treinamento supervisionado e treinamento não-supervisionado. Parte dos pesos são ajustados através do treinamento supervisionado, enquanto outros são obtidos através de treinamento não-supervisionado.

No treinamento supervisionado, a rede neural é treinada com o auxílio de um professor. Para tanto, a rede necessita de um vetor de entrada e vetor alvo representando a saída desejada. Juntos eles são chamados de *par de treinamento*. Toda vez que for apresentada à rede uma entrada, deve-se verificar se a saída obtida (gerada a partir de cálculos efetuados com os pesos que a rede possui) confere com a saída desejada para aquela entrada. Sendo diferente, a rede deverá ajustar os pesos de forma que armazene o conhecimento desejado. Essa iteratividade deverá ser repetida com todo o conjunto de treinamento (entradas e saídas), até que a taxa de acerto esteja dentro de uma faixa considerada satisfatória. Um dos algoritmos mais difundidos para treinamento deste tipo de rede é o algoritmo retropropagação (*backpropagation* no idioma inglês) [Werbos, 1974; Wasserman, 1989; Haykin, 1994; Jain et al., 1996]. Este algoritmo foi proposto por Werbos em 1974 [Werbos, 1974].

O treinamento não-supervisionado não necessita de um alvo para as saídas e, portanto, nenhuma comparação é necessária para respostas predeterminadas. O conjunto de treinamento consiste exclusivamente de vetores de entrada. A rede processa essas entradas e se organiza de modo que acabe classificando-as usando, para isso, seus próprios critérios. Esse tipo de rede utiliza os neurônios como classificadores, e os dados de entrada, como elementos para classificação. O processo de classificação fica por conta da rede neural e o seu algoritmo de aprendizado. A auto-organização demonstrada nas redes neurais não-supervisionadas, envolve o processo de competição e o processo de cooperação entre os neurônios da rede.

A Figura 4.5 ilustra os dois paradigmas de treinamentos mencionados.

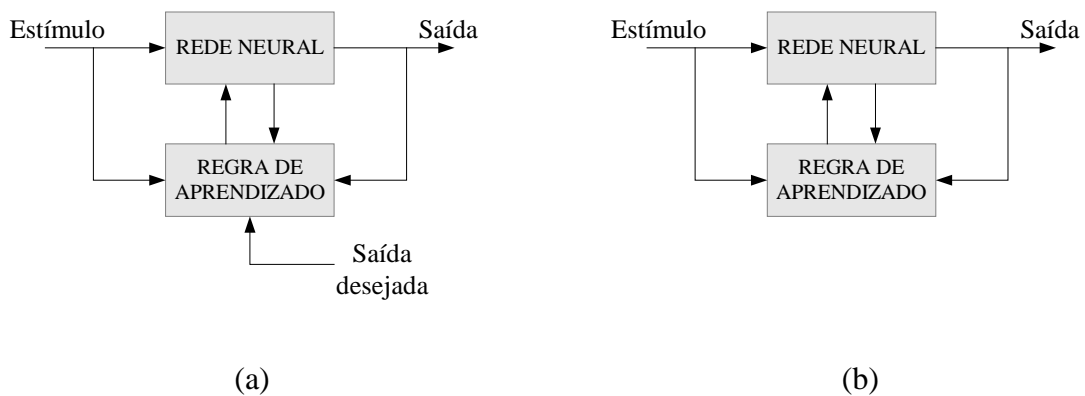


Figura 4.5 – Principais modos de treinamentos de uma rede neural: (a) Treinamento supervisionado; (b) Treinamento não-supervisionado.

4.6 Regras de Adaptação dos Pesos

Durante o processo de aprendizagem os pesos normalmente percorrem uma modificação iterativa. Na iteração l o peso entre o neurônio i e o neurônio j (vide Figura 4.6), $w_{ij}^{(l)}$, influencia a função calculada pela rede. O algoritmo de treinamento julga a qualidade do peso e eventualmente determina se o peso deve sofrer uma modificação $\Delta w_{ij}^{(l)}$ no seu valor na

próxima iteração $l + 1$. Assim, se define a regra básica de adaptação dos pesos [Rauber, 2005]:

$$w_{ij}^{(l+1)} = w_{ij}^{(l)} + \Delta w_{ij}^{(l)}. \quad (4.6.1)$$

Costuma-se iniciar os pesos aleatoriamente. O algoritmo de aprendizagem percorre um número fixo de iterações e/ou até que uma condição de parada seja atingida.




Figura 4.6 – Pesos entre neurônios (caso geral com realimentação).

4.6.1 Aprendizagem pela Regra de Hebb

Um dos trabalhos pioneiros nos estudos de sistemas capazes de adquirir conhecimento foi desenvolvido por Hebb, em 1949. Ele criou uma hipótese de que o peso de ligação entre dois neurônios que estão ativos ao mesmo tempo deve ser reforçado. Essa lei traduz-se para a regra de aprendizagem de Hebb [Rauber, 2005]:

$$\Delta w_{ij} = \eta y_i y_j \quad (4.6.1.1)$$

em que a taxa de aprendizagem η é um fator de escala positivo que determina a velocidade da aprendizagem.

A definição dessa regra baseia-se em estudos biológicos do cérebro, mas como já foi constatada, a correspondência do modelo matemático com a realidade biológica é somente uma idealização aproximada. A regra de Hebb define um algoritmo de adaptação dos pesos, porém sem a definição de um objetivo a atingir, por exemplo, minimizar um erro entre um valor desejado e calculado.

4.6.2 Aprendizagem pela Regra de Delta

A regra de delta, ou regra de Widrow-Hoff, como também é conhecida, é uma regra de adaptação de pesos com um objetivo bem visível [Widrow, 1990]. Um função y_j' é calculada na saída (neurônio j) da rede. O valor desejado y_j que a rede deve calcular é conhecido durante o treinamento supervisionado. Assim, pode-se calcular o erro $e_j = y_j - y_j'$ entre o valor calculado e o valor desejado. O peso entre o neurônio i e o neurônio j que é responsável por esse erro deve ser, então, modificado proporcional à ativação e ao erro, escalado por uma taxa de aprendizagem η [Raubert, 2005]:

$$\Delta w_{ij} = \eta e_j y_i = \eta (y_j - y_j') y_i. \quad (4.6.2.1)$$

Para esta regra, o objetivo do algoritmo de treinamento é minimizar o erro entre os valores calculados pela rede e desejados pelos exemplos fornecidos num problema de aprendizagem supervisionada.

4.6.3 Aprendizagem Competitiva

No treinamento competitivo, consideram-se as redes neurais em que um único neurônio pode ser ativo ao mesmo tempo. Isso significa que somente o *vencedor* i^* emite um sinal de ativação $y_{i^*} = 1$, e todos os outros neurônios têm ativação igual a zero, $y_i = 0$ para $i \neq i^*$. É um aprendizado não-supervisionado, e essa regra pode ser descrita pela seguinte equação, sendo η a taxa de aprendizagem [Raubert, 2005]:

$$\Delta w_{ij} = \eta y_i (x_i - w_{ij}). \quad (4.6.3.1)$$

O efeito dessa regra é que os pesos w_i se deslocam em direção ao estímulo (entrada) da rede, x . Quando o aprendizado competitivo é utilizado, os neurônios competem entre si pelo direito de atualizar seus pesos. Estes algoritmos de aprendizado têm sido mais

usados em problemas que abordam a classificação, a extração de características, a compressão de dados e a formação de *clusters* (agrupamentos). Exemplos de redes neurais que utilizam aprendizagem competitiva para adaptar os pesos são o modelo auto-organizável de Kohonen [Kohonen, 1987] e as redes da família ART [Carpenter & Grossberg, 1991c].

4.7 Conclusão

Neste capítulo, foram apresentados os principais conceitos, envolvendo redes neurais artificiais, a estrutura básica de um neurônio biológico, e as principais características associadas às diferentes estruturas de neurônio artificial. Foram apresentados os principais paradigmas de treinamento e regras de aprendizagem para a adaptação dos pesos da rede. No próximo capítulo, será dada atenção especial a uma classe de redes neurais, as redes baseadas na Teoria da Ressonância Adaptativa [Carpenter & Grossberg, 1991c] que será a essência da pesquisa proposta.

Capítulo 5

Teoria da Ressonância Adaptativa

5.1 Introdução

Um das mais importantes características das Redes Neurais Artificiais (RNA) refere-se a capacidade de generalização, ou seja, produzir respostas para padrões de entradas que são similares, mas não idênticos, aos padrões apresentados à rede durante o seu treinamento. Quando uma rede multicamadas é treinada com o algoritmo retropropagação (*backpropagation*) [Werbos, 1974], *e.g.*, espera-se que ela forneça como resposta a classificação correta correspondente ao padrão de entrada, e que ela continue a responder satisfatoriamente a quaisquer padrões de entrada, dentro do domínio, apresentados futuramente. Entretanto, o conhecimento a respeito de determinado domínio do mundo real pode se modificar ao longo do tempo. O mesmo acontece com os padrões de entrada de uma RNA, que podem modificar com o tempo para acomodar as mudanças ocorridas. Assim, para um número de aplicações, o desempenho da rede pode decair gradativamente à medida que o tempo passa, uma vez que os pesos definidos na fase de treinamento não refletem as novas situações. Para adaptar novos padrões de entrada indefinidamente, um algoritmo de aprendizado de RNA deve ser plástico.

Uma alternativa para solucionar este problema seria retreinar a rede com os novos padrões de entrada. Entretanto, isto pode levar à perda de informações aprendidas anteriormente. Para preservar o conhecimento previamente aprendido, um algoritmo de treinamento de RNA não deve ser somente plástico, mas também estável. Uma outra solução seria retreinar a rede frequentemente com os novos e os antigos padrões. Isto resolveria o problema, mas está longe de representar uma solução viável. Este conflito é conhecido como dilema estabilidade-plasticidade [Carpenter & Grossberg, 1991c].

Sendo assim, é necessário, então, um modelo de RNA incremental, que não precise recomeçar seu treinamento do ponto inicial a cada vez que aparecerem novos padrões de entrada e que preserve o conhecimento adquirido anteriormente. Uma família de RNA denominada ART (*Adaptive Resonance Theory*) [Carpenter & Grossberg, 1991c] foi desenvolvida para solucionar este dilema.

Neste trabalho, faz-se o uso de uma arquitetura neural da Teoria da Ressonância Adaptativa, designada ARTMAP Euclidiana [Vuskovic & Du, 2002a], que é uma generalização da rede ART1 [Carpenter & Grossberg, 1987a]. Sendo assim, a seguir, apresentam-se os principais conceitos sobre redes neurais desta teoria, os quais são a essência da pesquisa proposta.

5.2 Redes Baseadas na Teoria da Ressonância Adaptativa

A origem da Teoria da Ressonância Adaptativa (ART, de *Adaptive Resonance Theory*) pode ser dada a Von der Malsburg, em 1973, que foi um dos primeiros a apresentar uma rede neural artificial com característica auto-organizável para modelagem do córtex visual dos maiores vertebrados, e influenciou o trabalho de Teuvo Kohonen e Steven Grossberg [Anagnostopoulos, 2001]. Para emular a atividade neural organizada em sistemas biológicos sem ter de implementar conexões de realimentação não-lineares, Kohonen desenvolveu o mapa de características auto-organizável, designado rede SOFM (*Self Organizing Feature Map*), com treinamento não-supervisionado [Kohonen, 1982], e posteriormente desenvolveu a arquitetura de quantização de vetores de aprendizagem, LVQ (*Learning Vector Quantization*), com treinamento supervisionado [Kohonen, 1987].

De outro lado, Grossberg levantou questões sobre o dilema estabilidade-plasticidade [Grossberg, 1976]: como pode um sistema treinado permanecer plástico (adaptativo) em resposta a uma nova informação, e ainda permanecer estável em resposta a informações irrelevantes? Como pode um sistema preservar seu conhecimento já adquirido e ao mesmo ser flexível o suficiente para armazenar nova informação? Como pode um sistema decidir quando passar do estado estável ao plástico e vice-versa? Grossberg respondeu a essas questões com a teoria da ressonância adaptativa (ART). Em uma rede baseada na teoria da

ressonância adaptativa, informações são trocadas entre as camadas da rede. O treinamento é possível na rede quando ocorre ressonância da atividade neural, ou seja, quando um padrão já treinado é apresentado e a rede o reconhece; e quando um novo padrão de entrada é apresentado e a rede percebe que o padrão constitui uma nova informação e, então, entra em estado ressonante para memorizá-lo.

Assim, a primeira arquitetura baseada na teoria da ressonância adaptativa é a rede Grossberg, denominada GN (*Grossberg Network*) [Grossberg, 1976]. A rede GN apresenta duas camadas, sendo que a primeira realiza a normalização dos dados de entrada enquanto a segunda, que é uma camada competitiva com conectividade de realimentação não-linear, realiza a seleção dos padrões de saída e os armazena na memória de curto prazo. Adicionalmente, os pesos adaptativos representam a memória de longo prazo do modelo. O comportamento do modelo é descrito por um conjunto de equações diferenciais não-lineares.

Baseado no modelo de Grossberg, GN, a arquitetura ART1 foi desenvolvida para realizar agrupamentos de padrões binários, por Carpenter e Grossberg em 1987, realizando o treinamento não-supervisionado [Carpenter & Grossberg, 1987a]. A partir de então, a arquitetura ART1 tornou-se o mais famoso modelo da família ART, em termos de pesquisa relacionada e aplicações. No mesmo ano, 1987, ART1 foi estendida para manipular padrões com valores reais e a arquitetura foi designada ART2 [Carpenter & Grossberg, 1987b]. A rede ARTMAP, composta por dois módulos ART1, foi a primeira arquitetura baseada na teoria da ressonância adaptativa apropriada para a tarefa de classificação, apresentando treinamento supervisionado [Carpenter et al., 1991a]. Numa concepção diferenciada de ART2, a rede ART Nebulosa foi também designada para agrupamentos de padrões com valores reais [Carpenter et al., 1991b]. Em 1992, a arquitetura ARTMAP foi estendida para ARTMAP Nebulosa para a classificação de padrões com valores reais, usando o treinamento supervisionado [Carpenter et al., 1992]. Diversas variações da arquitetura ART têm sido desenvolvidas desde então. Pesquisas em todo o mundo foram e estão sendo realizadas no sentido de melhorar as propriedades de generalização destas arquiteturas, tornando-as mais eficientes tanto no sentido de rapidez no processamento da rede quanto de precisão de resultados, cada qual visando adaptar-se aos problemas que pretendem resolver e maximizar o seu desempenho. Dentre as diversas variações pode-se citar: PROBART [Marriott, 1995], ART-EMAP [Carpenter & Ross, 1995], ARTMAP GAUSSIANA [Williamson, 1996], ARTMAP-FD

[Carpenter et al., 1997], ARTMAP Boosted [Verzi et al., 1998], μ ARTMAP [Gomés-Sánchez et al., 2002], etc.

5.3 Características Básicas dos Sistemas ART

A teoria da ressonância adaptativa é apropriada para aplicações de reconhecimento de padrões, e indicada para classificação de padrões. ART é um sistema que auto-organiza padrões de entrada em categorias de reconhecimento, mantendo um equilíbrio entre as propriedades de plasticidade e de estabilidade. A propriedade de plasticidade define a habilidade da rede em criar novas categorias de reconhecimento, quando padrões estranhos estimulam a rede ART. A propriedade de estabilidade é responsável pela habilidade em agrupar padrões similares na mesma categoria de reconhecimento. Uma regra de similaridade, que define onde agrupar um padrão, é determinada por um grau de semelhança entre um padrão previamente armazenado.

A rede ART é um modelo de treinamento competitivo não-supervisionado. É destinada para treinar, rápida e estavelmente, categorias de reconhecimento em resposta a uma seqüência arbitrária de padrões de entradas. ART é formada por dois principais subsistemas [Carpenter & Grossberg, 1991c]: o *subsistema de atenção* e o *subsistema de orientação* (vide Figura 5.1). O subsistema de atenção consiste de dois campos de neurônios: F_1 , que processa os dados de entrada; e F_2 , que agrupa os padrões de treinamento em categorias de reconhecimento, em que cada campo pode consistir de várias camadas de neurônios. Estes campos são conectados com pesos de conexão, que são responsáveis pelo armazenamento das informações através de um processo que envolve a escolha da categoria, critério de equalização e treinamento. O subsistema de orientação é controlado por um parâmetro de vigilância (ρ), que determina se um padrão de entrada pode ser incluído em uma das categorias existentes. Os neurônios da camada F_2 , camada que representa as categorias de reconhecimento, são de dois tipos: comprometidos e descomprometidos (ou livres) [Carpenter & Grossberg, 1991c]. Os nós comprometidos são aqueles que armazenam as informações dos padrões já apresentados à rede, representando categorias reais, e os nós descomprometidos são nós vazios, que representam a memória “em branco” da rede.

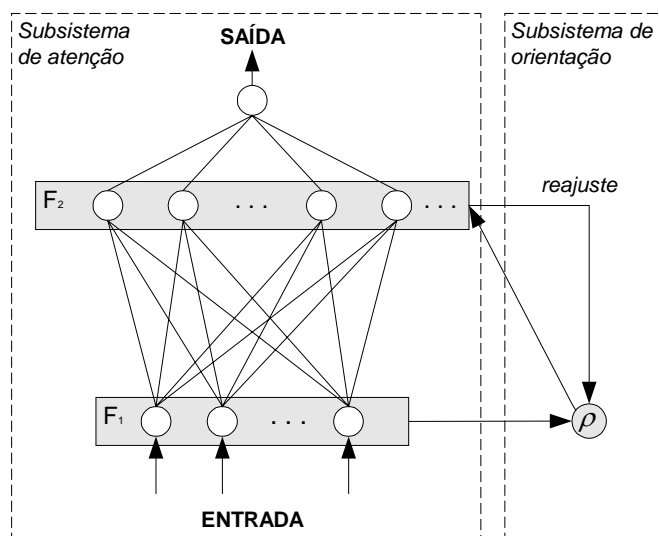


Figura 5.1 – Arquitetura básica da rede ART.

A formação dos pesos de conexão alocados entre as camadas F_1 e F_2 é detalhada na Figura 5.2. Trata-se de uma conexão entre N componentes de atividade correspondentes aos componentes do vetor de entrada \mathbf{a} (em F_1) e M neurônios na atividade F_2 . A escolha do número M é arbitrária, porém, deve ser suficiente para abrigar todas as categorias formadas em F_2 . Assim sendo, costuma-se adotar o número M igual ao número de vetores padrões a serem armazenados, ou seja, ter-se-iam, no máximo, M categorias formadas (uma para cada padrão). Essa situação é pouco plausível do ponto de vista prático, considerando que algumas categorias podem ficar “vazias”, ou seja, não armazenam nenhuma informação, mas ocupam “memória” no sistema. Outra alternativa que pode ser adotada é a criação contínua de novos neurônios à medida que novas categorias são formadas, sendo esta mais interessante se comparada à anterior, visto que trabalha com um número reduzido de neurônios, sendo, portanto, mais rápida. Estas duas alternativas podem ser facilmente implementadas nas redes neurais ART.

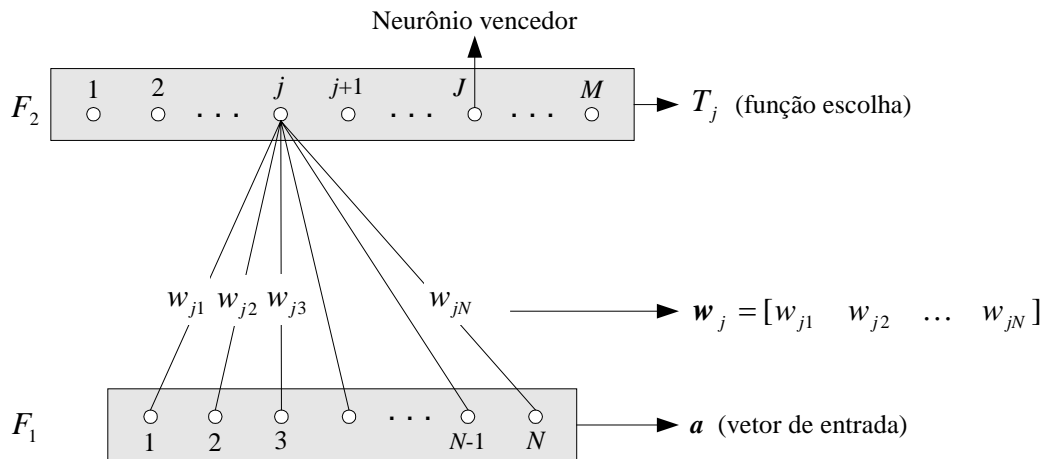


Figura 5.2 – Formação do vetor de peso que conecta as camadas F_1 e F_2 da rede ART.

O processo de classificação de rede ART consiste de quatro fases principais: *reconhecimento, comparação, busca e treinamento* [Carpenter & Grossberg, 1991c].

1) Reconhecimento

Cada neurônio do campo F_1 (camada de entrada) recebe sinais de baixo para cima do vetor de entrada e de cima para baixo do campo F_2 (camada de saída, que representa a categoria ativa). A atividade é calculada e o vetor resultante é comparado com todos os vetores de pesos já armazenados na rede (memória) para encontrar o que mais se assemelha ao padrão de entrada atual. O neurônio do campo F_2 , com maior valor de ativação, é selecionado como provável categoria para armazenar o novo padrão. O neurônio selecionado envia ao campo F_1 seu protótipo.

2) Comparação

Nesta fase acontece um mecanismo de reajuste, que é responsável por testar a similaridade entre o vetor de entrada e o vetor de comparação, z , que é o vetor resultante da

atividade calculada no campo F_1 mediante o vetor protótipo dado pelo campo F_2 após a fase de reconhecimento. A maneira pela qual se define como de que modo a comparação irá ocorrer é definida por um parâmetro chamado *vigilância* (ρ), que determina se um padrão de entrada pode ser incluído em uma das categorias existentes. Se o valor da comparação for maior do que ρ , então o padrão de entrada é incluído na categoria ativa, caso contrário, a rede entra em fase de busca.

3) Busca

Durante esta fase, a rede procura um novo neurônio do campo F_2 para representar o vetor de entrada atual. O neurônio da camada de saída rejeitado na fase de comparação anterior é desabilitado nesta seleção. O vetor de entrada é reapresentado, e a rede entra novamente na fase de comparação, que termina com o teste no mecanismo de reajuste para determinar a similaridade entre o novo protótipo escolhido e o vetor de entrada atual. Este processo é repetido, desabilitando neurônios da camada de saída, até encontrar um neurônio de saída que melhor se assemelhe ao vetor de entrada corrente, dentro dos limites do parâmetro de vigilância ρ . Se nenhum neurônio de saída for encontrado, o vetor de entrada é então considerado de uma classe desconhecida, sendo alocado um neurônio de saída que não esteja associado ainda a nenhuma categoria para representá-lo.

4) Treinamento

O algoritmo de aprendizado da rede ART é não-supervisionado e pode ser ativado a qualquer momento, permitindo que a rede aprenda novos padrões continuamente. Há dois tipos de treinamento para a rede ART: aprendizado rápido e aprendizado lento [Carpenter & Grossberg, 1991c]. No aprendizado rápido, os pesos de conexão são ajustados para seus valores ótimos em poucos ciclos, geralmente em apenas um ciclo de treinamento. No aprendizado lento, os pesos são ajustados lentamente em vários ciclos de treinamento, possibilitando um ajuste melhor dos pesos da rede aos padrões de treinamento.

As redes ARTs são muito sensíveis a variações em seus parâmetros durante o treinamento. O parâmetro mais crítico é o parâmetro de vigilância (ρ) que controla a resolução do processo de classificação. Se ρ assume um valor baixo, *e.g.*, a rede permite que padrões não muito semelhantes sejam agrupados na mesma categoria de reconhecimento, criando poucas classes. Se a ρ for atribuído um valor alto (próximo a 1), pequenas variações nos padrões de entrada levarão à criação de novas classes.

A seguir, apresenta-se o algoritmo da arquitetura ART nebulosa, que é uma generalização da rede ART1.

5.4 Algoritmo ART Nebuloso

ART nebulosa é uma generalização da rede ART1. A generalização é alcançada usando as operações da teoria de conjuntos nebulosos [McNEIL & Thro, 1994; Terano et al., 1987] ao invés das operações da teoria de conjuntos binários. A estrutura geral da rede ART Nebulosa é essencialmente a mesma de ART1. A arquitetura consiste de um campo de pré-processamento de neurônios, F_0 , que modifica o vetor de entrada atual a , e um campo F_1 que recebe ambas entradas de F_0 e entradas de F_2 . A camada F_1 possui $2N$ nós (neurônios), enquanto a camada F_2 possui um número suficiente de nós para acomodar os padrões de entrada em categorias de reconhecimento e realizar o treinamento.

O algoritmo resumido da rede neural ART nebulosa consiste, basicamente, nos seguintes passos [Carpenter et al., 1991b; Carpenter & Grossberg, 1991c; Carpenter et al. 1992]:

Passo 1. Inicialização de pesos e parâmetros da rede

Inicialmente, todos os pesos dos neurônios são fixados iguais a 1, $w_{ij} = 1$, o parâmetro de vigilância é escolhido entre 0 e 1, $\rho \in [0, 1]$, o parâmetro de escolha é escolhido maior do que 0, $\alpha > 0$, e o parâmetro da taxa de treinamento é escolhido entre 0 e 1, $\beta \in [0, 1]$.

Passo 2. Codificação do vetor de entrada

Um novo padrão de entrada $\mathbf{a} = [a_1 \ a_2 \ \dots \ a_N]$ de N elementos (em que cada elemento a_i é um número real no intervalo $[0,1]$) sofre uma codificação complementar preliminar. Isto produz um vetor de entrada \mathbf{I} de $2N$ elementos, tal que:

$$\mathbf{I} \triangleq [\mathbf{a} \ \mathbf{a}^c] = [a_1 \ a_2 \ \dots \ a_N \ a_1^c \ a_2^c \ \dots \ a_N^c]. \quad (5.4.1)$$

Sendo: $a_i^c = 1 - a_i$.

Esta codificação complementar é uma regra de normalização que preserva a informação de amplitude.

Note que:

$$\begin{aligned} |\mathbf{I}| &= |[\mathbf{a} \ \mathbf{a}^c]| \\ &= \sum_{i=1}^N a_i + \left(N - \sum_{i=1}^N a_i \right) \\ &= N. \end{aligned} \quad (5.4.2)$$

Passo 3. Escolha da categoria

A ativação T_j é calculada para cada neurônio j de F_2 , usando a função escolha:

$$T_j = \frac{|\mathbf{I} \wedge \mathbf{w}_j|}{\alpha + |\mathbf{w}_j|}, \quad (5.4.3)$$

em que o operador \wedge é o operador nebuloso AND, definido por [McNEIL & Thru, 1994; Terano et al., 1987]:

$$(\mathbf{p} \wedge \mathbf{q})_i \triangleq \min(p_i, q_i) \quad (5.4.4)$$

e a norma $|\cdot|$ é definida por:

$$|\mathbf{p}| \equiv \sum_{i=1}^{2N} |p_i|. \quad (5.4.5)$$

O sistema é dito “fazer a escolha da categoria” quando no máximo um neurônio torna-se ativo. A categoria escolhida é indexada por J , em que:

$$T_J = \max \{T_j : j = 1, \dots, M\}. \quad (5.4.6)$$

Passo 4. Teste de vigilância

A ressonância ocorre se a função *match*, $|\mathbf{I} \wedge \mathbf{w}_J|/|\mathbf{I}|$ da categoria escolhida satisfaz o critério de vigilância:

$$|\mathbf{I} \wedge \mathbf{w}_J| \geq \rho |\mathbf{I}|. \quad (5.4.7)$$

O treinamento, então, resulta como definido no Passo 5.

Do contrário, se o critério de vigilância falhar para a categoria escolhida, o valor da função escolha T_J é fixado em 0 até que o critério seja satisfeito para aquela entrada. Um novo índice J é, então, escolhido pela equação (5.4.6). O processo de busca continua até que o índice J escolhido satisfaça a equação (5.4.7).

Passo 5. Atualização do vetor protótipo

Encerrada a busca, o vetor peso \mathbf{w}_J é atualizado de acordo com a seguinte equação [Carpenter & Grossberg, 1991c]:

$$\mathbf{w}_J^{(novo)} = \beta (\mathbf{I} \wedge \mathbf{w}_J^{(velho)}) + (1 - \beta) \mathbf{w}_J^{(velho)}. \quad (5.4.8)$$

O treinamento rápido corresponde a fixar $\beta = 1$.

A substituição do operador de interseção *crisp* (não-nebuloso) (\cap), que descreve a dinâmica da rede ART1, pelo operador nebuloso *AND* (\wedge) da teoria de conjuntos nebulosos [McNEIL & Thru, 1994; Terano et al., 1987] na escolha, busca e leis de treinamento de ART1 (Tabela 5.1), leva a uma versão mais poderosa da rede ART1. Esta generalização é no sentido de melhorar o desempenho da rede no que se refere, principalmente, ao tempo de execução do treinamento e, também, no processamento de dados analógicos.

Tabela 5.1 – Comparação de ART1 e ART nebulosa.

Módulo	ART1 (binário)	ART nebulosa (analógico)
Escolha da categoria	$T_j = \frac{ \mathbf{I} \cap \mathbf{w}_j }{\alpha + \mathbf{w}_j }$	$T_j = \frac{ \mathbf{I} \wedge \mathbf{w}_j }{\alpha + \mathbf{w}_j }$
Critério <i>Match</i>	$ \mathbf{I} \cap \mathbf{w}_j \geq \rho \mathbf{I} $	$ \mathbf{I} \wedge \mathbf{w}_j \geq \rho \mathbf{I} $
Treinamento	$\mathbf{w}_j^{(novo)} = \beta(\mathbf{I} \cap \mathbf{w}_j^{(velho)}) + (1 - \beta)\mathbf{w}_j^{(velho)}$	$\mathbf{w}_j^{(novo)} = \beta(\mathbf{I} \wedge \mathbf{w}_j^{(velho)}) + (1 - \beta)\mathbf{w}_j^{(velho)}$

5.5 Representação Geométrica do Algoritmo ART Nebuloso

A rede ART Nebulosa usa hiper-retângulos para representar suas categorias de reconhecimento [Carpenter et al., 1992]. Por simplicidade, considera-se o vetor de entrada bi-dimensional. Após a codificação complementar o padrão $\mathbf{a} = [a_1 \ a_2]$ torna-se (considerando-se $a \in [0, 1]$):

$$\mathbf{I} = [\mathbf{a} \ \mathbf{a}^c] = [a_1 \ a_2 \ 1 - a_1 \ 1 - a_2]. \quad (5.5.1)$$

Do mesmo modo, o vetor peso \mathbf{w} é codificado como:

$$\mathbf{w}_j = [\mathbf{u}_j \quad \mathbf{v}_j] \quad (5.5.2)$$

sendo:

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

A interpretação geométrica de cada categoria j pode ser entendida como um retângulo R_j , em que os vetores \mathbf{u}_j e \mathbf{v}_j estão situados em vértices opostos de R_j , sendo \mathbf{u}_j e \mathbf{v}_j vetores bi-dimensionais. O tamanho deste retângulo é definido como a soma de sua base por sua altura, ou seja [Carpenter et al., 1992]:

$$\begin{aligned} |R_j| &\triangleq |\mathbf{v}_j - \mathbf{u}_j| & (5.5.3) \\ &= |(v_{1j} - u_{1j})(v_{2j} - u_{2j})| \\ &= |(v_{1j} - u_{1j})| + |(v_{2j} - u_{2j})| \end{aligned}$$

sendo:

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

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

Considerando que a rede ART realiza o treinamento rápido, com $\beta = 1$, quando um neurônio descomprometido J da camada F_2 é selecionado para armazenar um protótipo a_i , o vetor peso correspondente é $\mathbf{w}_J = [a_i \quad a_i^c]$, sendo sua representação geométrica dada pelo ponto \mathbf{a} (Figura 5.3 (a)).

Quando a categoria J é escolhida novamente pelo padrão a_k , o vetor peso é agora atualizado por:

$$\begin{aligned}
 \mathbf{w}_J &= \begin{bmatrix} (a_k \wedge a_i) & (a_k^c \wedge a_i^c) \\ (a_k \wedge a_i) & (a_k \vee a_i)^c \end{bmatrix} \\
 &= \begin{bmatrix} (a_k \wedge a_i) & (a_k \vee a_i)^c \end{bmatrix} \\
 &= [\mathbf{u}_J \quad \mathbf{v}_J]
 \end{aligned}
 \tag{5.5.4}$$

sendo o operador nebuloso AND, \wedge , definido pela equação (5.4.4); e o operador nebuloso OR, \vee , definido por [McNEIL & Thru, 1994; Terano et al., 1987]:

$$(\mathbf{p} \vee \mathbf{q})_i \triangleq \max(p_i, q_i).
 \tag{5.5.5}$$





Figura 5.3 – Representação geométrica dos pesos da rede neural ART. (a) Categoria composta por um padrão. (b) Categoria composta por dois padrões. (c) Expansão da categoria J durante o treinamento rápido para $R_J \oplus \mathbf{a}$.

Assim, a categoria J é expandida e representada por um retângulo, como mostra a Figura 5.3 (b).

O treinamento aumenta o tamanho de R_j enquanto o tamanho de w_j diminui. Durante o processo de treinamento rápido R_j é expandido para $R_j \oplus \mathbf{a}$, representando o menor retângulo contendo R_j e \mathbf{a} (Figura 5.3 (c)). Os vértices de $R_j \oplus \mathbf{a}$ são dados por $(\mathbf{a} \wedge \mathbf{u}_j)$ e $(\mathbf{a} \vee \mathbf{v}_j)$. O tamanho de $R_j \oplus \mathbf{a}$ é, então, definido por [Carpenter et al., 1992]:

$$|R_j \oplus \mathbf{a}| \triangleq |(\mathbf{a} \vee \mathbf{v}_j) - (\mathbf{a} \wedge \mathbf{u}_j)|. \quad (5.5.6)$$

Cada categoria j é representada pelo menor retângulo que contém todos os padrões escolhidos/armazenados durante o treinamento para aquela categoria. Esta propriedade demonstra que a arquitetura ART é inerentemente estável, ou seja, o conhecimento já adquirido pela rede é sempre preservado. O tamanho máximo de R_j é condicionado ao parâmetro de vigilância ρ , com a condição de que:

$$|R_j \oplus \mathbf{a}| \leq 2(1 - \rho). \quad (5.5.7)$$

Em geral, se \mathbf{a} tem dimensão M , o hiper-retângulo R_j inclui os dois vértices $\wedge_j \mathbf{a}$ e $\vee_j \mathbf{a}$, em que o i -ésimo componente de cada vetor é definido por [Carpenter et al., 1992]:

$$(\wedge_j \mathbf{a})_i = \min\{a_i : \mathbf{a} \text{ é codificado pela categoria } j\} \quad (5.5.8)$$

$$(\vee_j \mathbf{a})_i = \max\{a_i : \mathbf{a} \text{ é codificado pela categoria } j\}. \quad (5.5.9)$$

Do mesmo modo que as equações (5.5.2) e (5.5.3), o tamanho de R_j é dado por:

$$|R_j| = |\vee_j \mathbf{a} - \wedge_j \mathbf{a}| \quad (5.5.10)$$

e o vetor peso w_j é dado por:

$$\mathbf{w}_j = [\wedge_j \mathbf{a} \quad (\vee_j \mathbf{a})^c]. \quad (5.5.11)$$

Assim:

$$|\mathbf{w}_j| = \sum_i (\wedge_j \mathbf{a})_i + \sum_i [1 - (\vee_j \mathbf{a})_i] = M - |\vee_j \mathbf{a} - \wedge_j \mathbf{a}| \quad (5.5.12)$$

e o tamanho do hiper-retângulo R_j é conseqüentemente,

$$|R_j| = M - |\mathbf{w}_j|. \quad (5.5.13)$$

A partir das equações (5.4.2), (5.4.7) e (5.4.8), conclui-se que:

$$|\mathbf{w}_j| \geq \rho M ; \quad (5.5.14)$$

e das equações (5.5.13) e (5.5.14), têm-se:

$$|R_j| \leq (1 - \rho)M . \quad (5.5.15)$$

Assim, alto valor para o parâmetro de vigilância ($\rho \cong 1$) leva a R_j de baixa dimensão enquanto um valor baixo para o parâmetro de vigilância ($\rho \cong 0$) gera R_j de alta dimensão.

5.6 Algoritmo ARTMAP Nebuloso

A arquitetura ARTMAP, introduzida recentemente [Carpenter et al., 1991a], é uma rede mais sofisticada. É designada para treinar e realizar o mapeamento entre dois espaços de vetores, usando ambas leis de treinamento supervisionado e não-supervisionado. Este modelo é composto por duas sub-redes ART1: ARTa e ARTb. A primeira rede ARTMAP foi utilizada para classificar vetores de entradas binários, cada elemento do vetor indicando a presença ou ausência de uma dada característica. Uma rede ARTMAP mais geral foi proposta para classificar vetores de entrada cujos elementos assumem valores nebulosos, entre 0 e 1, indicando o nível de presença de cada característica. Esta generalização é

alcançada substituindo os módulos ART1 de ARTMAP por módulos ART nebuloso. A nova rede é conhecida como rede ARTMAP nebulosa [Carpenter et al., 1992].

O sistema ARTMAP nebuloso na sua forma geral, inclui dois módulos ART nebuloso (ARTa e ARTb) cujas camadas são ligadas por um módulo inter-ART que inclui um campo de mapeamento controlando o treinamento de um mapa associativo de categorias de reconhecimento de ARTa para categorias de reconhecimento de ARTb [Carpenter & Grossberg, 1991c; Carpenter et al., 1992]. O campo de mapeamento também controla a regra *matching tracking*, que aumenta o parâmetro de vigilância da rede ARTa por uma quantia mínima necessária para corrigir um erro preditivo [Carpenter et al., 1992].

As redes ARTa e ARTb são de estruturas iguais como a rede ART nebulosa descrita na seção anterior, exceto que em ARTa há uma vigilância básica usada para controlar o sistema. A arquitetura ARTMAP nebulosa é mostrada na Figura 5.4.

Durante o treinamento supervisionado ARTa recebe uma corrente de padrões de entrada $\{a^M\}$ e ARTb recebe uma corrente de padrões $\{b^M\}$, em que b^M é a predição correta dada a^M . Quando uma predição em ARTa não é confirmada por ARTb, a inibição da memória associativa inter-ART ativa o processo *match tracking*. Este processo aumenta a vigilância em ARTa por uma quantia mínima necessária para o sistema ativar uma outra categoria em ARTa que iguala a categoria em ARTb, ou para treinar uma nova categoria em ARTa. Os mecanismos de controle interno das ARTMAP's criam categorias de reconhecimento estáveis, de forma ótima, via maximização da generalização preditiva em operações em tempo real [Carpenter & Grossberg, 1991c; Carpenter et al., 1992]. A rede neural ARTMAP nebulosa realiza treinamento supervisionado como o *backpropagation* [Werbos, 1974]. Mas diferente do algoritmo *backpropagation*, a rede ARTMAP nebulosa é auto-organizável, auto-estabilizável e apropriada para treinamento em tempo-real.

Baseada na observação que o treinamento da rede ARTMAP leva a diferentes pesos adaptativos e diferentes categorias de reconhecimento para diferentes ordenações de um dado conjunto de treinamento, introduz-se uma *estratégia de votação* [Carpenter et al., 1992]. A *estratégia de votação* usa um sistema ARTMAP que é treinado diversas vezes com diferentes ordenações para o mesmo conjunto de treinamento. A predição final é dada pelas soluções geradas com maior frequência. Como o conjunto de elementos que fazem predições

errôneas varia de uma simulação para a próxima, esta estratégia cancela muitos erros que ocorrem na fase de análise (diagnóstico).

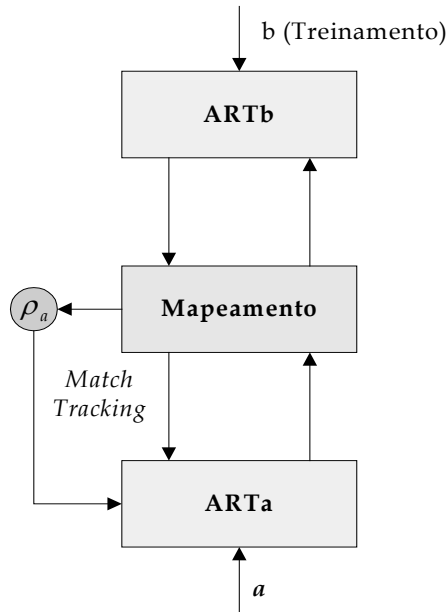


Figura 5.4 – Arquitetura ARTMAP nebulosa.

5.7 Conclusão

Foram apresentados, neste capítulo, os principais conceitos sobre as redes da Teoria da Ressonância Adaptativa, redes ART, em particular as redes ART1, ART nebulosa e ARTMAP nebulosa. Este capítulo introduz os conceitos necessários para a apresentação da rede ARTMAP Euclidiana, que será tratada no próximo capítulo e é a arquitetura usada neste trabalho para o diagnóstico da estabilidade transitória de sistemas de energia elétrica multimáquinas.

Capítulo 6

Rede Neural ARTMAP Baseada na Distância Euclidiana

6.1 Introdução

A rede neural ARTMAP é adequada para a resolução de uma série de problemas complexos. Por exemplo, em sistemas elétricos de potência: análise de segurança, análise de estabilidade transitória, previsão de carga, etc. A importância do emprego deste sistema refere-se às características de estabilidade e plasticidade, as quais oferecem à rede neural uma aprendizagem estável, múltipla generalização e convergência rápida. Porém, as redes neurais da família ART apresentam algumas dificuldades operacionais: razoável sensibilidade aos parâmetros da rede (parâmetro de vigilância, etc.) e a precisão das análises. Os efeitos da sensibilidade paramétrica têm sido resolvidos, ou atenuados, através do emprego de novas concepções de treinamento e de arquitetura das redes neurais ART [Williamson, 1996]. Igualmente, várias propostas têm sido apresentadas na literatura especializada visando sanar o problema da imprecisão. Grande parte da imprecisão decorre em consequência, principalmente, do mecanismo de escolha de categorias e do teste de vigilância que necessita de aperfeiçoamento.

Neste contexto, apresenta-se, neste capítulo, a arquitetura neural ARTMAP Euclidiana, que será o modelo utilizado nesta pesquisa para a solução do problema da análise da estabilidade transitória. Trata-se de uma concepção que visa melhorar a qualidade das soluções (maior precisão sem afetar o tempo de cálculo necessário à realização do treinamento e demais rotinas), se comparada à formulação da rede neural ARTMAP convencional.

6.2 ARTMAP Euclidiana

A rede neural ARTMAP Nebulosa utiliza hiper-retângulos para representar geometricamente suas categorias, que são responsáveis por resumir os padrões de entrada [Carpenter et al., 1992]. O uso de hiper-retângulo para representar as categorias induz ao uso da norma- L_1 , a qual é usada no cálculo da função de ativação e, também, da função *match* na rede ARTMAP Nebulosa. No entanto, em muitos casos, hiper-retângulos podem não ser, necessariamente, a melhor forma para agrupar os dados de entrada, nem a geometria baseada na norma- L_1 leva necessariamente a resultados de classificação ótimos em comparação com outras geometrias. Considere, por exemplo, um esquema de dados bi-dimENSIONAL que implica uma representação de categoria elipsoidal, como mostra a Figura 6.1. Neste caso, o uso de retângulos seria um caminho ineficiente para descrever os padrões, observando que os cantos do retângulo assumem a presença de padrões adicionais [Anagnostopoulos, 2001].




Figura 6.1 – Representação de categoria elipsoidal *versus* representação retangular.

Considerando os fatos mencionados anteriormente, é de grande interesse encontrar diferentes tipos de geometrias para representar mais eficientemente as categorias das redes neurais ART descendentes. A primeira investigação sobre essa concepção foi com a rede neural ARTMAP Gaussiana, desenvolvida por Williamson em 1996 [Williamson, 1996], em que a norma- L_2 foi adotada e as distâncias foram definidas em termos da distância de Mahalanobis.

Deve-se ressaltar que as redes neurais ART descendentes, baseadas na distância Euclidiana, constitui-se num caso particular de redes ART de Mahalanobis. Contudo, a opção, nesta pesquisa, pela distância Euclidiana, decorre do fato de que a concepção Mahalanobiana não preserva a característica de plasticidade.

A rede ARTMAP Nebulosa tradicional requer a normalização e codificação complementar dos padrões de entrada, que duplica a dimensão da rede e introduz um considerável custo computacional. Neste sentido, as redes neurais ART e ARTMAP baseadas na distância Euclidiana [Vuskovic & Du, 2002a] e distância de Mahalanobis [Vuskovic & Du, 2002b], foram desenvolvidas, em que a normalização e a codificação complementar do vetor de entrada não são necessárias. Neste caso, a dimensão do vetor de entrada é a metade, se comparada à dimensão para o caso do algoritmo ARTMAP nebuloso convencional.

Definição 3. A distância Euclidiana entre dois pontos $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_p]$ e $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_p]$ em um espaço p -dimensional, é definida como [URL, 2005]:

$$d_E(\mathbf{x}, \mathbf{y}) = \sqrt{(x_1 - y_1)^2 + \dots + (x_p - y_p)^2} = \sqrt{(\mathbf{x} - \mathbf{y})(\mathbf{x} - \mathbf{y})^T} \quad (6.2.1)$$

e $d_E(\mathbf{x}, \mathbf{0}) = \|\mathbf{x}\|_2 = \sqrt{x_1^2 + \dots + x_p^2} = \sqrt{\mathbf{x} \mathbf{x}^T}$ é a norma Euclidiana de \mathbf{x} .

Definição 4. A distância de Mahalanobis entre dois pontos $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_p]$ e $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_p]$ em um espaço p -dimensional, é definida como [URL, 2005]:

$$d_S(\mathbf{x}, \mathbf{y}) = \sqrt{(\mathbf{x} - \mathbf{y}) \mathbf{S}^{-1} (\mathbf{x} - \mathbf{y})^T} \quad (6.2.2)$$

e $d_S(\mathbf{x}, \mathbf{0}) = \|\mathbf{x}\|_S = \sqrt{\mathbf{x} \mathbf{S}^{-1} \mathbf{x}^T}$ é a norma de \mathbf{x} . \mathbf{S} é a matriz de covariância.

Na arquitetura neural ARTMAP baseada na distância Euclidiana, a distância Euclidiana é usada nas funções de ativação e função *match* da rede neural ART e ARTMAP [Vuskovic & Du, 2002a]:

$$T_j = (\mathbf{a} - \mathbf{w}_j)(\mathbf{a} - \mathbf{w}_j)^T \quad (6.2.3)$$

$$FM_j = \frac{T_j}{\max(\mathbf{a}\mathbf{a}^T, \mathbf{w}_j\mathbf{w}_j^T)} \quad (6.2.4)$$

Diferente de ART e ARTMAP a escolha da categoria candidata é aquela que tem ativação mínima e a ressonância ocorre se a função *match* da categoria escolhida encontra o critério de vigilância. Assim:

$$T_j = \min \{T_j : j = 1, \dots, M\} \quad (6.2.5)$$

$$FM_j < \rho \quad (6.2.6)$$

Baixa vigilância, agora, resulta em rigorosa condição de ressonância e um maior número de nós de saída. A função de adaptação (vetor de pesos) permanece a mesma da arquitetura ARTMAP tradicional:

$$\mathbf{w}_j^{(k+1)} = \beta(\mathbf{a}) + (1 - \beta)\mathbf{w}_j^{(k)} \quad (6.2.7)$$

O algoritmo de treinamento da rede é essencialmente o mesmo como em ARTMAP clássico. Uma diferença está no parâmetro de vigilância, que é reduzido ao valor mínimo da função de ativação menos um valor positivo pequeno, caso o critério de vigilância falhe [Vuskovic & Du, 2002a]. A classificação é decidida pela distância Euclidiana, ou seja, o padrão cuja distância Euclidiana com o modelo seja mínima, é a predição correta. As representações geométricas dos modelos, que são representados pela média dos exemplos, da arquitetura neural ARTMAP baseada na distância Euclidiana, são círculos centrados na média dos exemplos com raio ρ (parâmetro de vigilância).

A Figura 6.2 apresenta um fluxograma do algoritmo da rede neural ARTMAP Euclidiana.

Como inovação, é acrescentado, na fase de predição, um mecanismo de atualização das categorias de reconhecimento. O critério consiste em estabelecer um número mínimo de membros, exigido para cada categoria gerada na fase de treinamento (NC_{min}). Durante a apresentação de um padrão de entrada na fase de predição, a classe predita é avaliada e, se ela possuir um número inferior ao preestabelecido, então, o padrão em questão é adicionado a essa classe, por meio da atualização dos vetores de peso, aumentando em um o número de vetores pertencentes àquela categoria, e assim sucessivamente, para todos os padrões que forem apresentados à rede. Esse mecanismo permite que as categorias sejam constantemente atualizadas, melhorando sua região de definição e, conseqüentemente, a precisão dos resultados.

Durante a apresentação dos vetores de entrada, na fase de treinamento e predição, é incorporado à rede um neurônio “vazio”, representando uma categoria de reconhecimento sem a presença de nenhum padrão de entrada, com um nível de ativação (valor da função de ativação) T_0 . Essa idéia foi originalmente proposta na referência Vakil-Baghmished e Pavesic (2003) para a rede neural ARTMAP Nebulosa, diminuindo grande parte do tempo gasto na fase do treinamento, pois ao estabelecer um valor mínimo que a função de ativação pode assumir ($0 \leq T_0 \leq 1$), diminui o número de candidatos a vencedor, e, conseqüentemente, diminui o número de neurônios na competição.




Figura 6.2 – Fluxograma do algoritmo da rede neural ARTMAP Euclidiana.

Nesta pesquisa, a idéia é estabelecer uma distância máxima que um vetor pode ter com uma determinada categoria de reconhecimento, uma vez que a rede neural ARTMAP baseada na distância Euclidiana sugere a escolha de uma categoria candidata com ativação

mínima. Com isso, o número de neurônios candidatos a vencedor (T_j), para representar o vetor de entrada (categoria de reconhecimento), é reduzido, e o tempo para terminar a busca por esse neurônio torna-se menor. Esse valor máximo, T_0 , é determinado, a princípio, experimentalmente. Se durante o treinamento o neurônio T_0 é selecionado para representar o vetor de entrada atual, então uma nova categoria é criada. Na fase de predição T_0 é mantido, e se ele é escolhido como categoria vencedora, então se diz que para aquela entrada não houve predição. Sugere-se fazer uma análise mais detalhada desse vetor para verificar a possibilidade de inseri-lo na rede como nova informação (treinamento continuado).

6.3 Conclusão

Neste capítulo foi apresentada a rede neural ARTMAP baseada na distância Euclidiana, designada ARTMAP Euclidiana, que será a arquitetura neural usada no diagnóstico da estabilidade transitória de sistema de energia elétrica. A principal vantagem do uso desta arquitetura neural refere-se à precisão e uma redução do volume computacional em comparação à rede neural ARTMAP nebulosa tradicional. O menor volume de cálculo é observado, tendo em vista que a dimensão do vetor de entrada na rede ARTMAP Euclidiana é consideravelmente menor, ou seja, é a metade da dimensão do vetor padrão de entrada da rede ARTMAP nebulosa.

Capítulo 7

Análise de Estabilidade Transitória: Solução Proposta via Rede Neural ARTMAP Euclidiana

7.1 Introdução

Neste capítulo será apresentado um esquema de análise de estabilidade transitória baseado na rede neural ARTMAP Euclidiana. Este esquema proposto contempla as fases de treinamento, treinamento continuado e análise. Trata-se de um mecanismo em que é realizado o treinamento usando dados e resultados gerados por simulação e, “permanentemente”, é realizado o treinamento continuado, à medida que as análises forem efetivadas. Para tanto, serão estabelecidas as entradas e saídas da rede neural. Estas informações são fornecidas por um programa computacional de análise de estabilidade transitória que, a partir dos dados da rede elétrica, considerando-se uma lista de contingências (curto-circuito trifásico com saída de linha de transmissão) e diferentes topologias, provem os valores das margens de segurança associadas. 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 binários (associados às contingências: barra de defeito e nós terminais do circuito que sai de operação). A saída é essencialmente representada por código binário.

Deve-se ressaltar que a consideração de várias topologias da rede elétrica, para fins de análise, constitui-se num fator diferencial em relação às demais propostas na literatura. Trata-se de um dispositivo que busca realizar, de forma mais realista, o que efetivamente ocorre na operação dos sistemas elétricos de potência, ou seja, trabalham-se com topologias diversificadas e não uma topologia fixa.

7.2 Estímulos de Entrada

A estrutura neural proposta visa a análise da estabilidade transitória de sistemas de energia elétrica que corresponde à determinação da margem de segurança, considerando-se defeitos de curto-circuito trifásico com saída de linha de transmissão. Os estímulos de entrada (X) e de saída (Y), para a fase de treinamento, são definidos usando um programa computacional híbrido [Fonseca & Decker, 1985], que emprega o conceito de simulação e o Método Direto de Lyapunov (método da energia). Assim, os vetores padrões de entrada da rede neural (entrada do módulo ARTa) são definidos como [Minussi et al., 2001]:

$$X_r \triangleq [P \ Q \ A_r] \quad (7.2.1)$$

sendo:

$$P = [P_1 \ P_2 \ \dots \ P_{ns}];$$

$$Q = [Q_1 \ Q_2 \ \dots \ Q_{ns}];$$

P_i = potência elétrica ativa da i -ésima barra do sistema;

Q_i = potência elétrica reativa da i -ésima barra do sistema;

A_r = vetor que contém os índices das contingências e informação sobre a topologia do sistema, representado em código binário [0,+1].

O padrão X é um vetor n -dimensional:

$$n = 2ns + nc \quad (7.2.2)$$

em que:

ns = número de barras do sistema;

nc = número de *bits* correspondente ao número (índice) da contingência e configuração do sistema;

Neste caso, levando-se em conta o modelo clássico [Anderson & Fouad, 1977; Pai, 1981; Ribbens-Pavella & Evans, 1985; Fouad & Vittal, 1992], é razoável utilizar somente as potências ativa e reativa para a avaliação da estabilidade transitória, que corresponde à análise usando-se o critério da margem de segurança. Isto porque a topologia da rede e demais parâmetros (constante de inércia, reatância transitória, etc.) são considerados constantes. A idéia é utilizar somente as variáveis causais (potências ativa e reativa) e os parâmetros que expressam alterações na rede (representação das contingências).

O número de *bits* (nc) de \mathbf{A} é consideravelmente menor do que $2ns$. Deste modo, a dimensão do vetor padrão (7.2.1) é significativamente menor, se comparada às principais propostas encontradas na literatura para a resolução do problema usando redes neurais [Sobajic & Pao, 1989; Pao & Sobajic, 1991; Park et al., 1997].

Para a realização do treinamento da rede neural deve-se proceder a apresentação de um conjunto de dados, no caso, $\mathbf{X}_r \triangleq [\mathbf{P} \ \mathbf{Q} \ \mathbf{A}_r]$ (entrada) e \mathbf{Y} (saída), constituindo o conjunto de pares de treinamento. Trata-se da geração dos vetores \mathbf{P} e \mathbf{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 (ou pseudo-aleatória) da carga (demanda aleatória ou pseudo-aleatória), como mostrado a seguir [Lotufo, 2004].

Considere que um sistema com uma determinada topologia contendo NB barras, sendo que são NG barras de geração e as demais são barras de carga ($NL = NB - NG$). Considere, ainda, que se deseja realizar o despacho de geração para atender uma demanda variável tomando-se como referência o caso base: PG^0 , QG^0 , PL^0 e QL^0 , sendo:

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

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

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

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

Para se gerar um grande espectro de variação da demanda, o critério a ser usado refere-se a distribuição aleatória da demanda e, conseqüentemente, da geração para atender a

demanda, tomando-se variações percentuais da carga e da geração em torno do caso base (considerado como sendo o perfil de geração/carga de 100%). Por exemplo, arbitrando-se um percentual de 10%, pode-se realizar vários perfis de geração e de carga realizando despachos de geração e definição da carga do sistema distribuindo-se a geração e a carga de forma aleatória nas barras do sistema, respeitando-se o percentual arbitrado [Lotufo, 2004].

As potências ativas das barras de geração podem ser definidas por [Lotufo, 2004]:

$$PG_i = PG_i^0 + \Delta PG_i \quad (7.2.3)$$

sendo:

PG_i = potência ativa no i -ésimo gerador, fixada aleatoriamente (ou pseudo-aleatoriamente);

$$\Delta PG_i = PG_{total}^0 \times PER \times AG_i / KG; \quad (7.2.4)$$

$$PG_{total}^0 = \sum_{i \in \Omega(G)} PG_i^0; \quad (7.2.5)$$

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

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

AG_i = número aleatório de uma 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: $AG_i \in [0, 1]$;

$$KG = 100 AG_{total}; \quad (7.2.6)$$

$$AG_{total} = \sum_{i \in \Omega(G)} AG_i. \quad (7.2.7)$$

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

Com relação as cargas ativas, os perfis de variação (curva variável de demanda) podem ser, então, obtidos por [Lotufo, 2004]:

$$PL_i = PL_i^0 + \Delta PL_i \quad (7.2.8)$$

sendo:

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

$$\Delta PL_i = PL_{total}^0 \times PER \times AL_i / KL; \quad (7.2.9)$$

$$PL_{total}^0 = \sum_{i \in \Omega(L)} PL_i^0; \quad (7.2.10)$$

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

$$KL = 100 AL_{total}; \quad (7.2.11)$$

$$AL_{total} = \sum_{i \in \Omega(L)} AL_i; \quad (7.2.12)$$

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

As cargas reativas são fixadas considerando-se uma distribuição que preserva o fator de potência referente ao caso base. Este procedimento tenta estabelecer uma distribuição com um nível de inter-relação entre a potência ativa [Lotufo, 2004].

7.3 Estímulos de Saída

Os estímulos a serem aplicados no módulo ARTb da rede neural ARTMAP Euclidiana são as margens de segurança correspondentes aos vetores padrões de entrada (módulo ARTa) descritos pela equação (7.2.1).

A estratégia proposta neste trabalho é a utilização de intervalos de margem de segurança em que as contingências se encontram. Por exemplo, uma contingência com margem de segurança igual a 0,5 pode ser convencionada como pertencendo ao intervalo (0,4; 0,6). Esta forma permite que se representem as contingências através de código binário e reduz o número de classes no módulo ARTb, que é uma forma mais adequada para trabalhar com a rede ARTMAP, tornando o treinamento mais rápido e a análise mais confiável (há sempre a garantia da 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 para determinada contingência. Ressalta-se que este procedimento pode ser implementado tomando um número maior ou menor de intervalos, sem esforços adicionais, a critério da entidade usuária. Com o propósito de estabelecer estes intervalos, será proposto o uso do conceito de *Esforço de Deslocamento da Margem de Segurança*, conforme estabelecido a seguir [Minussi, 1990, Minussi & Freitas Filho, 1998]:

- *Esforço de Deslocamento da Margem de Segurança* (EDMS). Define-se EDMS como sendo uma função que relaciona as margens de segurança inicial e final de um determinado intervalo da seguinte forma [Minussi, 1990; Minussi & Freitas Filho, 1998]:

$$g = \frac{1 - M^A}{1 - M^B} - 1 \quad (7.3.1)$$

sendo:

g = esforço de deslocamento da margem de segurança;

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

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

Deste modo, o intervalo, em termos do conceito de margem de segurança, pode ser definido como:

$$IMS \triangleq (M_k^A, M_k^B) \quad (7.3.2)$$

em que:

IMS = intervalo considerado;

k = índice que indica o k -ésimo intervalo.

A equação (7.3.1) dá a noção de quanto a relação $Ee/Ecrit$ (Ee = valor da energia da contingência e $Ecrit$ = energia crítica da contingência), referente à margem de segurança final (M^B), é menor se comparada ao valor desta relação calculada na condição inicial (M^A). A unidade subtraída em (7.3.1) é empregada para ajustar a equação de tal modo que se tenha $\mathcal{G} = 0$ quando $M^B = M^A$ (neste caso, nenhum esforço é observado). Nota-se que \mathcal{G} é definido no intervalo $[0, +\infty)$ e possui crescimento significativo à medida que M^B se aproxima de 1.

O conceito de EDMS foi empregado nas referências Minussi (1990) e Minussi & Freitas Filho (1998) 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 ($M \geq Mmin$, sendo $Mmin$ = 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 \mathcal{G} , os intervalos de linearizações podem ser inferidos, ou seja, o erro, em cada segmento, mantém-se 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.

Esta concepção será utilizada neste trabalho para definir os intervalos associados às contingências, conforme é mostrado na Tabela 7.1, considerando-se $\mathcal{G} = 0,35$ e os valores da margem de segurança compreendidos em $(-3, 1)$.

O esforço da margem de segurança pode ser atribuído, com segurança, até o valor igual a 1,5 [Minussi, 1990], *i.e.*, o erro a ser observado é relativamente pequeno. A escolha de $\vartheta = 0,35$ foi fixada visando formar um grupo de intervalos que cubra todo o espectro de variação da margem de segurança e com um número razoável de segmentação. Deve-se destacar 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 e 6 *bits* pode-se trabalhar, respectivamente, com 15, 31 e 63 intervalos.

Tabela 7.1 – Representação binária da saída da rede neural ARTMAP nebulosa.

Número	Margem de Segurança (M)	Intervalo da Margem de Segurança (IMS)	Representação Binária da Saída (IMS)
1	-3	Menor ou igual do que -3	0 0 0 1
2	-1,9630	(-3 ; -1,9630]	0 0 1 0
3	-1,1948	(-1,9630 ; -1,1948]	0 0 1 1
4	-0,6258	(-1,1948 ; -0,6258]	0 1 0 0
5	-0,2043	(-0,6258 ; -0,2043]	0 1 0 1
6	0,10790	(-0,2043 ; 0,10790]	0 1 1 0
7	0,33920	(0,10790 ; 0,33920]	0 1 1 1
8	0,51050	(0,33920 ; 0,51050]	1 0 0 0
9	0,63740	(0,51050 ; 0,63740]	1 0 0 1
10	0,73140	maior do que 0,63740	1 0 1 0

O uso, na Tabela 7.1, de uma margem de segurança igual a -3 como limite inferior de referência, decorre do fato de que valores menores (mais negativos) são contingências de altíssimo grau de instabilidade o que, via de regra, conduzem aos casos de perdas de unidades geradoras, podendo chegar a um indesejável *blackout*, se não tomadas as medidas preventivas de forma correta. Portanto, no intervalo 1 ($M \leq -3$) são agrupadas as contingências que produzem grandes instabilidades no sistema. Para contingências associadas

às margens de segurança próximas da unidade, por exemplo, inclusas no intervalo 10, o sistema se comporta de forma efetivamente robusta.

Com esta representação (Tabela 7.1), têm-se 10 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 podem inserir-se novas informações com o objetivo de tornar a extração do conhecimento mais efetiva.

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, a quantidade de potência redespachada no sistema que produz uma alteração na margem de segurança de -3 para $-1,9630$ (Intervalo 2), produziria uma alteração da margem de segurança de $0,6374$ para $0,7314$ (Intervalo 10). Pode-se estender esta observação, também, aos demais intervalos. Estes resultados têm sido observados nas simulações apresentadas nas referências [Minussi, 1990] e [Minussi & Freitas Filho, 1998]. Nota-se que neste trabalho não se aplica o redespacho de geração ou qualquer outra ação corretiva. O exemplo abordado é apenas ilustrativo, que serve unicamente para evidenciar a coerência de seu uso para a determinação dos referidos intervalos.

Então, a saída será definida por:

$$Y \triangleq [IMS_k] \quad (7.3.3)$$

sendo:

Y = vetor de saída da rede neural;

IMS_k = vetor correspondente ao k -ésimo intervalo da margem de segurança associada à contingência representada em código binário.

O k -ésimo intervalo IMS_k associado à i -ésima contingência (margem de segurança M_i) é definido observando-se a relação $M_i \in IMS_k$.

A Figura 7.1 ilustra o esquema de estímulos (entrada e saída) da rede neural durante as fases de treinamento e diagnóstico.

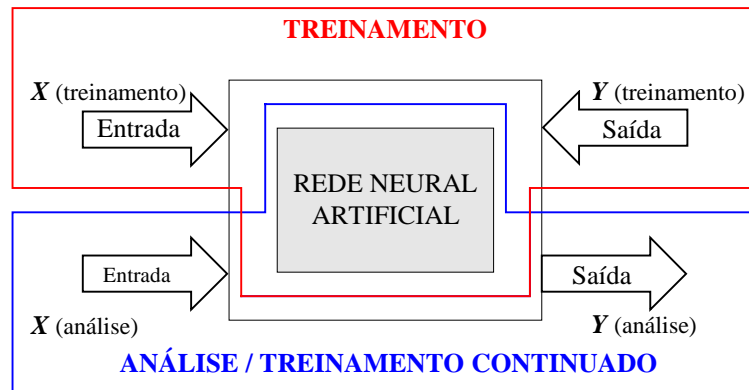


Figura 7.1 – Esquema de Estímulos da rede neural.

7.4 Representação Esquemática do Trabalho Proposto

Nesta seção, 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. A rede neural empregada corresponde a uma versão da rede neural da família ART (ARTMAP Euclidiana), com treinamento supervisionado. Trata-se de uma abordagem de análise para aplicações em tempo real. O funcionamento das redes neurais é constituído por três fases fundamentais, que são o treinamento, treinamento continuado 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. A fase de treinamento continuado está incorporada à fase de análise, através da execução de várias rotinas: aquisição de dados da operação, processamento e ajuste de pesos de forma similar à rotina de treinamento da rede neural.

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

Fase 1: Geração de dados (de entrada e de saída) para uso no treinamento da rede neural e 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 denominado *Simul* [Fonseca & Decker, 1985]. É usado um conjunto extenso de perfis de geração e de carga, os quais são gerados, por processo aleatório (ou pseudo-aleatório), com o objetivo de “simular” os níveis de geração necessários para atender a demanda diária durante um período preestabelecido. Este procedimento visa substituir o uso do despacho econômico. Como resultado, ter-se-á um procedimento que demanda um menor tempo de processamento sem comprometer a qualidade das soluções, pois o que efetivamente ocorre é “simular” um número grande de possíveis perfis de geração e carga do sistema. Usando-se os dados obtidos a partir das simulações realizadas na Fase 1, é preparado o conjunto de dados (de entrada e de saída) para a fase de treinamento da rede neural, conforme foi proposto nas Seções 7.2 e 7.3. Trata-se de um procedimento de extração do conhecimento através da experiência: os exemplos, correspondentes aos dados simulados, são apresentados à rede neural. Esta fase é realizada *off-line*.

Fase 2: Análise

Uma vez concluído o treinamento da rede neural, pode-se executar a análise de estabilidade transitória. Esta fase 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.

Fase 3: Treinamento Continuado

Na Figura 7.2 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. Este dispositivo deve estar agregado ao módulo de análise, ou seja, após o treinamento ter sido concluído. Trata-se do desenvolvimento de um esquema que possibilita manter, permanentemente, a extração do conhecimento do problema a ser abordado (análise de estabilidade transitória), a partir do treinamento realizado, considerando-se os dados gerados via simulação computacional, utilizando os resultados da análise do centro de operação. Consiste, portanto, de módulos de filtros (considerar ou rejeitar as informações) e memória (armazenamento, atualização (reforço) e diagnóstico). Esta etapa distingue-se da fase inicial do treinamento, tendo em vista que a operação dispõe de um grande número de dados e de resultados que podem ser aproveitados ou não. Daí decorre a necessidade de desenvolver rotinas adequadas para processar, armazenar e utilizar tais informações. O módulo “treinamento continuado” pode ser aperfeiçoado a ponto de ser considerado, também, modelos mais elaborados (*e.g.*, modelo completo de Park). Ainda que não haja a disponibilidade de se gerar um índice para modelos mais elaborados, por exemplo, via simulação, é possível, por meio de redes neurais, se gerar um índice híbrido combinando a simulação e algum método baseado no emprego da função energia. Este dispositivo deverá ser objeto de estudo em pesquisas futuras. A exequibilidade do desenvolvimento deste procedimento, certamente, produzirá resultados significativos para a operação de sistemas de energia elétrica, ou seja, é uma possibilidade de realização efetiva da análise, de qualidade, em tempo-real. No Capítulo 8 será apresentado um esquema para realização do treinamento continuado.

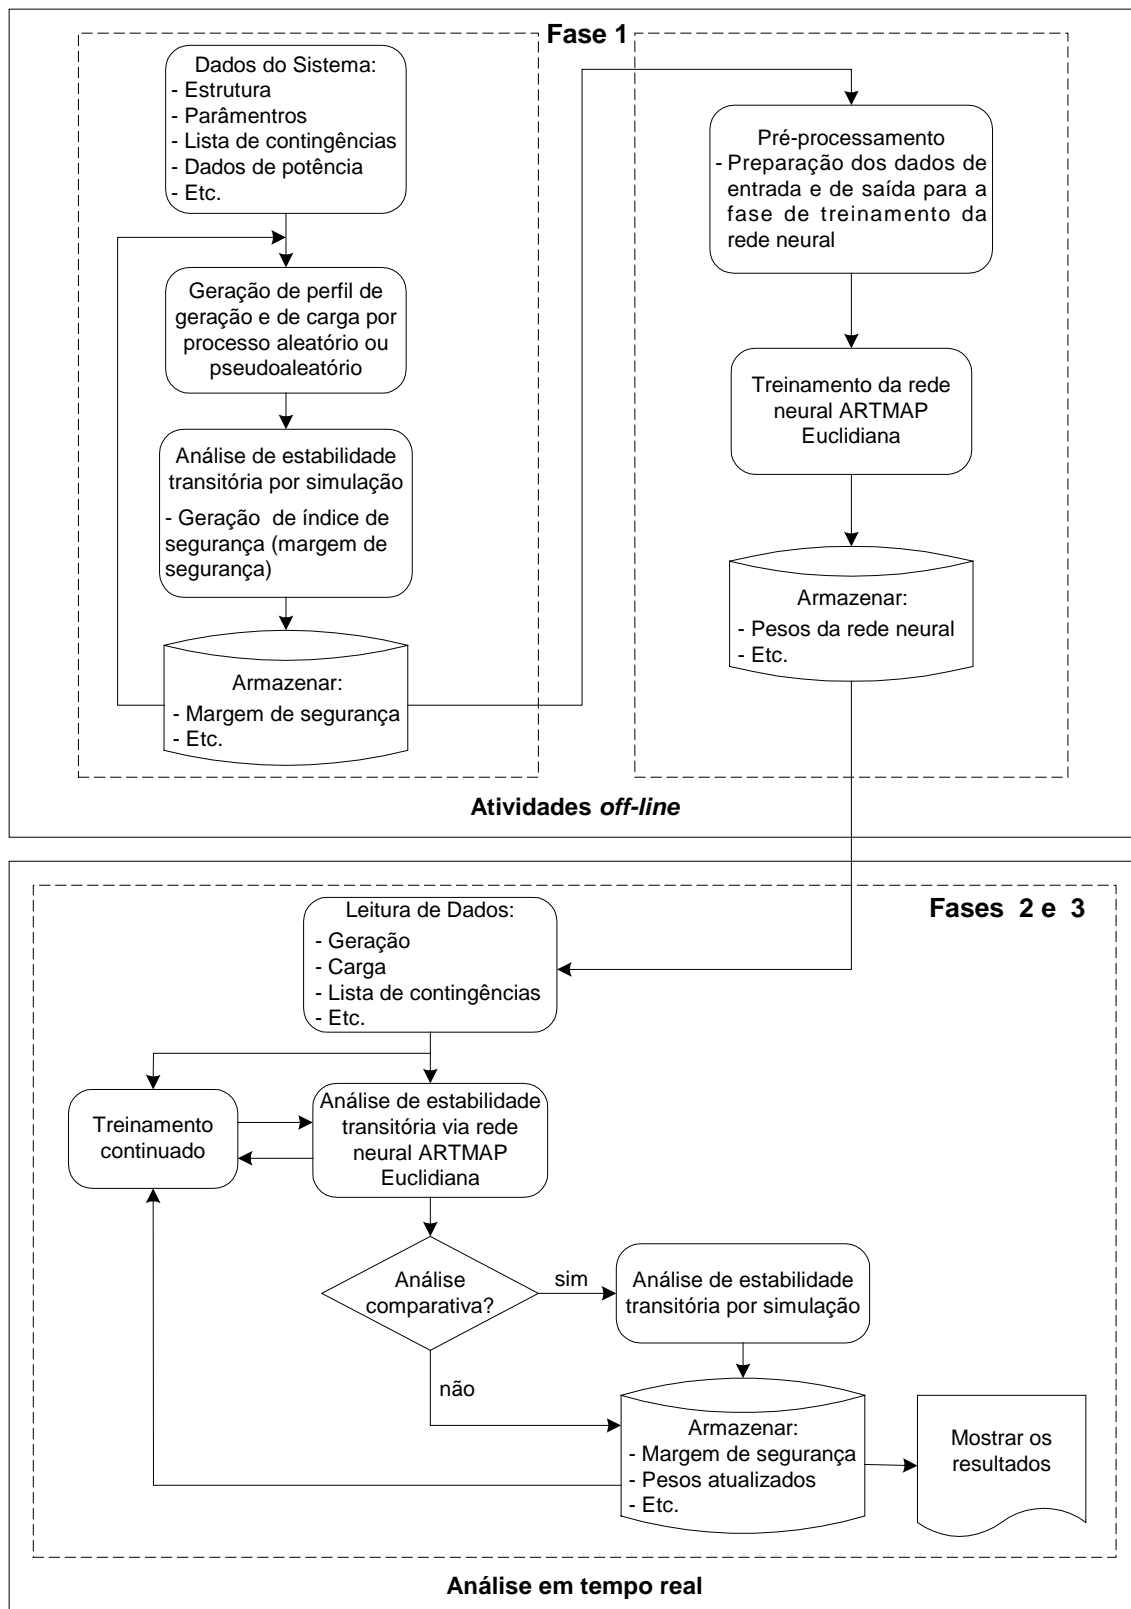


Figura 7.2 - Diagrama esquemático de análise de estabilidade transitória por redes neurais.

7.5 Conclusão

Neste capítulo foram abordadas, basicamente, as particularidades referentes à estrutura neural para a resolução do problema de análise da estabilidade transitória, a escolha das informações que constituem as entradas e saídas para a fase de treinamento e as entradas para o módulo de análise (diagnóstico). No Capítulo 8 será apresentado um esquema destinado à realização do treinamento continuado, com o propósito de compor o algoritmo de execução da análise de estabilidade transitória (Figura 7.2) relativo à fase 3. Estes resultados serão, por conseguinte, implementados no capítulo subsequente, que versará sobre as aplicações, considerando-se um sistema de energia elétrica multimáquinas.

Capítulo 8

Algoritmo de Execução do Treinamento Continuado

8.1 Introdução

No esquema para análise de estabilidade transitória, por redes neurais ART descendente (ARTMAP Euclidiana), abordado no Capítulo 7, contempla a rotina de treinamento continuado. Trata-se de um recurso que visa tornar o sistema de análise mais eficiente, ou seja, a extração do conhecimento é realizada de modo permanente. Esta rotina se constitui, a princípio, numa efetiva possibilidade do emprego de redes neurais na análise em tempo real, destruindo o conceito, até então, sobre as limitações (instabilidade e não-plasticidade) das redes neurais no trato de problemas reais o que tem conferido pouca confiabilidade de aplicação. Assim sendo, na seqüência, será apresentado um procedimento para a implementação do treinamento continuado, que está fundamentado no conceito de detecção de novidade e de anomalia.

8.2 Treinamento Continuado

Para o desenvolvimento do sistema que integra o treinamento continuado na rede neural ARTMAP Euclidiana, foram investigados trabalhos baseados no conceito de Detecção de Novidade (DN) (*Novelty Detection*) [Bishop, 1994] e Detecção de Anomalia (DA) (*Anomaly Detection*) [Liao et. al., 2005] como critério para acionar a inclusão de um novo padrão no banco de memória da rede neural. A DN é um conceito semelhante à DA. Porém, a diferença é que a DN se refere ao descobrimento de novos eventos que aparecem no ambiente que se está abordando. Ou seja, não é detectar anomalias e sim algo que é novidade. Trata-se de identificações importantes, pois, na maioria das vezes, estes eventos são causadores de

dados consideráveis (prejuízos materiais, ataque à integridade pessoal, etc.). A antecipação é a grande aliada para prevenir a ocorrência de sinistros, ou, pelo menos, minimizar as suas conseqüências.

É utilizando esta mesma conceituação que foi desenvolvida a rotina para a ativação da inclusão de novos padrões a partir do mecanismo *match tracking* da rede neural ARTMAP Euclidiana. Esta estratégia deverá ser usada, sempre que necessário, a partir de dados simulados e, principalmente, de informações disponíveis na base de dados das empresas do setor elétrico.

O procedimento adotado nesta pesquisa, visa o desenvolvimento de um mecanismo de definição do momento em que será necessário realizar o treinamento continuado e, também, principalmente, quando houver disponibilidade de dados, incluir ou rejeitar estes dados nas matrizes de pesos da rede neural. A seguir, descreve-se esse procedimento.

8.2.1 Critério para inclusão e rejeição dos dados

O funcionamento adaptativo das redes neurais da família ART permite que novos padrões sejam incluídos a memória da rede permanentemente, melhorando, assim, seu desempenho e tornando seu funcionamento mais eficaz. Para que essa rotina funcione eficientemente é necessário um mecanismo que “selecione” os dados que são realmente importantes para fazer parte da memória da rede. Neste sentido, a partir do neurônio “vazio”, T_0 , introduzido na rede neural ARTMAP Euclidiana, como descrito no Capítulo 6, é realizado o exame do padrão atual, que durante a fase de análise, foi alocado nesta categoria (T_0). Se o neurônio T_0 foi escolhido como categoria vencedora, então uma nova categoria é criada (composta por esse único padrão) e o padrão em questão é indexado como “indeterminado”, e faz-se necessária uma análise para saber se realmente este padrão é importante para ser acrescido à memória da rede ou não. Essa “importância” é medida a partir da apresentação dos padrões subseqüentes à rede neural. Se outros padrões forem indexados à nova categoria, então, a partir de um número mínimo preestabelecido (N_{min}), a categoria é considerada como “novidade”, e seu vetor peso passa a fazer parte da memória da rede. Do contrário, depois de um certo número de inclusão de vetores na rede (N_{max}) sem que N_{min} seja atingido, a

categoria dita “indeterminada” é eliminada do processo. Várias categorias designadas “indeterminadas” podem estar ativas ao mesmo tempo, desde que T_0 tenha sido selecionado a cada apresentação dos padrões subseqüentes. Essas categorias são eliminadas ou incluídas na rede, de acordo com N_{min} e N_{max} estabelecidos.

Pode haver a necessidade, também, de se “apagar” memória da rede neural. Ou seja, depois de realizado o treinamento e treinamento continuado, podem ocorrer que algumas categorias fiquem inativas, sem ter feito previsão alguma, pois nenhum padrão semelhante ao treinado foi apresentado à rede. Essas categorias podem ser eliminadas do processo, simplesmente com a exclusão do vetor peso correspondente, e se, no futuro, se julgar necessário incluir novamente tal categoria, isso pode ser feito através do treinamento continuado.

O treinamento continuado é efetivado, também, a partir do critério de atualização de categorias de reconhecimento, estabelecido no Capítulo 6.

Os passos a seguir, descrevem o funcionamento do módulo *treinamento continuado*, caso ele seja acionado durante a fase de análise:

Passo 1. Apresentação do vetor de entrada à rede neural ARTMAP Euclidiana.

Passo 2. Se a categoria vencedora (categoria escolhida para alocar o padrão atual) tiver ativação T_0 , ou seja, nenhuma das classes existentes é semelhante o suficiente com o padrão atual para alocá-lo, então, cria-se uma nova categoria indexada como “indeterminada”, e segue-se com a apresentação de um novo padrão à rede (Passo 1).

Passo 3. Se a categoria vencedora, T_j , for uma das categorias existentes, a predição é realizada. Também, se o número mínimo de exemplares dessa categoria (NC_{min}) ainda não foi atingido, então adicionar o novo padrão a essa classe. Caso contrário, seguir com a apresentação de um novo padrão (Passo 1).

Passo 4. Se a categoria vencedora for uma categoria “indeterminada” existente, então adicionar o padrão atual à categoria e verificar se N_{min} foi atingido. Caso N_{min} tenha sido atingido, então a categoria passa a ser considerada como “novidade” e

finalmente ela é adicionada à memória da rede como nova informação. Caso contrário, seguir com a apresentação de um novo padrão (Passo 1).

Passo 5. Eliminar do processo as categorias indexadas como “indeterminada” cujo número mínimo de exemplos dessa categoria (N_{min}) não tenha sido atingido após um número máximo de vetores (N_{max}) terem sido apresentado à rede.

Considerando os passos descritos acima, os principais parâmetros envolvidos no processo podem ser resumidos da seguinte forma:

- N_{cmin} : número mínimo de membros que uma categoria, formada na fase de treinamento, deve conter para ser considerada eficiente para realizar uma boa predição.
- N_{min} : número mínimo de membros que uma categoria indexada como “indeterminada” deve conter para ser definida como “novidade”.
- N_{max} : número máximo que uma categoria indexada como “indeterminada”, sem ter atingido N_{min} , deve aguardar para ser rejeitada como nova informação e eliminada do processo.

8.3 Conclusão

Neste capítulo foi proposto um esquema para a realização do treinamento continuado. Este mecanismo está fundamentado no conceito de detecção de novidade e de anomalia que, de forma adequada, pôde ser adaptado para executar a tarefa de realização de filtro (considerar ou rejeitar as informações) durante o processo de análise da estabilidade transitória. Processo este que busca adquirir o conhecimento de forma contínua. Com estes resultados suficientemente lapidados, no Capítulo 9 serão, então, realizados os testes da metodologia proposta.

Capítulo 9

Aplicação

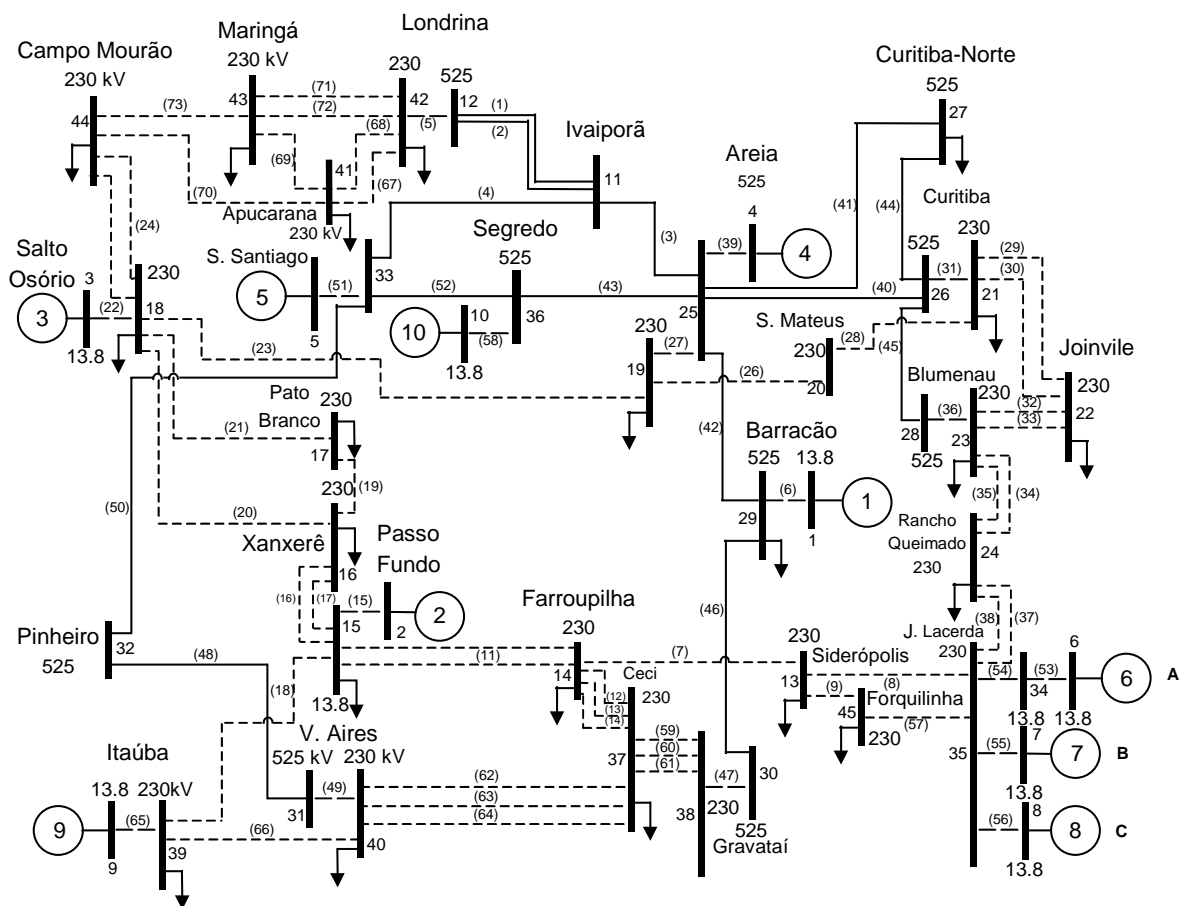
9.1 Introdução

Neste capítulo serão apresentados os resultados da análise de estabilidade transitória de sistemas elétricos de potência, através da rede neural ARTMAP Euclidiana [Vuskovic, 2002a], considerando-se um sistema teste que corresponde a uma possível configuração do sistema elétrico Sul-brasileiro (10 unidades geradoras, 45 nós e 73 linhas de transmissão). O modelo da dinâmica do sistema corresponde ao modelo clássico. Os resultados obtidos, por redes neurais, são comparados com os resultados produzidos por simulação híbrida e com a rede neural ARTMAP nebulosa. Esta comparação tem por objetivo testar a metodologia proposta. Deve-se ressaltar que, o que se pretende é propor uma metodologia de análise da estabilidade transitória para aplicações *on-line*, ou seja, que gere os diagnósticos, de forma rápida e, evidentemente, que sejam confiáveis. Os resultados de simulação apresentados foram obtidos usando-se um microcomputador Pentium IV de 1.8 GHz.

9.2 Configuração do Sistema

O sistema utilizado para testar a metodologia proposta é composto por 10 máquinas síncronas (cada máquina síncrona representando o conjunto gerador), 73 linhas de transmissão e 45 barras [Freitas Filho, 1996; Minussi & Freitas Filho, 1998]. O diagrama unifilar deste sistema é mostrado na Figura 9.1, e os respectivos dados encontram-se relacionados no Apêndice B.

Nestes estudos, consideram-se defeitos tipo curto-circuito trifásico com tempo de eliminação 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. O universo de variação da geração e da carga está compreendido entre 80 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 seqüência randômica. Assim, para um mesmo percentual, diferentes sementes geram diferentes despachos de geração e diferentes perfis de carga. Este procedimento gera um conjunto adequado de padrões para a fase de treinamento.



(--) Número das linhas de transmissão.

Figura 9.1 – Diagrama unifilar do sistema baseado na configuração da região sul do Brasil.

Tabela 9.1 - Conjunto de contingências

Número do defeito	Defeito		
	Barra sob curto-circuito	Saída de circuito	
		Barra inicial	Barra final
1	17	16	17
2	41	41	42
3	43	43	44
4	44	18	44
5	44	41	44

Na fase de análise, são considerados diferentes perfis de geração e de cargas (obtidos com diferentes sementes), se comparados aos dados usados na fase de treinamento. O conjunto de contingências é mostrado na Tabela 9.1. São consideradas 5 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. O treinamento da rede neural é realizado considerando um conjunto em torno de 1500 perfis (em média 100 por contingência para cada configuração do sistema) de geração e de carga e as margens de segurança correspondentes (para as 5 contingências). Nestes experimentos consideram-se 3 configurações diferentes:

- (1) Sistema operando com todas as linhas de transmissão;
- (2) Sistema operando com a retirada da linha entre os nós 16 e 18 e
- (3) Sistema operando com a retirada da linha entre os nós 18 e 19.

Este procedimento visa ilustrar a possibilidade de realizar a análise, considerando-se vários perfis de potência, bem como várias topologias que, certamente, é mais plausível do ponto de vista operacional.

Após a realização do treinamento da rede neural ARTMAP Euclidiana, procede-se a obtenção das análises de contingências. Pretende-se apresentar a análise comparativa entre os resultados padrões (gerados via execução do programa *Simul* [Fonseca & Decker, 1985],

versão para microcomputador) e os resultados obtidos pela rede neural ARTMAP Nebulosa e rede neural ARTMAP Euclidiana. Os resultados gerados pelo programa Simul são usados como referência, por serem precisos, considerando-se o modelo clássico. Deve-se ressaltar que se pode empregar qualquer método de análise de estabilidade transitória como agente “professor”, desde que a metodologia escolhida seja dotada de recurso que gere um índice de estabilidade e não, apenas, a informação de que é estável ou instável, como acontece, por exemplo, na simulação convencional [Stott, 1979].

As comparações são efetivadas usando como função de inferência o intervalo da margem de segurança (*IMS*). Como visto anteriormente, o intervalo *IMS* refere-se ao conjunto de valores da margem de segurança compreendido entre um valor mínimo (*Mmin*) e um valor máximo (*Mmax*). Os limites de cada intervalo, *IMS*, são definidos usando o conceito de esforço de deslocamento da margem de segurança (\mathcal{G}). Assim, cada contingência estando contida em um determinado intervalo *IMS* (*Mmin*, *Mmax*), terá uma margem de segurança esperada entre *Mmin* e *Mmax* que, neste trabalho, foram definidos na Tabela 7.1 (Capítulo 7), considerando-se para $\mathcal{G} = 0,35$. O acerto ou não desta predição é observado comparando-o com o intervalo *IMS* indicado pelo método de simulação híbrida (*Simul*). Pode-se, ainda, implementar um esquema mais segmentado (maior número de intervalos *IMS*) adotando-se valores menores para \mathcal{G} com o propósito de tornar a análise mais precisa. Neste caso, ter-se-á 5 ou mais *bits* para a representação das saídas (em código binário).

Deste modo, são apresentados os resultados das análises de contingências considerando-se os níveis de carregamento compreendido entre 80 e 130%. De acordo com a *estratégia de votação* [Carpenter et al., 1992], foram executados 5 treinamentos considerando-se ordens aleatórias diferentes. Tomando como resolução do problema as soluções geradas com maior frequência, está-se eliminando possíveis previsões errôneas. Este processo, ainda que realizado com repetição de treinamento, é bastante rápido. O treinamento, com a inclusão da estratégia de votação, é realizado na ordem de 1 segundo com o equipamento computacional como anteriormente especificado (Pentium IV / 1.8 GHz).

Considerando-se, portanto, a maior frequência de ocorrência nos casos treinados, apresenta-se na Tabela 9.2 as previsões fornecidas (intervalos *IMS*'s) pela rede neural ARTMAP Euclidiana. Nesta tabela constam, também, os resultados obtidos por simulação (resultados de referência) e pela rede neural ARTMAP Nebulosa para fins comparativos. A

coluna 1 da Tabela 9.2, representa o número do defeito (considerando as 5 contingências adotadas) e sua respectiva configuração (considerando as 3 topologias diferentes). O percentual e a semente usados nas análises encontram-se indicados nas colunas 2 e 3, respectivamente.

Ressalta-se que o erro no diagnóstico, entre as três metodologias, é proporcional à diferença entre as classes indicadas, respectivamente. Por exemplo, se a indicação, para determinada contingência analisada, for observada na ordem de classes 3, 1 e 2, respectivamente, via Simul, ARTMAP nebulosa e ARTMAP Euclidiana, a análise pela rede neural ARTMAP apresenta um maior erro (conseqüentemente, menos precisa) em comparação à rede ARTMAP Euclidiana. Ou seja, a distância entre a classe correta é 2 e 1 respectivamente. Contudo, deve-se observar um detalhe importante, não apenas enfocando a referida distância, como também, se a classe se encontra à direita ou à esquerda da classe correta, tendo em vista que indicações à esquerda é preferível por se tratar de um diagnóstico mais crítico.

O treinamento da rede neural ARTMAP Euclidiana foi realizado utilizando-se os seguintes parâmetros, determinados experimentalmente:

- Parâmetro de vigilância inicial da rede ARTa ($\bar{\rho}_a$) = 0,97;
- Parâmetro de vigilância da rede ARTb (ρ_b) = 0,20;
- Parâmetro de vigilância do módulo inter-ART (ρ_{ab}) = 0,95;
- Parâmetro de treinamento β = 0,01;
- Número de intervalos (*IMS*) = 10.

Tabela 9.2 – Resultados da análise de estabilidade transitória, obtidos por simulação (resultados de referência), rede neural ARTMAP Nebulosa e pela rede neural ARTMAP Euclidiana.

No. do defeito/ Config.	Perfil de geração/carga		Intervalo da margem de segurança (IMS)		
	% do caso base	semente	<i>Simul</i>	ARTMAP Nebulosa	ARTMAP Euclidiana
1 / 1	130	427	3	4	4
1 / 1	125	383	4	4	4
1 / 1	120	143	3	5	4
1 / 1	115	440	5	5	4
1 / 1	110	499	7	7	7
1 / 1	105	945	6	6	6
1 / 1	95	845	6	6	6
1 / 1	90	793	9	8	8
1 / 1	85	747	7	7	7
1 / 1	80	771	9	8	8
2 / 1	130	8	4	5	4
2 / 1	125	14	6	5	6
2 / 1	120	18	5	5	5
2 / 1	115	174	6	6	6
2 / 1	110	259	6	7	6
2 / 1	105	308	7	7	7
2 / 1	95	265	8	8	8
2 / 1	90	468	9	8	8
2 / 1	85	473	9	8	8
2 / 1	80	277	9	8	8
3 / 1	130	841	5	4	4
3 / 1	125	928	5	5	5
3 / 1	120	785	8	7	7
3 / 1	115	590	6	6	6
3 / 1	110	844	7	6	7
3 / 1	105	911	7	6	7
3 / 1	95	680	9	8	8
3 / 1	90	824	8	8	8
3 / 1	85	476	8	8	8
3 / 1	80	293	8	8	8

No. do defeito/ Config.	Perfil de geração/carga		Intervalo da margem de segurança (IMS)		
	% do caso base	semente	<i>Simul</i>	ARTMAP Nebulosa	ARTMAP Euclidiana
4 / 1	130	549	4	4	4
4 / 1	125	539	4	5	4
4 / 1	120	825	6	6	6
4 / 1	115	930	6	6	6
4 / 1	110	991	5	5	5
4 / 1	105	948	6	6	6
4 / 1	95	798	7	7	7
4 / 1	90	819	7	7	7
4 / 1	85	728	8	7	7
4 / 1	80	573	9	8	8
5 / 1	130	121	3	4	4
5 / 1	125	93	2	4	4
5 / 1	120	138	3	4	3
5 / 1	115	286	4	4	4
5 / 1	110	392	5	5	5
5 / 1	105	989	6	6	6
5 / 1	95	840	7	7	7
5 / 1	90	809	7	7	7
5 / 1	85	688	8	8	8
5 / 1	80	814	8	8	8
1 / 2	130	815	4	4	4
1 / 2	125	755	4	4	4
1 / 2	120	914	3	4	4
1 / 2	115	962	3	4	4
1 / 2	110	449	5	5	5
1 / 2	105	902	4	4	4
1 / 2	95	603	5	5	5
1 / 2	90	811	6	6	6
1 / 2	85	493	5	6	5
1 / 2	80	89	6	6	6
2 / 2	130	399	3	4	4
2 / 2	125	803	3	4	4
2 / 2	120	751	6	6	6
2 / 2	115	289	6	6	6

No. do defeito/ Config.	Perfil de geração/carga		Intervalo da margem de segurança (IMS)		
	% do caso base	semente	<i>Simul</i>	ARTMAP Nebulosa	ARTMAP Euclidiana
2 / 2	110	441	7	7	7
2 / 2	105	370	7	7	7
2 / 2	95	276	9	8	8
2 / 2	90	212	8	8	8
2 / 2	85	25	5	6	5
2 / 2	80	380	8	7	7
3 / 2	130	748	3	3	4
3 / 2	125	799	3	3	4
3 / 2	120	990	6	6	6
3 / 2	115	831	6	6	6
3 / 2	110	350	6	6	6
3 / 2	105	249	6	6	6
3 / 2	95	852	7	6	7
3 / 2	90	810	7	6	7
3 / 2	85	913	6	6	6
3 / 2	80	445	7	7	7
4 / 2	130	505	3	4	4
4 / 2	125	662	5	5	5
4 / 2	120	763	3	5	4
4 / 2	115	903	4	5	4
4 / 2	110	349	4	4	4
4 / 2	105	951	4	4	4
4 / 2	95	964	6	6	6
4 / 2	90	760	5	5	5
4 / 2	85	398	5	5	5
4 / 2	80	756	8	7	7
5 / 2	130	641	3	4	4
5 / 2	125	889	4	4	4
5 / 2	120	790	5	4	5
5 / 2	115	949	4	4	4
5 / 2	110	981	3	4	4
5 / 2	105	923	5	5	5
5 / 2	95	648	6	6	6
5 / 2	90	698	6	6	6

No. do defeito/ Config.	Perfil de geração/carga		Intervalo da margem de segurança (IMS)		
	% do caso base	semente	<i>Simul</i>	ARTMAP Nebulosa	ARTMAP Euclidiana
5 / 2	85	670	8	8	8
5 / 2	80	720	9	8	8
1 / 3	130	544	1	4	4
1 / 3	125	816	1	4	4
1 / 3	120	886	1	4	4
1 / 3	115	934	2	4	4
1 / 3	110	924	2	4	4
1 / 3	105	938	3	4	4
1 / 3	95	892	3	4	3
1 / 3	90	812	3	3	3
1 / 3	85	562	5	5	5
1 / 3	80	665	5	5	5
2 / 3	130	395	1	4	4
2 / 3	125	500	4	4	4
2 / 3	120	33	3	3	3
2 / 3	115	171	1	4	4
2 / 3	110	317	5	5	5
2 / 3	105	869	5	5	5
2 / 3	95	932	6	6	6
2 / 3	90	946	7	7	7
2 / 3	85	769	7	7	7
2 / 3	80	571	7	7	7
3 / 3	130	546	4	4	4
3 / 3	125	749	3	3	3
3 / 3	120	596	3	3	3
3 / 3	115	916	3	3	3
3 / 3	110	992	4	4	4
3 / 3	105	723	4	4	4
3 / 3	95	521	5	5	5
3 / 3	90	966	7	7	7
3 / 3	85	944	6	6	6
3 / 3	80	522	9	9	8
4 / 3	130	296	3	4	4
4 / 3	125	642	3	3	3

No. do defeito/ Config.	Perfil de geração/carga		Intervalo da margem de segurança (IMS)		
	% do caso base	semente	<i>Simul</i>	ARTMAP Nebulosa	ARTMAP Euclidiana
4 / 3	120	875	3	3	3
4 / 3	115	474	3	3	4
4 / 3	110	135	3	3	3
4 / 3	105	418	3	3	3
4 / 3	95	377	4	4	4
4 / 3	90	443	3	4	4
4 / 3	85	246	4	4	4
4 / 3	80	419	5	5	5
5 / 3	130	24	1	4	4
5 / 3	125	483	1	4	4
5 / 3	120	409	1	4	4
5 / 3	115	848	1	4	4
5 / 3	110	794	2	4	4
5 / 3	105	548	2	4	4
5 / 3	95	795	3	3	3
5 / 3	90	887	3	3	3
5 / 3	85	689	3	3	3
5 / 3	80	797	3	3	3

Na Tabela 9.2 constam 150 análises da estabilidade transitória, considerando-se as mesmas contingências usadas na fase de treinamento, porém, são considerados diferentes perfis de geração e de cargas (obtidos com diferentes sementes). Os resultados destacados com sombreamento referem-se às análises consideradas com melhoria, comparados com os resultados previstos anteriormente pela rede neural ARTMAP Nebulosa. Essa melhoria refere-se à coincidência ou aproximação com o intervalo da margem de segurança dado pelo método de referência (*Simul*). Os resultados destacados em negrito correspondem a não confirmação, através da rede neural ARTMAP Euclidiana, um resultado antes considerado melhor pela rede neural ARTMAP Nebulosa. Analisando-se esses resultados, pode-se concluir que a rede neural ARTMAP Euclidiana proporciona soluções que podem ser consideradas satisfatórias, em termos de precisão. Em alguns casos, não houve coincidência

entre a previsão via rede neural ARTMAP Euclidiana e o método de simulação (considerado como referência em termos de precisão). Isto ocorreu, provavelmente, em consequência do número pequeno de exemplos empregados no treinamento, principalmente em algumas classes particulares. Por exemplo, os exemplos pertencentes às classes 1, 2 e 3, fizeram a maioria de suas previsões na classe 4, significando que essas classes (1, 2 e 3) não tiveram dados de treinamento suficientes para representar bem sua categoria no módulo ART. A precisão aumenta à medida que se emprega um conjunto de treinamento mais volumoso (maior número de estímulos). Este problema tenderá a ser superado, à medida que for executada a rotina referente ao treinamento continuado. Em relação à rede neural ARTMAP Nebulosa, além de ter sido alcançado uma melhoria em relação ao tempo de processamento, a precisão também foi melhorada (resultados destacados com sombreadimento), embora algumas previsões que foram dadas corretamente pela rede neural ARTMAP Nebulosa, tenham sido não confirmadas pela rede neural ARTMAP Euclidiana (resultados destacados em negrito). Mesmo assim, o número de acertos aumentou, superando os erros, como pode ser observado.

9.3 Resultados Considerando o Treinamento Continuado

Considerando o treinamento continuado, como descrito na Seção 7.4, foram realizados testes com os mesmos dados usados durante a fase de análise, cujos resultados foram mostrados na seção anterior. O treinamento continuado considera os dados que estão sendo apresentados a rede e, se necessário, adiciona esses dados à memória da rede para aperfeiçoar a região de definição das categorias existentes ou cria novas categorias, considerando os dados como nova informação. A Tabela 9.3 apresenta esses resultados, comparando-os com os resultados dado pela rede neural ARTMAP Euclidiana sem a inclusão do treinamento continuado.

Os parâmetros adotados foram:

$$NC_{min} = 100;$$

$$N_{min} = 5;$$

$$N_{max} = 1000.$$

Tabela 9.3 – Resultados da análise de estabilidade transitória, obtidos por simulação (resultados de referência) e pela rede neural ARTMAP Euclidiana, considerando o treinamento continuado (TC).

No. do defeito/ Config.	Perfil de geração/carga		Intervalo da margem de segurança (IMS)		
	% do caso base	semente	<i>Simul</i>	ARTMAP Euclidiana	ARTMAP Euclidiana com TC
2 / 1	85	473	9	8	9
2 / 1	80	277	9	8	9
3 / 1	120	785	8	7	8
4 / 1	85	728	8	7	8
5 / 1	130	121	3	4	3
1 / 2	120	914	3	4	3
1 / 2	115	962	3	4	3
3 / 2	130	748	3	4	3
3 / 2	125	799	3	4	3
4 / 2	80	756	8	7	8
5 / 2	110	981	3	4	3
1 / 3	125	816	1	4	2
1 / 3	120	886	1	4	2
1 / 3	110	924	2	4	3
2 / 3	130	395	1	4	3
3 / 3	80	522	9	8	9
4 / 3	130	296	3	4	3
4 / 3	115	474	3	4	3
5 / 3	130	24	1	4	3
5 / 3	125	483	1	4	3
5 / 3	120	409	1	4	2
5 / 3	115	848	1	4	1
5 / 3	110	794	2	4	2

Para a execução do treinamento continuado, foram considerados os mesmos 150 padrões usados para a análise de estabilidade transitória, cujos resultados foram apresentados na Tabela 9.2. Na Tabela 9.3 apresentam-se 23 análises de estabilidade transitória que

sofreram alteração. Esses resultados referem-se aos dados que tiveram sua predição melhorada com a inclusão da rotina referente ao treinamento continuado, comparado-os com os resultados dados pela rede neural ARTMAP Euclidiana, sem a execução dessa rotina. As outras análises (127 padrões) mantiveram suas predições.

Verificando-se os resultados apresentados na Tabela 9.3, pode-se concluir que o treinamento continuado possibilita melhores resultados, ou seja, alguns padrões coincidiram o intervalo da margem de segurança dado pelo resultado de referência, e outros se aproximaram do intervalo correto, pois é permitida a inclusão de padrões a memória da rede, mesmo durante a fase de análise. Essa inclusão melhora a definição das categorias de reconhecimento formadas durante a fase de treinamento, melhorando a predição dos resultados, continuamente. Os padrões podem ainda ser reconhecidos como “novidade”, criando uma nova categoria e permitindo que uma nova situação seja reconhecida pelo processo. Observa-se, por exemplo, que os padrões que deviam ter a predição nas classes 1,2 e 3, conseguiram fazer uma melhor distinção das categorias e uma melhor predição, com alguns erros ainda, que tendem a ser superados à medida que novos padrões forem apresentados à rede, no processo de análise, e incorporados à memória da rede ARTMAP Euclidiana, conforme descrito no algoritmo mostrado na Figura 7.2. Ou, ainda, realizando o treinamento continuado, considerando-se novas simulações disponibilizadas, através da execução de um programa “professor”, *e.g.*, o programa *Simul*. Deve-se observar que o maior erro ocorreu com relação às contingências situadas no intervalo 1 (contingências supercríticas). Fato este constatado, tendo em vista à baixa disponibilidade de exemplos. Contudo, à medida que se disporem de mais dados padrões para a execução do treinamento continuado, o desempenho da rede neural ARTMAP Euclidiana tenderá melhorar, ou seja, esta rede neural tornar-se-á mais “experiente”.

O treinamento continuado trata de uma rotina muito importante para que a rede continue funcionando à medida que mudanças no sistema sejam detectadas. Ainda, permite que as categorias existentes sejam continuamente melhoradas, fazendo predições mais precisas.

9.4 Conclusão

Neste Capítulo foram realizadas as análises da estabilidade transitória através de uma rede neural ARTMAP Euclidiana. O sistema exemplo refere-se a um sistema de energia elétrica composto por 10 máquinas síncronas, 73 linhas de transmissão e 45 barras. Estes resultados foram comparados com os obtidos via metodologia híbrida, *Simul* [Fonseca & Decker, 1985]. Pode-se concluir que esta rede obtém respostas com grande rapidez, sempre encontra uma solução (característica de estabilidade) e permite a implementação de esquemas que contemple o aprendizado permanente (característica de plasticidade) sem haver necessidade de iniciar novamente o treinamento. Estas soluções podem ser consideradas satisfatórias, também, em termos de precisão. De um modo geral, pode-se concluir que a rede neural ARTMAP Euclidiana, com inclusão do treinamento continuado, constitui-se numa ótima alternativa de análise de estabilidade transitória, principalmente em análise *on-line*. A precisão dos resultados está diretamente relacionada com a quantidade de padrões de treinamento e, especialmente, com o uso de um esquema que contemple o reforço do treinamento (treinamento continuado). Deste ponto de vista, a rede neural ARTMAP Euclidiana proporcionará uma maior eficiência com a implementação de um esquema adequado de treinamento continuado, conferindo-a maior “experiência” e, conseqüentemente, proporcionando maior qualidade das soluções. Ou seja, havendo maior disponibilidade de dados, maior deverá ser qualidade da análise.

Capítulo 10

Conclusão e Sugestões Para Trabalhos Futuros

10.1 Conclusão

Foi desenvolvido, nesta pesquisa, um procedimento de análise de estabilidade transitória de sistemas de energia elétrica multimáquinas, através de uma rede neural ARTMAP Euclidiana. Com esta arquitetura pôde-se idealizar um procedimento de análise de estabilidade transitória de sistemas elétricos de potência. Como ilustração da metodologia foram apresentados os resultados da análise de estabilidade transitória, via rede neural ARTMAP Euclidiana, considerando-se um sistema elétrico de potência correspondente a uma possível configuração do sistema da região sul do Brasil composto por 45 barras, 73 linhas de transmissão e 10 máquinas síncronas. Os estímulos de entrada da rede neural são constituídos pelos vetores de potências ativa e reativa nodais (dados analógicos) e pelos dados das contingências e configuração do sistema (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). O treinamento foi realizado considerando-se 5 contingências (curto-circuito trifásico sólido com saída de linha de transmissão) e três possíveis configurações do sistema. Ressalta-se que este procedimento permite que se considerem várias topologias da rede elétrica, que é uma novidade entre as propostas disponíveis na literatura. As contingências foram arbitradas como incidentes em vários pontos da rede elétrica (5 localizações). Foram considerados níveis de carregamentos arbitrados de forma aleatória dentro de um universo compreendido entre 80 e 130% da carga total do sistema. Para a fase de predição, foi implementado um esquema que inclui novos padrões à memória da rede, melhorando a região de definição das categorias de reconhecimento e, conseqüentemente, a precisão dos

resultados. 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 SEE. A rede neural ARTMAP Euclidiana tem proporcionado a obtenção de soluções bastante rápidas (menos de 1 segundo utilizando um microcomputador Pentium IV de 1,8 MHz, considerando-se a execução da estratégia de votação com 5 repetições de treinamento). A qualidade das soluções pode ser considerada adequada. Concluindo-se, a rede neural ARTMAP Euclidiana 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/saída bem elaborado (em quantidade e qualidade suficientes). O principal destaque da rede neural ARTMAP refere-se à característica de plasticidade. Com esta propriedade pode-se conceber mecanismos que contemplem o treinamento continuado (reforço do treinamento) sem destruir o conhecimento extraído anteriormente (observa-se que na maioria das redes neurais propostas na literatura especializada, o reforço do treinamento pressupõe a reinicialização do processo, destruindo o conhecimento adquirido anteriormente). Deste modo, a rede neural estará permanentemente se aperfeiçoando o que irá proporcionar soluções cada vez mais precisas, conforme comentado anteriormente. Este assunto deverá ser investigado em pesquisa futura.

As principais contribuições desta pesquisa são assim destacadas: (1) metodologia neural (ARTMAP Euclidiana) para análise da estabilidade transitória de sistemas de energia elétrica mais eficiente (mais rápida e mais precisa), se comparada às redes neurais ARTMAP nebulosa; (2) metodologia que permite o trabalho com diferentes topologias; (3) encontra-se incluso o mecanismo do treinamento continuado. Esta alternativa possibilita que se estude e, finalmente, seja implementada a análise de estabilidade transitória em tempo real.

10.2 Sugestões Para Trabalhos Futuros

Os resultados desta pesquisa podem ser considerados satisfatórios (no contexto da precisão e da rapidez na obtenção das soluções), conforme argumentado anteriormente.

Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar esta metodologia mais eficiente:

- 1) Desenvolvimento de estruturas neurais alternativas à rede ARTMAP Euclidiana, empregando, por exemplo, outras distâncias geométricas como propostas nas referências Dagher (2005a) e Dagher (2005b). Tratam-se de procedimentos mais gerais que buscam estabelecer a formação de classes de forma mais precisas em comparação aos resultados aqui apresentados;
- 2) Desenvolvimento de metodologias mais eficientes de realização do treinamento continuado que possam avançar ainda mais as pesquisas deste mecanismo. Ressalta-se que o resultado de uma eventual melhoria poderá, também, ser bastante útil para a resolução de grande variedade de problemas da vida real que efetivamente necessitam da extração continuada do conhecimento, *e.g.*, análise de sinais, previsão de carga, análise de imagens, etc.;
- 3) Desenvolvimento de uma metodologia neural ART descendente para análise da estabilidade transitória considerando-se modelos mais elaborados que o modelo clássico, por exemplo, o modelo completo de Park [Stott, 1979]. Esta rotina poderá ser implementada, através do emprego de um segundo módulo neural para a obtenção de um índice constituído a partir da combinação de um índice quantitativo / qualitativo (*e.g.*, semelhante ao índice da margem de segurança (equação (3.2.1)), e de um índice qualitativo, baseados em resultados apurados via simulação, e resultados disponíveis na operação do sistema de energia elétrica. Assim, o desafio está lançado.

Capítulo 11

Referências Bibliográficas

- ANAGNOSTOPOULOS, G. C. “Novel Approaches Adaptive Resonance Theory for Machine Learning”, *Dissertation of Doctor*, Department of Electrical Engineering, University of Central Florida, Orlando, Florida, 2001.
- ANDERSON, P. M.; FOUAD, A. A. “Power System Control and Stability”, *IEEE Series on Power Engineering*, USA, Second Edition, 2003.
- ATHAY, T.; SHERKET, V. R.; PODMORE, R.; VIRMANI, S.; PUECH, C. “Transient Energy Stability Analysis”, *Conference on 'System Engineering For Power'*, Davos, Switzerland, 1979.
- BISHOP, C. M. “Novelty Detection and Neural Network Validation”, *IEE Proceedings Vision, Image and Signal Processing*, Vol. 141, Issue: 4, pp. 217-222, August, 1994.
- CARPENTER, G. A.; ROSS, W. D. “ART-EMAP: A Neural Network Architecture for Object Recognition by Evidence Accumulation”, *IEEE Transactions on Neural Networks*, Vol. 6, 805-818, 1995.
- CARPENTER, G. A.; RUBIN, M. A.; STREILEIN, W. W. “ARTMAP-FD: Familiarity Discrimination Applied to Radar Target Recognition”, *Proceeding International Conference on Neural Network*, Vol. III, pp. 1459-1464, 1997.
- CARPENTER, G. A.; GROSSBERG, S. “A Massively Parallel Architecture for a Self-organizing Neural Pattern Recognition Machine”, *Computer Vision, Graphics, and Image Processing*, Vol. 37, pp. 54-115, 1987a.

- CARPENTER, G. A.; GROSSBERG, S. "ART2: Self-organizing of Stable Category Recognition Codes for Analog Input Patterns", *Applied Optics*, 26(23), pp. 4919-4930, 1987b.
- 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 Transaction on Neural Networks*, 3(5), pp. 698-713, 1992.
- CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. "ARTMAP: Supervised Real-time Learning and Classification of Non-stationary data by a Self-organizing Neural Network", *Neural Networks*, Vol. 6, pp. 565-588, 1991a.
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. "Fuzzy ART: Fast Stable Learning and Categorization of Analog Patterns by an Adaptive Resonance System", *Neural Networks*, 4(6), pp. 759-771, 1991b.
- CARPENTER, G. A.; GROSSBERG, S. "Pattern Recognition by Self-Organizing Neural Networks", *The MIT Press*, Cambridge, Massachusetts, USA, 1991c.
- DAGHER, I. "L-p Fuzzy ARTMAP Neural Network Architecture", *Soft Computer*, 2005.
- DAGHER, I. "ART Networks with Geometrical Distances", *Journal of Discrete Algorithms*, In Press, Corrected Proof, Available online 15 July 2005, 16p.
- ELGERD, O. I. "Electric Energy Systems Theory: An Introduction", New York, NY, *MacGraw Hill Book Company*, 1971.
- EPRI "Transient Stability Margin as a Tool For Dynamic Security Assessment", *Iowa State University*, EPRI EL-1755, Project 1355-3, Ames, Iowa, 1981.
- FONSECA, L. G. S.; DECKER, I. C. "Iterative Algorithm for Critical Energy Determination in Transient Stability of Power System", *IFAC - Symposium Planning & Operation in Electric Energy System*, Rio de Janeiro – RJ, Brazil, pp. 483-489, 1985.

- FOUAD, A. A.; VITTAL, V. “Power System Transient Stability Analysis Using the Transient Energy Function Method”, *Prentice Hall*, Englewood Cliffs, New Jersey, 1992.
- FREITAS FILHO, W. “Controle de Segurança Dinâmica de Sistemas de Energia Elétrica via Análise de Sensibilidade e Redes Neurais”, *Dissertação de Mestrado*, Programa de Pós-graduação em Engenharia Elétrica – UNESP, Ilha Solteira – SP, Dezembro, 1996.
- GOMÉS-SÁNCHEZ, E.; DIMITRIADIS, Y. A.; CANO-IZQUIERDO, J. M.; LÓPEZ-CORONADO, J. “ μ ARTMAP: use of mutual information for category reduction in Fuzzy ARTMAP”, *IEEE Transactions on Neural Networks*, Vol. 13, No. 1, 58-69, 2002.
- GROSSBERG, S. “Adaptive Pattern Recognition and Universal Encoding II: Feedback, Expectation, Olfaction, and Illusions”, *Biological Cybernetics*, Vol. 23, pp. 187-202, 1976.
- HAYKIN, S. “Neural Networks: A Comprehensive Foundation”, *Prentice-Hall*, Upper Saddle River, New Jersey, USA, 1994.
- IEEE – TASK FORCE “Proposed Terms & Definitions for Power System Stability”, *IEEE Transactions on Power Apparatus and Systems*, Vol. PAS – 101, No. 7, pp. 1894-1898, July, 1982.
- JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. “Artificial Neural Networks: A Tutorial”, *IEEE Computer*, Vol. 29, No. 3, pp. 31-44, March, 1996.
- KARTALOPOULOS, S. V. “Understanding Neural Networks and Fuzzy Logic”, *IEEE Press*, New York, 1996.
- KING, R. L. “Artificial Neural Networks And Computational Intelligence”, *IEEE Computer Application in Power*, pp. 14-29, October, 1998.

- KOHONEN, T. “Self-Organized Formation of Topologically Correct Feature Maps”, *Biological Cybernetics*, Vo. 43, pp. 59-69, 1982.
- KOHONEN, T. “Self-Organizing and Associative Memory”, 2nd edition, Springer-Verlag, Berlin, Germany, 1987.
- KUNDUR, P. “Power System Stability and Control”, *McGraw Hill*, Palo Alto, CA, U.S.A., EPRI Editors, 1994.
- KUNG, S. Y. “Digital Neural Networks”, *Prentice-Hall*, Englewood Cliffs, N. Jersey, USA, 1993.
- LIAO, Y.; VEMURI, V. R.; PASOS A. “Adaptive Anomaly Detection With Evolving Connectionist Systems”, *Journal of Network and Computer Applications*, In Press, Corrected Proof, Available online 26 August 2005, 22p.
- LOTUFO, A. D. P. “Análise de Sensibilidade por Redes Neurais para Estudos da Estabilidade Transitória de Sistemas Elétricos de Potência”, *Tese de doutorado*, Programa de Pós-graduação em Engenharia Elétrica – UNESP, Ilha Solteira – SP, Agosto, 2004.
- MARCHIORI, S. C.; MINUSSI, C. R., LOTUFO, A. D. P. “Rede Neural ARTMAP Nebulosa para Análise de Estabilidade Transitória de Sistemas de Energia Elétrica”, *Revista da Sociedade Brasileira de Redes Neurais – Learning and Nonlinear Models*, Vol.1, No.1, pp.61-78, 2002.
- MARRIOTT, S.; HARRISON, R. F. “A Modified Fuzzy ARTMAP Architecture for the Approximation of Noisy Mappings”, *Neural Networks*, Vol. 8, No. 4, pp. 619-641, 1995.
- McNEIL, F. M.; THRO, E. “Fuzzy Logic a Practical Approach”, *Academic Press*, 1994.
- MENDES FILHO, E. F.; CARVALHO, A. C. P. L. “Tutorial Introdutório Sobre Redes Neurais Artificiais”, *Departamento de Ciências de Computação e Estatística – USP*, Fevereiro, 1997.

- MINUSSI, C. R. “Controle de Segurança Dinâmica em Sistemas de Energia Elétrica”, *Tese de Doutorado*, Programa de Pós-graduação em Engenharia Elétrica – UFSC, Florianópolis – SC, Novembro, 1990.
- MINUSSI, C. R.; FREITAS FILHO, W. “Sensitivity Analysis For Transient Stability”, *IEE Proceedings on Generation, Transmission And Distribution*, Vol. 145, No. 6, pp. 669-674, 1998.
- 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”, *V Congresso Brasileiro de Redes Neurais*, pp. 31-36, Rio de Janeiro – RJ, 2001.
- PAI, M. A. “Power System Stability”, *North Holland Control Series*, 1981.
- PAO, Y. H.; SOBAJIC, D. J. “Combined Use of Unsupervised And supervised Learning For Dynamic Security Assessment”, *IEEE PICA-91*, pp. 278-284, 1991.
- PARK, Y. M.; KIN, G. -W.; CHO, H. -S; LEE, K. Y. “A New Algorithm for Kohonen Layer Learning With Application to Power System Stability Analysis”, *IEEE Transactions on Systems, Man, And Cybernetics*, Vol. 27, No. 6, pp. 1030-1033, December, 1997.
- PAVELLA, M.; ERNST, D.; RUIZ-VEGA, D. “Transient Stability of Power Systems a Unified Approach to Assessment and Control”, Boston, U.S.A., *Kluwer Academic Publisher*, 2000.
- RAUBER, T. W. “Redes Neurais Artificiais”, disponível em <http://www.lia.ufc.br/~eti/2003/menu/modulos/RNA/RNA-RedesNeuraisArtificiaisII.pdf>. Acesso em 9 de junho de 2005.
- RIBBENS-PAVELLA, M.; EVANS, P. J. "Direct Methods For Studying Dynamics of Large-scale Electric Power Systems - A Survey", *Automatica*, Vol. 21, pp. 1-2, 1985.

- SILVEIRA, M. C.G. “Análise de Estabilidade Transitória de Sistemas Elétricos por Redes neurais ARTMAP Nebulosas Modulares”, Tese de Doutorado, Programa de Pós-graduação em Engenharia Elétrica – Faculdade de Engenharia de Ilha Solteira – UNESP, Outubro-2003.
- SILVEIRA, M. C. G.; LOTUFO, A. D. P.; 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, 7p, 2003.
- SIMPSON, P. K. “Artificial Neural Systems: Foundations, Paradigms, Applications, and Implementations”, *Pergamon Press*, New York, 1989.
- SOBAJIC, D. J.; PAO, Y-H. “Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems”, *IEEE Transactions on Power Systems*, Vol. 4, No. 1, pp. 220-227, February, 1989.
- STOTT, B. “Power System Dynamic Response Calculations”, *Proceedings of the IEEE*, Vol. 67, No. 2, pp. 219 – 241, January, 1979.
- TERANO, T.; ASAI, K.; SUGENO, M. “Fuzzy Systems Theory And Its Application”, *Academic Press*, New York, USA, 1987.
- Tutorial <http://www.din.uem.br/ia/neurais/>. Acesso em 2 de março de 2005.
- URL <http://allserv.ugent.be/~svaelst/courses/distance.pdf>. Acesso em 15 de agosto de 2005.
- VAKIL-BAGHMISHED, M-T.; PAVESIC, N. “A Fast Simplified Fuzzy ARTMAP Network”, *Neural Processing Letters*, Vol.17, pp. 273 – 316, 2003.
- VENIKOV, V. A.; ANISIMOVA, N. D.; EZHKOV, V. V.; ZHUKOV, L. A.; LIKTENS, J. V.; FIEDOROV, D. A.; TSOVIANOV, A. N. “Calculos de Estabilidad de Sistemas Electricos Automatizados”, *Editora Mir*, Moscou, Russia, 1970.

- VERZI, S. J.; HEILEMAN, G. L.; GEORGIOPOULOS, M.; HEALY, M. J. “Boosting the performance of ARTMAP”, *Proceedings of IJCNN 98*, pp. 396-401, 1998.
- VUSKOVIC, M.; DU, S. “Classification of EMG Patterns with Simplified Fuzzy ARTMAP Networks”, *Proceeding of the 2002 International Joint Conference on Neural Networks, Networks, Honolulu – Hawaii, May 12-17, 2002a*.
- VUSKOVIC, M.; DU, S. “Simplified ARTMAP Network Based on Mahalanobis Distance”, *Proceeding of the 2002 International Conference on Mathematics and Engineering Techniques in Medicine and Biological Science, Las Vegas, Nevada, June 27-27, 2002b*.
- WASSERMAN, P. D. "Neural Computing - Theory And Practice", *Van Nostrand Reinhold*, New York, USA, 1989.
- WERBOS, P. J. “Beyond Regression: New Tools For Prediction And Analysis in The Behavioral Sciences”, *Master Thesis*, Harvard University, 1974.
- WIDROW, B.; LEHR, M. A. “30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation”, *Proceedings of the IEEE*, Vol. 78, No. 9, pp. 1415-1442, September, 1990.
- WILLIAMSON, J. R. “Gaussian ARTMAP: A Neural Network for Fast Incremental Learning of Noisy Multidimensional Maps”, *Neural Networks*, Vol. 9, No. 5, pp. 881-897, 1996.

Apêndice A

Algoritmo Computacional para a Determinação da Margem de Segurança

Considerando os conceitos apresentados no Capítulo 3, pode-se descrever o algoritmo de análise de estabilidade transitória de sistemas de energia elétrica (Método PEBS Iterativo), mediante os seguintes passos [Fonseca & Decker, 1985]:

Passo 1. Ler os dados.

Passo 2. Determinar o fluxo de potência do sistema pré-defeito.

Passo 3. Iniciar o contador de contingências:

$$r \leftarrow 1.$$

Passo 4. Contador de contingências:

$$r \leftarrow r + 1.$$

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

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 defeito e pós- defeito, é determinado usando o método Runge-Kutta de segunda ordem (integração numérica das equações diferenciais (2.3.1));

(b) energia e tempo crítico determinados utilizando-se o algoritmo proposto na [Fonseca et al., 1985]. A função de Lyapunov, tipo energia, é avaliada de acordo com as expressões (3.2.2)-(3.2.4).

Passo 9. Última contingência? Se verdadeira, ir ao passo 10. Do contrário, retornar ao passo4.

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 10. Finalizar o processo de cálculo.

Apêndice B

Dados do Sistema de Energia Elétrica

A seguir, apresentam-se os dados e o diagrama unifilar referentes a uma configuração-teste baseada no sistema sul-brasileiro composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão. Os dados referem-se a uma base de 100 MVA.

Tabela A1 – Dados de barras do sistema sul-brasileiro (10 máquinas).

IDENTIFICAÇÃO		TENSÃO		CARGA		GERAÇÃO	
Nº	NOME	MÓD.	ÂNG.	MW	MVAr	MW	MVAr
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

Tabela A1 - Continuação.

IDENTIFICAÇÃO		TENSÃO		CARGA		GERAÇÃO	
Nº	NOME	MÓD.	ÂNG.	MW	MVAr	MW	MVAr
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
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 A2 - 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 A2 - Continuação.

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 A2 - Continuação.

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 A3 - 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 Relacionados com a Pesquisa de Doutorado

De acordo com as exigências do Regulamento do PPGEE (Programa de Pós-graduação em Engenharia Elétrica) da Faculdade de Engenharia de Ilha Solteira – UNESP, Art. 45, Parágrafo único, o aluno de Doutorado deverá ter publicado ou ter sido aceito para publicação, no mínimo, dois artigos completos, relacionados com a pesquisa, 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 relacionados com a pesquisa de doutorado:

1. **MARCHIORI, S. C.**; MINUSSI, C. R., LOTUFO, A. D. P. “Rede Neural ARTMAP Nebulosa para Análise de Estabilidade Transitória de Sistemas de Energia Elétrica”, *Revista da Sociedade Brasileira de Redes Neurais – Learning and Nonlinear Models*, Vol.1, No.1, pp. 61-78, 2002.
2. SILVEIRA, M. C. G.; FERREIRA, W. P.; **MARCHIORI, S. C.**; MINUSSI, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Usando uma Rede Neural ARTMAP Nebulosa”, *XIV Congresso Brasileiro de Automática*, pp. 3171-3177, Natal – RN, 2002.
3. **MARCHIORI, S. C.**; MINUSSI, C. R. “Rede Neural ARTMAP Euclidiana para Análise da Estabilidade Transitória de Sistemas Elétricos”, *XXV Congresso da Sociedade Brasileira de Computação e V Encontro Nacional de Inteligência Artificial*, pp.573-582, São Leopoldo –RS, 2005.
4. **MARCHIORI, S. C.**; LOTUFO, A. D. P.; MINUSSI, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Por Rede Neural ARTMAP Euclidiana”, *VII Simpósio Brasileiro de Automação Inteligente*, São Luís – MA, 2005.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)