unesp

UNIVERSIDADE ESTADUAL PAULISTA

Pós-Graduação em Engenharia Elétrica

RADO

Estabilidade Transitória de Sistemas de Energia Elétrica: Uma Metodologia de Análise Via Rede Neural ARTMAP Nebulosa

12100001229

Sandra Cristina Marchiori

Ilha Solteira - SP

cm 1 2 3 4 5 6 7 8 unesp 12 13 14 15 16 17 18 19

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

Estabilidade Transitória de Sistemas de Energia Elétrica: Uma Metodologia de Análise Via Rede Neural ARTMAP Nebulosa

Sandra Cristina Marchiori

Carlos Roberto Minussi

Orientador

Ilha Solteira – SP, agosto de 2001.

BCpIS - FEIS - UNESP

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

Estabilidade Transitória de Sistemas de Energia Elétrica: Uma Metodologia de Análise Via Rede Neural ARTMAP Nebulosa

1210001229

Sandra Cristina Marchiori

Carlos Roberto Minussi

Orientador

Proc. 040/2001-NRD 108/01
UNESP - "CAMPUS DE ILHA SOLTEIRA"
SERVIÇO TÉC. DE BIBLIOTECA E DOCUMENTAÇÃO
02/10/01 30/10/01
Ailza Te. 1229
Doação Autor R$ 10,00
M317e

Dissertação submetida à Universidade Estadual Paulista – UNESP, Câmpus de Ilha Solteira, para a obtenção do título de Mestre em Engenharia Elétrica.

30400007
ENGA. ELÉTRICA
Exp 53784

Ilha Solteira – SP, agosto de 2001.

BCpIS - FEIS - UNESP

"Estabilidade Transitória de Sistemas de Energia Elétrica: Uma Metodologia de Análise Via Rede Neural ARTMAP Nebulosa"

Sandra Cristina Marchiori

DISSERTAÇÃO SUBMETIDA À FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA – UNESP – COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO TÍTULO DE MESTRE EM ENGENHARIA ELÉTRICA (ME).

Prof. Dr. Antonio Padilha Feltrin – Coordenador

COMISSÃO EXAMINADORA:

Prof. Dr. Carlos Roberto Minussi - orientador

Prof. Dr. Walmir de Freitas Filho

Prof. Dr. Antonio Padilha Feltrin

Ilha Solteira – SP, agosto de 2001

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Esta dissertação de mestrado 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 99/04333-5.

BCpIS - FEIS - UNESP

"As idéias nada podem realizar. Para realizar as idéias são necessários homens que ponham a funcionar uma força prática."

Karl Marx

BCpIS - FEIS - UNESP

Aos meus pais, Norival e Odelir, pelo exemplo de vida e apoio em todos os momentos.

Dedico.

Agradecimento Especial

Ao meu orientador, Prof. Dr. Carlos Roberto Minussi, que com dedicação, paciência e compreensão me auxiliou na execução deste trabalho. Fica guardado o exemplo de profissional e de pessoa. A você, o meu respeito e admiração!

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Agradecimentos

A realização deste trabalho tornou-se possível graças à colaboração, direta e indireta, de muitas pessoas, porém, poucas vezes lembramos de agradecer àqueles que estiveram presentes dando seu apoio, seja ele técnico, financeiro ou emocional. Talvez eu não lembre de todos neste momento, mas alguns é impossível esquecer.

Agradeço aos meus pais, Norival e Odelir, pelo incentivo e pelo apoio em todos os momentos da minha vida, pela confiança, carinho e amor que sempre depositaram em mim e por serem, em sua simplicidade, os melhores pais que poderia desejar.

A minha irmã, Selma, que sempre me serviu de exemplo por seu profissionalismo, seriedade e também por estar sempre ao meu lado apoiando-me e incentivando-me em todos os momentos, e ao meu irmão, Paulo Henrique.

Ao meu noivo, Wesley, pelo seu amor, carinho, compreensão e por compartilhar da melhor forma possível, dos melhores momentos de minha vida de maneira segura e carinhosa.

A minha grande amiga Lilian, por estar sempre ao meu lado mesmo quando isto se tornava difícil, pelo carinho, atenção e pelos maravilhosos momentos que vou sempre lembrar.

Ao Prof. Dr. Carlos Roberto Minussi, pela orientação, confiança, incentivo, amizade e por contribuir para minha formação profissional e realização deste trabalho.

unesp

Ao Prof. Dr. Walmir de Freitas Filho e ao Prof. Dr. Antonio Padilha Feltrin, pelas suas participações, sugestões e críticas pertinentes.

Aos professores do curso de Pós-graduação em Engenharia Elétrica da UNESP - Campus de Ilha Solteira, pela busca contínua da excelência e da qualidade dos trabalhos e condições de realização dos mesmo e pelos ensinamentos dispensados.

Aos funcionários da seção de pós-graduação da UNESP - Campus de Ilha Solteira, Arlindo, Fafá e Paulo, e funcionários do Departamento de Engenharia Elétrica da UNESP, Sueli e Cristina, pela atenção sempre solícita.

Aos técnicos Deoclécio e Carlos Alex, pelo suporte técnico no laboratório de informática.

Aos amigos de pós-graduação, em especial as amigas Gilvana e Mara, pela ajuda e companheirismo.

À Fundação de Amparo à Pesquisa do Estado de São Paulo - FAPESP, pelo auxílio financeiro dado a esta pesquisa.

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

E finalmente, agradeço a Deus, que me deu força e vontade para superar todos os obstáculos encontrados no caminho, e me fez chegar a este momento em que posso agradecer a todos pela minha vitória.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Resumo

Este trabalho tem por objetivo o desenvolvimento de uma metodologia para a análise de estabilidade transitória de Sistemas de Energia Elétrica usando redes neurais artificiais baseadas na arquitetura ARTMAP cujas operações matemáticas originais são substituídas por operações no contexto de conjuntos nebulosos (ARTMAP nebulosa). Esta arquitetura busca explorar a similaridade entre os conceitos computacionais da teoria de conjuntos nebulosos e a rede neural ART (*Adaptive Resonance Theory*). As arquiteturas ART apresentam as características de estabilidade e plasticidade, as quais são qualidades imprescindíveis para a realização do treinamento e execução da análise. Visa-se, deste modo, empregar um treinamento mais rápido, se comparado com a formulação convencional do algoritmo *backpropagation*, conseqüentemente tornando a análise mais competitiva em comparação aos principais métodos encontrados na literatura especializada. Como ilustração da metodologia são apresentados os resultados da análise de estabilidade transitória, através da rede neural ARTMAP nebulosa, 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.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Abstract

The objective of this work is the development of a methodology for transient stability analysis of Electric Power Systems using neural networks based on the ARTMAP architecture which original mathematical operations are replaced by operations in the context of fuzzy sets (fuzzy ARTMAP). This architecture explores the similarity between the computational concepts of the fuzzy sets theory and the ART neural network (Adaptive Resonance Theory). The ART architectures present the stability and plasticity features, which are indispensable qualities for the training accomplishment and analysis execution. Therefore it is used a faster training, if compared with the conventional formulation of the Backpropagation algorithm, consequently making the analysis more competitive than the major methods found in the specialized literature. As illustration of the methodology, it is presented the results of transient stability analysis, through the fuzzy ARTMAP neural network, considering a power system corresponding to a possible southern Brazil Systems configuration composed by 45 bus, 73 transmission lines and 10 synchronous machines.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Notação e Simbologia

SEE = Sistemas de Energia Elétrica

MDL = Método Direto de Lyapunov

RNA = Redes Neurais Artificiais

ART = *Adaptive Resonance Theory* (Teoria da Ressonância Adaptativa)

CA = Centro de Ângulos

E = atendimento das restrições de igualdades

I = atendimento das restrições de desigualdades

$\overline{E}$ = não atendimento das restrições de igualdades

$\overline{I}$ = não atendimento das restrições de desigualdades

$g_i(\theta)$ = $Pm_i - Pe_i - (M_i PCOA)/MT$

M_i = $2H_i/\omega_s$

H_i = constante de inércia (s)

ω_s $\triangleq$ velocidade síncrona

= $2\pi f_0$

f_0 = freqüência nominal do sistema (Hz)

θ_i $\triangleq$ ângulo do rotor da *i*-ésima máquina síncrona referida ao CA (rad. elét.)

= $\delta_i - \delta_0$

unesp

δ_i = ângulo do rotor da i-ésima máquina síncrona medida com relação a uma máquina que gira à velocidade síncrona (rad. elét.)

δ_0 = $\sum_{j \in N} M_j \delta_j$

N $\triangleq$ conjunto de índices das máquinas que compõem o sistema

= $\{1, 2, ..., ng\}$

ng = número de máquinas síncronas

Pm_i = potência mecânica de entrada (pu)

Pe_i = potência elétrica de saída (pu)

$PCOA$ $\triangleq$ potência acelerante do CA

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

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

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

= $1/2 \sum_{i \in N} M_i \omega_i^2$

$Ep\ (\theta)$ $\triangleq$ energia potencial

= $-\sum_{i \in N} \int_{\theta_i^p}^{\theta_i} g_i(\theta) d\theta_i$

p = ponto de equilíbrio pós-falta

PEBS = *Potential Energy Boundary Surface* (Superfície Limite de Energia Potencial)

$D(\theta)$ = derivada direcional da Energia Potencial

$< . , . >$ = produto interno de dois vetores n-dimensionais

$g(\theta)$ = $[g_1(\theta) \quad g_2(\theta) \quad \dots \quad g_3(\theta)]^T$

T = transposto

$\| \bullet \|_e$ = norma euclidiana

LTM = *Long Term Memory* (Memória à Longo Prazo)

STM = *Short Term Memory* (Memória à 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

I = $\left(a, a^c\right)$

= $\left(a_1, a_2, \dots, a_n, a_1^c, a_2^c, \dots, a_n^c\right)$

a_i^c = $1 - a_i$

a_i = padrão de entrada para a rede ART nebulosa

T_j $\triangleq$ função escolha

= $\dfrac{\left|I \wedge w_j\right|}{\alpha + \left|w_j\right|}, \; j = 1, \dots, 2n$

unesp

$\wedge$ = operador nebuloso *and*

$\cap$ = operador de interseção *crisp*

T_J = $\max\{T_j : j = 1, ..., 2n\}$

J = índice da categoria escolhida

$w_J^{'}$ $\underline{\Delta}$ atualização do vetor de pesos

= $\beta\left(I \wedge w_J\right) + (1-\beta) w_J$

$\boldsymbol{X}_r$ $\underline{\Delta}$ vetor padrão de entrada da rede neural ARTMAP nebulosa (entrada do módulo ARTa) correspondente a *r*-ésima contingência

= $[\boldsymbol{P}^T \ \boldsymbol{Q}^T \ \Lambda_r{}^T]^T$

$\boldsymbol{P}$ = $[P_1 \ P_2 \ \ldots P_{ns}]^T$

$\boldsymbol{Q}$ = $[Q_1 \ Q_2 \ \ldots Q_{ns}]^T$

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

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

Λ_r = vetor que contém os índices das contingências representado em código binário [0,+1]

n = $2ns + nb$

ns = número de barras do sistema

nb = número de *bits* correspondente ao número (índice) da contingência

$\underline{\boldsymbol{X}}_r$ $\underline{\Delta}$ vetor padrão de entrada da rede neural (entrada do módulo ARTa) correspondente a *r*-ésima contingência normalizado

= $[\underline{\boldsymbol{S}}^T \Lambda_r{}^T]^T$

$\underline{\boldsymbol{S}}$ = $\dfrac{\boldsymbol{S}}{|\boldsymbol{S}|}$

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

$|S|$ = $\sum_{i=1}^{n} |S_i|$

S = $[P^T Q^T]^T$

ϑ $\triangleq$ Esforço de Deslocamento da Margem de Segurança

= $(1 - M^A) / (1 - M^B) - 1$

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

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

I_k $\triangleq$ intervalo em termos do conceito de margem de segurança

= (M^{A_k}, M^{B_k})

k = índice que indica o k-ésimo intervalo

$Mmin$ = margem de segurança mínima preestabelecida

$Mmax$ = margem de segurança máxima preestabelecida

Y $\triangleq$ vetor de saída da rede neural (entrada do módulo ARTb)

= $[I_k]^T$

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

Índice

1 Introdução 1

2 Análise de Segurança de Sistemas de Energia Elétrica 6

2.1 Introdução 6

2.2 Estados da Operação de Sistemas de Energia Elétrica 6

2.3 Conclusão 11

3 Modelo do Sistema 12

3.1 Introdução 12

3.2 Modelo do Sistema Referido ao Centro de Ângulos 14

3.3 Conclusão 17

4 Análise de Estabilidade Transitória 18

4.1 Introdução 18

4.2 Margem de Segurança 19

4.3 Critério e Algoritmo de Análise da Estabilidade Transitória 21

4.4 Conclusão 23

5 Redes Neurais Artificiais 24

5.1 Introdução 24

5.2 Modelo do Neurônio 25

5.2.1 Modelo Biológico 25

5.2.2 Modelo Artificial 26

unesp

5.3 Características Gerais das Redes Neurais 29
5.3.1 Estrutura da Rede Neural 29
5.3.2 Treinamento da Rede Neural 30
5.4 Conclusão 31

6 Redes Neurais Baseadas na Teoria da Ressonância Adaptativa 32

6.1 Introdução 32
6.2 Características Básicas dos Sistemas ART 33
6.3 Algoritmo ART Nebuloso 38
6.4 Algoritmo ARTMAP Nebuloso 41
6.5 Conclusão 43

7 Análise de Estabilidade Transitória: Solução Proposta via Rede Neural ARTMAP Nebulosa 44

7.1 Introdução 44
7.2 Estímulos de Entrada 44
7.3 Estímulos de Saída 47
7.4 Conclusão 51

8 Aplicação 52

8.1 Introdução 52
8.2 Configuração do Sistema 53
8.3 Conclusão 64

9 Conclusão e Sugestões para Trabalhos Futuros 66

9.1 Conclusão 66
9.2 Sugestões para Trabalhos Futuros 69

10 Referências Bibliográficas 71

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Apêndice A Algoritmo do Método PEBS Iterativo ([19]) 78

Apêndice B Dados do Sistema Teste (versão do sistema elétrico 81
de potência da região sul do Brasil).

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Lista de Figuras

Figura 1 -	Estados de operação dos sistemas de energia elétrica e transições	10
Figura 2 -	Componentes de um neurônio biológico	26
Figura 3 -	Diagrama esquemático de um neurônio artificial de McCulloch-Pitts	27
Figura 4 -	Exemplos de funções de ativação	28
Figura 5 -	Arquitetura básica da rede ART1	34
Figura 6 -	Arquitetura ARTMAP nebulosa	42
Figura 7 -	Diagrama unifilar do sistema baseado na configuração da região sul do Brasil	54

unesp

Lista de Tabelas

Tabela 1 - Comparação de ART1 e ART nebulosa 40

Tabela 2 - Representação binária da saída da rede neural ARTMAP nebulosa 49

Tabela 3 - Resultados da análise da estabilidade transitória (margens de segurança) obtidos através do programa PEBS Iterativo ([19]) que serão utilizados no treinamento da rede neural 55

Tabela 4 - Dados de saída (intervalos I) para a fase de treinamento da rede neural 56

Tabela 5 - Resultados da análise da estabilidade transitória (margens de segurança) obtidos através do programa PEBS Iterativo ([19]) para fins de comparação com os resultados gerados pela rede neural ARTMAP nebulosa 57

Tabela 6 - Resultados das previsões da rede neural ARTMAP nebulosa considerando-se 7 execuções de treinamento em ordens aleatórias diferentes 60

Tabela 7 - Resultados comparativos das previsões fornecidas pela rede neural ARTMAP nebulosa e o algoritmo PEBS Iterativo ([19]) 61

Tabela 8 - Contingências classificadas de acordo com o método PEBS Iterativo ([19]), considerando-se cada intervalo da margem de segurança 63

Tabela 9 - Dados de barras do sistema sul-brasileiro (10 máquinas) 81

Tabela 10 - Dados do sistema de transmissão 83

Tabela 11 - Dados das máquinas síncronas 85

1 Introdução

A análise de estabilidade transitória de Sistemas de Energia Elétrica (SEE) consiste na avaliação dos efeitos procedentes de perturbações que causam grandes e indesejáveis oscilações nos ângulos das máquinas síncronas. Esta análise pode ser realizada através das soluções das equações diferenciais não-lineares que descrevem o movimento do sistema - equação de oscilação da máquina síncrona - e posteriormente via análise da evolução da posição angular de cada máquina síncrona ao longo do tempo (simulação). As técnicas utilizadas para a simulação são precisas e não apresentam restrições quanto ao tipo de modelo empregado, contudo consomem uma grande quantidade de tempo para a realização dos cálculos e na obtenção da análise. Um procedimento alternativo consiste na obtenção da análise sem se resolver tais equações diferenciais. Neste contexto, encontra-se o Método Direto de Lyapunov (MDL), cujos resultados são considerados satisfatórios quando se emprega o modelo clássico ([43]). Para modelos mais elaborados, não existem, ainda, resultados concretos. Entretanto, a literatura tem demonstrado esforços neste sentido.

Tendo em vista a grande quantidade de defeitos a serem analisados, a complexidade e a grande dimensão dos atuais SEE, a simulação assim como o MDL são alternativas que ainda não oferecem totais condições para aplicações em tempo-real. Novas abordagens de análise, baseadas na inteligência artificial ([18, 30]), em especial as redes neurais ([24, 26, 28, 30, 32, 44, 47]), têm sido relatadas na literatura com o propósito de superar tais dificuldades. Assim sendo, este trabalho visa investigar a aplicação de Redes Neurais Artificiais (RNA) no diagnóstico da estabilidade transitória de Sistemas de Energia Elétrica.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Redes Neurais Artificiais são concepções em *hardware* e/ou *software* baseadas no mecanismo de funcionamento do cérebro sendo, portanto, capazes de aprender com a experiência ([24, 26, 28, 30, 32, 44, 47]). Deste modo, é possível executar tarefas como recuperação da informação, diagnósticos complexos, previsão, reconhecimento de padrão contendo ruído ou dados distorcidos entre outras.

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*) ([50]). Esta técnica tem se mostrado eficiente, sendo considerada, pela literatura especializada, como um *benchmark* em termos de precisão. Contudo, o tempo de processamento é relativamente alto.

Desta forma, pretendeu-se, neste trabalho, investigar o uso da rede neural ARTMAP ([8]). Esta rede faz parte de um conjunto de propostas (ART, ART1, ART2 e ARTMAP) ([8–13]) destinado 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 multi-dimensionais (multi-entradas/multi-saídas). A formulação da rede ARTMAP através do uso da teoria de conjuntos nebulosos ([28, 34, 46]), designada ARTMAP nebulosa ([9–13]), tem conferido à formulação original ([8]) uma sensível redução do tempo necessário à execução do treinamento ([9, 10]). A rede ART possui a característica de estabilidade (capacidade de aprender através do ajuste dos seus pesos) e plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões sem perder a memória com relação aos padrões anteriores). Com tais características espera-se que esta rede apresente um desempenho superior ao tradicional *backpropagation*. A rede ARTMAP nebulosa será, então, usada para avaliação da estabilidade transitória considerando-se contingências tipo curto-circuito. Neste contexto, será desenvolvido um arranjo para avaliação da estabilidade transitória baseada na informação de tempos críticos de chaveamento e/ou o cálculo da margem de segurança ([4, 19, 21, 36,

unesp

37]) como um aproximador de funções complexas (análise qualitativa e quantitativa), ou, ainda, como um classificador de padrões (análise qualitativa). A margem de segurança, expressa em função de energia total, pode ser interpretada como uma medida de "distância" em relação à condição de instabilidade do sistema. O modelo dinâmico do sistema adotado, neste trabalho, será o modelo clássico, com o objetivo exclusivo de reduzir o custo computacional na geração dos dados para o treinamento. Ressalta-se, entretanto, que poderão ser utilizados, a princípio, modelos mais elaborados, sem a necessidade de se promover modificações significativas na arquitetura proposta.

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

Ressalta-se que na literatura especializada encontram-se poucas referências que abordam o problema da análise de estabilidade através do emprego de redes neurais ([27, 38, 39, 41, 42, 45]). Em todas elas, o problema da análise de estabilidade transitória é formulado visando a determinação dos tempos críticos para faltas de curtos-circuitos. As referências [27, 38, 39, 42, 45] utilizam redes neurais com treinamento realizado via o uso do algoritmo retropropagação ([50]). Em [38] é utilizado o algoritmo retropropagação com controlador nebuloso, o qual ajusta a taxa de treinamento, com o propósito de reduzir o número de ciclos e o tempo de execução na fase de treinamento. Na referência [42] a análise de estabilidade transitória é realizada através do uso da rede neural de Kohonen ([48]) considerando sistemas compostos por máquina síncrona × barra infinita. Na referência [41], a rede neural é composta por dois módulos: supervisionado e não-supervisionado executados por uma rede neural com ligação funcional ([41]), cuja finalidade é reduzir o tempo de treinamento. Há outras referências, em destaque, que abordam problemas associados aos sistemas elétricos de potência com redes neurais que empregam o conceito ART, *e.g.*,

unesp

análise de faltas em sistemas de transmissão ([1]), e estabilidade de pequenas oscilações ([3]).

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

Capítulo 2 : será abordada a questão da análise de segurança de sistemas de energia elétrica. Serão apresentados e discutidos os estados operativos e suas circunstâncias de ocorrência;

Capítulo 3 : apresentar-se-á o modelo dinâmico, com vistas à análise de estabilidade transitória de sistemas elétricos de potência, representado pelo modelo clássico;

Capítulo 4 : será apresentado o critério de análise da estabilidade transitória baseado no conceito de energia total do sistema;

Capítulo 5 : serão apresentados os principais conceitos sobre redes neurais artificiais;

Capítulo 6 : serão abordados os principais conceitos sobre as redes neurais baseadas na teoria da ressonância adaptativa. Será apresentada, ainda, a formulação da rede neural ARTMAP nebulosa que constitui o conteúdo principal desta pesquisa;

Capítulo 7 : serão estabelecidas as entradas e saídas que serão usadas no treinamento da rede neural ARTMAP nebulosa;

Capítulo 8 : apresentar-se-ão os resultados da análise da estabilidade transitória, através da rede neural ARTMAP nebulosa, considerando-se uma versão do sistema da região sul do Brasil, composta por 45 barras, 73 linhas de transmissão e 10 máquinas síncronas;

Capítulo 9 : serão apresentadas as principais conclusões e sugestões para trabalhos futuros;

Capítulo 10 : serão relacionadas as referências bibliográficas.

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

Apêndice A : Algoritmo passo a passo do método PEBS Iterativo ([19]).

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

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

2 Análise de Segurança de Sistemas de Energia Elétrica

2.1 Introdução

Neste capítulo será abordada a questão da análise de segurança de sistemas de energia elétrica. Serão apresentados e discutidos os estados operativos e suas circunstâncias de ocorrência. Esta abordagem tem por objetivo dispor, executar estratégias que visem garantir o suprimento de energia com qualidade, evitar, ou pelo menos, minimizar os efeitos da interrupção do fornecimento de energia aos consumidores. Deste modo, procura-se situar o trabalho desenvolvido nesta pesquisa nas atividades dos centros de controle. As definições destes estados e suas transições foram estabelecidas por Dy Liacco ([15]) que se tornaram a principal e mais importante referência neste contexto.

2.2 Estados da Operação dos Sistemas de Energia Elétrica

O funcionamento dos sistemas elétricos de potência podem ser descritos por cinco estados operativos ([15, 49]):

1) normal;
2) de alerta;
3) de emergência;
4) *in extremis*;
5) restaurativo.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Todos estes estados são caracterizados pelo atendimento ou não das restrições de igualdades e das restrições de desigualdades das equações que descrevem o funcionamento dos sistemas. As restrições de igualdades (equações algébricas e diferenciais) representam as leis físicas que regem a operação, enquanto que as restrições de desigualdades estão associadas às violações operativas e de segurança. As equações algébricas referem-se ao balanço de potência, ou seja, a geração total que deverá suprir a carga total mais as perdas elétricas associadas aos vários equipamentos da rede elétrica (sistema de transmissão, sistema de distribuição, transformadores, etc.). As equações diferenciais descrevem o comportamento dinâmico do sistema causado por perturbações. As inequações (ou restrições de desigualdades) representam os limites físicos dos equipamentos elétricos, *e.g.*, as correntes não devem exceder um nível máximo (associado ao limite térmico dos equipamentos), as tensões nodais devem estar compreendidas entre um valor mínimo e um valor máximo, a máquina síncrona somente poderá fornecer energia estritamente dentro de certos limites (entre a potência mínima e potência máxima), os ângulos (argumentos das tensões nodais) não devem exceder a uma abertura máxima, etc.

Em resumo, estes estados são evidenciados através da observação do cumprimento ou não das equações e inequações que governam os sistemas elétricos. As transições de estados são estabelecidas em função da aplicação de ações corretivas que são o redespacho de geração, corte de carga, chaveamento de equipamentos elétricos, reajuste do perfil de tensão nodal, etc. Como ilustração, tomando-se o caso em que uma determinada linha esteja com seu limite violado (excesso de corrente e/ou diferença angular expressiva), pode-se resolver este problema, a princípio, através de um redespacho de geração. É evidente que este processo deve ser realizado com critério e com o uso de técnicas apropriadas (via otimização, por exemplo).

Assim sendo, apresenta-se, a seguir, uma breve descrição destes estados e, na seqüência, são mostradas as suas transições ([15]).

unesp

Estado Normal: Caracteriza-se como sendo o estado operativo em que todas as restrições são satisfeitas, indicando que a geração é adequada para suprir a demanda total do sistema e que não há equipamento sobrecarregado (violação de limites). Neste estado, há margem de reserva de capacidade associada à transmissão, geração, etc. suficiente para proporcionar um adequado nível de segurança, mesmo havendo ocorrência das contingências (aumento de carga, curto-circuito, perda de equipamento, entrada/saída de carga, etc.) que freqüentemente são impostas ao sistema.

Estado de Alerta: Neste estado, todas as restrições operativas encontram-se satisfeitas, porém, há riscos de não serem atendidas, caso venham ocorrer contingências no sistema. Este estado é considerado inseguro, por conseguinte, ações preventivas devem ser tomadas visando a retomada ao estado normal.

Estado de Emergência: Se uma contingência, suficientemente severa, ocorrer antes da implementação da ação preventiva, o sistema entra no estado de emergência. Neste caso, as restrições de desigualdades são violadas. Contudo, o sistema pode permanecer intacto, desde que ações de controle de emergência (medidas heróicas) sejam iniciadas no sentido de recuperar o estado de alerta. Se estas medidas não forem implementadas rapidamente, ou forem ineficientes, o sistema entra em um novo estado de desintegração, ou *in extremis*.

unesp

Estado *In Extremis*: Neste estado, as equações e as inequações são violadas. O sistema não pode permanecer por muito tempo nesta condição, pois, assim, uma parte do sistema quase sempre será perdida. A ação de controle de emergência deve ser diretamente introduzida para salvar o sistema que se encontra em operação e evitar o colapso total da rede elétrica.

Estado Restaurativo: Depois que o colapso tenha sido contido, o sistema pode evoluir para o estado restaurativo. Neste estado, o sistema pode transitar entre o estado de alerta e normal, dependendo das circunstâncias envolvidas. Constitui-se na ação em que são conectados novamente os componentes que se encontram fora de serviço (linhas de transmissão, geradores, transformadores, etc.) e o restabelecimento das cargas desligadas.

Na Figura 1, apresenta-se um esquema mostrando os vários estados operativos e suas transições ([15]). Para melhor ilustrar tais estados, emprega-se a seguinte convenção ([15]):

E = atendimento das restrições de igualdades;

I = atendimento das restrições de desigualdades;

$\overline{E}$ = não atendimento das restrições de igualdades;

$\overline{I}$ = não atendimento das restrições de desigualdades.

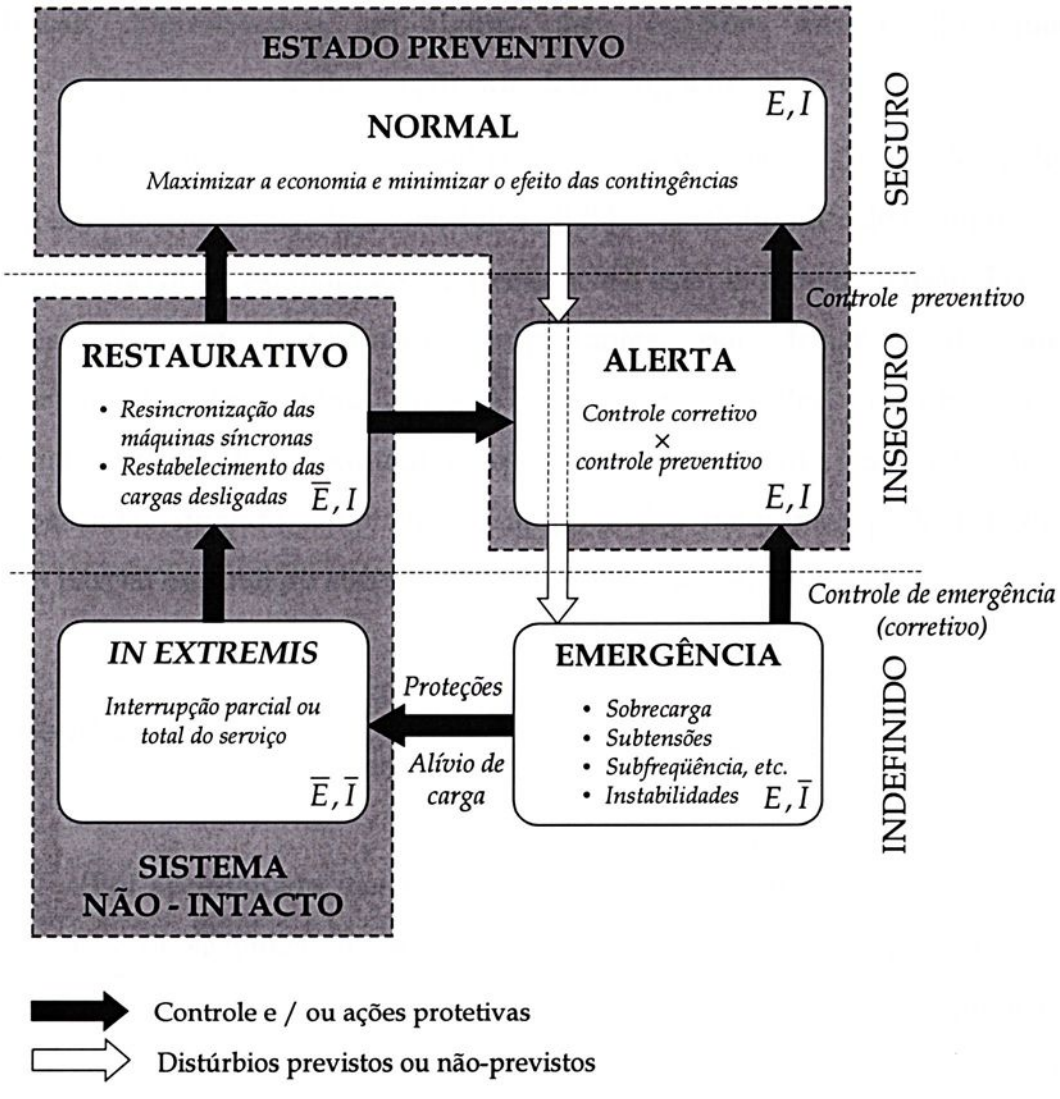


Figura 1 – Estados de operação dos sistemas de energia elétrica e transições.

O conceito de segurança utilizado neste capítulo, refere-se à operação, tanto do ponto de vista estático como dinâmico. No caso estático, ou de pequenas oscilações, os modelos são lineares e podem ser resolvidos usando uma série de técnicas disponíveis na literatura, *e.g.*, álgebra matricial, método de perturbação, análise de sensibilidade, análise modal, entre outras. Quando se trata da análise do sistema frente às grandes perturbações (saída de equipamentos de operação, curto-circuito, etc.), os modelos são não-lineares compostos por equações

algébricas, diferenciais e, em alguns casos, também, envolvendo equações diferenciais parciais (caso de transitórios eletromagnéticos).

O fenômeno de estabilidade dos sistemas elétricos de potência abrangem, basicamente, três módulos ([25]): estabilidade dos ângulos das máquinas síncronas, estabilidade de freqüência e estabilidade de tensão. Estas três divisões são significativamente importantes por tratar-se da análise comportamental do sistema quando sujeitos às grandes perturbações que, potencialmente, podem conduzir o sistema à instabilidade. Esta instabilidade, principalmente quando envolvem os ângulos das máquinas, pode provocar o colapso parcial ou total do sistema, como discutido anteriormente.

2.3 Conclusão

Foi apresentado, neste capítulo, uma descrição sucinta sobre a análise de segurança de sistemas de energia elétrica. Os vários estados operativos foram abordados, bem como suas transições que são promovidas em conseqüência das ações de controle. Deste modo, este trabalho de dissertação insere-se no contexto da análise de segurança de sistemas de energia elétrica, atendo-se ao módulo referente à análise de estabilidade transitória que será tratada nos capítulos subseqüentes.

unesp

3 Modelo do Sistema

3.1 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 combinando com a saída das linhas sob falta. 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 a falta para o barramento mais próximo. A eliminação da falta 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 ARTMAP ([9])) para a realização da análise de estabilidade transitória. Considera-se a análise de estabilidade de primeira oscilação onde pode-se empregar o chamado modelo clássico ([2, 16, 20, 40]). A opção por esta abordagem mais simples de modelo deve-se ao fato de que, para extrair o

unesp

conhecimento deste problema, via redes neurais, é necessário impor uma rotina de dados que constitui a fase de treinamento da rede. Estes dados devem conter informações quantitativas e qualitativas de cada uma das contingências. Para efetivamente constituir uma boa capacidade de generalização (análise de situações não previstas nos casos simulados), faz-se necessária a utilização de um grande número de dados de entrada e de saída para a fase do treinamento da rede neural. Para atender estas características, no momento, salvo melhor julgamento, somente podem ser proporcionados quando se utiliza os métodos diretos de análise, mais especificamente, os métodos de energia ([16, 20, 40]). Estes métodos, embora tenham apresentado grande evolução nos últimos anos, ainda há carência de resultados práticos para modelos mais elaborados. Deve-se destacar que a simulação (resolução do sistema de equações algébricas/diferenciais não-lineares e exame das soluções obtidas) é considerada, pela literatura especializada, um *benchmark* de análise de transitórios eletromecânicos. Nesta metodologia, pode-se simular qualquer modelo (qualquer que se seja a sua sofisticação). Contudo, o grande obstáculo reside na obtenção somente da análise qualitativa, ou seja, a informação se o sistema é ou não estável para uma contingência em particular. Não é possível, a princípio, a menos que se empregue o método de tentativa e erro, saber quanto estável ou instável é o sistema. Além disto, os métodos de simulação consomem grande quantidade de tempo para a análise, isto porque empregam, entre outras rotinas, métodos de integração numérica, registros das curvas de oscilação, e envolvem a participação de um especialista para a conclusão da análise, tudo isto efetuando uma simulação por vez.

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 ([19]), 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

unesp

tempo crítico) do sistema para uma lista preestabelecida de contingências. Os resultados são bastantes 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 empregam 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) ([16, 20, 40]), constitui a melhor opção ([4]), 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.

3.2 Modelo do Sistema Referido ao Centro de Ângulos

Considerando-se um Sistema de Energia Elétrica composto por ng máquinas síncronas, o comportamento dinâmico da i-ésima máquina pode ser descrito pela seguinte equação diferencial (equação de oscilação da máquina síncrona) ([2, 20, 40]):

$$M_i \ddot{\theta}_i - g_i(\theta) = 0, \quad i \in N \tag{3.2.1}$$

sendo:

$$g_i(\theta) = Pm_i - Pe_i - (M_i PCOA)/MT; \tag{3.2.2}$$

M_i = $2 H_i / \omega_s$;

H_i = constante de inércia (s);

ω_s $\triangleq$ velocidade síncrona (rad. elét./s)

= $2\pi f_0$;

f_0 = freqüência nominal do sistema (Hz);

θ_i $\triangleq$ ângulo do rotor da *i*-ésima máquina síncrona referida ao CA (rad. elét.)

= $\delta_i - \delta_0$;

δ_i = ângulo do rotor da i-ésima máquina síncrona medida com relação a uma máquina que gira à velocidade síncrona (rad. elét.);

δ_0 = $\sum_{j \in N} M_j \delta_j$;

Pm_i = potência mecânica de entrada (pu);

Pe_i = potência elétrica de saída (pu);

$PCOA$ $\triangleq$ potência acelerante do CA

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

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

N $\triangleq$ $\{1, 2, ..., ng\}$

= conjunto de índices das máquinas que compõem o sistema;

ng = número de máquinas síncronas.

A potência elétrica usada na equação (3.2.2), 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 [2, 20,

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

40]. Trata-se de um procedimento rápido do cálculo da potência elétrica, principalmente, quando esta refere-se à condição de falta (período de permanência do curto-circuito) e pós-falta (eliminação da falta com saída da linha de transmissão), empregando o método proposto na referência [37].

O modelo do sistema referido ao centro de ângulos (equação (3.2.1)) apresenta as seguintes propriedades:

Propriedade 1. A potência acelerante do centro de ângulos, quando calculada no ponto de equilíbrio estável, é nula ([36, 40]).

Propriedade 2. O somatório do produto da posição angular θ pela inércia de cada máquina síncrona do sistema é igual a zero, ou seja ([36, 40]):

$$\sum_{j \in N} M_j \theta_j = 0 . \tag{3.2.3}$$

Propriedade 3. O somatório do produto da velocidade angular ω pela inércia de cada máquina síncrona do sistema é igual a zero, ou seja ([36, 40]):

$$\sum_{j \in N} M_j \omega_j = 0 . \tag{3.2.4}$$

A Propriedade 1 é estabelecida a partir da formulação do problema do fluxo de potência que é determinado fazendo-se ($Pm - Pe = 0$) para todas as máquinas que compõem o sistema. Isto 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.

unesp

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 $(ng - 2)$ variáveis de estado do sistema permite o cálculo das duas variáveis restantes utilizando-se as equações (3.2.3) e (3.2.4).

Estas propriedades serão úteis na determinação da função energia total do sistema, como será abordada no Capítulo 4.

Outras definições e termos utilizados em problemas de estabilidade de sistemas de energia elétrica podem ser encontrados na referência [25]. Trata-se de um importante texto de referência nesta área de conhecimento.

3.3 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 ([43]). 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 ([4]). 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 realizadas as simulações com o propósito de gerar as informações de entrada e saída para a execução do treinamento da rede neural.

unesp

4 Análise de Estabilidade Transitória

4.1 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, *e.g.*, 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 o estator 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.

Outra alternativa 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, apresentam-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 falta, o critério e algoritmo para a análise de estabilidade transitória, baseada em uma metodologia híbrida que combina o Método Direto

unesp

de Lyapunov (MDL) e a resolução das equações diferenciais, considerando defeitos tipo curto-circuito com saída de operação de linha de transmissão.

4.2 Margem de Segurança

O diagnóstico da estabilidade transitória de SEE pode ser efetuado através do emprego do conceito da margem de segurança definida por ([3, 19, 20]):

$$M_r = (Ecrit_r - Ee_r) / Ecrit_r \tag{4.2.1}$$

sendo:

$Ecrit_r$ = 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 ([21]). 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 ([4, 19, 21, 36, 37]):

- $M_r < 0$, 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 (3.2.2) não se caracteriza como força potencial ([36]), consequentemente, não é possível determinar uma função energia potencial do

unesp

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 (3.2.1) é dada por ([4, 19, 21, 36, 37, 40]):

$$E(\theta,\omega)=Ec(\omega)+Ep(\theta) \tag{4.2.2}$$

sendo:

$Ec\ (\omega)\ \triangleq$ energia cinética

$$= 1/2\sum_{i\in N} M_i\omega_i^2\ ; \tag{4.2.3}$$

$Ep\ (\theta)\ \triangleq$ energia potencial

$$= -\sum_{i\in N}\int_{\theta_i^p}^{\theta_i} g_i(\theta)d\theta_i\ . \tag{4.2.4}$$

O superscrito (p) refere-se ao ponto de equilíbrio pós-falta e $g_i(\theta)$ é dada pela equação (3.2.2).

Desenvolvendo a expressão referente a energia potencial, obtém-se ([21, 36]):

$$Ep(\theta)=-\sum_{i\in N}\int_{\theta_i^p}^{\theta_i} Pm_i\,d\theta_i+\sum_{i\in N}\int_{\theta_i^p}^{\theta_i} Pe_i\,d\theta_i+\sum_{i\in N}\int_{\theta_i^p}^{\theta_i}(M_i/MT)PCOA\,d\theta_i\ . \tag{4.2.5}$$

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 (4.2.5) torna-se nulo) a energia total do sistema é dada por ([4, 19, 36, 40]):

$$E(\theta,\omega)=1/2\sum_{i\in N} M_i\, d\theta_i+\sum_{i\in N} Pm_i\left(\theta_i-\theta_i^p\right)d\theta_i+\sum_{i\in N}\int_{\theta_i^p}^{\theta_i} Pe_i\, d\theta_i\,. \qquad (4.2.6)$$

Observa-se que, em função da consideração das condutâncias de transferência, a função energia total do sistema – equação (4.2.6) – é dependente do caminho de integração ([19, 36, 40]). 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 ([19, 40]). 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 ([19]).

4.3 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, neste trabalho, baseados no algoritmo PEBS (*Potential Energy Boundary Surface*) ([4]) Iterativo ([19]). 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 ([4, 19]):

$$D(\theta)=-<g(\theta),(\theta-\theta^p)>/\left\|\theta-\theta^p\right\|_e \qquad (4.3.1)$$

sendo:

$<.,.>$ = produto interno de dois vetores n-dimensionais;

$g(\theta)$ = $[g_1(\theta)\;\; g_2(\theta)\;\; \ldots\;\; g_n(\theta)]^T$;

$g_i(\theta) \quad \triangleq \; Pm_i - Pe_i - (M_i / MT)PCOA;$

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

Definição 2. *Superfície Limite de Energia Potencial* (PEBS em inglês) ([4, 19]) é definida como os pontos correspondentes aos zeros da derivada direcional (4.3.1), 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 ([36]).

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

A análise de estabilidade transitória, utilizando-se o conceito da PEBS ([4, 19]), consiste na determinação de um ponto sobre a trajetória de falta, por processo iterativo, de tal modo que a evolução da trajetória pós-falta, 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 DEE - FEIS - UNESP. Trata-se de um programa em linguagem Fortran, versão para microcomputador. Este algoritmo refere-se ao apresentado na referência [19]. No Apêndice A é apresentado este algoritmo passo a passo.

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

4.4 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 ([19]) 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 nebulosa ([9])), que é a metodologia de análise de estabilidade transitória de sistemas de energia elétrica proposta neste trabalho.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

5 Redes Neurais Artificiais

5.1 Introdução

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 ([24, 26, 28, 30, 35, 44, 47 – 51]).

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. As redes neurais vêm sendo usadas, com sucesso, na solução de problemas de reconhecimento de padrão, otimização combinatória, 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 a estrutura de uma rede neural, seus componentes e funcionamento. Serão, também, abordadas as formas de treinamento destas redes, ou seja, os treinamentos supervisionado (baseado em estímulos de entrada/saída da rede) e não-supervisionado (os estímulos são apenas de entrada).

Este capítulo é preparatório à rede neural que deverá ser abordada no capítulo subseqüente. Trata-se de uma rede neural ARTMAP ([8 – 13]) que visará a execução da análise de estabilidade transitória de sistemas de energia elétrica.

unesp

5.2 Modelo do Neurônio

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 ([24]). 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.

Apresenta-se, a seguir, o modelo de neurônio biológico mais conhecido na literatura. Ressalta-se que, vários tipos de neurônios têm sido identificados, cada qual se distingue dos demais pela forma do corpo celular ([35]). Estas diferenças morfológicas exibem especializações funcionais importantes. Apresenta-se, também, o modelo neural artificial proposto em 1943 por McCulloch e Pitts ([24, 28, 35]).

5.2.1 Modelo Biológico

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 ([24]).

Os neurônios são formados pelos *dendritos*, que são um conjunto de terminais de entrada e que possuem a função de receber os estímulos transmitidos por outros neurônios e retransmiti-los ao *corpo celular*; pelo *corpo celular*, que corresponde a parte central do neurônio, responsável pela geração e recepção dos impulsos nervosos; e pelos *axônios*, que são longos terminais de saída, responsáveis por transmitir os estímulos para outras células. As ligações entre os dendritos de um neurônio e os axônios de neurônios adjacentes são chamadas de

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

sinapses. Sinapse é a região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre eles ([35, 44]).

A Figura 2 mostra as partes que compõem o neurônio biológico anteriormente descritos.

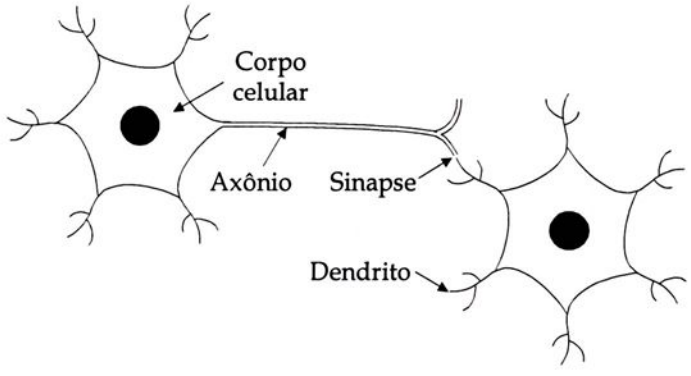


Figura 2 – Componentes de um neurônio biológico.

5.2.2 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 ([35]).

Em 1943, McCulloch e Pitts ([24]) formularam o primeiro modelo de neurônio artificial. Trata-se de um autômato binário simples, cujas entradas e saída são do tipo booleano. 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 ([24]).

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

Quando o potencial de ativação tem valor superior a um limiar de disparo preestabelecido, 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. A Figura 3 mostra o esquema de um neurônio do tipo descrito ([24, 28]).

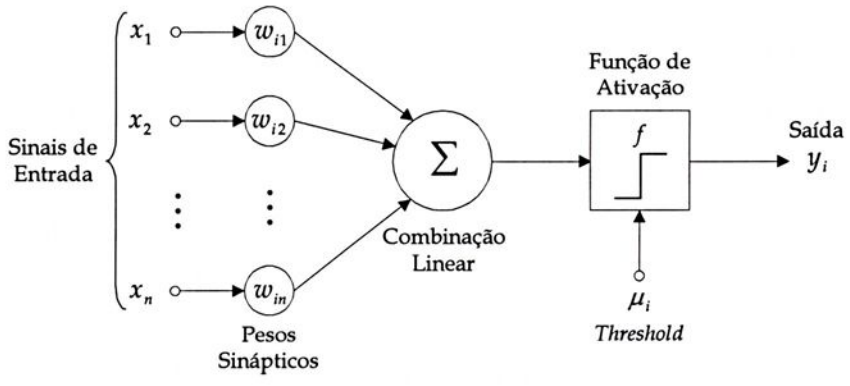


Figura 3 – Diagrama esquemático de um neurônio artificial de McCulloch-Pitts.

A saída do *i*-ésimo neurônio, segundo esse modelo, é expressa como ([28]):

$$y_i(t+1) = f\left(\sum_{j=1}^{n} w_{ij}\, x_j(t) - \mu_i\right) \qquad (5.2.2.1)$$

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;

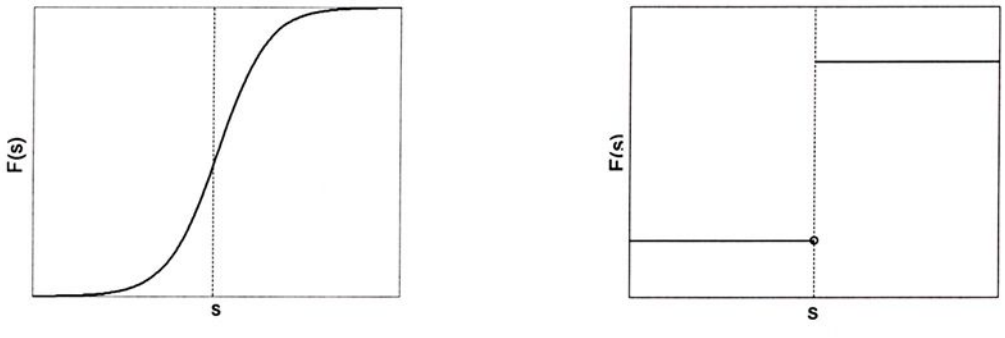
f = função de ativação degrau definida por ([28, 32]):

$$f(a) = \begin{cases} 1, & \text{se a} \geq 0 \\ 0, & \text{se a} < 0 \end{cases} . \qquad (5.2.2.2)$$

O neurônio de McCulloch e Pitts pode conter, ainda, um peso *bias* alimentado por uma constante (arbitrado como sendo +1) que atua como controle do nível de saída do neurônio ([21]).

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 mostra alguns exemplos de funções de ativação ([28, 32, 35]).



(a) $F(s) = \dfrac{1}{1+e^{-\lambda s}}$

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

Figura 4 – Exemplos de funções de ativação: (a) Sigmóide; (b) Relé.

sendo:

λ = inclinação da função sigmoidal.

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 ([28, 45, 50]).

5.3 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 ([35]).

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

5.3.1 Estrutura da Rede Neural

As redes neurais podem ser classificadas em dois tipos quando a sua estrutura: redes recorrentes e redes não-recorrentes.

Definição 3. *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 ([24]).

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

As redes que possuem esta estrutura desenvolvem uma memória a longo prazo nos neurônios internos ([24, 44, 48]).

Definição 4. *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 ([24]).

Redes não-recorrentes ou *feedforward* não possuem memória, sendo que, sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos ([24, 44, 48]).

5.3.2 Treinamento da Rede Neural

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.

Denomina-se algoritmo de treinamento a um conjunto de regras bem definidas para a solução de um problema de treinamento ([18]). 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:

unesp

Definição 5. *Treinamento Supervisionado.* Consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada ([24, 32, 43]).

O treinamento supervisionado necessita de um vetor de entrada e vetor alvo representando a saída desejada. Juntos eles são chamados de par de treinamento. Um dos algoritmos mais difundidos para treinamento deste tipo de rede é o algoritmo retropropagação (*backpropagation* no idioma inglês) ([24, 26, 40, 48, 50]). Este algoritmo foi proposto por Werbos ([50]) em 1974.

Definição 6. *Treinamento Não-supervisionado.* Consiste no ajuste de pesos de uma rede neural levando-se em conta somente o conjunto de padrões de entrada ([24, 32, 43]).

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. O processamento extrai as propriedades estatísticas e grupos similares em classes.

5.4 Conclusão

Neste capítulo, foram apresentados os principais conceitos envolvendo redes neurais artificiais, a estrutura básica de um neurônio biológico e as principais características envolvendo as diferentes estruturas de neurônio artificial. No próximo capítulo será dada atenção especial a uma classe de redes neurais, as redes baseadas na Teoria da Ressonância Adaptativa ([8]) que será a essência da pesquisa proposta neste trabalho.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

6 Redes Neurais baseadas na Teoria da Ressonância Adaptativa

6.1 Introdução

Umas das mais importantes características das Redes Neurais Artificiais (RNA) é 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*) ([50]), *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 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 deve não ser

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

somente plástico, mas também estável. Uma outra solução seria retreinar a rede freqüentemente 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 ([8]).

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 (*Adaptative Resonance Theory*) ([8]) foi desenvolvida para solucionar este dilema.

Existem duas classes gerais de redes neurais ART: ART1, ART2 e ART3 ([8]). Enquanto ART1 é destinada para classificação de padrões de entradas binária, ART2 e ART3 são destinados para padrões analógicos. Neste trabalho, faz-se o uso de uma arquitetura neural da Teoria da Ressonância Adaptativa, designada ARTMAP nebulosa ([8–13, 33]), que é uma generalização da rede ART1 ([8]). Sendo assim, a seguir, apresentam-se os principais conceitos sobre redes neurais desta teoria os quais são a essência da pesquisa proposta.

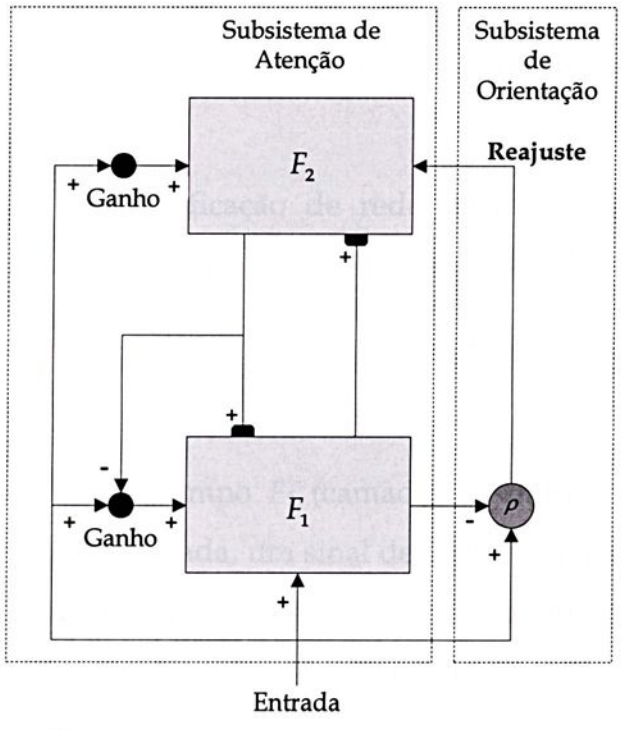
6.2 Características Básicas dos Sistemas ART

A Teoria da Ressonância Adaptativa (ART, de *Adaptive Resonance Theory*) foi inicialmente proposta por Stephen Grossberg, em 1976, e em publicações posteriores, em parceria com Gail Carpenter (1986/87) ([8]). 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 (discriminação) e de estabilidade (generalização) ([8]). A propriedade de plasticidade define a habilidade da rede em criar novas categorias de reconhecimento, quando padrões estranhos estimulam a rede ART. A propriedade

unesp

de estabilidade é responsável pela habilidade em agrupar padrões similares na mesma categoria de reconhecimento. Uma regra de similaridade que define onde agrupar os padrões é determinada por um grau de semelhança entre um padrão



previamente armazenados.

Figura 5 – Arquitetura básica da rede ART1.

O primeiro modelo da família ART a ser desenvolvido foi a rede ART1 ([8]). Esta rede é destinada para treinar, rápida e estavelmente, categorias de reconhecimento em reposta a uma seqüência arbitrária de padrões de entradas binárias. ART1 é formada por dois principais subsistemas ([8]): *o subsistema de atenção* e o *subsistema de orientação* (ver Figura 5). 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 *feedforward* e *feedback*. Os pesos de conexão formam os componentes da memória a longo prazo (LTM – *Long Term Memory*) do

sistema e multiplica os sinais ao longo destes caminhos. O nome memória a curto prazo (STM – *Short Term Memory*) será associado com o padrão de atividade que desenvolve-se sobre um campo quando um padrão de entrada é processado ([8]). O subsistema de orientação é controlado por um parâmetro de vigilância (ρ), necessário para estabilizar o processamento em STM e o treinamento em LTM. Esta vigilância determina se um padrão de entrada pode ser incluído em uma das categorias existentes.

O processo de classificação de rede ART consiste de quatro fases principais: *reconhecimento*, *comparação*, *busca* e *treinamento* ([8]).

1) Reconhecimento

Cada neurônio do campo F_1 (camada de entrada) pode receber três sinais: um sinal do vetor de entrada, um sinal de *feedback* do campo F_2 (camada de saída) e um sinal da unidade controle (ganho), que são controladas pela Regra 2/3 ([8]). Esta regra determina que um neurônio somente será ativado se receber, pelo menos, dois sinais excitatórios; caso contrário, a ativação não ocorre. Na fase de reconhecimento, o vetor de entrada e o sinal de controle de ganho do campo F_1 (sinal que determina o fluxo de dados para a camada de entrada) são enviados à camada de entrada, onde será aplicada, a cada neurônio, a Regra 2/3. O vetor resultante é comparado com todos os vetores de pesos *feedforward* para encontrar o mais semelhante. Esta comparação é realizada calculando o produto interno entre o vetor de saída resultante e o vetor de pesos *feedforward* para cada neurônio do campo F_2, como indica equação (6.2.1):

$$y_j = \sum_i w_{ji} x_i \tag{6.2.1}$$

em que:

y_j = ativação do neurônio de saída j, definido pelo produto interno entre seu vetor de pesos w_j e seu vetor de entrada x.

unesp

O neurônio do campo F_2, com maior valor de ativação, é selecionado como provável categoria para armazenar o novo padrão. A inibição lateral faz com que somente o neurônio vencedor do campo F_2 fique ativo. 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 aplicação da Regra 2/3 no campo F_1 mediante o vetor protótipo dado pelo campo F_2 após a fase de reconhecimento. O teste é feito calculando a razão R, por meio da equação (6.2.2), entre o número de valores iguais a 1 de ambos os vetores e comparando o resultado desta razão com o parâmetro de vigilância ρ. Se R for maior que ρ, então, o padrão de entrada é incluído na categoria do neurônio do campo F_2 ativado. Caso contrário, outro neurônio do campo F_2 deverá ser encontrado para armazenar o vetor de entrada, e a rede entra na fase de busca.

$$R = \frac{\left\| \sum x_i \, z_{ij} \right\|}{\left\| \sum x_i \right\|} \qquad (6.2.2)$$

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

unesp

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 ART1 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 ART1: aprendizado rápido e aprendizado lento ([8]). No aprendizado rápido, os pesos *feedforward* 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.

Com o objetivo de apresentar a arquitetura ARTMAP nebulosa, metodologia utilizada nesta pesquisa, a seguir, apresenta-se o algoritmo da arquitetura ART nebulosa, que é uma generalização da rede ART1.

unesp

6.3 Algoritmo ART Nebuloso

ART nebulosa é uma generalização da rede ART1. A generalização é alcançada usando as operações da teoria de conjuntos nebulosos ([34, 46]) ao invés das operações da teoria de conjuntos binários. O componente ART nebulosa na rede ARTMAP nebulosa ([9, 33]) 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. Não é necessário distinguir os pesos de conexão dos caminhos de *feedback* e *feedforward* entre os campos F_1 e F_2 no módulo ART nebuloso, ambos serão implementados pelos mesmos pesos ([7]).

O algoritmo resumido da rede neural ART nebulosa consiste, basicamente, nos seguintes passos ([6, 7, 9, 22, 33]):

Passo 1. Iniciação 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 $a = (a_1, a_2, ..., a_n)$ 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 I de $2n$ elementos, tal que ([9]):

$$I = (a, a^c) = \left(a_1, a_2, \ldots, a_n, a_1^c, a_2^c, \ldots, a_n^c\right) \qquad (6.3.1)$$

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

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

Passo 3. Escolha da categoria.

A ativação T_j é calculada para cada neurônio j de F_2, usando a função escolha ([9]):

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|}, \tag{6.3.2}$$

em que o operador $\wedge$ é o operador nebuloso *and*, definido por ([9]):

$$(p \wedge q)_i \equiv \min (p_i, q_i), \text{ com } p \text{ e } q \in \Re^{2n}, \tag{6.3.3}$$

e a norma $|.|$ é definida por:

$$|p| \equiv \sum_{i=1}^{2n} |p_i|. \tag{6.3.4}$$

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 ([9]):

$$T_J = \max \{T_j : j = 1, ..., 2n\}. \tag{6.3.5}$$

Passo 4. Teste de vigilância.

A ressonância ocorre se a função match, $|I \wedge w_J| / |I|$ da categoria escolhida encontra o critério de vigilância:

$$|I \wedge w_J| \geq \rho |I|. \tag{6.3.6}$$

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 o critério ser satisfeito para aquela entrada. Um novo índice J é, então, escolhido pela equação (6.3.5).

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

O processo de busca continua até que o índice J escolhido satisfaça a equação (6.3.6).

Passo 5. Atualização do vetor protótipo.

Encerrada a busca, o vetor peso w_J é atualizado de acordo com a seguinte equação ([9]):

$$w_J^{'} = \beta\left(I \wedge w_J\right) + (1-\beta)w_J \tag{6.3.7}$$

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 ([28, 34, 46]) na escolha, busca e leis de treinamento de ART1 (Tabela 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 1 – Comparação de ART1 e ART nebulosa ([9]).

Módulo	ART1 (binário)	ART nebulosa (analógico)
Escolha da categoria	$T_j = \dfrac{\lvert I \cap w_j \rvert}{\alpha + \lvert w_j \rvert}$	$T_j = \dfrac{\lvert I \wedge w_j \rvert}{\alpha + \lvert w_j \rvert}$
Critério *Match*	$\lvert I \cap w_j \rvert \geq \rho \lvert I \rvert$	$\lvert I \wedge w_j \rvert \geq \rho \lvert I \rvert$
Treinamento	$w_J = \beta\left(I \cap w_J\right) + (1-\beta)w_J$	$w_J^{'} = \beta\left(I \wedge w_J\right) + (1-\beta)w_J$

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

6.4 Algoritmo ARTMAP Nebuloso

A arquitetura ARTMAP ([8 –13, 23, 29]), introduzida recentemente (Carpenter *et al.*, 1991), 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 ([8]). 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 ([9]).

O sistema ARTMAP nebuloso ([9, 33]) 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 ([9]). O campo de mapeamento também controla a regra *matching tracking* ([5, 9]) , que aumenta o parâmetro de vigilância da rede ARTa por uma quantia mínima necessária para corrigir um erro preditivo ([8, 9]).

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 6.

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 ([9]). 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

unesp

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 medida ótima por maximização da generalização preditiva em operações em tempo real ([8, 9]). A rede neural ARTMAP nebulosa realiza treinamento supervisionado como o *backpropagation* ([50]). Mas diferente do algoritmo *backpropagation*, a rede ARTMAP nebulosa é auto-organizável, auto-estabilizável e apropriada para treinamento em tempo-real ([9, 10]).

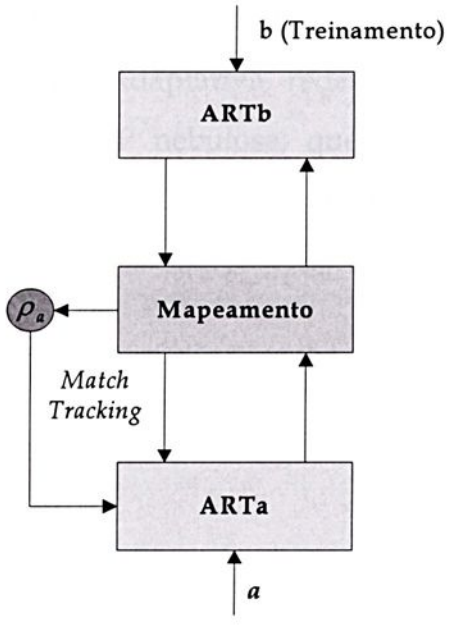


Figura 6 – Arquitetura ARTMAP nebulosa.

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* ([9]). A *estrátegia 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

freqüência. Como o conjunto de elementos que fazem predições errôneas varia de uma simulação para a próxima, esta estratégia cancela muitos dos erros.

Existem diversas variações da rede ARTMAP, como pode ser visto, *e.g.*, nas referências [13, 14, 17, 52]. Cada qual visando adaptar-se aos problemas que pretendem resolver e maximizar o seu desempenho.

6.5 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, que será a rede utilizada, neste trabalho, para fazer o diagnóstico da estabilidade transitória de sistemas de energia elétrica multi-máquinas.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

7 Análise de Estabilidade Transitória: Solução Proposta via Rede Neural ARTMAP Nebulosa

7.1 Introdução

Neste capítulo 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), 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 falta e nós terminais do circuito que sai de operação). A saída é essencialmente representada por código binário.

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 faltas 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 ([19]), que emprega o conceito de simulação e o Método Direto de Liapunov (método da

unesp

energia). Assim, os vetores padrões de entrada da rede neural (entrada do módulo ARTa) são definidos como ([38]):

$$\boldsymbol{X}_r \triangleq [\boldsymbol{P}^T \ \boldsymbol{Q}^T \ \Lambda_r{}^T]^T \tag{7.2.1}$$

sendo:

$\boldsymbol{X}_r$ = vetor padrão correspondente a r-ésima contingência;

$\boldsymbol{P}$ = $[\, P_1 \ \ P_2 \ \ldots P_{ns} \,]^T$;

$\boldsymbol{Q}$ = $[\, Q_1 \ \ Q_2 \ \ldots Q_{ns} \,]^T$;

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

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

Λ_r = vetor que contém os índices das contingências representado em código binário [0,+1].

O padrão $\boldsymbol{X}$ é um vetor n-dimensional:

$$n = 2ns + nb \tag{7.2.2}$$

em que:

ns = número de barras do sistema;

nb = número de *bits* correspondente ao número (índice) da contingência.

Neste caso, levando-se em conta o modelo clássico ([2, 20, 40, 43]), 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 (Seção 4.2). 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).

unesp

O número de *bits* (*nb*) de Λ 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 ([41, 42, 45]).

Tendo em vista que os componentes do vetor de entrada da rede neural ARTMAP nebulosa devem estar compreendidos entre 0 e 1, o vetor padrão (7.2.1) deverá ser normalizado. Considerando-se que o vetor Λ_r já satisfaz esta condição (números binários), a normalização será aplicada somente ao subvetor $[\boldsymbol{P}^T \boldsymbol{Q}^T]^T$:

$$\underline{\boldsymbol{X}}_r \triangleq [\,\underline{\boldsymbol{S}}^T \Lambda_r{}^T\,]^T \tag{7.2.3}$$

sendo:

$$\underline{\boldsymbol{S}} = \frac{\boldsymbol{S}}{|\boldsymbol{S}|};$$

$$|\boldsymbol{S}| = \sum_{i=1}^{n} |S_i|;$$

$$\boldsymbol{S} = [\boldsymbol{P}^T \boldsymbol{Q}^T]^T.$$

Com isto, procura-se preservar a característica dos dados binários e formam-se dois subvetores que não apresentam interações diretas entre si, sendo, portanto, independentes. Este procedimento não é significativo para a fase de treinamento, contudo, a princípio, proporciona melhores condições para uma boa predição. Se houver necessidade, a normalização, também, poderá ser realizada considerando-se o vetor completo $\boldsymbol{X}_r$. Poderão, ainda, ser empregadas outras formas que atendem o critério em que todos os elementos do vetor $\boldsymbol{X}_r$ estejam contidos no intervalo [0,1], por exemplo, aplicando-se a função sigmóide em cada componente, ou parte dos componentes de $\boldsymbol{X}_r$.

unesp

7.3 Estímulos de Saída

Os estímulos a serem aplicados no módulo ARTb da rede neural ARTMAP são as margens de segurança correspondentes aos vetores padrões de entrada (módulo ARTa) descritos pela equação (7.2.3).

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 represente 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. Com o propósito de estabelecer estes intervalos, será proposto o uso do conceito de *Esforço de Deslocamento da Margem de Segurança*, conforme estabelecido na seguinte definição ([36, 37]):

Definição 5. Define-se *Esforço de Deslocamento da Margem de Segurança* (EDMS) como sendo uma função que relaciona as margens de segurança inicial e final de um determinado intervalo da seguinte forma ([36, 37]):

$$\vartheta = (1 - M^A) \,/\, (1 - M^B) - 1. \qquad (7.3.1)$$

sendo:

ϑ = 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:

$$\mathcal{I}_k \triangleq (M^A{}_k , M^B{}_k) \tag{7.3.2}$$

em que:

$\mathcal{I}$ = 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 $\vartheta = 0$ quando $M^B = M^A$ (neste caso, nenhum esforço é observado). Nota-se que ϑ é definido no intervalo [0, +∞) e possui crescimento significativo à medida que M^B se aproxima de 1.

O conceito de EDMS foi empregado nas referências [36] e [37] 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

unesp

equações algébricas e diferenciais não-lineares). Atribuindo-se um valor fixo para ϑ, os intervalos de linearizações podem ser inferidos, ou seja, o erro em cada segmento se mantém na mesma ordem de grandeza. Portanto, o EDMS serve como um parâmetro para estabelecer a validade das linearizações e, conseqüentemente, estimar a região, no espaço de estado, em que se pode resolver o referido problema, através de um modelo linear, sem que haja comprometimento da precisão dos resultados.

Esta concepção será utilizada neste trabalho para definir os intervalos associados às contingências, conforme é mostrado na Tabela 2, considerando-se $\vartheta = 0{,}35$ e os valores da margem de segurança compreendidos em (–3, 1).

Tabela 2 – Representação binária da saída da rede neural ARTMAP nebulosa.

Número	Margem de Segurança (M)	Intervalo da Margem de Segurança ($\mathcal{I}$)	Representação Binária da Saída ($\mathcal{I}$)
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	(0,63740 ; 0,73140]	1 0 1 0
11	0,80110	(0,73140 ; 0,80110]	1 0 1 1
12	0,85260	(0,80110 ; 0,85260]	1 1 0 0
13	0,89080	(0,85260 ; 0,89080]	1 1 0 1
14	0,91910	(0,89080 ; 0,91910]	1 1 1 0
15	0,94010	maior do que 0,9191	1 1 1 1

unesp

O esforço da margem de segurança pode ser atribuído, com segurança, até o valor igual a 1,5 ([36]), *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.

Com esta representação (Tabela 2), têm-se 15 classes de saída, independentemente do número de contingências. Esta alternativa de solução é bastante vantajosa para o treinamento da rede e, principalmente, para a atividade do treinamento continuado, pois facilmente 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 [36] e [37]. 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:

$$\boldsymbol{Y} \triangleq [\boldsymbol{I}_k]^T \tag{7.3.3}$$

sendo:

Y = vetor de saída da rede neural;

$\mathcal{I}_k$ = vetor correspondente ao k-ésimo intervalo da margem de segurança associada à contingência representada em código binário.

O k-ésimo intervalo $\mathcal{I}_k$ associado à i-ésima contingência (margem de segurança M^i) é definido observando-se a relação $M^i \in \mathcal{I}_k$.

7.4 Conclusão

Neste capítulo foram abordados, basicamente, as particularidades referentes à estrutura neural para a resolução do problema de análise da estabilidade transitória, a escolha e o pré-processamento das informações que constituem as entradas e saídas para a fase de treinamento e as entradas para o módulo de análise (predição). Estes resultados serão, por conseguinte, implementados no capítulo subseqüente que versará sobre as aplicações considerando-se um sistema de energia elétrica multi-máquinas.

BCpIS - FEIS - UNESP

8 Aplicação

8.1 Introdução

Neste capítulo serão apresentados os resultados da análise de estabilidade transitória de sistemas elétricos de potência, através da rede neural ARTMAP nebulosa ([9]), considerando-se um sistema teste que corresponde a uma possível configuração do sistema elétrico Sul-Brasileiro ([37]). Para o treinamento da rede neural, foram considerados quatro níveis de geração para atender a demanda de energia. Estes níveis foram adotados considerando-se quatro percentuais do caso base (correspondentes aos dados relacionados no Apêndice B) ([41, 45]). Este procedimento não é tão plausível do ponto de vista da operação. A forma mais adequada é utilizar os dados do despacho diário de geração, por exemplo, através de uma estratégia de despacho econômico ([31]). Estes perfis de geração deveriam ser, por conseguinte, utilizados como dados de entrada para gerarem as margens de segurança (que é o enfoque empregado nesta pesquisa) e, conseqüentemente, obterem os intervalos das margens de segurança. Contudo, a opção, considerando tais percentuais (geração/cargas proporcionais), não invalida o emprego de despachos que são obtidos por outros procedimentos. A metodologia apresentada nesta pesquisa não depende do tipo de vetor que está sendo apresentado na entrada da rede. Porém, em pesquisas futuras, deverão ser incluídos estudos que contemplem, também, conjuntos de pares de treinamento mais realistas. Assim sendo, neste capítulo serão apresentados os resultados da análise de estabilidade transitória, através da rede neural ARTMAP nebulosa, que serão comparados com os fornecidos pelo método PEBS Iterativo ([19]). Esta comparação tem por objetivo testar a metodologia proposta. Deve-se ressaltar que,

unesp

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 III de 500 MHz.

8.2 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 ([21, 37]). O diagrama unifilar deste sistema é mostrado na Figura 7 e os respectivos dados encontram-se relacionados no Apêndice B.

Foram consideradas 15 contingências tipo curto-circuito com 4 perfis de geração/carga (80, 90, 100 e 110%) do caso base para o treinamento, e 85, 95, 105 e 115% para a fase do diagnóstico (análise). Estas contingências foram escolhidas como incidentes em vários pontos da rede elétrica. Ressalta-se que a variação entre o menor e o maior nível de carregamento do sistema é de aproximadamente 45% – considerando-se o treinamento e o diagnóstico – que é bastante expressiva e, certamente, é suficiente para representar o espectro de variação da carga elétrica diária (compreendida entre o menor valor e o valor de pico). Utilizou-se uma implementação computacional desenvolvida em linguagem *Fortran* (Método PEBS Iterativo ([19])/versão para microcomputador), que determina o tempo crítico e a margem de segurança, considerando-se uma lista preestabelecida de contingências.

unesp

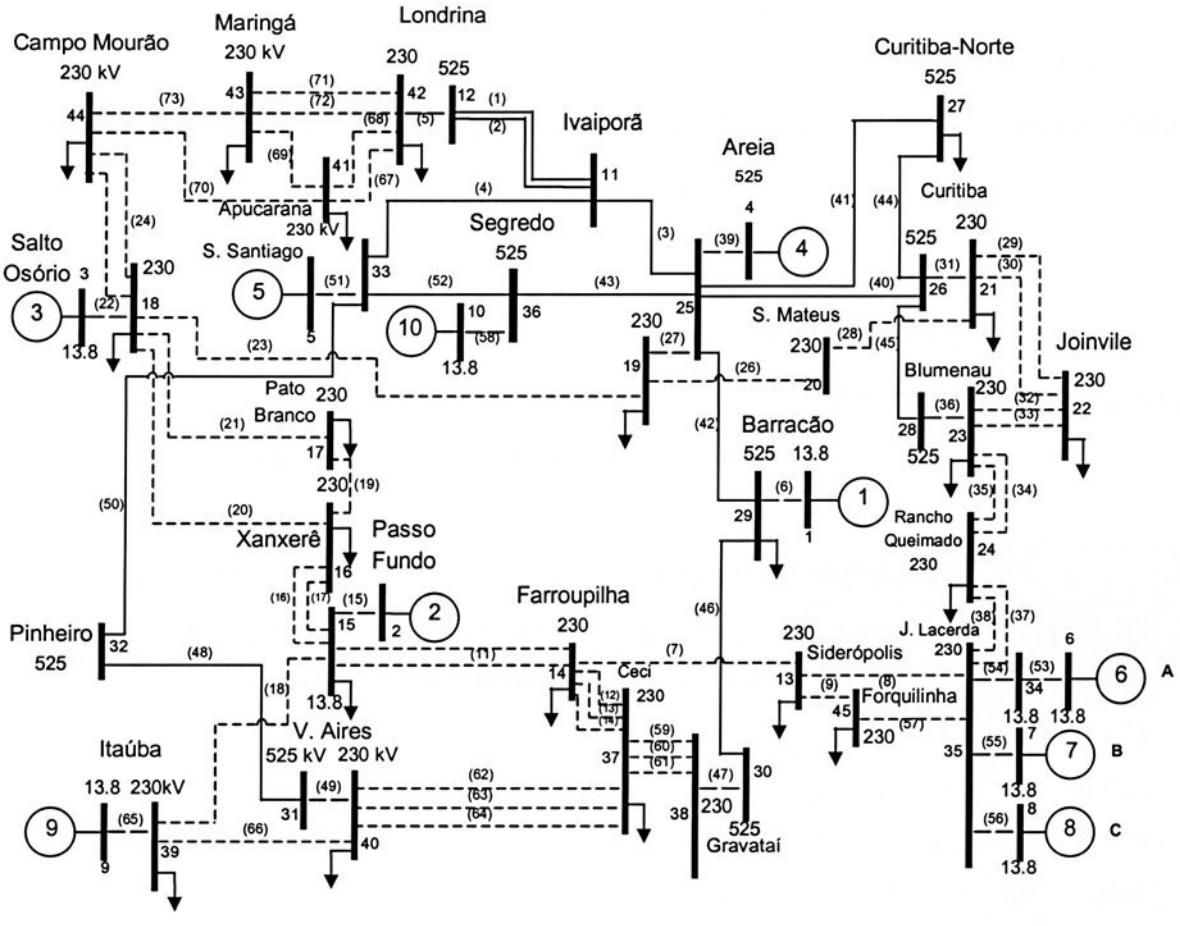


Figura 7 - Diagrama unifilar do sistema baseado na configuração da região sul do Brasil.

Na Tabela 3 são relacionados os resultados da análise de estabilidade transitória que compõem o conjunto de dados para o treinamento da rede neural para os perfis de geração/carga correspondentes a 80, 90, 100 e 110% do caso base (dados fornecidos no Apêndice B). A simbologia $q(r\text{-}s)$ apresentada na primeira coluna da Tabela 3 significa:

$q(r\text{-}s)$ = falta na barra q com saída de operação da linha entre os nós r e s. (8.2.1)

Na segunda coluna é apresentado o código binário de cada contingência. Nas demais colunas são apresentados o número da contingência e o valor da margem de segurança, considerando-se os carregamentos correspondentes a 80, 90, 100 e 110% do caso base.

Tabela 3 – Resultados da análise da estabilidade transitória (margens de segurança) obtidos através do programa PEBS Iterativo ([19]) que serão utilizados no treinamento da rede neural.

Falta		Margem de Segurança							
Número	Representação binária	80% do Caso Base		90% do Caso Base		100% do Caso Base		110% do Caso Base	
11(11-25)	0 0 0 1	1	0,9023	16	0,8502	31	0,7632	46	0,5735
13(13-45)	0 0 1 0	2	0,9681	17	0,9532	32	0,9327	47	0,9060
13(13-35)	0 0 1 1	3	0,9708	18	0,9565	33	0,9362	48	0,9095
15(14-15)	0 1 0 0	4	0,9045	19	0,8768	34	0,8354	49	0,8012
24(24-35)	0 1 0 1	5	0,9835	20	0,9748	35	0,9631	50	0,9481
18(18-19)	0 1 1 0	6	0,1270	21	–0,5417	36	–1,6596	51	–4,0761
18(16-18)	0 1 1 1	7	0,3865	22	0,0710	37	–0,4799	52	–1,8010
18(18-44)	1 0 0 0	8	0,4234	23	0,0709	38	–0,4804	53	–1,3000
25(11-25)	1 0 0 1	9	0,9642	24	0,9455	39	0,9097	54	0,7767
25(25-26)	1 0 1 0	10	0,9721	25	0,9613	40	0,9494	55	0,9342
29(29-30)	1 0 1 1	11	0,9414	26	0,8851	41	0,8123	56	0,7043
33(33-36)	1 1 0 0	12	0,7721	27	0,6845	42	0,5532	57	0,3465
35(35-45)	1 1 0 1	13	0,9112	28	0,8747	43	0,8260	58	0,7640
39(39-40)	1 1 1 0	14	0,6145	29	0,4295	44	0,1233	59	–0,2283
39(15-39)	1 1 1 1	15	0,7239	30	0,6178	45	0,4560	60	0,2475

Estes resultados foram gerados através do programa PEBS Iterativo ([19]). Este programa fornece os resultados da análise (tempo crítico e margem de segurança). Trata-se de um método híbrido constituído por um método de integração numérica (séries de Taylor truncadas, *i.e.*, são preservados somente os

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

primeiros termos das séries) e o método da energia (que é um caso particular do método direto de Lyapunov ([40])). Este método foi escolhido porque proporciona resultados bastantes precisos, com tempo de execução reduzido. Esta precisão refere-se essencialmente quando se considerando o modelo clássico. Esta técnica, a princípio, não se aplica a modelos mais elaborados como, por exemplo, o modelo completo de Park ([2]) e tantos outros disponíveis na literatura técnica.

Na Tabela 4 são apresentadas as saídas para o treinamento da rede neural, considerando-se as contingências relacionadas na Tabela 3 para $\vartheta = 0{,}35$. As saídas correspondem aos intervalos $\mathcal{I}$, conforme definidos na Tabela 2 (Capítulo 7), representados em código binário. A simbologia da falta (primeira coluna) é a mesma apresentada na Tabela 3 (Equação (8.2.1)).

Tabela 4 – Dados de saída (intervalos $\mathcal{I}$) para a fase de treinamento da rede neural.

Falta	Intervalo ($\mathcal{I}$)			
	80% do Caso Base	90% do Caso Base	100% do Caso Base	110% do Caso Base
11(11-25)	14	12	11	9
13(13-45)	15	15	15	14
13(13-35)	15	15	15	14
15(14-15)	14	13	12	12
24(24-35)	15	15	15	15
18(18-19)	7	5	3	1
18(16-18)	8	6	5	3
18(18-44)	8	6	5	3
25(11-25)	15	15	14	11
25(25-26)	15	15	15	15
29(29-30)	15	13	12	10
33(33-36)	11	10	9	8
35(35-45)	14	13	12	11
39(39-40)	9	8	7	5
39(15-39)	10	9	8	7

unesp

Na Tabela 5 são relacionados os resultados da análise de estabilidade transitória, via método PEBS Iterativo ([19]), para os perfis de geração/carga correspondentes a 85, 95, 105 e 115% medidos em relação ao caso base. Estes resultados foram obtidos com o propósito de servir como referência para comparação com os resultados obtidos com a utilização da rede neural ARTMAP nebulosa. A organização desta tabela é a mesma da Tabela 3.

Tabela 5 – Resultados da análise da estabilidade transitória (margens de segurança) obtidos através do programa PEBS Iterativo ([19]) para fins de comparação com os resultados gerados pela rede neural ARTMAP nebulosa.

Falta	Margem de Segurança							
	85% do Caso Base		95% do Caso Base		105% do Caso Base		115% do Caso Base	
11(11-25)	1	0,8752	16	0,8105	31	0,6958	46	0,3985
13(13-45)	2	0,9614	17	0,9439	32	0,9197	47	0,8883
13(13-35)	3	0,9642	18	0,9473	33	0,9233	48	0,8917
15(14-15)	4	0,8914	19	0,8552	34	0,8124	49	0,7773
24(24-35)	5	0,9795	20	0,9696	35	0,9560	50	0,9375
18(18-19)	6	–0,1502	21	–0,9363	36	–2,3377	51	–4,5873
18(16-18)	7	0,2490	22	–0,1638	37	–1,1022	52	–2,8241
18(18-44)	8	0,2974	23	–0,1638	38	–1,1067	53	–2,4539
25(11-25)	9	0,9630	24	0,9316	39	0,8543	54	0,6331
25(25-26)	10	0,9678	25	0,9552	40	0,9417	55	0,9243
29(29-30)	11	0,9176	26	0,8486	41	0,7540	56	0,6744
33(33-36)	12	0,7325	27	0,6258	42	0,4622	57	0,1971
35(35-45)	13	0,8986	28	0,8496	43	0,7979	58	0,7230
39(39-40)	14	0,5199	29	0,3175	44	0,0000	59	–0,5274
39(15-39)	15	0,6588	30	0,5459	45	0,3823	60	0,1351

unesp

O treinamento da rede neural ARTMAP nebulosa foi realizado utilizando-se os seguintes parâmetros:

- Parâmetro de vigilância inicial da rede ARTa ($\overline{\rho}_a$) = 0,4;
- Parâmetro de vigilância da rede ARTb (ρ_b) = 0,99;
- Parâmetro de vigilância do módulo inter-ART (ρ_{ab}) = 0,95;
- Parâmetro de escolha α = 1;
- Taxa de treinamento β = 0,99;
- Número de intervalos ($\mathcal{I}$) = 15.

O conjunto de pares de treinamento é constituído por 60 padrões de entrada/saída. As dimensões dos vetores de entrada e de saída são, respectivamente, 94 e 5. São considerados 15 intervalos definidos como mostrados na Tabela 2 (Capítulo 7). Estes padrões são empregados visando a execução do treinamento da rede em ordem aleatória. Na ordem natural (ordem em que os vetores são lidos) os vetores são apresentados, quase sempre, numa seqüência previsível. Portanto, a ordem aleatória é empregada com o objetivo de "destruir" esta formação lógica. Neste caso, o treinamento torna-se mais eficiente e mais imune aos vícios que porventura possam estar presentes no conjunto de pares de treinamento.

Após a realização do treinamento da rede neural ARTMAP nebulosa, procede-se a obtenção das análises de contingências. Pretende-se apresentar a análise comparativa entre os resultados padrões (via método PEBS Iterativo) e os resultados obtidos pela rede neural. As comparações são efetivadas usando como função de inferência o intervalo da margem de segurança ($\mathcal{I}$). Como visto anteriormente, o intervalo $\mathcal{I}$ 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 $\mathcal{I}$ são definidos usando o conceito de esforço

unesp

de deslocamento da margem de segurança (ϑ). Assim, cada contingência estando contida em um determinado intervalo $\mathcal{I}$ (*Mmin*, *Mmax*), terá uma margem de segurança esperada entre *Mmin* e *Mmax* que, neste trabalho, foram definidos na Tabela 2 (Capítulo 7), considerando-se para ϑ = 0,35. O acerto ou não desta predição é observado comparando-o com o intervalo $\mathcal{I}$ indicado pelo método PEBS Iterativo. Pode-se, ainda, implementar um esquema mais segmentado (maior número de intervalos $\mathcal{I}$) adotando-se valores menores para ϑ 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 iguais a 85, 95, 105 e 115%. De acordo com a *estratégia de votação* ([9]), foram executados 7 treinamentos considerando-se ordens aleatórias diferentes, cujos resultados estão relacionados na Tabela 6. A primeira coluna da Tabela 6 refere-se a simbologia da falta, como definida na Equação (8.2.1). Os números apresentados nas colunas 2 a 5 referem-se aos intervalos previstos pela rede neural para as 7 simulações. Tomando como resolução do problema as soluções geradas com maior freqüência, está-se eliminando possíveis previsões errôneas. Observam-se que em alguns casos (85% do caso base: contingências 18(16-18), 25(25-26) e 39(39-40); 95% do caso base: contingências 18(18-44), 25(11-25) e 39(15-39); 105% do caso base: contingências 13(13-45), 13(13-35) e 25(11-25); 115% do caso base: contingência 13(13-45) e 13(13-35)) não houve repetitividade completa na indicação dos intervalos, constituindo, deste modo, os resultados errôneos. Deve-se destacar que seqüências diferentes de apresentação de padrões, na fase de treinamento, produzirão alocações diferentes nas atividades F_2^a e F_2^b nas redes ARTa e ARTb, respectivamente. O módulo inter-ART proporciona o devido acerto (casamento) entre os módulos ARTa e ARTb. Em alguns casos, tendo em vista os erros de arredondamentos, bem como do mecanismo de geração dos indicadores (vencedores de ARTa e ARTb), poderão ocorrer estes ruídos. Na maioria das vezes a adoção da estratégia de votação com 5 simulações é suficiente para obter resultados satisfatórios. Este processo, ainda

unesp

que realizado com repetição de treinamento, é bastante rápido. Para destacar, considerando-se o exemplo que está sendo abordado (60 padrões em que a entrada e saída possuem 94 e 5 (188 e 10 na forma com complemento) componentes, respectivamente), para uma única seqüência de treinamento são consumidos em torno de 12 centésimos de segundo para realizar a fase de treinamento (que é o maior volume de cálculo). O treinamento, com a inclusão da estratégia de votação, é realizado na ordem de 1 segundo com o equipamento computacional como anteriormente especificado (Pentium III / 500 MHz).

Tabela 6 – Resultados das previsões da rede neural ARTMAP nebulosa considerando-se 7 execuções de treinamento em ordens aleatórias diferentes.

Falta	Intervalo (I)			
	85% do Caso Base	95% do Caso Base	105% do Caso Base	115% do Caso Base
11(11-25)	12,12,12,12,12,12,12	11,11,11,11,11,11,11	9,9,9,9,9,9,9	9,9,9,9,9,9,9
13(13-45)	15,15,15,15,15,15,15	15,15,15,15,15,15,15	15,14,14,14,14,14,14	14,14,14,14,14,14,6
13(13-35)	15,15,15,15,15,15,15	15,15,15,15,15,15,15	15,14,14,14,14,14,15	15,14,14,14,14,14,15
15(14-15)	13,13,13,13,13,13,13	13,13,13,13,13,13,13	12,12,12,12,12,12,12	12,12,12,12,12,12,12
24(24-35)	15,15,15,15,15,15,15	15,15,15,15,15,15,15	15,15,15,15,15,15,15	15,15,15,15,15,15,15
18(18-19)	7,7,7,7,7,7,7	5,5,5,5,5,5,5	1,1,1,1,1,1,1	1,1,1,1,1,1,1
18(16-18)	8,8,8,8,6,6,8	6,6,6,6,6,6,6	5,5,5,5,5,5,5	3,3,3,3,3,3,3
18(18-44)	6,6,6,6,6,6,6	6,5,5,5,5,5,5	3,3,3,3,3,3,3	3,3,3,3,3,3,3
25(11-25)	15,15,15,15,15,15,15	14,15,14,14,14,14,14	14,11,14,14,14,14,14	11,11,11,11,11,11,11
25(25-26)	15,14,15,15,15,15	15,15,15,15,15,15,15	15,15,15,15,15,15,5	15,15,15,15,15,15,15
29(29-30)	15,15,15,15,15,15,15	13,13,13,13,13,13,13	10,10,10,10,10,10,10	10,10,10,10,10,10,10
33(33-36)	11,11,11,11,11,11,11	10,10,10,10,10,10,10	8,8,8,8,8,8,8	8,8,8,8,8,8,8
35(35-45)	14,14,14,14,14,14,14	13,13,13,13,13,13,13	13,13,13,13,13,13,13	11,11,11,11,11,11,11
39(39-40)	9,9,8,9,9,8,8	8,8,8,8,8,8,8	5,5,5,5,5,5,5	5,5,5,5,5,5,5
39(15-39)	10,10,10,10,10,10,10	8,8,8,8,9,8,8	7,7,7,7,7,7,7	7,7,7,7,7,7,7

unesp

Considerando-se, portanto, a maior freqüência de ocorrência nos casos treinados, apresentam-se na Tabela 7 as previsões fornecidas (intervalos $\mathcal{I}$s) pela rede neural ARTMAP nebulosa. Nesta tabela constam, também, os resultados obtidos através do método PEBS Iterativo ([19]) para fins comparativos.

Tabela 7 – Resultados comparativos das previsões fornecidas pela rede neural ARTMAP nebulosa e o algoritmo PEBS Iterativo ([19]).

Falta	Carregamento							
	85% do Caso Base		95% do Caso Base		105% do Caso Base		115% do Caso Base	
	PEBS Iterativo	ARTMAP Nebulosa	PEBS Iterativo	ARTMAP Nebulosa	PEBS Iterativo	ARTMAP Nebulosa	PEBS Iterativo	ARTMAP Nebulosa
11(11-25)	13	12	12	11	10	9	8	9
13(13-45)	15	15	15	15	15	14	13	14
13(13-35)	15	15	15	15	15	14	14	14
15(14-15)	14	13	13	13	12	12	11	12
24(24-35)	15	15	15	15	15	15	15	15
18(18-19)	6	7	4	5	2	1	1	1
18(16-18)	7	8	6	6	4	5	2	3
18(18-44)	7	6	6	5	4	3	2	3
25(11-25)	15	15	15	14	13	14	9	11
25(25-26)	15	15	15	15	15	15	15	15
29(29-30)	14	15	12	13	11	10	10	10
33(33-36)	11	11	9	10	8	8	7	8
35(35-45)	14	14	12	13	11	13	10	11
39(39-40)	9	9	7	8	6	5	5	5
39(15-39)	10	10	9	8	8	7	7	7

Analisando-se os resultados mostrados na Tabela 7, pode-se concluir que a rede neural ARTMAP nebulosa proporciona soluções que podem ser consideradas satisfatórias, em termos de precisão. Em alguns casos, não houve

unesp

coincidência entre a previsão via rede neural ARTMAP nebulosa e o método PEBS Iterativo (considerado como referência em termos de precisão). Isto ocorreu, provavelmente, em conseqüência do número pequeno de exemplos empregados no treinamento. A precisão aumenta à medida em que se emprega conjunto de treinamento mais volumoso (maior número de estímulos). Para destacar, a rede não poderá prever contingências contidas nos intervalos 2 e 4, tendo em vista que o conjunto de treinamento não contém nenhum par de treinamento nestes intervalos (há ausência de oportunidade de ensinamento), conforme verifica-se na Tabela 8 em que é evidenciado o número de ocorrências de contingências em cada categoria de intervalos. Há intervalos em que ocorreu baixa freqüência de contingências (por exemplo, os intervalos 1, 3, 6, 7, 10 e 13). Tudo isto contribui para reduzir o nível de exatidão das previsões. Há, também, outro fator intrínseco da rede neural ARTMAP importante neste contexto, ou seja, as classes são estabelecidas baseadas no emprego do conceito de hiper-retângulos, cujas dimensões dependem do tamanho dos parâmetros de vigilâncias, tanto do módulo ARTa, assim como do módulo ARTb. O parâmetro de vigilância da rede ARTb é fixado através da entrada de dados, porém, a magnitude do parâmetro de vigilância do módulo ARTa depende do mecanismo de sintonia exercido pelo módulo inter-ART. Considerando-se um conjunto de padrões de entrada/saída, através da rotina de treinamento, os agrupamentos de classes são definidos sem que haja o controle pelo usuário. Deste modo, haverá um maior ou menor número de contingências contidas em um determinado hiper-retângulo. Isto contribui para a ocorrência de casos em que a previsão falha em indicar um determinado intervalo vizinho ao intervalo em que deveria ser a escolha correta. Para ilustrar este detalhe, toma-se como exemplo uma coleção de figuras composta por triângulos, quadrados e círculos. Deseja-se identificar as figuras semelhantes. Com o devido ajuste do parâmetro de vigilância (ρ) pode-se perfeitamente agrupar triângulos, quadrados e círculos em três classes. Cada classe deverá estar contida em um hiper-retângulo. Se atribuirmos um determinado valor para ρ, os agrupamentos poderão ser formados, por exemplo, em que um deles conterá os

unesp

círculos e o outro, quadrados e triângulos. Se diminuirmos ainda mais o parâmetro ρ, haverá um único agrupamento contendo todas as figuras que poderiam ser chamadas coletivamente apenas de "coisas". Neste caso, não há condições de fazer distinções sobre estes objetos. Deste modo, pode-se concluir que, à medida que ρ diminui, haverá um aumento da generalização e um decréscimo da precisão. No sentido inverso, aumentando-se o parâmetro de vigilância, diminuir-se-á a generalização e aumentar-se-á a precisão dos resultados. A rede ARTMAP, através da interface inter-ART, uma vez arbitrado um valor do parâmetro de vigilância da rede ARTb, estabelecerá, de forma automática, o nível de generalização e precisão dos resultados.

Tabela 8 – Contingências classificadas de acordo com o método PEBS Iterativo ([19]), considerando-se cada intervalo da margem de segurança.

Número	**Intervalo da Margem de Segurança (I)**	**Contingências classificadas de acordo com o Método PEBS Iterativo ([19]) (Fase de treinamento)**
1	Menor ou igual do que -3	51
2	(–3 ; –1,9630]	–
3	(–1,9630 ; –1,1948]	36, 52, 53
4	(–1,1948 ; –0,6258]	–
5	(–0,6258 ; –0,2043]	21, 37, 38, 59
6	(–0,2043 ; 0,10790]	22, 23
7	(0,10790 ; 0,33920]	6, 44, 60
8	(0,33920 ; 0,51050]	7, 8, 29, 45, 57
9	(0,51050 ; 0,63740]	14, 30, 42, 46
10	(0,63740 ; 0,73140]	15, 27, 56
11	(0,73140 ; 0,80110]	12, 31, 54, 58
12	(0,80110 ; 0,85260]	16, 34, 41, 43, 49
13	(0,85260 ; 0,89080]	19, 26, 28
14	(0,89080 ; 0,91910]	1, 4, 13, 39, 47, 48
15	Maior do que 0,9191	2, 3, 5, 9, 10, 11, 17, 18, 20, 24, 25, 32, 33, 35, 40, 50, 55



O tempo de processamento, referente à fase de treinamento, é assim distribuído:

- *Tempo para uma etapa de treinamento:*
  ≈ 12 centésimos de segundo;

- *Tempo para a realização do mecanismo da estratégia de votação (5 simulações):*
  ≈1 segundo.

8.3 Conclusão

Neste Capítulo foram realizadas as análises da estabilidade transitória através de uma rede neural ARTMAP nebulosa. 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 método PEBS Iterativo ([19]). 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. Houve alguns casos em que as previsões não foram totalmente corretas. Neste sentido, foram discutidos os principais fatores que podem contribuir para que tais previsões não sejam plenamente exatas, ou ainda, quais serão as medidas que deverão ser tomadas visando conferir maior eficiência à rede neural. De um modo geral, pode-se concluir que a rede neural ARTMAP nebulosa 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

unesp

continuado). Deste ponto de vista, a rede neural ARTMAP nebulosa 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.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

9 Conclusão e Sugestões para Trabalhos Futuros

9.1 Conclusão

Foi desenvolvido nesta dissertação de mestrado um procedimento de análise de estabilidade transitória de sistemas de energia elétrica multi-máquinas, através de uma rede neural ARTMAP nebulosa. Esta rede é composta por dois módulos de redes neurais ART (*Adaptive Resonance Theory*) ([8–13]) e um módulo inter-ART que executa a interface entre as duas redes neurais, proporcionando a sintonia dos padrões de entrada e de saída. O módulo ART é uma rede neural não-supervisionada (treinamento baseado em estímulos somente de entrada). As redes neurais ART apresentam as características de estabilidade (garantia da obtenção de uma solução) e plasticidade (permite elaborar o reforço do treinamento sem destruir o conhecimento adquirido previamente). Interligando-se estas duas redes neurais (ARTa para a recepção da entrada e ARTb para a recepção da saída na fase de treinamento), através do módulo inter-ART, confere à rede ARTMAP o treinamento supervisionado. A rede neural ARTMAP, formulada através dos operadores lógico-nebulosos, além de tornar mais rápido o treinamento, se comparada à rede ARTMAP convencional ([8]), permite o mapeamento entre entradas analógicas/binárias e saídas analógicas/binárias. Com esta arquitetura pôde-se idealizar um procedimento de análise de estabilidade transitória de sistemas elétricos de potência. Os estímulos de entrada da rede neural são constituídos pelo vetores de potências ativa e reativa nodais (dados analógicos) e pelos dados das contingências (dados binários). As saídas correspondem às margens de segurança do sistema representadas por intervalos

unesp

compreendidos entre os valores mínimo e máximo. Deste modo, foi possível representar as saídas em código binário (saídas binárias).

Como ilustração da metodologia são apresentados os resultados da análise de estabilidade transitória, via rede neural ARTMAP nebulosa, 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. O treinamento foi realizado considerando-se 60 contingências de curto-circuito trifásico sólido com saída de linha de transmissão. As contingências foram arbitradas como incidentes em vários pontos da rede elétrica (15 localizações). Foram considerados 4 níveis de carregamentos lineares correspondentes a 80, 90, 100 e 110% do caso base. Para as previsões, foram consideradas as mesmas contingências, porém, com carregamentos correspondentes a 85, 95, 105 e 115%.

Os resultados obtidos podem ser considerados satisfatórios, ou seja, atingiram os objetivos propostos. Estes objetivos foram: investigar a aplicação de redes neurais para execução de diagnósticos da estabilidade transitória de sistemas elétricos de potência. A rede neural ARTMAP tem proporcionado a obtenção de soluções bastante rápidas (cerca 1 segundo utilizando um microcomputador Pentium III de 500 MHz, considerando-se a execução da estratégia de votação com 5 repetições de treinamento). A qualidade das soluções foram adequadas. Contudo, foram observadas algumas imprecisões. Estas imprecisões não foram decorrentes da rede neural e sim do uso em um conjunto de treinamento não suficientemente completo. Deve-se destacar que a precisão dos resultados é dependente do volume de dados para o treinamento e, também, do número de segmentos de saída (intervalos I). Um maior número de segmentos pode ser obtido tomando-se valores menores para o parâmetro ϑ (esforço de deslocamento da margem de segurança). Contudo, para aumentar o número de intervalos será necessário utilizar um grande conjunto de pares de treinamento (número de exemplos) para reduzir as possibilidades de existência de intervalos vazios (que não contenham contingências). Intervalos vazios não oferecem

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

oportunidades de aprendizado e, conseqüentemente, introduzem os indesejáveis focos de ruídos no treinamento.

Concluindo-se, a rede neural ARTMAP nebulosa obtém respostas com grande rapidez (há compatibilidade com as aplicações *on-line*) e a precisão é dependente da implementação de um esquema adequado de treinamento, adotando-se um volume de dados de entrada/saída bem elaborado (em quantidade e qualidade suficientes). Todavia, há sempre a garantia na obtenção das soluções (característica de estabilidade), com precisão adequada ou não. Pode-se verificar, entretanto, que se o conjunto de dados de treinamento não for suficientemente elaborado, as respostas, embora contenham imprecisões, com a utilização da estratégia de votação, podem ser adotadas como válidas. Ou seja, considerando-se todos os resultados simulados não se verificou nenhum erro grosseiro que chegasse a inutilizar as análises. 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 maioria da 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. Ressalta-se que o esquema reforço pode ser implementado com um tempo de execução, também, bastante reduzido. Para destacar, se utilizados no treinamento do exemplo abordado no Capítulo 8 os dados para previsões (carregamentos de 85 a 115% do caso base) e considerados outros perfis de geração/carga para previsões, os acertos ficam bem próximos de 100%. Assim, ter-se-iam resultados mais precisos, ainda, à medida que novos exemplos forem incorporados. Estes exemplos podem ser os resultados das simulações da análise de estabilidade que rotineiramente são obtidos pelas companhias do setor elétrico, bastando, apenas, incluir rotinas que realizem o pré-processamento destes resultados e

unesp

adequadamente ser extraído o conhecimento de forma incremental pela rede neural ARTMAP.

9.2 Sugestões Para Trabalhos Futuros

Os resultados desta pesquisa podem ser considerados satisfatórios (do ponto de vista da precisão e rapidez na obtenção das soluções), conforme argumentado anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar a análise, através da rede neural ARTMAP nebulosa, ainda mais eficiente:

1) introduzir novos dispositivos e procedimento à rede neural desenvolvida, visando a melhoria das soluções, por exemplo, incluir novos mecanismos para geração de classes e sintonia (*match tracking*) entre entrada e saída da rede neural, empregar técnicas estocásticas em que se determinam probabilidades das inferências, ou seja, a informação de que uma determinada contingência possui a probabilidade p de estar contida no intervalo I_k que é uma forma interessante de abordagem;

2) desenvolver estratégias de implementação do treinamento continuado;

3) usar perfis de geração e de carga, na fase de treinamento, mais realistas, por exemplo, gerados a partir de uma rotina que englobe o despacho econômico e a previsão de carga;

3) usar um maior número de padrões no treinamento com o objetivo de ampliar o nível de precisão das análises. Este detalhe deve ser evidenciado nos resultados das análises realizadas: de 120 contingências, levando-se em conta as fases de treinamento e de diagnóstico, apenas 19 são instáveis (cerca de 15% do total de contingências). Justamente nos estados instáveis e criticamente instáveis/estáveis observou-se um maior número de imprecisões. Isto ocorreu,

unesp

certamente, por haver poucos estímulos (contingências instáveis) à rede neural. Não houve, portanto, a assimilação adequada do conhecimento para contingências instáveis por ausência exclusiva de oportunidades;

5) empregar a rede neural ARTMAP nebulosa para o diagnóstico da estabilidade transitória para modelos mais elaborados do que o modelo clássico.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

10 Referências Bibliográficas

[1] AGGARWAL, R. K.; XUAN, Q. Y.; LI, F. and BENNET, A. "A Novel Approach to Fault Diagnosis in Multicircuit Transmission Lines Using Fuzzy ARTMAP Neural Networks", *IEEE Transactions on Neural Networks*, Vol. 10, No. 5, September - 1999, pp. 1214-1220.

[2] ANDERSON, P. M.; FOUAD, A. "Power System Control and Stability", *IOWA State University Press*, USA, 1977.

[3] ASSADI, H.; TAN, A.; ETEZADI-AMOLI, M.; EGBERT, D. and FADALI, M. S. "Application of the ARTMAP Neural Network to Power System Stability Studies", *IEEE - International Conference on Systems, Man and Cybernetics*, Vol.2, 1992, pp. 1080-1085.

[4] ATHAY, T.; SHERKET, V. R.; PODMORE, R.; VIRMANI, S. and PUECH, C. "Transient Energy Stability Analysis", *Conference on 'System Engineering For Power'*, Davos, Switzerland, 1979.

[5] BARTFAI, G. "On the Match Tracking Anomaly of the ARTMAP Neural Network", *Neural Networks*, Vol. 9, No. 2, March - 1996, pp. 295-308.

[6] BLUME, M. and ESENER, S. C. "An Efficient Mapping of Fuzzy ART onto a Neural Architecture", *Neural Networks*, Vol. 10, No. 3, April - 1997, pp. 409-411.

[7] CANTIN, M. A.; BLAQUIÈRE, Y.; SAVARIA, Y.; LAVOIE, P. and GRANDER, E. "Analysis of Quantization Effects in a Digital Hardware Implementation of a ART Neural Network Algorithm", *IEEE International*

unesp

Symposium on Circuits and Systems, Geneva, Switzerland, May – 2000, pp. 28-31.

[8] CARPENTER, G. A. and GROSSBERG, S. "Pattern Recognition by Self-Organizing Neural Networks", *The MIT Press*, Cambridge, Massachusetts, USA, 1991.

[9] CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.: REYNOLDS, J. H. and ROSEN, D. B. "Fuzzy ARTMAP: A Neural Network Architecture For Incremental Supervised Learning of Analog Multidimensional Maps", *IEEE Transactions on Neural Networks*, Vol. 3, No. 5, September – 1992, pp. 698-713.

[10] CARPENTER, G. A. and GROSSBERG, S. "A Self-Organizing Neural Networks For Supervised Learning, Recognition, and Prediction", *IEEE Communications Magazine*, September – 1992, pp.38-49.

[11] CARPENTER, G. A. and GROSSBERG, S. "Self-Organizing Neural Network Architectures For Real Time Adaptive Pattern Recognition", *An Introduction to Neural Electronic Networks, Academic Press*, 1989, pp. 455-477.

[12] CARPENTER, G. A.; GOPAL, S.; MACOMBER, S.; MARTENS, S. and WOODCOCK, C. E. "A Neural Network Method for Efficient Vegetation Mapping", *Remote Sensing of Environment*, Vol. 70, No. 3, December – 1999, pp. 326-338.

[13] CARPENTER, G. A.; MILENOVA, B. L. and NOESKE, B. W. "Distributed ARTMAP: A Neural Network For Fast Distributed Supervised Learning", *Neural Networks*, Vol. 11, No. 5, July – 1998, pp. 793-813.

[14] CHEE, P. L.; HARRISON, R. F. and KENNEDY, R. L. "Application of Autonomous Neural Network Systems to Medical Pattern Classification Tasks", *Artificial Intelligence in Medicine*, Vol. 11, No. 3, November – 1997, pp. 215-239.

unesp

[15] DY LIACCO, T. E. "Control of Power Systems via the Multi-Level Concepts", *PhD*. Thesis, Case Western Reserve University, 1968, Rep. SRC-68-19.

[16] EPRI "Transient Stability Margin as a Tool For Dynamic Security Assessment", *Iowa State University*, EPRI EL-1755, Project 1355-3, Ames, Iowa, 1981.

[17] FENG, K. and HOBEROCK, L. L. "A Modified ARTMAP Network With Applications to Scheduling of a Robot-Vision-Tracking System", *Journal of Dynamic Systems, Measurement, and Control*, Vol. 118, March – 1996, pp. 1-8.

[18] FOGEL, D. B. "Evolutionary Computation: Toward a New Philosophy of Machine Intelligence", *IEEE Press*, New York, 1995.

[19] FONSECA, L. G. S. and 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, 1985, pp. 483-489.

[20] FOUAD, A. A. and VITTAL, V. "Power System Transient Stability Analysis Using the Transient Energy Function Method", *Prentice Hall*, Englewood Cliffs, New Jersey, 1992.

[21] 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.

[22] GEORGIOPOULOS, M.; FERNLUND, H.; BEBIS, G. and HEILEMAN, G. L. "Order of Search in Fuzzy ART and Fuzzy ARTMAP: Effect of the Choice Parameter", *Neural Networks*, Vol. 9, No. 9, December – 1996, pp. 1541-1559.

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

[23] GRANGER, E.; RUBIN, M. A.; GROSSBERG, S. and LAVOIE, P. "A What-and-Where Fusion Neural Network For Recognition and Tracking of Multiple Radar Emitters", *Neural Networks*, No. 14, 2001, pp. 325-344.

[24] HAYKIN, S. "Neural Networks: A Comprehensive Foundation", *Prentice-Hall*, Upper Saddle River, New Jersey, USA, 1994.

[25] IEEE - TASK FORCE "Proposed Terms & Definitions for Power System Stability", *IEEE Transactions on Power Apparatus and Systems*, Vol. PAS - 101, No. 7, July - 1982, pp. 1894-1898.

[26] JAIN, A. K.; MAO, J. and MOHIUDDIN, K. M. "Artificial Neural Networks: A Tutorial", *IEEE Computer*, Vol. 29, No. 3, March - 1996, pp. 31-44.

[27] JIRIWIBHAKORN, S.; COONICK, A. H. and CORY, B. J. "Fast Critical Clearing Time Function Approximation Using Neural Networks and Sobol Sequences", *IEEE Power Engineering Review*, January - 2000, pp. 51-53.

[28] KARTALOPOULOS, S. V. "Understanding Neural Networks and Fuzzy Logic", *IEEE Press*, New York, 1996.

[29] KEYVAN, S.; SONG, X. and KELLY, M. "Nuclear Fuel Pellet Inspection Using Artificial Neural Networks", *Journal of Nuclear Materials*, Vol. 264, No. 1-2, January - 1999, pp. 141-154.

[30] KING, R. L. "Artificial Neural Networks And Computational Intelligence", *IEEE Computer Application in Power*, October - 1998, pp. 14-29.

[31] KIRCHMAYER, L. K. "Economic Operation of Power Systems", *John Wiley & Sons*, New York, 1958.

[32] KUNG, S. Y. "Digital Neural Networks", *PTR Prentice-Hall*, Englewood Cliffs, N. Jersey, USA, 1993.

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

[33] LLOBET, E.; HINES, E. L.; GARDNER, J. W.; BARTLETT, P. N. and MOTTRAM, T. T. "Fuzzy ARTMAP Based Electronic Nose Data Analysis", *Sensors and Actuators B: Chemical*, Vol. 61, No. 1-3, December - 1999, pp. 183-190.

[34] McNEIL, F. M. and THRO, E. "Fuzzy Logic a Practical Approach", *Academic Press*, 1994.

[35] MENDES FILHO, E. F. and CARVALHO, A. C. P. L. "Tutorial Introdutório Sobre Redes Neurais Artificiais", *Departamento de Ciências de Computação e Estatística - USP*, Fevereiro - 1997.

[36] 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.

[37] MINUSSI, C. R. and FREITAS FILHO, W. "Sensitivity Analysis For Transient Stability", *IEE Proceedings on Generation, Transmission And Distribution*, Vol. 145, No. 6, pp. 669-674, 1998.

[38] 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.

[39] MINUSSI, C. R. and SILVEIRA, M. C. G. "Transient Stability Analysis of Electric Power Systems by Neural Networks", *38 rd Midwest Symposium on Circuits And Systems*, Rio de Janeiro - RJ, 1995, pp. 1305-1308.

[40] PAI, M. A. "Power System Stability", *North Holland Control Series*, 1981.

[41] PAO, Y. H. and SOBAJIC, D. J. "Combined Use of Unsupervised And supervised Learning For Dynamic Security Assessment", *IEEE PICA-91*, pp. 278-284.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

[42] PARK, Y. M.; KIN, G. -W.; CHO, H. -S; and 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, December – 1997, pp. 1030-1033.

[43] RIBBENS-PAVELLA, M. and EVANS, P. J. "Direct Methods For Studying Dynamics of Large-scale Electric Power Systems - A Survey", *Automatica*, Vol. 21, 1985, pp. 1-2.

[44] SIMPSON, P. K. "Artificial Neural Systems: Foundations, Paradigms, Applications, and Implementations", *Pergamon Press*, New York, 1989.

[45] SOBAJIC, D. J. and PAO, Y-H. "Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems", *IEEE Transactions on Power Systems*, Vol. 4, No. 1, February – 1989, pp. 220-227.

[46] TERANO, T.; ASAI, K. and SUGENO, M. "Fuzzy Systems Theory And Its Application", *Academic Press*, New York, USA, 1987.

[47] WANG, D. "Pattern Recognition: Neural Networks in Perspective", *IEEE Expert*, August – 1993, pp. 52-60.

[48] WASSERMAN, P. D. "Neural Computing - Theory And Practice", *Van Nostrand Reinhold*, New York, USA, 1989.

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

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

[51] WIDROW, B.; LEHR, M. A. "30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation", *Proceedings of the IEEE*, Vol. 78, No. 9, September – 1990, pp. 1415-1442.

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

[52] WILLIAMSON, J. R. "Gaussian ARTMAP: A Neural Network for Fast Incremental Learning of Noisy Multidimensional Maps", *Neural Networks*, Vol. 9, No. 5, July – 1996, pp. 881-897.

N.B. Para a realização desta dissertação, assim como do texto, foram utilizados os *software Windows'NT*, editor *Word'97*, compilador *Fortran* PRO FORTRAN, *Matlab* (e *toolboxes*), versões para microcomputador. Todos estes *software* são aquisições oficiais da UNESP ou do Programa de Pós-graduação em Engenharia Elétrica – FEIS – UNESP.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Apêndice A

ALGORITMO DO MÉTODO PEBS ITERATIVO ([19])

Considerando os conceitos apresentados no Capítulo 4, pode-se descrever o algoritmo de análise de estabilidade transitória de sistemas de energia elétrica (Método PEBS Iterativo ([19]), mediante os seguintes passos ([21, 36]):

Passo 1. Calcular o fluxo de potência pré-falta.

Passo 2. Iniciação de parâmetros:

$Emax = 0$ (energia máxima inicial);

$Emin = 0$ (energia mínima inicial);

$Tmax = 0$ (tempo máximo inicial);

$Tmin = 0$ (tempo mínimo inicial);

$r = 1$ (contador de contingências).

Passo 3. Calcular as matrizes de admitância reduzidas às barras internas de geração (de falta e pós-falta) e o fluxo de potência pós-falta.

Passo 4. Determinar a trajetória de falta (integração das equações diferenciais (3.2.1) considerando-se a topologia de falta) até encontrar a PEBS, ou seja, até $D(\theta) = 0$:

- se $\exists\ D(\theta)$, então, fazer $\theta^* = 0$, e ir para o Passo 5;
- caso contrário, o sistema não encontrou a PEBS considerando-se o tempo de simulação. Neste caso, o sistema apresenta uma grande robustez, caracterizando-o como estável para a contingência analisada. Ir para o Passo 11.

Passo 5. Fazer $Ecrit^{(r)} \leftarrow Ep\,(\theta^*)$.

Esta adoção é feita baseada na suposição de que a trajetória pós-falta passa próxima a um ponto de equilíbrio instável ([36]). Neste caso, a energia cinética, avaliada neste ponto, é pequena, se comparada à energia potencial. A energia total é representada apenas pela energia potencial. Esta energia é adotada como uma estimativa inicial.

Passo 6. Determinar a trajetória de falta até que $E(\theta, \omega) = Ecrit^{(r)}$.

Fazer $T = Tcrit^{(r)}$ ($Tcrit^{(r)}$ = tempo em que se obteve $Ecrit^{(r)}$).

Passo 7. Monitorar a trajetória pós-falta até o tempo final de simulação:

- se $\exists\ D(\theta) = 0$, fazer $Emax = Ecrit^{(r)}$, $Tmin = T$ e ir para o Passo 8;
- caso contrário, fazer $Emin = Ecrit^{(r)}$, $Tmax = T$ e ir para o Passo 8.

Passo 8. Se $Emax = 0$, então, fazer $Emax = 1.3\ Ecrit^{(r)}$ e ir para o Passo 7.

Ressalta-se que não havendo uma melhor estimativa de $Emax$ ($Emax$ é necessariamente diferente de zero) arbitra-se, neste trabalho, um valor correspondente a 30% superior a estimativa de $Ecrit^{(r)}$ anterior (valor arbitrado baseado na experiência com simulações ([19]).

Se $Emax \neq 0$, ir para o Passo 9.

Passo 9. Fazer

$$Ecrit^{(r)} \leftarrow \frac{E\ max\ + E\ min}{2}.$$

Passo 10. Se $|E max - E min| \leq$ tolerância, o processo convergiu. Ir para o Passo 11.

Caso contrário, voltar para o Passo 6.

Passo 11. Contador de contingências: $r \leftarrow r + 1$.

unesp

Passo 12. Última contingência? Se verdadeiro, ir ao Passo 13. Do contrário, retornar ao Passo 2.

Passo 13. 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.).

unesp

Apêndice B

DADOS DO SISTEMA DE ENERGIA ELÉTRICA

A seguir apresenta-se os dados e o diagrama unifilar referentes a uma configuração 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 9 - 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

unesp

Tabela 9 - 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	Forquilinha 230	0,977	-37,360	0,901	-0,447	0,000	0,000

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

Tabela 10 - 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	Forquilinha 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

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

Tabela 10 - 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	Forquilinha 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

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Tabela 10 - 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 11 - 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

unesp

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Ilha Solteira
Programa de Pós-Graduação em Engenharia Elétrica
Av. Brasil Centro, 56
15385-000 Ilha Solteira - SP
www.dee.feis.unesp.br