ANÁLISE DA ESTABILIDADE TRANSITÓRIA DE SISTEMAS ELÉTRICOS USANDO UMA REDE NEURAL EUCLIDIANA ART&ARTMAP COM TREINAMENTO CONTINUADO

Angela Leite Moreno[1], *Carlos Roberto Minussi*[2]

Abstract — *This work presents a procedure for analysis of transitory stability of first oscillation (model classic) of electric power systems using a neural network based on the architecture ART (Adaptive Resonance Theory), call of Euclidean ART-ARTMAP with Continuous Training. This network is composed for a module Euclidean ART and of a module ARTMAP, together with a routine of continuous training that seeks to turn the most efficient analysis. This routine is constituted an effective possibility of the job of neural networks in the analysis in real time, destroying the concept, until then, about the limitations (instability and no-plasticity) of the neural networks in the treatment of real problems that has been checking little application reliability. To illustrate the proposed neural framing, an application is presented considering an electric system (multimachine) composed of 10 synchronous machines, 45 buses, and 73 transmission lines.*

Index Terms — Adaptive Resonance Theory, Euclidean ART, ARTMAP, Continuous Training, Power Systems, Analysis of transitory Stability.

INTRODUÇÃO

A estabilidade é a característica do sistema elétrico de potência, ou parte do sistema, que lhe permite desenvolver em seus elementos forças restauradoras iguais ou maiores que as forças perturbadoras, as quais permitem estabelecer um estado de equilíbrio entre os elementos. O limite de estabilidade é o fluxo máximo de potência que pode passar em determinado ponto do sistema, quando todo ele ou parte a que se refere o limite de estabilidade está operando de maneira estável [21]. Nos sistemas elétricos de potência existem limites de estabilidade para regimes permanentes e transitórios. O primeiro é atingido quando o fluxo máximo de potência possível em um determinado ponto do sistema, sem perda de estabilidade, for atingido de forma gradual. Já o segundo, quando o fluxo máximo de potência possível em um determinado ponto, também sem perda de estabilidade, for atingido, mas de forma brusca, após uma perturbação do sistema. Em geral o limite da estabilidade transitória de um sistema é menor que o limite de estabilidade em regime permanente. Portanto, para que o sistema opere dentro de seus limites de estabilidade, é necessário que seja mantido com margens as quais permitam que a ocorrência de perturbações causadas por falhas e suas eliminações não levem a perda de estabilidade do sistema. A análise da estabilidade transitória pode ser feita através da simulação passo a passo, que é precisa e não apresenta restrição quanto ao tipo de modelo empregado, entretanto este tipo de simulação necessita de grande quantidade de tempo para a realização de cálculos e análise. Assim, o uso de redes neural para a realização deste tipo de análise vem se mostrando como uma alternativa eficiente [2, 5, 7, 9, 12, 13].

O procedimento apresentado neste trabalho para análise da estabilidade transitória de sistemas de energia elétrica multi-máquinas é utilizar uma rede neural ART Euclidiana & ARTMAP com Treinamento Continuado. Esta arquitetura apresenta dois diferenciais em relação a outras já utilizadas para abordar tal problema: primeiro um módulo ART Euclidiano que realiza uma pré-classificação que é utilizada no módulo ARTMAP para uma melhor classificação, e um módulo de treinamento continuado o qual faz com que a rede neural consiga armazenar novos dados sem a necessidade de realizar o retreinamento.

MODELO DO SISTEMA

Considerando um SEE composto por ng máquinas síncronas, o comportamento dinâmico da i-ésima máquina pode ser descrito pela seguinte equação [11]:

$$M_i\ddot{\theta}_i - P_i(\theta) = 0. \qquad i \in NG \qquad (1)$$

em que:

- $P_i(\theta) = Pm_i - Pe_i - (M_i PCOA)/MT$ (2)
- $M_i = \frac{2H_i}{\omega_s}$ (3)
- H_i é a constante de inércia *(s)*
- ω_s é a velocidade síncrona (rad. elét./s) dada por: $\omega_s = 2\pi f_0$;
- f_0 é a frequência nominal do sistema (Hz);
- θ_i é o ângulo rotor da *i*-ésima máquina síncrona referida ao CA (rad. elét.) que é dada por: $\theta_i = \delta_i - \delta_0$;
- δ_i é o ângulo do rotor da *i*-ésima máquina síncrona medida com relação a uma máquina que gira à velocidade síncrona (rad. elét.);
- $\delta_0 = \sum_{j \in NG} M_j \delta_j$ (4)
- PCOA é a potência acelerante do CA que é dada por:

$$PCOA = \sum_{j \in NG} Pm_j - Pe_j \qquad (5)$$

- $MT = \sum_{j \in NG} M_j$ (6)
- *NG* é o conjunto de índices das máquinas síncronas que compõem o sistema: *NG = { 1, 2, 3, ... , ng };*
- *ng* é o número de máquinas síncronas.

1 Angela Leite Moreno, Professora Assistente da Universidade Federal de Alfenas, Rua Gabriel Monteiro da Silva, 700, sala E204C, 37.130-000, Alfenas, MG, Brasil, amoreno@unifal-mg.edu.br
2 Carlos Roberto Minussi, Professor Adjunto da UNESP, Ilha Solteira, SP, Brasil, minussi@dee.feis.unesp.br

A potência elétrica *(Pe)*, considerando-se as simplificações introduzidas no modelo clássico, pode ser calculada de várias formas. A mais comum consiste em realizar o cálculo, a partir da matriz de admitância reduzida às barras internas de geração, como proposto em [11]. Trata-se de um procedimento rápido do cálculo da potência elétrica, principalmente, quando esta se refere à condição de defeito (período de permanência do curto-circuito) e pós-defeito (eliminação do defeito com saída da linha de transmissão), empregando o método proposto na referência [9].

MARGEM DE SEGURANÇA

A análise da estabilidade transitória de Sistemas de Energia Elétrica pode ser realizada com base no conceito de energia e margem de segurança (método direto) [3, 4, 11]. Considerando-se uma contingência de índice *r*, tem-se:

$$M_r = (Ecrit_r - Ee_r)/Ecrit_r \tag{7}$$

em que:

- $Ecrit_r$ é a energia total crítica do sistema;
- Ee_r é a energia total do sistema avaliada no instante de eliminação do defeito (t_e).

A margem de segurança pode ser interpretada como uma "medida de distância" em relação à situação de instabilidade do sistema [5]. 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 [5]:

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

Ressalta-se que, quando são consideradas as condutâncias de transferência, a Equação (2) não se caracteriza como força potencial [8], não é possível determinar uma função energia potencial do sistema – representada pela primeira integral do movimento – que se constitui dependente do caminho de integração descaracterizando-a como energia potencial. Porém, por abuso de linguagem, o termo energia total do sistema será utilizado sempre que houver referência à função tipo energia. Por conseguinte, a energia total relativa ao sistema (1) é dada por [3, 5, 8, 10, 11]:

$$E(\theta,\omega) = E_c(\omega) + E_p(\theta) \tag{8}$$

em que:

- $E_c(\omega)$ é a energia cinética

$$Ec(\omega) = \frac{1}{2}\sum_{i \in NG} M_i \omega_i^2 \tag{9}$$

- $E_p(\theta)$ é a enercia potencial

$$Ep(\theta) = -\sum_{i \in NG} \int_{\theta_i^p}^{\theta_i} p_i(\theta)\, d\theta_i \tag{10}$$

O sobrescrito *(p)* refere-se ao ponto de equilíbrio pós-defeito e $P_i(\theta)$ é dada pela Equação (2).

A margem de segurança é utilizada como saída da rede, para que possamos realizar o treinamento utilizaremos intervalos de margem de segurança em que as contingências se encontram, conforme proposto em [5]:

$$\vartheta = \frac{(1 - M^A)}{(1 - M^B)} - 1 \tag{11}$$

em que:

- ϑ é o esforço de deslocamento da margem de segurança;
- M^A é o valor da margem de segurança inicial do intervalo;
- M^B é o valor da margem de segurança inicial do intervalo.

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

$$IMS_k = (M_k^A, M_k^B) \tag{12}$$

em que:

- IMS: é o intervalo considerado
- k: é o índice que indica o k-ésimo intervalo.

Consideraremos, neste trabalho, $\vartheta = 0{,}35$ e $M_1^A = -3$, obtendo, deste modo, os seguintes valores da margem de segurança:

TABELA 1
INTERVALOS DA MARGEM DE SEGURANÇA

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

REDE NEURAL ART

Neste trabalho é proposto o uso do modelo neural auto-associativo baseado na Teoria da Ressonância adaptativa, ou ART. As redes neurais ART englobam uma variedade ampla de redes neurais baseadas explicitamente na neurofisiologia, e são definidas em relação ao seu algoritmo de treinamento em termos de equações diferenciais detalhadas e críveis como modelos plausíveis dos neurônios biológicos. Na prática, as redes ART são implementadas como soluções analíticas ou aproximações para estas equações diferenciais. A ressonância adaptativa sobre qual a teoria se refere ocorre quando padrões de atividade nas camadas de entrada e saída se reforçam em sinergia. A arquitetura básica de uma rede ART consiste em três grupos de unidades: um campo para processamento de entrada (camada F_1), as unidades *cluster* (camada F_2), e um mecanismo de reinicialização, responsável por controlar o grau de similaridade dos padrões associados a um mesmo *cluster*. A camada F_1 é composta de duas partes: entrada e interface. A porção interface combina sinais da porção entrada e da camada F_2, para uso na comparação da similaridade entre o sinal de entrada e o vetor de pesos da unidade *cluster* candidata.

Algoritmo da Rede Neural ART

- ***Passo 1:*** Leitura dos dados de entrada: Os dados de entrada são denotados pelo vetor: $\boldsymbol{a} = [\, a_1 \;\; a_2 \;\; \ldots \;\; a_M \,]$ M-dimensional. Este vetor é normalizado com o intuito de evitar a proliferação de muitas categorias. Assim:

$$\bar{a} = \frac{a}{|a|} \tag{13}$$

onde: $\bar{a}$ é o vetor normalizado e:

$$|a| = \sum_{i=1}^{M} a_i \tag{14}$$

- ***Passo 2:*** Codificação do vetor de entrada: A codificação de complemento é realizada para preservar a amplitude da informação:

$$\bar{a}_i^c = 1 - \bar{a}_i \tag{15}$$

em que: $\bar{a}_i^c$ é o vetor complementar do vetor de entrada normalizado. Deste modo, o novo vetor de entrada será um vetor *2M*-dimensional que será denotado por:

$$I = [\bar{a} \quad \bar{a}^c] \tag{16}$$

Com isso todos os vetores de entrada após a normalização e codificação terão a mesma magnitude: *M*.

Passo 3: Vetor de Atividade: O vetor de atividade de F2 é simbolizado por $y = [y_1 \quad y_2 \quad \cdots \quad y_n]$, em que: *N* é o número de categorias criadas em F2. Assim, temos:

$$y_j = \begin{cases} 1, & \text{se o nó } j \text{ de } F2 \text{ for ativo,} \\ 0, & \text{caso contrário.} \end{cases} \tag{18}$$

- ***Passo 4:*** Parâmetros da Rede: Os parâmetros utilizados no processamento da rede ART são:
  1. Parâmetro de escolha: $\alpha > 0$;
  2. Taxa de Treinamento: $\beta \in [0,1]$;
  3. Parâmetro de Vigilância: $\rho \in [0,1]$.
- ***Passo 5:*** Inicialização dos Pesos: Inicialmente todos os pesos possuem valor igual a 1, ou seja:

$$w_{j1}(0) = w_{j2}(0) = \cdots = w_{jM}(0) = 1 \tag{19}$$

indicando que não existe nenhuma categoria ativa.

- ***Passo 6:*** Escolha da Categoria: Dado o vetor de entrada ***I*** em F1, para cada nó *j* em F2, a função de escolha T_j é determinada por

$$T_j = \frac{|I \cap w_j|}{\alpha + |w_j|} \tag{20}$$

em que $\cap$ é o operador intersecção:

$$I \cap w_j = \min = \min \tag{21}$$

A categoria é escolhida como sendo o nó *J* ativo, ou seja:

$$J = \arg\max\{T_j : j = 1, 2, \cdots, N\}. \tag{22}$$

Usando a Equação (22) podemos encontrar mais de uma categoria ativa, a categoria escolhida será aquela que possuir menor índice.

- ***Passo 7:*** Ressonância ou Reset: A ressonância ocorre se o critério de vigilância for satisfeito:

$$T_j = \frac{|I \cap w_j|}{|I|} \geq \rho \tag{23}$$

Caso o critério definido pela Equação (23) não seja satisfeito ocorre o *reset*. No *reset*, o nó *J* de F2 é excluído do processo de busca dado por (22) através da equação:

$$T_j = 0. \tag{24}$$

Então, utilizando a Equação (22), é escolhida uma nova categoria para o processo de ressonância. Este procedimento será realizado até que a rede encontre uma categoria que satisfaça Equação (23).

- ***Passo 8:*** Atualização dos Pesos (Treinamento): Após o vetor de entrada ***I*** ter completado o estado de ressonância, segue o processo de treinamento, no qual ocorre a modificação do vetor peso dado por:

$$w_j^{novo} = \beta(I \cap w_j^{velho}) + (1 - \beta) w_j^{velho} \tag{25}$$

Se tivermos $\beta = 1$ então teremos o treinamento rápido.

Rede Neural ART Euclidiana

A rede neural ART Euclidiana apresenta algumas particularidades em relação à rede ART tradicional, pois ela não requer nem a normalização nem a codificação dos vetores de entrada, isto reduz consideravelmente o custo computacional [6]. Assim, as funções de ativação e a função match da rede neural ART Euclidiana são dadas por:

$$T_j(a) = \sum_{i=1}^{M} \sqrt{(a_i - w_{ij})^2} \tag{26}$$

$$M_j = \frac{T_j}{\max(\sum a_i^2, \sum w_{ij}^2)} \tag{27}$$

Outra diferença é que ao invés de escolhermos a categoria que tem ativação máxima escolhemos a que tem ativação mínima e, a ressonância só ocorre se a função match da categoria escolhida for menor que o critério de vigilância.

$$J = \arg\min\{T_j : j = 1, 2, \cdots, N\}, \tag{28}$$

$$M_J < \rho \tag{29}$$

Deste modo, uma baixa vigilância resulta em rigorosa condição de ressonância e um maior número de nós de saída. A função de adaptação (vetor de pesos) continua a mesma da arquitetura ART tradicional [18]:

$$w_j^{novo} = \beta a + (1 - \beta) w_j^{velho} \tag{30}$$

Este procedimento pode ser visto através do fluxograma da Figura 1.

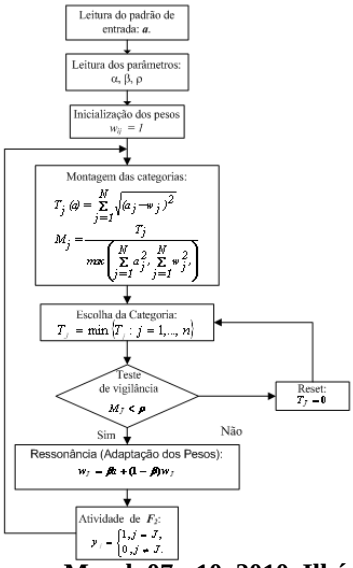

FIGURA 1
FLUXOGRAMA DA REDE ART EUCLIDIANA

Rede neural ARTMAP

A rede neural ARTMAP utiliza o paradigma de treinamento híbrido: nos dois módulos ART, designados ART_a e ART_b, utilizam-se o treinamento não-supervisionado enquanto que no módulo inter-ART realiza o treinamento supervisionado, pois trata-se de um módulo de memória associativa, observe a Figura 2. Os módulos ART_a e ART_b, desempenham as funções que um módulo ART descrito na seção anterior, durante a fase de treinamento (ou aprendizado) as entradas $\boldsymbol{a}^{(n)}$ são apresentandas ao Módulo ART_a, que deve realizar a montagem dos *clusters* de entrada, cuja saída correspondente $\mathbf{b}^{(n)}$ é apresentada ao módulo ART_b, que realiza a *clustering* dos dados de saída. O módulo inter-ART realiza um mapeamento cujo propósito é estabelecer um "casamento" entre as entradas e saídas.

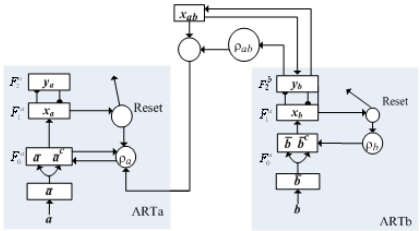

FIGURA 2
MAPA DE CAMPO DE UMA REDE NEURAL ARTMAP

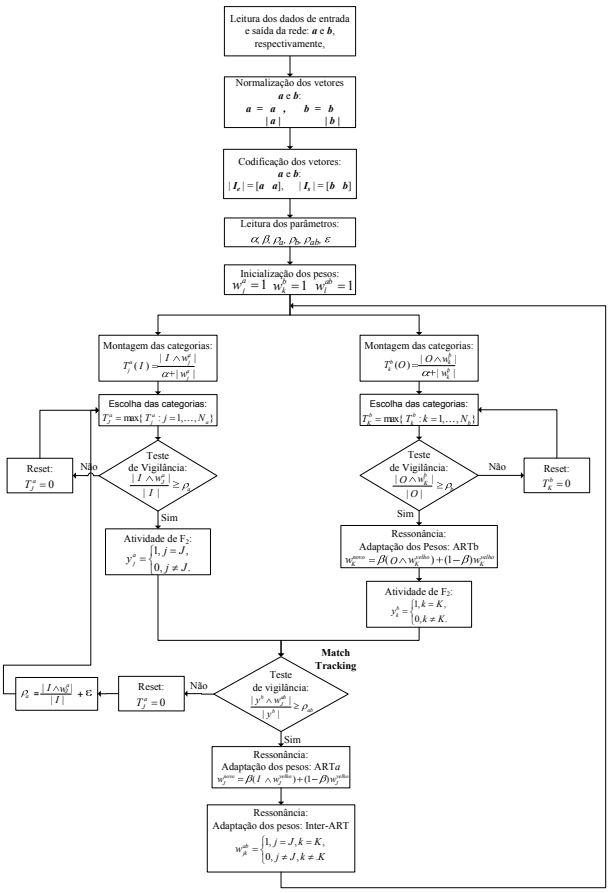

FIGURA 3
FLUXOGRAMA DE UMA REDE NEURAL ARTMAP

Para concluir a discussão a respeito deste tipo de rede é apresentado na Figura 3 o fluxograma da rede neural ARTMAP.

REDE NEURAL ART EUCLIDIANA & ARTMAP COM TREINAMENTO CONTINUADO

A rede neural ART proposta neste trabalho é uma rede ART composta por um módulo ART Euclidiano juntamente com um módulo ARTMAP, além de um algoritmo de treinamento continuado. A função do módulo ART Euclidiano é classificar os vetores de entrada em categorias que serão convertidos em dados binários, que juntamente com outros dados serão utilizados para compor os dados de entrada da rede ARTMAP cuja saída também serão dados analógicos. Durante a fase de análise, o primeiro passo será verificar se o dado de entrada já faz parte ou é similar a algum dos padrões já existentes, caso seja a rede realizará a previsão, caso não seja compatível com nenhum dos dados já existentes utilizará o programa SIMUL para fazer a previsão desta entrada e ainda no ambiente SIMUL buscará novas entradas para formar convenientemente a categoria. Deste modo, o programa estará sempre assimilando novas categorias.

ANÁLISE DA ESTABILIDADE TRANSITÓRIA VIA

REDE ART EUCLIDIANA & ARTMAP COM TREINAMENTO CONTINUADO

Considerando-se o problema da análise da estabilidade transitória apresentado, o par de padrões de entrada e de saída à rede neural pode se escrito da seguinte forma:

$$X^k = [P^k \quad Q^k \quad B_T^k \quad B_F^k] \tag{31}$$

$$Y^k = [M^k] \tag{32}$$

para $k = 1, 2, \ldots, NP$, sendo:

- X^k: *k*-ésimo vetor padrão de entrada da rede neural;
- Y^k: *k*-ésimo vetor padrão de saída da rede neural;
- P^k: vetor de potência elétrica ativa nodal constituinte do *k*-ésimo vetor padrão de entrada;
- Q^k: vetor de potência elétrica reativa nodal constituinte do *k*-ésimo vetor padrão de entrada;
- B_T^k: vetor binário representativo da configuração associada ao k-ésimo vetor padrão de entrada;
- B_F^k: vetor binário representativo da falta (contingência) associada ao k-ésimo vetor padrão de entrada;
- M^k: índice de severidade (margem de segurança) associado ao k-ésimo vetor padrão de saída [12];
- *NP*: número de pares de vetores padrões.

Com o modelo definido pelas Equações (31) e (32), pode-se compor a grande maioria das situações operativas dos sistemas elétricos de potência (diversidade de perfis de carga/de geração, bem como a diversidade de configurações do sistema de transmissão).

A composição do vetor binário $\mathbf{B_T}$ foi projetada para representar todas as configurações da rede elétrica considerada e, também, outras que efetivamente venham a ser operadas. Tecnicamente, este detalhe foi idealizado tomando-se 14 *bits* que é suficiente para representar as configurações básicas e também para abrigar as configurações não previstas. Este procedimento é por si só um grandioso avanço, mesmo se comparado ao procedimento clássico via simulações. Por conseguinte, com esta estruturação há considerável redução da base de dados. Com relação ao vetor binário $\mathbf{B_F}$ as observações, *mutatis mutandis*, são as mesmas.

Assim, uma vez concluído o treinamento, a rede passará a realizar as análises dos casos reais e, uma vez julgada pertinente a inclusão de novos padrões na matriz de pesos da rede neural, é realizado o treinamento continuado. Este também é realizado imediatamente quando for identificada uma configuração "estranha" ao conjunto de configurações preestabelecido imediatamente em relação a esta configuração (apenas esta configuração será treinada, continuando os padrões já existentes sem treinamento). Este procedimento é essencialmente idêntico ao mecanismo do treinamento básico, porém, considerando-se um conjunto bem menor de vetores padrões que envolvem apenas a referida configuração e vários níveis de carga e de geração.

APLICAÇÃO E CONCLUSÃO

O problema abordado trata dados referentes a uma configuração do sistema sul-brasileiro (Figura 4) composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão. Os estímulos de entrada da rede neural são constituídos pelos vetores de potência ativa e reativa nodais, que são dados analógicos, e pelos dados das contingências e configuração do sistema que são dados binários. As saídas correspondem às margens de segurança considerando-se falta de curto-circuito trifásico, que são convertidas em dados binários [13] e, então, aplicadas à rede neural para a execução do treinamento. O treinamento foi implementado utilizando um total de 2615 dados de contingências arbitrados em incidentes em vários pontos da rede elétrica (11 localizações), isto considerando níveis de carregamento dentro de um universo compreendido entre 80 e 130% da carga total do sistema, cada dado é gerado considerando-se uma variação em torno do estado nominal (caso base) e determinada semente para o processo de geração de seqüências aleatórias. Em seguida, foram analisados os dados, entre estes dados havia dados de novos padrões referentes a outras configurações com os quais a rede realizou o treinamento continuado. Então, novamente foram inseridos dados com o mesmo tipo de falta e a rede e realizou-se a análise. Sem o treinamento continuado, houve um acerto de 87%, considerando-se as 2615 simulações realizadas, já com o treinamento continuado este acerto aumentou para 89%. Quando apresentada uma configuração estranha a rede, realiza-se o treinamento continuado e, portanto o resultado é o mesmo apresentado no SIMUL, ao apresentar um dado com a mesma configuração, houve um acerto de 85%. Com o tempo, novos padrões devem sem assimilados pela rede, melhorando assim o índice de acerto.

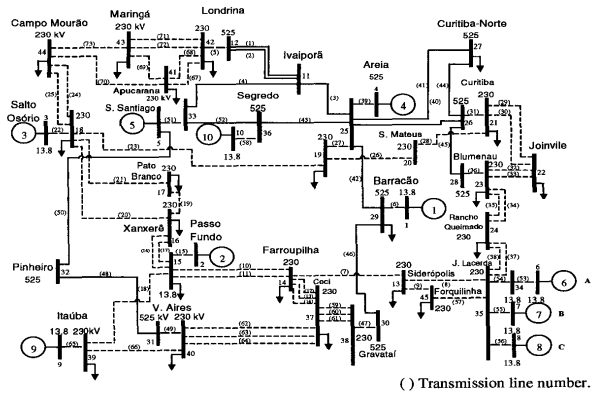

FIGURA 5
SISTEMA SUL-BRASILEIRO

References

[1] Braga, A. P., Ludermir, T. B., Carvalho, A. C. P. L. F. *Redes Neurais Artificiais, Teorias e Aplicações*. 1 Ed. LTC - Livros Técnicos Científicos Editora S.A., 2000.

[2] Ferreira, W.P.; Silveira, M.C.G.; Lotufo, A.D.P. e Minussi, C. R. "Análise de estabilidade transitória de sistemas de energia elétrica por rede neural baseada na Teoria da Ressonância Adaptativa", *5th Latin American Congress on Electricity, Generation and Transmission*, São Pedro-SP, Novembro-2003, (Artigo B-135).

[3] Fonseca, L. G. S. and Decker, I. C. "Iterative algorithm for critical energy determination in transient stability of power system", *IFAC* -

Symposium Planning and Operation in Electric Energy System, Rio de Janeiro-RJ, Brazil, 1985, pp.483-489.

[4] Fonseca, L. G. S. and Minussi, C. R. "Redespacho de geração para controle de segurança dinâmica em sistemas de energia elétrica através da análise de sensibilidade", *8º Congresso Brasileiro de Automática*, Belém-PA, 1990, pp.735-740.

[5] Freitas Filho, W. *Controle de Segurança Dinâmica de Sistemas de Energia Elétrica Via Análise de Sensibilidade de Redes Neurais*, Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica - UNESP, Ilha Solteira-SP, Dezembro, 1996.

[6] Kenaya, R. "Euclidean ART Neural Networks", *Proceedings of the World Congress on Engeneering and Computer Science 2008*, WCECS2008, October 22-24, 2008, San Francisco, USA,

[7] Marchiori, S. C. *Estabilidade Transitória de Sistemas de Energia Elétrica: Uma Metodologia de Análise Via Rede Neural ARTMAP Nebulosa*, Dissertação de Mestrado, Programa de Pós-graduação em Engenharia Elétrica, UNESP, Campus de Ilha Solteira, Ilha Solteira - SP, Agosto 2001.

[8] Minussi, C. R. *Controle de Segurança Dinâmica em Sistemas de Engenharia Elétrica*, Tese de Doutorado, Programa de Pós-Graduação em Engenharia Elétrica - UFSC, Florianópolis-SC, Novembro 1990.

[9] 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.

[10] Minussi, C. R. and Freitas Filho, W. "Sensitivity Analysis For transient stability", *IEE Proceedings on Generation, Transmission and Distribution*, vol.145, No.6, 1998, pp.669-674.

[11] Pai, M. A. *Power System Stability*, North Holland Control Series, 1981.

[12] Silveira, M. C. G. *Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Por Redes Neurais ARTMAP Nebulosas Modulares*, Tese de Doutorado, Programa de Pós-graduação em Engenharia Elétrica, UNESP - Campus de Ilha Solteira - SP, Outubro-2003.

[13] Silveira, M. C. G.; Lotufo, A. D. P. and Minussi, C. R. "Transient stability analysis of electrical power systems using a neural network based on *fuzzy* ARTMAP", *IEEE Bologna Power Tech 2003 Conference, Bologna - Italy*, 7p. (To appear), 2003.