

# FORMAÇÃO DE CLASSES DE PERFIS DE GERAÇÃO E DE CARGA EM SISTEMAS ELÉTRICOS USANDO UMA REDE NEURAL ART NEBULOSA

FERNANDA C. L. TRINDADE, CARLOS R. MINUSSI

*Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Campus de Ilha Solteira  
Caixa Postal 31, 15385-000, Ilha Solteira, SP, Brasil*

*E-mails: [fernandaclt@hotmail.com](mailto:fernandaclt@hotmail.com), [minussi@dee.feis.unesp.br](mailto:minussi@dee.feis.unesp.br)*

**Abstract** This work presents a methodology for generation and load profiles clustering formation based on fuzzy-ART (Adaptive Resonance Theory) neural network. It is a method that seeks to form the similar groups of nodal electric power, with the purpose of reducing the computational effort used in the resolution of a series of studies accomplished in electric power systems, e.g., transient stability analysis, voltage stability analysis, distribution system planning, etc. The ART architectures present plasticity and stability characteristics, which are very important for the training and to execute the analysis in a fast way, allowing the continuous training. The continuous training consists in the inclusion the new patterns, if available, in an appropriate way, on the weight matrix of the ART neural network. This was the main reason of the use this neural network ART-family. To illustrate the proposed neural network an application is presented for a multi-machine electric power systems composed of 10 synchronous machines, 45 buses and 73 transmission lines.

**Keywords** Electric Power Systems, Clustering Technique, Nodal Electric Power Injection, Neural Networks, Adaptive Resonance Theory.

**Resumo** Este artigo apresenta uma metodologia para a formação de classes de perfis de geração e de carga em sistemas de energia elétrica baseada numa rede neural ART (*Adaptive Resonance Theory*) nebulosa. Trata-se de um procedimento que visa agrupar os vetores referentes às injeções de potência nodais por conjuntos similares, com o propósito de reduzir o esforço computacional empregado na resolução de uma série de estudos realizados em sistemas elétricos de potência, e.g., análise de estabilidade transitória, análise de estabilidade de tensão, planejamento de sistemas de distribuição, etc. As arquiteturas ART apresentam as características de estabilidade e de plasticidade, as quais são imprescindíveis para a realização do treinamento e execução da análise de forma rápida e continuada, ou seja, toda vez que houver disponibilidade de novos padrões, não haverá necessidade de reiniciar o treinamento, bastando apenas armazenar tais padrões, de forma adequada, na memória da rede neural (conjunto de pesos). Esta foi a principal razão do emprego desta rede neural da família ART-descendente. Como forma de ilustrar a estrutura neural proposta, apresenta-se uma aplicação considerando-se um sistema elétrico composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão.

**Palavras-chave** Sistemas Elétricos de Potência, Técnica de Agrupamento, Injeção de Potência Nodal, Redes Neurais, Teoria da Ressonância Adaptativa.

## 1 Introdução

Neste artigo pretende-se investigar o uso da rede neural ART nebulosa (Carpenter et al., 1992; Carpenter, 2001) como técnica de agrupamento em ambientes de sistemas de energia elétrica, especialmente em problemas de agrupamento de classes similares de perfis de geração e de carga. Trata-se de um procedimento bastante útil para a resolução de problemas abordados na operação (Chicco et al., 2005; Levi et al. 2005), bem como no planejamento. Ou seja, visa reduzir o volume de processamento e a dimensão do conjunto de dados para o treinamento e análises, quando se emprega, por exemplo, outras metodologias neurais para a resolução de problemas como: análise de estabilidade transitória (Ferreira et al., 2006; Sawhney et al. 2006), análise de estabilidade de tensão, previsão de cargas elétricas, etc. Aplicam-se, ainda, quando há necessidade de conhecer características de similaridade, dentro de um conjunto de dados ou padrões. A arquitetura ART é uma rede neural não-supervisionada. Neste caso, a extração do conhecimento é realizada baseada apenas nos estímulos de entrada. Nos experimentos, aqui abordados, usam-se os dados dos diferentes perfis de geração e de carga nodais do sistema elétrico. Na fase de treinamento serão

usados padrões de geração e de carga produzidos de forma aleatória, considerando-se um universo de variação, tomando-se um determinado percentual em torno do carregamento nominal do sistema.

A escolha recaiu sobre a arquitetura ART por razões de eficiência, ou seja, trata-se de uma rede neural que é estável e plástica. A teoria de ressonância é um fenômeno bastante observado na natureza, em especial, é um dos principais mecanismos empregados pelo cérebro humano para agregar o conhecimento. Todo o processo de reconhecimento dar-se-á por um processo de observação de verossimilhança (ressonância). Com estas qualidades, as redes neurais da família ART (Carpenter et al. 1992, Georgiopoulos et al. 1999) se destacam em relação às demais redes disponíveis na literatura especializada. A estabilidade está associada à garantia da obtenção de soluções. A plasticidade, por sua vez, refere-se à capacidade de incluir novos padrões sem a necessidade de reiniciar todo o processo de treinamento, como é comumente observado na maioria das redes neurais disponíveis na literatura. Outra importante característica refere-se à grande velocidade de realização do treinamento, bem como o diagnóstico correspondente, tornando-as um sistema adequado para aplicação em tempo real.

Visando ilustrar o método proposto apresentam-se os resultados considerando-se um sistema multimáquinas.

## 2 Rede Neural ART Nebulosa: Algoritmo

A rede neural ART é composta por três camadas:  $F_0$  (camada de entrada),  $F_1$  (camada de comparação) e  $F_2$  (camada de reconhecimento que armazena as categorias (*clusters*)), conforme é mostrado na Figura 1. O subsistema de atenção possui duas camadas de neurônios interconectados: uma camada serve como nível de comparação (campo  $F_1$ ) e a outra de reconhecimento (campo  $F_2$ ), sendo o campo  $F_0$  a camada de nós que representa o vetor de entrada atual  $\mathbf{A}$ . Os padrões de atividade desenvolvidos sobre os nós nas duas camadas,  $F_1$  e  $F_2$ , no estado de ressonância são chamados de memória a curto prazo (*short-term memory* – STM). A aprendizagem ocorre durante o período de ressonância (Carpenter et al. 1992).




Figura 1. Arquitetura da rede neural ART.

O subsistema de orientação é necessário para estabilizar o processo de STM e a aprendizagem em LTM. Logo, permite que a rede aprenda em torno de novas entradas sem esquecer seu conhecimento prévio. Ele é responsável pelo controle do padrão a ser reconhecido e possui dois sinais de entrada e um de saída. Os dois sinais de entrada são representados pelos padrões de dados de entrada e pela atividade total em  $F_1$  e o sinal de saída pelo *reset* (Carpenter et al. 1992).

O algoritmo desta rede neural consiste, basicamente, nos seguintes passos (Carpenter et al. 1992):

### Passo 1. Definição dos Parâmetros da Rede

Os parâmetros utilizados no processamento da rede ART nebulosa são:

1. Parâmetro de Escolha :  $\alpha > 0$ ;
2. Taxa de Treinamento :  $b \in [0, 1]$ ;
3. Parâmetro de Vigilância:  $r \in [0, 1]$ .

### Passo 2. Inicialização dos Pesos

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

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

indicando que não existe nenhuma categoria ativa.

### Passo 3. Dados de Entrada

Os dados de entrada são denotados pelo vetor  $\mathbf{a} = [a_1 \ a_2 \ \dots \ a_M]$   $M$ -dimensional. Este vetor é normalizado com o intuito de evitar a proliferação de categorias. Assim:

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|} \quad (1)$$

sendo:

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

$$|\mathbf{a}| = \sum_i a_i. \quad (2)$$

### Passo 4. Codificação do vetor de entrada

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

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (3)$$

em que:

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

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

$$\mathbf{I} = [\bar{\mathbf{a}} \ \bar{\mathbf{a}}^c] \\ = [\bar{a}_1 \ \bar{a}_2 \ \dots \ \bar{a}_M \ \bar{a}_1^c \ \bar{a}_2^c \ \dots \ \bar{a}_M^c] \quad (4)$$

$|\mathbf{I}| = \sum_{i=1}^M \bar{a}_i + \sum_{i=1}^M \bar{a}_i^c = M$  (todos os vetores com normalização e codificação complementada terão mesmo comprimento  $M$ ).

### Passo 5. Vetor de Atividade

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

$$y_j = \begin{cases} 1, & \text{se o nó } j \text{ de } F_2 \text{ é ativo} \\ 0, & \text{caso contrário.} \end{cases} \quad (5)$$

### Passo 6. Escolha da Categoria

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

$$T_j = \frac{|\mathbf{I} \wedge \mathbf{w}_j|}{\alpha + |\mathbf{w}_j|} \quad (7)$$

sendo:

= operador *and* nebuloso, definido

por:

$$(\mathbf{I} \wedge \mathbf{w})_i = \min(I_i, w_i). \quad (8)$$

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

$$J = \arg \text{Max} \{ T_j \} \\ j = 1, 2, \dots, N. \quad (9)$$

Usando-se a equação (9), se existir mais de uma categoria ativa, a categoria escolhida será aquela que possuir menor índice.

### Passo 7. Ressonância ou Reset

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

$$\frac{|\mathbf{I} \wedge \mathbf{w}_J|}{|\mathbf{I}|} \geq \rho \quad (10)$$

Caso o critério definido pela equação (10) não seja satisfeito, ocorre o *reset*. No módulo *reset*, o nó  $J$  de  $F_2$  é excluído do processo de busca dado por (9), ou seja,  $T_J = 0$ . Então, é escolhida uma nova categoria através de (9) para o processo de ressonância. Este procedimento será realizado até que a rede encontre uma categoria que satisfaça (10).

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

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

$$\mathbf{w}_J^{(k+1)} = b (\mathbf{I} \wedge \mathbf{w}_J^{(k)}) + (1 - b) \mathbf{w}_J^{(k)} \quad (11)$$

sendo:

$J$  = categoria ativa;

$\mathbf{w}_J^{(k+1)}$  = vetor peso atualizado;

$\mathbf{w}_J^{(k)}$  = vetor peso referente à atualização anterior.

Deve-se observar que, se  $b = 1$ , tem-se o treinamento rápido.

## 3 O Problema Abordado

A principal aplicação abordada neste relatório consiste no estudo de similaridade de padrões em problemas de sistemas elétricos de grande porte. Os padrões a serem considerados são as potências elétricas, ativa e reativa, nodais do sistema. Tais padrões são representados por vetores gerados aleatoriamente (ou pseudo-aleatoriamente), respeitando o balanço de potência da rede elétrica. Este procedimento visa definir um conjunto de vetores que possa representar os possíveis estados de operação. Este conjunto é, então, usado para a realização do treinamento da rede neural ART nebulosa. Deve-se ressaltar que o treinamento é realizado na forma não-supervisionada. Assim sendo, a busca de evidência de similaridade (agrupamento) é um procedimento importante para o desenvolvimento de processos de análise de sistemas de energia elétrica. Na presente pesquisa o enfoque das análises será dado considerando a segurança estática da rede.

## 4 Estímulos de Entrada

Os estímulos de entrada ( $\mathbf{X}$ ), para a fase de treinamento, são da seguinte forma (Lotufo, 2004):

$$\mathbf{X}_r \underline{\Delta} [ \mathbf{P} \ \mathbf{Q} ] \quad (12)$$

sendo:

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

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

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

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

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

$$n = 2ns + nc$$

em que:

$ns$  = número de barras do sistema;

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

A representação vetorial adotada, neste artigo, é por linha e não por coluna, como habitualmente usada na literatura. Esta representação é a mais adequada, quando se trabalha com as redes neurais da família ART que são totalmente concebidas com a notação por linha.

Neste caso, levando-se em conta o caráter estático da rede elétrica, é razoável utilizar somente as potências ativa e reativa (Lotufo, 2004). 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). A representação das contingências não é empregada nesta pesquisa. Contudo, em trabalhos futuros, é intenção usá-la, também, em rotinas de análise mais complexas (estabilidade de tensão, etc.).

Para a realização do treinamento da rede neural deve-se proceder a apresentação de um conjunto de dados, no caso,  $\mathbf{X}_r \underline{\Delta} [ \mathbf{P} \ \mathbf{Q} ]$  (entrada). Trata-se da geração dos vetores  $\mathbf{P}$  e  $\mathbf{Q}$ , para a geração e para a carga do sistema por um procedimento de distribuição aleatória da geração (despacho aleatório para atender a demanda) e, também, de distribuição aleatória (ou pseudo-aleatória) da carga (demanda aleatória ou pseudo-aleatória), como será mostrado a seguir (Lotufo, 2004).

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

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

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

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

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

Para se gerar um grande espectro de variação da demanda, o critério a ser usado refere-se à distribuição aleatória da demanda e, conseqüentemente, da geração para atender a demanda, tomando-se variações percentuais da carga e da geração em torno do caso base (considerado como sendo o perfil de geração/carga

de 100%). Por exemplo, arbitrando-se um percentual de 10%, pode-se realizar vários perfis de geração e de carga realizando despachos de geração e definição da carga do sistema, distribuindo-se a geração e a carga de forma aleatória nas barras do sistema, respeitando-se o percentual arbitrado.

As potências ativas das barras de geração podem ser definidas por:

$$PG_i = PG_i^0 + \Delta PG_i \quad (13)$$

sendo:

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

$$\Delta PG_i = PG_{total}^0 \times PER \times AG_i / KG \quad (14)$$

$$PG_{total}^0 = \sum_{i \in \Omega(G)} PG_i^0 \quad (15)$$

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

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

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

$$KG = 100 AG_{total} \quad (16)$$

$$AG_{total} = \sum_{i \in \Omega(G)} AG_i \quad (17)$$

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

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

$$PL_i = PL_i^0 + \Delta PL_i \quad (18)$$

sendo:

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

$$\Delta PL_i = PL_{total}^0 \times PER \times AL_i / KL \quad (19)$$

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

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

$$KL = 100 AL_{total} \quad (20)$$

$$AL_{total} = \sum_{i \in \Omega(L)} AL_i \quad (21)$$

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

As cargas reativas são fixadas considerando-se uma distribuição que preserva o fator de potência referente ao caso base. Este procedimento

tema estabelecer uma distribuição com um nível de inter-relação entre a potência ativa (Lotufo, 2004).

## 5 Aplicações

Redes Neurais Artificiais (RNA) (Kartolopoulos, 1996) são consideradas uma importante técnica de inteligência artificial e têm sido utilizadas com sucesso em muitas áreas de sistemas de potência. Muitas literaturas têm demonstrado o potencial das RNA em análise de sistemas de potência, ressaltando a velocidade de seus cálculos.

As aplicações propostas neste artigo, referem-se a um estudo de estabilidade estática de sistemas de energias elétrica de grande porte, baseado numa possível versão da configuração do sistema elétrico sul-brasileiro mostrado na Figura 2.

O sistema utilizado é composto por 10 máquinas síncronas (cada máquina síncrona representando o conjunto gerador), 73 linhas de transmissão e 45 barras (Minussi e Freitas, 1998). O diagrama unifilar deste sistema é mostrado na Figura 2.

O treinamento da rede é realizado usando-se um conjunto de perfis de geração e de carga e respectivas margens de segurança, associadas a um conjunto de contingências. Cada perfil corresponde a um despacho de geração, em relação ao caso base, realizado de forma aleatória para atender a demanda, também estabelecida randomicamente em cada barra do sistema. O universo de variação da geração e da carga está compreendido entre 80 e 130% em relação ao caso base do sistema. Portanto, cada perfil é gerado considerando uma variação percentual em torno do estado nominal (caso base) e uma determinada semente para o processo de geração da seqüência randômica. Assim, para um mesmo percentual, diferentes sementes geram diferentes despachos de geração e diferentes perfis de carga. Este procedimento gera um conjunto adequado de padrões para a fase de treinamento. Assim sendo, foram gerados, usando o programa Simul (1995), 1486 vetores padrões para a fase de treinamento e para a fase de testes. Na Tabela 1, são apresentados os resultados do processo de formação de agrupamento em função do parâmetro de vigilância ( $r$ ).

Tabela 1. Formação de agrupamentos em função do parâmetro de vigilância.

Parâmetro de Vigilância ( $r$ )	Quantidade de Categorias Criadas
0,95	52
0,96	83
0,97	135
0,98	212
0,99	366

Desta tabela pode-se observar o aumento do número de agrupamentos com o aumento do parâmetro de vigilância. Admitindo-se ajustado (melhor desempenho) o parâmetro  $r$ , a próxima

etapa da análise é associar os padrões usados no treinamento com as classes criadas, ou seja, para  $r$  igual a 0,95 foram criadas 52 categorias. Neste caso, pode-se estabelecer a análise definitiva associando-se o estado (vetor  $X$ ) com algum índice de segurança do sistema, por exemplo, um índice que pode ser gerado a partir do programa Simul: índice de estabilidade estática a partir do cálculo do fluxo de potência e de estabilidade transitória (para análise de defeitos de curto-circuito, por exemplo). Assim, na primeira etapa, está-se considerando os critérios estáticos. Numa etapa futura, poder-se-á incluir também um índice dinâmico. No caso do índice dinâmico, ao vetor  $X$  deve-se incluir as informações referentes à condição de defeito, por exemplo, usando-se a codificação binária, como usado na referência (Ferreira et al., 2006).

Tabela 2. Relação entre categorias e quantidade de vetores agrupados para  $r = 0,95$ .

Categoria	Quantidade de Vetores Agrupados	Categoria	Quantidade de Vetores Agrupados
1	31	27	49
2	9	28	5
3	536	29	8
4	42	30	9
5	261	31	28
6	5	32	5
7	13	33	13
8	11	34	3
9	12	35	4
10	43	36	6
11	7	37	5
12	17	38	10
13	26	39	6
14	6	40	3
15	15	41	19
16	104	42	10
17	8	43	5
18	15	44	10
19	9	45	6
20	30	46	3
21	9	47	6
22	10	48	4
23	5	49	7
24	13	50	5
25	4	51	3
26	11	52	2

## 6 Formulação Alternativa

O experimento apresentado na Seção 5 compreendeu a formação de agrupamentos de padrões por processo de similaridade. Tomando-se como exemplo a categoria 3, relacionada na Tabela 2, que agrega o maior número de padrões (536 padrões). A dimensão de cada vetor padrão  $X$  é 75 (75 componentes referentes às potências ativas e reativas nodais). Assim, tem-se 75 neurônios de entrada da rede neural ART nebulosa em um conjunto de 1486 vetores padrões,

considerando-se os padrões referentes ao treinamento e aqueles submetidos às análises.

Uma formulação alternativa, para operacionalização do processo de agrupamento, consiste na adoção do critério de formação de classes através da representação binária. Neste caso, considerando o experimento anterior, usando-se, por exemplo, 5 ou 6 bits será mais do que suficiente para a resolução deste problema. Portanto, tem-se uma redução de ordem (entrada para a saída) de 75 componentes (75 neurônios) para 5 ou 6 componentes binários (5 ou 6 saídas ativas). Estas saídas podem compor a entrada de uma outra rede neural (segundo módulo) que, conjuntamente, formam uma estrutura neural supervisionada, *e.g.*, a rede neural ARTMAP (Carpenter et al., 1992).

Além disso, esta formulação alternativa pode ser considerada, também, como um processo de conversão neural analógico-binário. Se o problema exigir a extração do conhecimento do modo supervisionado (rede neural ARTMAP), ter-se-á uma rede neural para segundo módulo ART, com uma entrada binária de dimensão reduzida. Neste caso, espera-se que a rotina referente ao treinamento e as análises sejam executadas de forma mais rápida e mais precisa, se comparadas à formulação convencional da rede neural ARTMAP.

## 7 Conclusão

Neste artigo foi apresentado um procedimento alternativo de técnica de agrupamento baseado numa rede neural ART nebulosa. Para demonstrar o desempenho deste sistema neural, foram apresentados os resultados de aplicação considerando um sistema de energia elétrica composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão. Os resultados obtidos são considerados satisfatórios, ou seja, atingiram os objetivos propostos. Estes objetivos foram: investigar a aplicação de redes neurais com técnica de agrupamento em ambientes de sistemas de energia elétrica.

## Agradecimentos

Os autores agradecem o suporte financeiro da FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo), Processo No. 04/15413-0.

## 8 Referências Bibliográficas

- Carpenter, G. A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H. e Rosen, D. B. (1992) "Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps", IEEE Transactions on

- Neural Networks, Vol. 3, Number 5, pp. 698-713.
- Carpenter, G. A. (2001) "Neural-network Models of Learning and Memory: Leading Questions and an Emerging Framework", Trends in Cognitive Sciences, Vol. 5, pp.114 - 118.
- Chicco, G.; Napoli, R.; Pigliione, F.; Postolache, P.; Scutariu, M. and Toader, C. (2005) "Emergent Electricity Customer Classification", IEE Proceedings-Generation, Transmission, and Distribution, Vol. 152, pp. 164 - 172.
- Ferreira, W. P., Silveira, M.C.G.; Lotufo, A. D. P. e Minussi, C. R. (2006) "Transient Stability Analysis of Electric Energy Systems via a Fuzzy ART-ARTMAP Neural Network Electric Power Systems Research, Vol. 76, Issues 6-7, pp. 466-475.
- Fung, W-K. e Liu, Y.-H. (2003) "Adaptive Categorization of ART Networks in Robot Behavior Learning Using Game-Theoretic Formulation", Neural Network, Vo. 16, No. 10, pp. 1403-1420.
- Georgiopoulos, M.; Dagher, I.; Heileman, G. L. e Bebis, G. (1996) "Properties of Learning of a Fuzzy ART Variant", Neural Networks 12, pp.837-850.
- Kartalopoulos, S. V. (1996) "Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications", IEEE Press, Piscataway, NJ, USA.
- Levi, V.; Strbac, G. e Allan, R. (2005) "Assessment of Performance-driven Investment Strategies of Distribution Systems Using Reference Networks", IEE Proceedings on Generation, Transmission and Distribution, Vol. 152, No. 1, pp. 1-10.
- Lotufo, A. D. P. (2004) "Análise de Sensibilidade por Redes Neurais para estudos da estabilidade transitória de Sistemas Elétricos de Potência", Tese de Doutorado, Programa de Pós-graduação em Engenharia Elétrica, UNESP, Campus de Ilha Solteira - SP.
- Minussi, C. R. e Freitas Filho, W. (1998) "Sensitivity Analysis for Transient Stability", IEE Proceedings on Generation, Transmission and Distribution, Vol. 145, No. 6, pp. 669-674.
- Sawhney, H. e Jeyasurya, B. (2006) "A Feed-forward Artificial Neural Network with Enhanced Feature Selection for Power System Transient Stability Assessment". Electric Power Systems Research, pp.1047 - 1054.
- Simul (1995) "Programa Computacional Para a Análise de Estabilidade Transitória via Método da Energia", Laboratório Computacional, Departamento de Engenharia Elétrica, Faculdade de Engenharia de Ilha Solteira - UNESP.

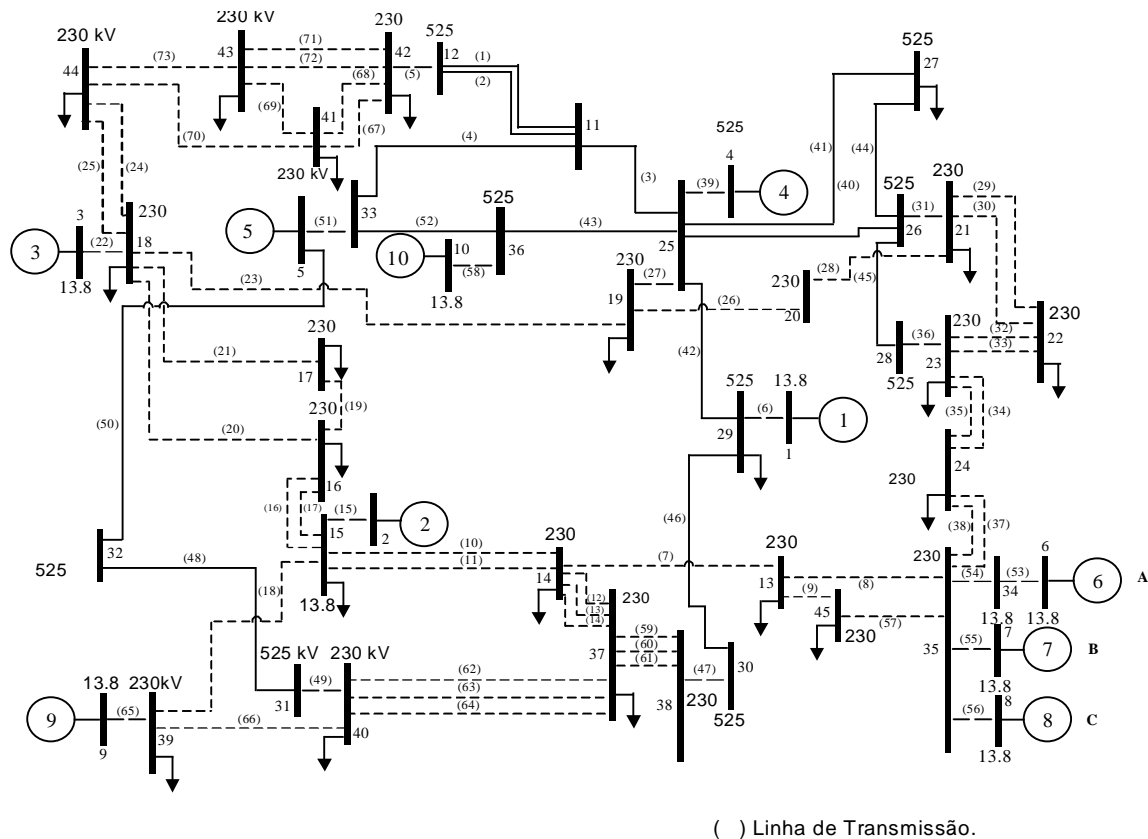


Figura 2. Sistema sob estudo.