

# ANÁLISE DE SENSIBILIDADE POR REDES NEURAS APLICADA AO ESTUDO DA ESTABILIDADE TRANSITÓRIA DE SISTEMAS ELÉTRICOS DE POTÊNCIA USANDO AS *TOOLBOXES* DO MATLAB

JEAN C. G. DONDA, ANNA D. P. LOTUFO, CARLOS R. MINUSSI, MARA L. M. LOPES

Depto. de Engenharia Elétrica, Universidade Estadual Paulista (UNESP) – Câmpus de Ilha Solteira  
Av. Brasil 56, 15385-000 Ilha Solteira, SP, Brasil

E-mails: jeandonda@hotmail.com, annadiva@dee.feis.unesp.br,  
minussi@dee.feis.unesp.br, malu\_malo@yahoo.com.br

**Abstract**— It was developed a procedure by feedforward neural networks, that gives the diagnosis of the transitory stability of an electric power system calculating the security margin and, afterwards calculates the sensitivity analysis, corresponding in this research to the partial derivatives of the security margin function. This is effectuated after training the neural network using the backpropagation algorithm. The toolbox Neural Network of MATLAB was used as a tool for developing this project. Tests were executed for a system with three synchronous machines.

**Keywords**— Transitory stability, sensibility analysis, electric systems, neural network, *MATLAB*, backpropagation.

**Resumo**— Desenvolveu-se um procedimento, via redes neurais multicamadas, que fornece o diagnóstico da estabilidade transitória de um sistema elétrico de potência, pelo cálculo da margem de segurança e, em seguida, efetuam a análise de sensibilidade, que corresponde nesta pesquisa às derivadas parciais da função margem de segurança após o treinamento da rede neural, cujo procedimento utilizado foi o algoritmo retropropagação. Utilizou-se a *Toolbox* Neural Network do MATLAB como ferramenta para o desenvolvimento do projeto. Os testes do procedimento desenvolvido foram efetuados para um sistema de três máquinas síncronas.

**Palavras-chave**— Estabilidade transitória, análise de sensibilidade, sistemas elétricos, redes neurais, *MATLAB*, retropropagação.

## 1 Introdução

A análise de estabilidade transitória constitui-se num dos principais estudos realizados em Sistemas de Energia Elétrica, visando avaliar os efeitos provocados por perturbações que produzem oscilações acentuadas nos ângulos das máquinas síncronas, *e.g.*, curto-circuito, saída/entrada em operação de equipamentos elétricos, etc. (Anderson e Fouad, 2003; Pavella et al., 2000). Essas contingências podem ocorrer em pontos estratégicos do sistema, levando-o a um estado de instabilidade, inclusive com desligamento de parte do mesmo. Portanto, apesar da probabilidade ser pequena, podem ocorrer os chamados *blackouts* (Sweet, 2000; Taylor, 1999), em que se faz necessário tomar medidas preventivas visando minimizar os efeitos desta situação.

A análise de estabilidade pode ser realizada através da simulação passo a passo, a qual é precisa e não apresenta restrição quanto ao tipo de modelo empregado, contudo necessita de uma grande quantidade de tempo para a realização dos cálculos e da análise, (Fouad e Vittal, 1992).

Novas abordagens neste contexto, baseadas na inteligência artificial, em especial as redes neurais (Minussi e Freitas Filho, 1998; Minussi e Silveira, 1995), têm sido encontradas na literatura, contribuindo para a avaliação de segurança dinâmica de sistemas elétricos de potência. A análise de sensibilidade também pode ser formulada por meio da extração de informações contidas na rede neural, após a realização da fase de treinamento. Para calcular as deriva-

das como proposto para a análise de sensibilidade, utilizou-se o algoritmo retropropagação (Werbos, 1974; Widrow e Lehr, 1990) bastante conhecido na literatura para treinamento de uma rede neural. A partir dos erros retropropagados e das derivadas parciais pode-se estimar a derivada das variáveis de saída da rede neural com relação à entrada, a qual é adotada para a solução do problema do controle preventivo e posteriormente ao redespacho de geração e o corte de carga conforme referências (Lotufo, 2004; Lotufo et al., 2007), no entanto este trabalho não apresenta o cálculo do redespacho e corte de carga. Para o cálculo das derivadas e análise de sensibilidade foi utilizado o aplicativo comercial MATLAB, (The Mathworks, Inc., 1996) em especial as *toolboxes* *Neural Networks*.

## 2 Redes Neurais

### 2.1 Estrutura da Rede Neural

Uma rede neural artificial (RNA), (Haykin, 1999; Kartalopoulos, 1996) corresponde a um conjunto de neurônios artificiais separados em camadas (entrada, intermediária e saída).

O processamento de um neurônio artificial resume-se em (Lopes, 2000):

1. Sinais são apresentados à entrada (conjunto de entradas  $x_1, x_2, \dots, x_n (\mathbf{X})$ );
2. Cada sinal é ponderado por um peso associado ( $w_1, w_2, \dots, w_n (\mathbf{V})$ ) que indica sua influência na saída da unidade;

3. As entradas ponderadas são aplicadas ao bloco somatório,  $\Sigma$ , onde se adiciona também uma entrada independente  $x_0 = 1$  associada a um peso *bias*.

4. A saída intermediária do neurônio (Widrow e Lehr, 1990) é, então, dada por:

$$s_i = \sum_j^n w_{ij} x_j \quad (1)$$

5. A saída é, então, convertida em não-linearidade através de funções de ativação (relé ou sigmóide).

## 2.2 Treinamento da Rede Neural

As redes neurais possuem a capacidade de aprender, para tanto, ela deve ser treinada, ajustando assim os seus pesos. Para tal, necessita-se de um procedimento predeterminado, neste caso, utiliza-se o algoritmo retropropagação (*backpropagation*).

O treinamento via algoritmo retropropagação é resumido a seguir (Lopes, 2000):

1. Inicialmente apresenta-se um padrão  $X$  à rede, o qual produzirá uma saída  $Y$ .

2. Em seguida calcula-se o erro de cada saída (diferença entre o valor desejado e a saída). A soma do erro quadrático instantâneo de cada neurônio alocado na saída da rede é dada por (Widrow e Lehr, 1990):

$$\varepsilon = \sum_{i=1}^{ns} \varepsilon_i^2 \quad (2)$$

sendo:

$$\varepsilon_i = d_i - y_i \quad (3)$$

$d_i$  = saída desejada do  $i$ -ésimo elemento da última camada da rede;

$y_i$  = saída do  $i$ -ésimo elemento da última camada;

$ns$  = número de neurônios da última camada da rede.

3. O próximo passo consiste na determinação do erro propagado pela rede associado à derivada parcial do erro quadrático de cada elemento com relação aos pesos. O gradiente  $\nabla_i(h)$  do erro quadrático com relação aos pesos do neurônio avaliado na iteração  $h$  pode ser expresso por (Lopes, 2000):

$$\nabla_i(h) = \frac{\partial \varepsilon_i^2}{\partial V_i(h)} = 2\varepsilon_i \frac{\partial \varepsilon_i}{\partial V_i(h)} \quad (4)$$

A função de ativação adotada, neste trabalho, é a função sigmóide definida por:

$$y_i = \left( \frac{2}{1 + e^{(-\lambda s_i + \rho)}} \right) - 1 \quad (5)$$

sendo:

$\rho$  = translação da curva  $y_i$ ;

$\lambda$  = inclinação da curva  $y_i$ .

Diferenciando a Equação (3) com relação ao vetor  $V_i$ , obtém-se:

$$\frac{\partial \varepsilon_i}{\partial V_i} = - \frac{\partial y_i}{\partial V_i} = - \left( \frac{\partial y_i}{\partial s_i} \frac{\partial s_i}{\partial V_i} \right)$$

sendo que:

$$\frac{\partial y_i}{\partial s_i} = sgm'(s_i) \quad (7)$$

$$\frac{\partial s_i}{\partial V_i} = X_i \quad (8)$$

Inserindo as Equações (6), (7) e (8) na Equação (4), resulta em:

$$\nabla_i(h) = -2\varepsilon_i sgm'(s_i) X_i \quad (9)$$

em que:

$X_i$  = vetor padrão:  $[x_{0i} \ x_{1i} \ x_{2i} \ \dots \ x_{3i}]^T$ .

4. Em seguida ocorre o ajuste dos pesos, que inicialmente são adotados randomicamente (Werbos, 1974).

Considerando-se o neurônio de índice  $i$  da rede, e utilizando-se o método do gradiente descendente (Widrow e Lehr, 1990), o ajuste de pesos é formulado como (Lopes, 2000):

$$V_i(h+1) = V_i(h) + \theta_i(h) \quad (10)$$

sendo:

$$\theta_i(h) = -\gamma [\nabla_i(h)];$$

$\gamma$  = taxa de treinamento;

$h$  = índice de iteração;

$\nabla_i(h)$  = gradiente do erro quadrático com relação aos pesos do neurônio avaliado em  $h$ ;

$V_i$  = vetor contendo os pesos do neurônio  $i$ .

Utilizando o gradiente estimado através da Equação (9) no método do gradiente descendente, Equação (10), tem-se o seguinte:

$$V_i(h+1) = V_i(h) + 2\gamma \beta_i X_i \quad (11)$$

Se o elemento  $i$  encontra-se na última camada, então:

$$\beta_i = sgm'(s_i) \varepsilon_i \quad (12)$$

Se ele encontra-se nas demais camadas, tem-se:

$$\beta_i = sgm'(s_i) \sum_{k \in R(j)} w_{ik} \beta_k \quad (13)$$

em que:

$sgm'(s_i)$  = derivada da função sigmóide, dada pela Equação (14), com relação a  $s_i$ ;

$R(j)$  = conjunto dos índices dos elementos que se encontram na fileira seguinte à fileira do elemento  $i$  e que estão interligados a ele.

A derivada parcial da função sigmóide dada pela Equação (5) pode ser expressa por:

$$\frac{\partial y_i}{\partial s_i} = \frac{\partial}{\partial s_i} \left\{ \left( \frac{2}{1 + e^{(-\lambda s_i + \rho)}} \right) - 1 \right\} = \frac{1}{2} \lambda (1 - y_i^2) \quad (14)$$

5. Por fim, um novo padrão é apresentado à rede e o processo é repetido até que a convergência seja observada ( $|\text{erro}| < \text{tolerância}$  preestabelecida) (Lopes, 2000), ou o número de iterações corresponda a um valor máximo previamente estabelecido.

### 3 Análise de Estabilidade Transitória de Sistemas de Energia Elétrica

A análise de estabilidade transitória pode ser realizada com base no conceito de energia e margem de segurança (método direto) (Elgerd, 1971). Considerando uma contingência de índice  $r$ , tem-se:

$$M_r = \frac{(E_{crit_r} - E_{e_r})}{E_{crit}} \quad (15)$$

sendo:

$E_{crit_r}$  = energia total crítica do sistema;

$E_{e_r}$  = energia total do sistema avaliada no instante de eliminação do defeito.

A estabilidade transitória para a  $r$ -ésima contingência pode ser avaliada, via margem de segurança, da seguinte forma (Elgerd, 1971):

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

Optou-se por esta abordagem, método direto, pois, para constituir uma rede neural com boa capacidade de generalização, faz-se necessário à utilização de um grande número de dados de entrada e de saída para a fase do treinamento. Estes dados devem conter informações quantitativas e qualitativas de cada contingência, sendo que, estas características podem ser proporcionadas somente quando se utilizam os métodos diretos de análise, mais especificamente, os métodos de energia (Fouad e Vittal, 1992; Pavella et al., 2000).

Para demonstrar a validade da metodologia proposta e possibilitar futuras aplicações para sistemas de energia elétrica reais de grande porte, utiliza-se o sistema de pequeno porte, Anderson & Fouad (Anderson e Fouad, 2003), mostrado na Figura 1.




Figura 1. Sistema Composto por Três Máquinas Síncronas.

Consideram-se defeitos de curto-circuito com tempo de eliminação de 6 ciclos (0,10s) com saída de linha de transmissão. Os valores em  $pu$  referem-se a uma base de 100 MVA. A contingência considerada é um curto-circuito trifásico na barra 7 com saída da linha de transmissão entre as barras 5 e 7, esta foi escolhida por ser a mais crítica (Lotufo, 2004).

#### 3.1 Análise de estabilidade por Redes Neurais

Nesta pesquisa o problema da análise de estabilidade transitória foi abordado via redes neurais. Os padrões

de entrada da rede neural utilizados no treinamento são definidos como:

$$X = [P \ Q]^T \quad (16)$$

em que:

$X$  = vetor padrão de entrada da rede neural;

$P = [P_1 \ P_2 \ P_3 \ \dots \ P_n]$ ;

$Q = [Q_1 \ Q_2 \ Q_3 \ \dots \ Q_n]$ ;

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

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

$n$  = número de barras do sistema.

Os estímulos de saída são às margens de segurança ( $M$ ) obtidas via metodologia PEBS (Fonseca e Decker, 1985).

$$\begin{aligned} X_j &= [P_j \ Q_j]^T \text{ (entradas)} \\ Y_j &= [M_j] \text{ (saídas)} \end{aligned} \quad (17)$$

$j = 1, 2, \dots, np$

no qual:

$np$  = número de pares de padrões de treinamento.

As potências ativas e reativas nodais, e às margens de segurança (critério de análise de estabilidade transitória) formam os perfis de treinamento, correspondentes a redes de geração realizados de forma pseudoaleatória para atender a demanda fixada aleatoriamente em cada barra. O universo de variação da carga encontra-se compreendido entre 80 e 120% em relação à carga nominal total do sistema.

Uma vez concluído o treinamento da rede neural, tem-se a estrutura da rede neural, com os valores de pesos e *bias*. Deste modo, a rede está dotada com capacidade de generalização, ou seja, aplicando-se um vetor padrão de entrada, propagando-se o sinal no sentido direto (entrada para saída), resultará na saída a estimativa da margem de segurança (diagnóstico), estabelecendo, deste modo, o mapeamento:

$$X \rightarrow Y = f(X) \quad (18)$$

Desta maneira, o processo de obtenção da análise de estabilidade transitória via redes neurais encontra-se por finalizado.

## 4 Análise de Sensibilidade

### 4.1 Introdução

A análise de sensibilidade corresponde ao cálculo da diferenciação de funções, porém, o problema sob enfoque nesta pesquisa apresenta uma função correspondente desconhecida, a função margem de segurança. Desta se conhece a expressão (15), mas não a sua forma, pois ela é dependente de um grande conjunto de informações do sistema. Sendo assim, pretende-se obter as derivadas parciais de uma função desconhecida. Certamente, é um problema complexo, que pode ser resolvido por redes neurais.

### 4.2 Formulação do Problema

A margem de segurança do sistema deve satisfazer a seguinte relação (Minussi e Silveira, 1995):

$$M \geq M_{\min} \quad (19)$$

sendo:

$M_{\min}$  = limite mínimo da margem de segurança do sistema ( $M_{\min} \geq 0$ ).

As possíveis ações de controle devem promover modificações nas margens de segurança, tais que, as seguintes relações sejam satisfeitas (Minussi e Silveira, 1995):

$$M_r^0 + \Delta M_r = M_{\min} \quad (20)$$

em que:

$M_r$  = margem de segurança referente a  $r$ -ésima contingência.

A mudança ( $\Delta M_r$ ), necessária à correção da margem de segurança, pode ser estimada através da teoria de sensibilidade, de primeira ordem, por (Elgerd, 1971):

$$\Delta M_r \cong \langle \partial M_r / \partial X, \Delta X \rangle \quad (21)$$

sendo:

$\partial M_r / \partial X$  = sensibilidade da margem de segurança com relação ao vetor  $X$ ;

$\Delta X$  = vetor correspondente à mudança nos componentes do vetor  $X$ ;

$\langle u, v \rangle$  = produto interno dos vetores  $u$  e  $v$   $n$ -dimensionais.

#### 4.3 Análise de Sensibilidade por redes Neurais

Concluído o treinamento, restará apenas a estrutura da rede neural, que estará dotada com capacidade de diagnosticar a margem de segurança.

Através da estrutura da rede neural treinada, pode-se também, estimar as derivadas das variáveis de saída (análise de sensibilidade) com relação aos componentes do vetor de entrada.

Para isso, considere  $X^k$  e  $M$  como sendo o  $k$ -ésimo par de vetores de entrada e de saída da rede neural. Considere, também, a rede neural não-recorrente mostrada na Figura 2, a qual utiliza como função não-linear a sigmóide (Equação 5).




Figura 2. Ilustração da Rede Neural Feedforward.

A Figura 2 apresenta uma RNA composta por duas camadas, onde são explicitadas as variáveis nos principais pontos da rede e as matrizes de peso. A camada de entrada possui  $n$  (dimensão do vetor de entrada  $X^k$ ) neurônios, e a de saída apenas um, pois o intuito é obter apenas a margem de segurança  $M$ .

Pretende-se, portanto, obter as derivadas parciais de  $M$  (saída) com relação a  $x_j^k$  ( $j$ -ésimo componente

do vetor de entrada  $X^k$ ). Para obtê-las, necessita-se das derivadas parciais intermediárias da rede neural. Assim, o cálculo das derivadas parciais de  $z_i^k$  ( $i$ -ésimo componente do vetor de saída  $Z^k$ ), com relação a  $x_j^k$ , pode ser obtido da seguinte forma (Lotufo, 2004; Lotufo et al., 2007):

$$\partial z_i^k / \partial x_j^k = 0,5 \lambda w_{ji} (1 - \{z_i^k\}^2) \quad (22)$$

sendo:

$x_j^k$  =  $j$ -ésimo componente do vetor de entrada  $X^k$ ;  
 $X^k = [x_1^k \ x_2^k \ \dots \ x_n^k]^T$ ;  
 $k$  = índice referente ao  $k$ -ésimo vetor padrão.

A saída intermediária da última camada da rede neural (entrada da função sigmóide da camada de saída) pode ser expressa por:

$$t = \{z^k\} V \quad (24)$$

em que:

$z^k = [z_1^k \ z_2^k \ \dots \ z_n^k]^T$ ;  
 $V = [v_1 \ v_2 \ \dots \ v_n]^T$ .

Assim:

$$\partial M^k / \partial x_j^k = \{\partial M^k(\lambda, t^k) / \partial t^k\} \partial t^k / \partial x_j^k \quad (25)$$

como:

$$\partial M^k(\lambda, t^k) / \partial t^k = 0,5 \lambda (1 - M^k{}^2);$$

$$\partial t^k / \partial x_j^k = \{V^k\}^T \partial z^k / \partial x_j^k;$$

$$\partial z^k / \partial x_j^k = [\partial z_1^k / \partial x_j^k \ \partial z_2^k / \partial x_j^k \ \dots \ \partial z_n^k / \partial x_j^k]^T.$$

Então, substituindo a Equação (22) e as considerações definidas acima, na Equação (25), obtém-se:

$$\frac{\partial M^k}{\partial x_j^k} = \frac{\lambda^2}{4} (1 - M^k{}^2) \{V^k\}^T [(1 - \{z_1^k\}^2) w_{j1} \dots (1 - \{z_n^k\}^2) w_{jn}]^T \quad (26)$$

Nota-se que a sensibilidade depende das matrizes  $W$  e  $V$  de pesos, da saída  $M$ , do parâmetro  $\lambda$  e do vetor de saídas intermediárias  $z$ . A rotina (26) é executada após a conclusão do treinamento, através de produtos matriciais simples, representando uma parcela muito pequena do tempo de processamento, se comparada à execução da etapa de treinamento.

Na Figura 3 apresenta-se o esquema neural para a obtenção da análise de sensibilidade. As setas com linhas simples e duplas indicam dados escalares e vetoriais (ou matriciais), respectivamente.

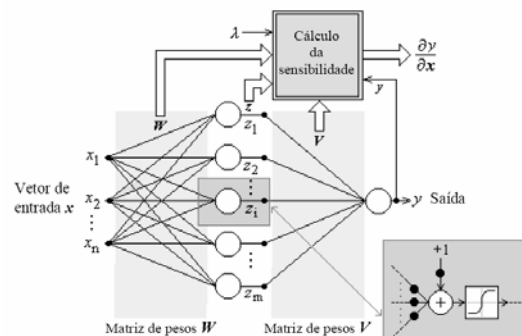


Figura 3. Rede Neural para o Cálculo da Sensibilidade  $\partial f(x)/\partial x$ .

## 5 Aplicação e Resultados

A *toolbox* de redes neurais artificiais do MATLAB facilita o manuseio das redes, sendo a proposta deste trabalho utilizá-la para testar a metodologia, a qual foi aplicada para um sistema composto por três máquinas síncronas, três transformadores, nove linhas de transmissão e nove barras (Fig. 1).

No enfoque do sistema Anderson & Fouad (Fig. 1), consideraram-se, os seguintes dados referentes à arquitetura e aos parâmetros da rede neural:

- Número de vetores padrão: 82
- Número de neurônios por camada: (18,1)
- Tipo de função de ativação: sigmóide (Eq. 5)
- Taxa de treinamento: 0.025
- Inclinação da função sigmóide: 0.15

Levando-se em consideração os parâmetros acima, tem-se o gráfico de treinamento, Figura 4.




Figura 4. Treinamento com 15000 iterações.

Através da Figura 4, verifica-se que a *performance* atingida está próxima da meta desejada com as 15000 iterações, pode-se dizer que a fase mais importante do processo de treinamento é as 5000 iterações iniciais, posteriormente a esta fase a convergência torna-se lenta. O tempo de treinamento é curto, cerca de 113 segundos para as 15000 iterações. Ressalta-se que se utilizou um conjunto de dados relativamente pequeno, 82 vetores padrão, para fazer o treinamento.

Em seguida, faz-se uso da rede treinada para diagnosticar as margens de segurança para um conjunto de potências e comparar o resultado fornecido pela rede com os resultados dados via PEBS. Na Tabela 1 mostra-se a análise comparativa entre os resultados obtidos. São considerados 8 perfis de geração e de carga distintos dos perfis utilizados no treinamento, fixados de forma pseudo-aleatória.

Tabela 1. Análise Comparativa dos Resultados.

Perfil	Potência Elétrica Ativa (Reativa) em pu						Margem de Perfil Segurança (M)	
	Barra						PEBS	Redes Neurais
	1	2	3	5	6	8		
Referência	1	1,594 (0,132)	0,807 (-0,094)	-1,219 (-0,489)	-0,873 (-0,290)	-0,979 (-0,342)	0,2507	0.2577
	2	1,530 (0,097)	0,714 (-0,123)	-1,159 (-0,467)	-0,797 (-0,262)	-0,959 (-0,335)	0,4010	0.4047
	3	1,498 (0,069)	0,593 (-0,147)	-1,077 (-0,437)	-0,722 (-0,235)	-0,957 (-0,334)	0,5077	0.4890
	4	1,117 (-0,007)	0,812 (-0,190)	-1,127 (-0,455)	-0,700 (-0,227)	-0,771 (-0,266)	0,7419	0.7392
	5	1,670 (0,169)	0,888 (-0,061)	-1,264 (-0,505)	-0,956 (-0,320)	-1,009 (-0,353)	0,0558	0.0599
	6	1,745 (0,218)	0,968 (-0,030)	-1,337 (-0,532)	-0,965 (-0,324)	-1,084 (-0,381)	-0,1216	-0.1340
	7	1,857 (0,273)	1,012 (0,001)	-1,410 (-0,559)	-0,978 (-0,329)	-1,155 (-0,407)	-0,3714	-0.3795
	8	2,063 (0,353)	0,966 (0,039)	-1,424 (-0,564)	-0,987 (-0,332)	-1,290 (-0,456)	-0,6644	-0.6266

Este experimento corresponde a uma hipotética curva de geração para atender a uma curva de carga diária. Os valores das potências ativas e reativas (valor entre parênteses) estão relacionados somente nas barras com carga ou geração, ou seja, as barras 1, 2, 3, 5, 6 e 8. Nas demais barras não há carga e nem geração. Não constam os valores de potência ativa e reativa na barra 1 (referência do sistema).

Observa-se que o diagnóstico obtido é muito próximo dos dados fornecidos via PEBS, portanto, a rede neural apresenta um bom mapeamento da função desconhecida, margem de segurança, podendo assim proporcionar bons resultados nos cálculos da sensibilidade.

A rede neural, além de realizar a análise da estabilidade (estimativa da margem de segurança), fornece o modelo da análise de sensibilidade ( $\partial M/\partial X$ ) referente à da contingência analisada.

Tabela 2. Modelo de Sensibilidade.

Perfil	Potência	Modelo de Sensibilidade $\partial M/\partial X$					
		Barra					
		1	2	3	5	6	8
1	Ativa	0.6652	-0.8430	0.1442	0.1788	0.0237	-0.3499
	Reativa	-0.9926	-1.1370	-1.0008	0.0123	0.0388	-0.1086
2	Ativa	0.5051	-0.7120	0.1643	0.1292	0.0043	-0.2344
	Reativa	-0.7654	-0.8963	-0.7836	0.0074	0.0246	-0.0701
3	Ativa	0.3905	-0.6151	0.1781	0.0925	-0.0099	-0.1527
	Reativa	-0.6015	-0.7224	-0.6269	0.0035	0.0144	-0.0428
4	Ativa	0.1978	-0.3493	0.0950	0.0619	0.0001	-0.0677
	Reativa	-0.3216	-0.3871	-0.3325	0.0070	0.0089	-0.0183
5	Ativa	0.8212	-0.9522	0.1113	0.2284	0.0457	-0.4703
	Reativa	-1.2105	-1.3627	-1.2061	0.0175	0.0536	-0.1493
6	Ativa	0.8844	-0.9702	0.0822	0.2476	0.0574	-0.5294
	Reativa	-1.2927	-1.4416	-1.2804	0.0191	0.0607	-0.1697
7	Ativa	0.8270	-0.8675	0.0547	0.2287	0.0570	-0.5096
	Reativa	-1.1986	-1.3284	-1.1832	0.0168	0.0580	-0.1644
8	Ativa	0.6071	-0.6154	0.0344	0.1611	0.0404	-0.3799
	Reativa	-0.8715	-0.9637	-0.8605	0.0100	0.0421	-0.1228

Na Tabela 2 apresentam-se as estimativas dos vetores de sensibilidade da margem de segurança em

relação aos vetores de entrada correspondentes aos perfis de geração/carga relacionados na Tabela 1.

O tempo para a obtenção do modelo de sensibilidade é de 0,156 segundos, tempo bem inferior ao de treinamento da rede, esta característica é a principal justificativa para o emprego desta metodologia.

Ressalta-se que todos os dados foram obtidos utilizando um computador com processador Celeron 2.53 GHz e 480 MB de memória RAM.

## 6 Conclusões

No treinamento da rede neural a tolerância pré-estabelecida não foi atingida, no entanto ficou muito próxima conforme (Fig. 4) para as 15000 iterações máximas. Com este resultado, obteve-se um bom mapeamento da função, fato verificado pelo diagnóstico das margens de segurança fornecido pela rede para os 8 perfis diferentes dos usados no treinamento (Tabela 1), os quais se aproximaram bastante das margens de segurança fornecidas pelo método PEBS.

Através da rede neural treinada obtiveram-se, também, as derivadas parciais desta, as quais se encontram dispostas na Tabela 2. Os vetores de sensibilidade,  $\partial M/\partial X$ , servem, num âmbito posterior, para definir um redespacho necessário para corrigir a margem de segurança para níveis preestabelecidos, ou seja, para níveis considerados seguros, do ponto de vista da estabilidade transitória.

Verificou-se um tempo bastante curto, comparado ao de treinamento, para a geração do modelo de sensibilidade. Notou-se, também, que respeitando alguns padrões é possível obter uma rede bastante confiável, que possibilita um bom desempenho na geração do modelo de sensibilidade.

Uma próxima etapa deste trabalho consiste em aplicá-lo a um sistema de maior porte, conforme referências Lotufo (2004) e Lotufo et al (2007).

## Agradecimentos

A FAPESP, financiadora do projeto (Processo Nº 06/01332-3).

A Anna Diva, orientadora, pela confiança depositada na realização deste projeto.

Ao professor Minussi e, em especial a professora Mara, pelas críticas e sugestões que contribuíram para a realização deste trabalho e para o próprio enriquecimento pessoal.

Ao Departamento de Engenharia Elétrica.

## Referências Bibliográficas

Anderson, P. M. e Fouad, A. A. (2003). Power System Control and Stability, *IEEE Series on Power Engineering*, USA, Second Edition.

Elgerd, O. I. (1971). Electric Energy Systems Theory: An Introduction, *MacGraw Hill Book Company*, New York, NY.

Fonseca, L. G. e Decker, I. C. (1985). 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, pp. 483-489.

Fouad, A. A. e Vittal, V. (1992). Power System Transient Stability Analysis Using the Transient Energy Function Method, *Prentice Hall*, Englewood Cliffs, New Jersey.

Haykin, S. (1999). Neural Networks: A Comprehensive Foundation, *Prentice-Hall*, Upper Saddle River, New Jersey, USA.

Kartalopoulos, S. V. (1996). Understanding Neural Networks And Fuzzy Logic: Basic Concepts and Applications, *IEEE Press*, Piscataway, NJ, USA.

Lopes, M. L. M. (2000). Desenvolvimento de um Sistema Previsor de Cargas Elétricas via Redes Neurais, *Dissertação de Mestrado, Programa de Pós-graduação em Engenharia Elétrica - Faculdade de Engenharia de Ilha Solteira - UNESP*.

Lotufo, A. D. P. (2004). Análise de Sensibilidade por Redes Neurais Para Estudos da Estabilidade Transitória de Sistemas Elétricos de Potência, *Tese de Doutorado, UNESP Ilha Solteira, SP*.

Lotufo, A. D. P., Minussi, C. R. e Lopes, M. L. M. (2007). Sensitivity Analysis By Neural Networks Applied To Power Systems Transient Stability. *Electric Power Systems Research*, **77(7)**: 730-738.

Minussi, C. R. e Freitas Filho, W. (1998). Sensitivity Analysis For Transient Stability, *IEEE Proceedings on Generation, Transmission And Distribution*, **145(6)**: 669-674.

Minussi, C. R. e Silveira, M. C. G. (1995). Transient Stability Analysis of Electric Power Systems by Neural Networks, *38th Midwest Symposium on Circuits And Systems*, Rio de Janeiro-RJ, pp. 1305-1308.

Pavella, M., Ernst, D. e Ruiz-Vega, D. (2000). Transient Stability of Power Systems A Unified Approach to Assessment and Control, Boston, U.S.A., *Kluwer Academic Publisher*.

Sweet, W. (2000). Restructuring the Thin-Stretched Grid, *IEEE Spectrum*, **37(6)**: 43-49.

Taylor, C. W. (1999). Improving Grid Behavior, *IEEE Spectrum*, Vol. 36, No. 6, pp. 40-45.

The Mathworks Inc. (1996). Manual de Utilização do MATLAB.

Werbos, P. J. (1974). Beyond Regression: New Tools For Prediction And Analysis in The Behavioral Sciences, *Master Thesis*, Harvard University.

Widrow, B. e Lehr, M. A. (1990). 30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation, *Proceedings of the IEEE*, **78(9)**: 1415-1442.