

# APLICAÇÃO DE SISTEMAS INTELIGENTES PARA ANÁLISE EM TEMPO REAL DO ESTADO DE OPERAÇÃO DE SISTEMAS DE POTÊNCIA EM RELAÇÃO À ESTABILIDADE DE TENSÃO

VICTORIA Y. MATSUNAGA, CAROLINA M. AFFONSO, WALTER BARRA JR.

*NESC, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Pará  
R. Augusto Corrêa N.01, Campus Universitário do Guamá, CP: 8619, CEP: 66.075-110, Belém-Pará-Brasil  
carolina@ufpa.br, walbarra@ufpa.br*

**Abstract**— This paper presents a methodology for on-line power system operation assessment related with voltage stability problems using computation intelligence. An artificial neural network is proposed to evaluate voltage stability margin using system collected data. A fuzzy system indicates the state system operation using as input the voltage stability margin evaluated by the neural network, bus voltage profile indexes and transmission line loading indexes. A set of simple fuzzy rules is built according to the well-known behavior of voltage collapse problems. Then, the method allows not only to assess system stability margin value, but also to assess system stability 'degree' using linguistic variables such as instable, alert, stressed or secure. The proposed method is implemented for IEEE 57 bus system.

**Keywords**— voltage stability, neural networks, fuzzy systems.

**Resumo**— Este artigo apresenta uma metodologia para análise em tempo real do estado de operação do sistema de potência com relação à estabilidade de tensão utilizando técnicas de inteligência computacional. Desenvolve-se uma rede neural artificial para estimação da margem de estabilidade de tensão utilizando diferentes grandezas mensuráveis a partir do sistema. Com base na margem de estabilidade estimada pela rede neural e indicadores do perfil de tensão e carregamento das linhas de transmissão, um sistema fuzzy indica o estado de operação da rede. Para isto utiliza-se um conjunto de regras simples construídas com base no comportamento já bem conhecido dos problemas de colapso de tensão. Deste modo, é possível não apenas estimar o valor da margem de estabilidade de tensão do sistema, mas também o seu 'grau' de estabilidade através de variáveis linguísticas, como instável, alerta, seguro ou carregado. O método proposto é testado para o sistema IEEE 57 barras.

**Palavras-chave**— estabilidade de tensão, redes neurais, sistemas fuzzy.

## 1 Introdução

Com o crescente aumento da demanda de energia e reestruturação do setor elétrico, contratos de energia são negociados visando principalmente interesses econômicos. Como consequência, o sistema tende a ser operado sob maiores condições de carregamento e com menor nível de segurança, aumentando a ocorrência de problemas de instabilidade de tensão.

Muitos países já relataram casos de instabilidade de tensão com grandes prejuízos financeiros (Corsi and Sabelli, 2004). Como exemplo pode-se citar o grande blecaute ocorrido em agosto de 2003 atingindo Canadá e Estados Unidos (U.S.-Canada Task Force, 2004). A instabilidade de tensão ocorre quando uma perturbação causa uma queda progressiva e irreversível na tensão em uma ou mais barras da rede, estando associada principalmente à falta de suporte de potência reativa em situações extremas de carregamento (Kundur, 1994; IEEE/CIGRE, 2004).

A operação dos sistemas de energia de modo cada vez mais estressado tem apontado para a necessidade de desenvolver ferramentas que permitam identificar em tempo real o quão próximo o sistema opera de seu limite de estabilidade (Morison et al., 2004; Zhihong and Jeyasurya, 2000). A estabilidade de tensão do sistema pode ser avaliada pelo cálculo da margem de estabilidade. No entanto, os métodos de

cálculo deste índice são lentos e, portanto, inadequados para aplicações em tempo real.

Por outro lado, ferramentas baseadas em inteligência computacional, como redes neurais artificiais, vêm mostrando resultados interessantes pois possuem a habilidade de solucionar problemas complexos não lineares cuja solução é obtida sem necessidade de formulação analítica. Devido à natureza não linear do problema em questão, a aplicação de redes neurais torna-se mais adequada quando comparada a outras técnicas. Além disso, uma vez treinada adequadamente, a rede fornece a resposta para uma dada entrada com mínimo esforço computacional e com capacidade de generalização.

Este trabalho apresenta um sistema inteligente que combina o uso de redes neurais artificiais e sistemas fuzzy. Primeiramente utiliza-se a rede neural para estimação da margem de estabilidade do sistema, utilizando para isso diferentes grandezas mensuráveis a partir das características da rede, visando à aplicação desta metodologia em um ambiente em tempo real. Posteriormente, utiliza-se lógica fuzzy para avaliar o 'grau' de estabilidade do sistema, classificado como instável, alerta, fortemente carregado, carregado, pouco carregado e seguro. Esta metodologia é testada no sistema IEEE 57 barras.

A principal contribuição deste trabalho está em não apenas avaliar a margem de estabilidade de tensão do sistema, mas também em analisar o que este índice numérico expressa em termos de estado de operação da rede. Apesar de agentes reguladores

definirem valores mínimos de margem de estabilidade de tensão para o sistema, como o WECC que sugere o mínimo de 5% para o caso de contingências simples, este valor numérico depende de cada sistema e por si só não tem significado (WECC, 1998). Ou seja, não existe uma faixa operativa deste índice que permita classificar o grau de estabilidade do sistema.

Este artigo está organizado como segue. A metodologia proposta para análise do estado de operação do sistema é apresentada na seção 2. A seção 3 apresenta o procedimento para geração dos cenários e a seção 4 o processo de tratamento dos dados. Os resultados obtidos com a aplicação da metodologia são apresentados na seção 5. A seção 6 apresenta as conclusões desta pesquisa.

## 2 Metodologia Proposta

### 2.1 Algoritmo

A metodologia proposta neste artigo combina o uso das técnicas de redes neurais artificiais (RNA) e sistemas fuzzy em duas etapas. Na primeira etapa utiliza-se a RNA para estimação da margem de estabilidade de tensão (MET) do sistema, utilizando diferentes grandezas mensuráveis a partir da rede ou obtidas através de cálculos simples, visando à aplicação desta metodologia e um ambiente de tempo real. Em uma segunda etapa, utiliza-se lógica fuzzy para avaliar o 'grau' de estabilidade do sistema, ou seja, o estado de operação do sistema (EOS), podendo ser classificado como instável, alerta, fortemente carregado, carregado, pouco carregado e seguro. Para isto utilizam-se como variáveis de entrada, além da margem de estabilidade de tensão previamente estimada pela RNA, indicadores do carregamento de potência nas linhas de transmissão e indicadores do perfil de tensão no sistema. A Figura 1 apresenta a metodologia proposta neste trabalho.




Figura 1. Metodologia proposta.

### 2.2 Margem de Estabilidade de Tensão

A margem de estabilidade de tensão representa a distância, em MW ou em percentual, do ponto base de operação até o ponto de máximo carregamento do sistema. Este índice pode ser obtido através de métodos da continuação que traçam a curva PV (Taylor, 1994). Para cada aumento no carregamento do sistema um problema de fluxo de carga é resolvido e os

valores da tensão nas barras da rede definem a curva PV, como mostra a Figura 2. O ponto de máximo carregamento (PMC), conhecido como nariz da curva PV, representa uma bifurcação sela-nó caracterizada por apresentar o determinante da matriz Jacobiana nulo. A partir de uma demanda superior a  $P_{max}$  não haverá mais convergência do fluxo de carga e nenhum acréscimo de potência poderá ser transmitido.




Figura 2. Curva PV.

### 2.3 Redes Neurais Artificiais

Utilizou-se uma rede neural multicamada direta com o algoritmo de aprendizado supervisionado *Backpropagation* para estabelecer o mapeamento entre o conjunto dos dados de entrada e de saída. O método de otimização utilizado para minimizar o erro médio quadrático foi o *Levenberg-Marquardt* (Haykin, 1994). Como variáveis de entrada foram utilizadas:

- Magnitude e ângulo das tensões nas barras da rede;
- Potência ativa fornecida por cada gerador;
- Reserva de potência reativa de cada gerador ( $R_i = Q_{gi}^{max} - Q_{gi}$ );
- Carregamento de potência ativa e reativa total do sistema.

Como variável de saída utilizou-se a margem de estabilidade de tensão, a qual deseja-se estimar.

### 2.4 Sistemas Fuzzy

O sistema fuzzy proposto utiliza como entrada a margem de estabilidade de tensão estimada pela RNA, indicadores do perfil de tensão do sistema e indicadores do carregamento nas linhas de transmissão. As regras fuzzy são utilizadas para avaliar a severidade do estado de operação do sistema, expressa através de variáveis linguísticas. Os métodos de inferência fuzzy (Mandani) e de defuzzificação utilizados foram, respectivamente, de mínimo e do cento da área (Wang, 1997).

#### 2.4.1 Índice de estabilidade de tensão

O índice de estabilidade (IE) é dividido em 3 categorias utilizando a notação fuzzy: negativo (N), baixo

(B) e positivo (P). A Figura 3 ilustra a função de pertinência deste índice.




Figura 3. Função de pertinência para IE.

#### 2.4.2 Indicador do perfil de tensão

Para avaliar o perfil de tensão do sistema utiliza-se como índice o número de barras com tensões abaixo de 0.9 pu (nTB) expresso em valores percentuais. Este índice também é dividido em 3 categorias utilizando a notação fuzzy: baixo (B), médio (M) e alto (A). A Figura 4 apresenta a função de pertinência deste índice.




Figura 4. Função de pertinência para nTB.

#### 2.4.3 Indicador do carregamento nas linhas de transmissão

Para avaliar o carregamento das linhas de transmissão utilizam-se dois índices: número de linhas de transmissão carregadas (nLC) e número de linhas de transmissão sobrecarregadas (nLSC), ambos expressos em valores percentuais. Foram consideradas como linhas carregadas aquelas em que o fluxo de potência está entre 85-100% de sua capacidade máxima, e sobrecarregadas as linhas em que o fluxo está acima de 100% de sua capacidade máxima. Ambos os índices são divididos em 3 categorias utilizando a notação fuzzy: baixo (B), médio (M) e alto (A). As Figuras 5 e 6 apresentam as funções de pertinência destes índices.

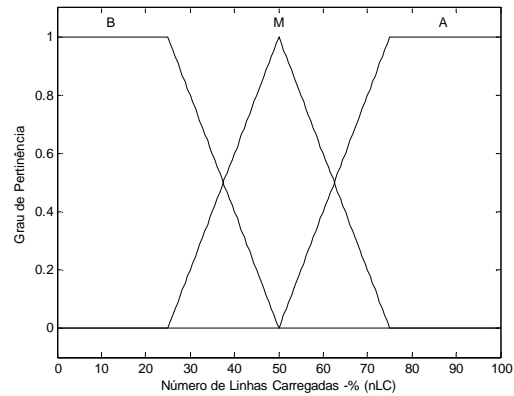


Figura 5. Função de pertinência para nLC.




Figura 6. Função de pertinência para nLSC.

#### 2.4.4 Variável de saída

Tem-se como variável de saída o estado de operação do sistema (EOS) classificado através de 6 variáveis linguísticas: instável (INS), alerta (AL), fortemente carregado (FC), carregado (C), pouco carregado (PC) e seguro (S). A Figura 7 apresenta a função de pertinência da variável de saída.




Figura 7. Função de pertinência para EOS.

A Tabela 1 apresenta algumas regras fuzzy utilizadas para classificar o estado de operação do sistema. Estas regras foram construídas tendo como base o conhecimento e experiência da ocorrência de problemas de estabilidade na operação do sistema.

Tabela 1. Regras fuzzy.

Se MET<N>	→ INS
Se MET<B> e nTB<M> e nLC<M> e nLSC<M>	→ AL
Se MET<P> e nTB<M> e nLC<M> e nLSC<A>	→ FC
Se MET<P> e nTB<A> e nLC<A> e nLSC<M>	→ C
Se MET<P> e nTB<M> e nLC<M> e nLSC<M>	→ PC
Se MET<P> e nTB<B> e nLC<B> e nLSC<B>	→ S

### 3 Seleção dos Cenários

A metodologia proposta foi aplicada ao sistema IEEE 57 barras. Este sistema é composto por 42 barras de carga, 4 geradores, 3 compensadores síncronos e 80 linhas de transmissão.

Dadas às inúmeras condições em que um sistema elétrico de potência pode operar e a impossibilidade das RNA's de aprender um conjunto ilimitado de estados, faz-se necessário delimitar o ambiente de operação da rede. Deste modo, este trabalho propõe-se uma estratégia de treinamento baseada na informação da previsão da demanda de energia. A partir desta previsão, realiza-se a simulação do estado do sistema numa faixa de operação dentro da qual se estima provável que o sistema opere. O conjunto de dados obtidos para o treinamento da rede foi gerado considerando duas variações: diferentes carregamentos e diferentes despachos de geração.

Tomou-se como base uma curva de carga típica ao longo de um dia, com intervalos de uma hora, totalizando 24 pontos de operação como mostra a Figura 8. A demanda total do sistema é obtida variando o fator de carregamento entre 0.5 e 1.0 através da expressão:

$$P = fc.P_o \quad (1)$$

onde:

fc – fator de carregamento;

P<sub>o</sub> – demanda total do sistema para o caso base;

P – demanda total do sistema.

Além destes pontos de operação considerou-se também a previsão do crescimento de 10% da demanda atual do sistema. Com isto, o fator de carregamento do sistema passa a variar entre 0.5 e 1.1. Para cada ponto de operação desta curva de carga foram considerados 3 despachos de geração distintos. Sendo assim, tem-se no total um conjunto de dados com 128 pontos de operação.

Para cada ponto de operação roda-se um fluxo de carga convencional pelo método de Newton, obtendo o estado da rede (módulo e ângulo da tensão, potência ativa dos geradores, reserva de potência reativa dos geradores e a demanda). Para este mesmo ponto de operação obtém-se a margem de estabilidade de tensão pelo método da continuação. Em ambos os casos consideraram-se o limite de potência reativa dos geradores. A Figura 8 ilustra o comportamento da margem de estabilidade conforme a variação da demanda. Nota-se que para situações de carregamen-

to elevado (horário de pico que ocorre às 19hs) tem-se menor margem de estabilidade de tensão, estando o sistema mais próximo de seu limite.




Figura 8. Curva de carga de um dia típico.

### 4 Tratamento dos Dados

Em muitas aplicações verifica-se que o número de entradas da RNA é muito elevado, e em muitos casos a informação contida nestes dados é redundante. Por esta razão torna-se interessante aplicar um procedimento que permitia reduzir o conjunto de dados original do problema, mantendo aqueles que contêm as principais características dos dados originais.

A escolha das variáveis de entrada da rede neural se dá pelo uso da técnica *Principal Component Analysis* (PCA) (Jolliffe, 1986). Para aplicar o PCA, primeiramente normalizou-se o conjunto de sinais entrada e saída para as 128 amostras, de modo que tenham média zero e desvio padrão unitário. Aplicando o PCA no conjunto de dados de entrada obteve-se uma redução de 127 para 18 elementos como mostra a Tabela 2. Para obtenção destes resultados consideraram-se os elementos que representam 99,9% da variabilidade do conjunto original de dados.

Tabela 2. Redução do número de entradas no sistema IEEE 57.

Variável	Nº de Entradas	Nº de Entradas da RNA
Magnitude da tensão	57	2
Ângulo da tensão	57	3
Potência ativa gerada	4	4
Reserva de pot. reativa	7	7
Demanda de pot. ativa	1	1
Demanda de pot. reativa	1	1
<b>Total</b>	<b>127</b>	<b>18</b>

### 5 Resultados

A metodologia proposta foi aplicada no sistema teste IEEE 57 barras para avaliação dos resultados. A ar-

quietura da RNA foi de 20 neurônios na camada de entrada e na camada escondida e um neurônio na camada de saída. As funções de transferência utilizadas na camada de entrada, escondida e de saída foram tangente hiperbólica, tangente hiperbólica e linear, respectivamente. Foram utilizadas 108 amostras para o treinamento e 20 amostras para a validação dos dados totalizando 128 amostras, sendo a tolerância para convergência do método igual a  $10^{-5}$ . A ferramenta computacional utilizada para aplicação da metodologia e simulação dos resultados foi o *toolbox* de redes neurais e fuzzy do MATLAB®.

A Figura 9 ilustra o erro quadrático médio durante o processo de convergência no treinamento da RNA. Após o treinamento, para verificar a eficiência de generalização da rede neural, a mesma foi testada utilizando-se um conjunto de 20 padrões de dados. Os resultados demonstram uma boa capacidade de generalização da rede neural (Figura 10).




Figura 9. Processo de treinamento da RNA.




Figura 10. MET calculada e estimada pela RNA.

Na Figura 11 são apresentados os erros absolutos e relativos referentes aos testes de validação. Os valores dos erros obtidos são baixos, indicando a eficiência do método em estimar a margem de estabilidade de tensão do sistema. Estes erros foram calculados utilizando as expressões

$$ER_i = \frac{MET_i^{calc} - MET_i^{RNA}}{MET_i^{calc}} \quad (2)$$

$$EA_i = |MET_i^{calc} - MET_i^{RNA}| \quad (3)$$

onde:

$MET_i^{calc}$  - margem de estabilidade de tensão calculada para a barra  $i$ ;

$MET_i^{RNA}$  - margem de estabilidade estimada pela rede neural para a barra  $i$ ;

$ER_i$  - erro relativo da barra  $i$ ;

$EA_i$  - erro absoluto da barra  $i$ .




Figura 11. Erro relativo e absoluto da MET predito pela RNA.

O mesmo conjunto de dados foi utilizado para avaliar o desempenho do sistema fuzzy. A Tabela 3 apresenta os resultados obtidos para alguns destes padrões. Na tabela constam, para cada amostra, a margem de estabilidade, os índices fuzzy (IE, nTB, nLC e nLSC) e o estado de operação da rede indicado pelo sistema fuzzy.

Tabela 3. Resposta do sistema fuzzy para os dados de validação.

MET(%)	IE	nTB(%)	nLC(%)	nLSC(%)	EOS
28,2	P	0	0	1,2	SE
22,3	P	5,2	10	8,7	PC
10,7	P	19,2	8,7	0	C
8,2*	P	29,8	22,5	12,5	FC
2,0*	P	64,9	87,5	0	C
0,4	B	82,4	38,7	28,7	AL
-1,02	N	-	-	-	INS

No caso em que a margem de estabilidade é de 8,2% o sistema fuzzy indica que a rede está fortemente carregada, pois existem 12,5% de linhas de transmissão com carregamento acima de sua capacidade máxima. Já o caso em que a margem de estabilidade é de 2%, apesar do valor da margem ser bem inferior quando comparado ao caso anterior, o que indicaria que o sistema está mais estressado, o sistema fuzzy indica que a rede está carregada e não fortemente carregada. Nota-se, portanto, que avaliando índices de carregamento das linhas de transmissão e de perfil de tensão, e não apenas o valor da margem de estabilidade, obtém-se informações mais precisas do estado de operação do sistema, o que é de grande auxílio na operação em tempo real do sistema para a tomada de decisão dos operadores.

## 6 Conclusão

Este trabalho apresenta um sistema inteligente que combina o uso de redes neurais artificiais e sistemas fuzzy para estimação da margem de estabilidade de tensão do sistema e avaliação de seu estado de operação em tempo real. A estimação da margem de estabilidade é feita através da rede neural, tendo como entrada diferentes grandezas mensuráveis a partir do sistema e como saída a margem de estabilidade. A arquitetura da rede utilizada foi multicamada direta com o algoritmo de aprendizado supervisionado *Backpropagation*.

Para avaliação do estado de operação da rede utilizou-se um sistema fuzzy, tendo como entrada a margem de estabilidade previamente estimada pela rede neural e índices de carregamento nas linhas de transmissão e índices do perfil de tensão do sistema, todos expressos em termos de variáveis linguísticas.

Esta metodologia foi testada no sistema IEEE 57 barras. Os resultados obtidos mostram a eficiência da rede neural em estimar adequadamente a margem de estabilidade de tensão do sistema em tempo real. Uma vez treinada adequadamente, a rede neural é capaz de prever a margem de estabilidade para outros pontos de operação. O erro absoluto e relativo obtido para cada ponto de operação com a aplicação desta metodologia foi consideravelmente baixo.

Utilizou-se, neste trabalho, o conjunto de dados de validação para a realização dos testes de desempenho da rede. No entanto, o mais adequado seria trabalhar com um conjunto de dados de teste diferentes daqueles usados para treinamento e validação. Em relação a esse aspecto, novos estudos de simulação estão sendo realizados e os resultados serão reportados em futuros artigos.

O sistema fuzzy também apresentou resultados satisfatórios, sendo uma ferramenta adequada para auxiliar os operadores do sistema, fornecendo informações relevantes acerca do estado de operação da rede elétrica. Deve-se observar que os parâmetros das funções de pertinência (grau de sobreposição e forma) são variáveis de projeto e, dessa forma, devem ser ajustados levando-se em conta as características do sistema de potência em estudo. Quanto às regras do sistema fuzzy, estas deverão variar muito pouco de um sistema para outro, uma vez que são baseadas em informações e em índices válidos para qualquer sistema de potência, como por exemplo, os indicadores de perfil de tensão e carregamento nas linhas de transmissão.

Com esta metodologia, além de estimar o valor da margem de estabilidade de tensão, o operador também tem acesso a informações da operação do sistema, tais como estado de alerta, carregado ou seguro, os quais não podem ser extraídos apenas através do valor da margem de estabilidade de tensão do sistema.

## Agradecimentos

Os autores agradecem ao apoio recebido do projeto de pesquisa e desenvolvimento "Desenvolvimento de um Sistema Baseado em Agentes Inteligentes para o Monitoramento de Unidades Geradoras na UHE de Tucuruí (código 4500052479)-ELETRONORTE-ANEEL-UFPA"

## Referências Bibliográficas

- Corsi, S. e Sabelli, C. (June, 2004). General Blackout in Italy Sunday September 28, 2003, h. 03:28:00, *Proceedings of IEEE Power Engineering Society General Meeting*, Vol. 2, pp.1691-1702.
- Haykin, S. (1994). *Neural Networks: a comprehensive foundation*. MacMillan College Publishing Co.
- IEEE/CIGRE Joint Task Force on Stability Terms and Definitions (May, 2004). Definition and Classification of Power System Stability, *IEEE Transactions on Power Systems*, Vol. 19, No. 2, pp. 1387-1401.
- Jolliffe, I.T. (1986). *Principal Component Analysis*, Springer, New York.
- Kundur, P. (1994). *Power System Stability and Control*. Ed. New York: McGraw-Hill.
- Morison, K., Wang, L., Kundur, P., Lin, X., Gao, W., He, C., Xue, F., Xu, J., Xu, T., and Xue, Y. (October, 2004). Critical Requirements for Successful On-Line Security Assessment, *Proceedings of the IEEE PSC&E*, New York.
- Taylor, C.W. (1994). *Power System Voltage Stability*, New York: McGraw-Hill Inc.
- U.S.-Canada Power System Outage Task Force (Apr., 2004). Final Report on the August 14, 2003 Blackout in the United States and Canada: Causes and Recommendations. Disponível: <http://www.iwar.org.uk/cip/resources/blackout-03/>
- Wang, L.X. (1997). *A Course in Fuzzy Systems and Control*. Prentice-Hall International, Inc.
- WECC Reactive Power Reserve Work Group (1998). Final Report: Voltage Stability Criteria, Undervoltage Load Shedding Strategy, and Reactive Power Reserve Monitoring Methodology. <http://www.wecc.biz>
- Zhihong Jia and Jeyasurya, B. (2000). Contingency Ranking for on-line Voltage Stability Assessment, *IEEE Transactions on Power Systems*, Vol. 15, No. 3, pp. 1093-1097.