



**SNPTEE  
SEMINÁRIO NACIONAL  
DE PRODUÇÃO E  
TRANSMISSÃO DE  
ENERGIA ELÉTRICA**

GAT 23  
14 a 17 Outubro de 2007  
Rio de Janeiro - RJ

#### **GRUPO IV**

#### **GRUPO DE ESTUDO DE ANÁLISE E TÉCNICAS DE SISTEMAS DE POTÊNCIA – GAT**

#### **AValiação ONLINE DA ESTABILIDADE DE TENSÃO**

**Eduardo Sodré \***

**Wellington Santos Mota**

**Benemar de S. Alencar**

**CHESF**

**UFCG**

**UFCG**

#### **RESUMO**

Neste artigo é proposto um sistema inteligente híbrido para avaliação online da estabilidade de tensão. São apresentados os resultados obtidos na avaliação da segurança do sistema real do Norte-Nordeste Brasileiro de 482 barras. Foram utilizadas a rede neural artificial RPROP, o sistema adaptativo neuro-fuzzy ANFIS e uma combinação híbrida destes. Os resultados obtidos confirmam o grande potencial de aplicação destas técnicas num módulo de avaliação de estabilidade de tensão online (**AET online**). Apresentam-se ainda os principais requisitos funcionais necessários para a implementação do módulo **AET online**.

#### **PALAVRAS-CHAVE**

Estabilidade de Tensão, Método da Continuação, Reconhecimento de Padrão, Sistema Neuro-Fuzzy, Técnica Híbrida.

#### **1.0 - INTRODUÇÃO**

A estabilidade de tensão tem-se apresentado como um dos fatores relevantes para a determinação da segurança da operação dos sistemas de potência, requerendo que sejam implementados processos de avaliação online. Apesar dos muitos requisitos necessários para a implementação dos módulos de avaliação online nos sistemas de gerenciamento de energia, a sua principal dificuldade encontra-se no fato de que para a correta análise de segurança é preciso levar em consideração muitos aspectos da operação e do funcionamento dos componentes dos sistemas.

A utilização das técnicas de IA pode solucionar grande parte das dificuldades de implantação de módulos de avaliação online e contribuir de forma valiosa, como companhia indispensável, nessa tarefa.

Uma referência interessante é o trabalho desenvolvido no projeto europeu de P&D denominado MORE CARE, que contou com 18 pesquisadores de 5 países (1). Este projeto teve como principal objetivo o desenvolvimento de um avançado sistema de controle incluindo funções de segurança online em ambos os modos preventivo e corretivo. Estas funções de segurança fazem uso de sistemas especialistas e redes neurais artificiais.

Num trabalho voltado para a rede de transmissão nórdica (2) que utilizou uma MLP com 8 neurônios na camada escondida, a conclusão foi que, apesar dos bons resultados observados, uma das principais desvantagens do uso das redes neurais é o enorme tempo dispendido durante o processo de treinamento. Esta desvantagem é própria do modelo MLP utilizado pelos autores. Como será visto adiante nos resultados desse artigo, esta desvantagem pode ser superada através do uso do sistema híbrido proposto.

No trabalho realizado no PSERC - Power System Engineering Research Center (3) foram investigadas as redes

neurais Kohonen e MLP. A MLP mostrou-se mais adequada para a solução do problema. Para aumentar a robustez do sistema proposto foram utilizadas múltiplas MLP's, com a solução final baseada numa média das saídas de cada uma delas.

O presente artigo demonstra a viabilidade da utilização de redes neurais e lógica fuzzy em um arranjo híbrido, na determinação da segurança do sistema em relação à estabilidade de tensão, em comparação com o uso da MLP-RPROP, do kNN e do sistema neuro-fuzzy ANFIS. São apresentados resultados obtidos com o sistema inteligente híbrido proposto num sistema real de 482 barras da região norte do Brasil, o sistema Norte-Nordeste (4).

Na Seção II são apresentados os principais requisitos funcionais necessários para a implementação do módulo **AET online**. Na Seção III é proposto o Sistema Híbrido a ser comparado com as outras técnicas, com seus respectivos resultados como classificador apresentados na Seção IV. As conclusões seguem na Seção V.

## 2.0 - MÓDULO **AET ONLINE**

O módulo de **AET online** (Avaliação da Estabilidade de Tensão online) deve operar em conjunto com o ambiente do SGE (Sistema de Gerenciamento de Energia) monitorando o estado do sistema de potência periodicamente, sob demanda, ou sob ocorrência de mudanças significativas no estado do sistema, para garantir a segurança contra ocorrência de contingências. Devendo estar disponível também no modo de estudo. As contingências selecionadas devem ser classificadas em dois grupos: **seguro** e **inseguro** (5).

A Figura 1. mostra os principais componentes (módulos) de uma **AET online**. O Monitor de Mudança dispara a execução orientada a eventos da função AET baseada nos dados analógicos e no status do sistema recebido do SCADA. Alternativamente, o Controle da Seqüência de Tempo-Real do SGE pode ser aumentado para incluir a ativação da execução da **AET online**. A Seleção de Contingências é configurada separadamente para permitir a exclusão ou a inclusão de um filtro de Contingências. A Análise das Contingências para avaliação da estabilidade de tensão pode ser configurada para usar ou a análise estática (regime permanente) ou a simulação dinâmica. O Monitor de Segurança de Tensão determina os limites operacionais seguros ou as regiões de operação para assegurar as margens de estabilidade de tensão adequadas. O Módulo de Melhoria da Segurança fornece uma assistência aos operadores na determinação das ações corretivas e/ou preventivas contra a ameaça da instabilidade de tensão.

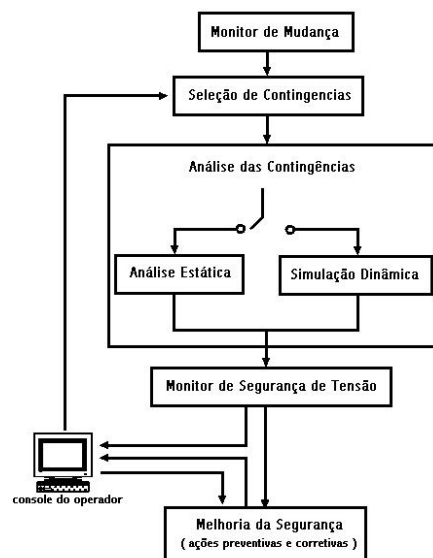


Figura 1. – Módulo **AET online**

É esperado que a **AET online** rode normalmente como parte da seqüência dos processos do tempo real, começando através da solução do Estimador de Estados. Portanto, em sua execução normal, os resultados da **AET online** são para intervalos de tempo definidos (de 5 a 30 minutos dependendo da implementação específica, sendo uma análise a cada 20 minutos um valor de referência razoável).

Os requisitos de desempenho da plataforma da **AET online** declarados abaixo estão baseados na suposição de cenários de tamanho e desempenho razoáveis. Os parâmetros de execução são os seguintes:

1. periodicidade da execução: 20 minutos.
2. análise de contingências: 300 contingências com diferentes graus de complexidade, incluindo não mais do que 30 contingências severas (um bom processo de seleção de contingências não poderá selecionar mais do que 30 contingências para processamento completo).
3. execução da AET: incluirá seleção de contingências, classificação, graduação e determinação de limites, como também, o cálculo de ações corretivas e preventivas.

Os limites da operação determinados pela **AET online** devem apresentar um erro de menos de 2% dos limites que seriam obtidos a partir da análise da mesma condição de operação realizando estudos off-line através da utilização de modelos detalhados.

Ao final desta seção tem-se um pequeno resumo da seguinte função básica da **AET online**: Avaliação da Segurança de Tensão.

#### Avaliação da Segurança de Tensão

Os operadores necessitam saber se o sistema e as condições de operação atendem os critérios de estabilidade de tensão. O critério pode especificar quão distante o sistema deveria estar da fronteira da instabilidade da tensão em termos de aumento de carga, aumento de transferência, ou outras formas de “stress”, quando sujeito a qualquer uma das contingências selecionadas. Pode haver outros critérios que devem ser atendidos também, tais como, reserva de reativo em diferentes partes do sistema e limites de declínio de tensão pós-contingência.

Vale salientar que esta função básica do módulo **AET online** pode ser complementada de forma valiosa por um sistema de reconhecimento de padrões utilizando IA.

### 3.0 - SISTEMA INTELIGENTE HÍBRIDO

Nesta Seção será apresentado primeiro o sistema neuro-fuzzy ANFIS e depois a rede neural RPROP, onde a partir desses dois sistemas classificadores são propostos: o **Sistema Classificador Híbrido RPROP** e também o **Sistema Classificador Híbrido kNN**. Os resultados de seus desempenhos são comparados na Seção 4.

#### 3.1 ANFIS - Adaptive Network-Based Fuzzy Inference System

Por simplificação e para esclarecer da melhor forma possível a matemática dos sistemas neuro-fuzzy, na explicação abaixo será considerado um sistema fuzzy com somente duas entradas ( $x, y$ ) e uma saída ( $z$ ), e a base de regras contendo duas regras *If-Then* fuzzy do tipo Takagi-Sugeno, conforme:

*Rule 1: If (x is  $A_1$  and y is  $B_1$ ) then  $f_1 = p_1x + q_1y + r_1$*

*Rule 2: If (x is  $A_2$  and y is  $B_2$ ) then  $f_2 = p_2x + q_2y + r_2$*

O sistema fuzzy é apresentado na Fig. 2 e a arquitetura ANFIS equivalente é apresentada na Fig. 3 (6).




Figura 2. Sistema Fuzzy Tipo Takagi-Sugeno.

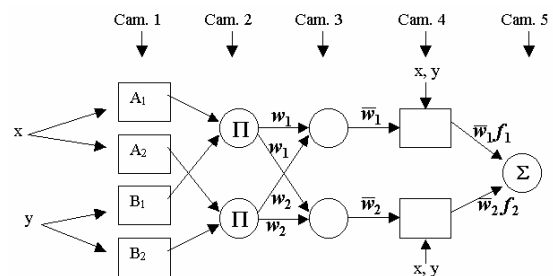


Figura 3. Arquitetura ANFIS.

As funções dos nós de cada camada são descritas abaixo

Camada 1: Cada nó  $i$  desta camada terá seus parâmetros treinados por um algoritmo de aprendizagem. Estes nós tem a seguinte função,

$$O_i^1 = \mu_{A_i}(x)$$

onde  $x$  é a entrada para o nó  $i$ , e  $A_i$  é a função lingüística (tensão pequena, corrente grande, etc.) associada com a função do nó.

Em outras palavras,  $O_i^1$  é um valor real especificando o grau de pertinência para qual o  $x$  dado satisfaz a função de pertinência  $A_i$ . Usualmente esta função tem a forma de uma Gaussiana, com o valor máximo igual a 1 e o valor mínimo igual a 0. Tal que,

$$\mu_{A_i}(x) = \frac{1}{1 + \left[ \left( \frac{x - c_i}{a_i} \right)^2 \right]^{b_i}}$$

ou

$$\mu_{A_i}(x) = \exp \left\{ - \left( \frac{x - c_i}{a_i} \right)^2 \right\}$$

onde  $\{a_i, b_i, c_i\}$  é o conjunto dos parâmetros.

Como os valores destes parâmetros vão mudar com o treinamento, a forma das funções Gaussianas variam de acordo com a mudança destes parâmetros, exibindo várias formas de funções de pertinência sobre as funções lingüísticas  $A_i$ . Estas mudanças é que serão responsáveis, em parte, pelo ajuste fino da resposta do sistema fuzzy. Os parâmetros desta camada são conhecidos como os parâmetros da premissa.

Camada 2: Nenhum dos nós  $i$  desta camada sofrerá treinamento. Eles simplesmente multiplicam os sinais de entrada enviando o produto para a saída. Por exemplo,

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2.$$

Cada nó de saída representa a "força" de disparo de uma regra.

Camada 3: Os nós  $i$  desta camada não sofrerão nenhuma mudança devido ao algoritmo de treinamento, estes nós são fixos. O  $i$ -ésimo nó calcula a razão entre a força de disparo da  $i$ -ésima regra e a soma das forças de disparo de todas as regras:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2.$$

Camada 4: Todos os nós  $i$  desta camada também terão os seus parâmetros treinados. Os nós desta camada tem a seguinte função

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$$

onde  $w$  é a saída da camada 3, e  $\{p_i, q_i, r_i\}$  é o conjunto dos parâmetros. Os parâmetros desta camada são conhecidos como os parâmetros do conseqüente.

Camada 5: Esta é uma camada de um único nó, que calcula a saída global do sistema como um somatório de todos os sinais de entrada, ou seja,

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

Após explicada acima a lógica da operação do sistema neuro-fuzzy simplificado, de duas regras, duas entradas e uma saída, vê-se que ele constitui-se numa rede neural que é funcionalmente equivalente a um sistema fuzzy. Por poder-se interpretar o sistema fuzzy como uma rede neural pode-se lançar mão dos algoritmos de treinamento das

redes neurais para o ajuste dos parâmetros do sistema fuzzy.

### 3.2 Rede Neural RPROP

RPROP, que segue de “resilient propagation” (7) é um algoritmo de aprendizado extremamente eficiente que executa o cálculo do  $\Delta\omega_{ji}$  (atualização do peso de um neurônio) da rede MLP de forma direta, baseado no sinal do gradiente e não no seu valor por completo.

Sendo as derivadas parciais de cada peso de um neurônio conhecidas, o objetivo de minimização da função erro  $E$  é obtida executando-se o gradiente descendente.

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t)$$

$$\Delta w_{ji} = -\eta \frac{\partial E(t)}{\partial w_{ji}}$$

Obviamente, a escolha da taxa de aprendizado  $\eta$ , que determina o tamanho do passo na direção contrária ao gradiente da função erro tem um importante efeito no tempo despendido até que a convergência seja alcançada (tempo de treinamento). Se a taxa de aprendizado é pequena, são necessários muitos passos até que um valor aceitável da função erro seja alcançado, de modo contrário, se a taxa de aprendizado é escolhida como sendo muito grande, provavelmente será apresentada uma oscilação da função erro  $E$ , não permitindo que seja atingido o valor desejado.

Para obter este algoritmo deve-se introduzir a variável  $\Delta_{ji}$  que é denominada de “valor atualizado”. Cada peso  $\Delta\omega_{ji}$  tem sua variável  $\Delta_{ji}$ , e ela determina de forma exclusiva o tamanho da variável  $\Delta\omega_{ji}$ . A variável segue a seguinte regra de aprendizagem:

$$\Delta_{ji}(t) = \begin{cases} \eta^+ * \Delta_{ji}(t-1) & \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} > 0 \\ \eta^- * \Delta_{ji}(t-1) & \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} < 0 \\ \Delta_{ji}(t-1) & \text{else} \end{cases}$$

onde  $0 < \eta^- < 1 < \eta^+$

Toda vez que a derivada parcial do correspondente peso muda de sinal, o que indica que a última atualização foi muito grande e o algoritmo pulou um mínimo local, a variável  $\Delta_{ji}$  é diminuída por um fator  $\eta^-$ . Se a derivada mantém seu sinal, a variável é levemente incrementada de modo a acelerar a convergência em regiões de planície.

A atualização da variável  $\Delta\omega_{ji}$  é realizada de acordo com a seguinte regra bastante simples: se a derivada parcial é positiva (função erro aumentando de valor), o peso  $\omega_{ji}$  é diminuído pela sua variável  $\Delta_{ji}$ . Se a derivada é negativa, o  $\Delta_{ji}$  é adicionado. Conforme equacionamento abaixo.

$$\Delta w_{ji}(t) = \begin{cases} -\Delta_{ji}(t) & \text{if } \frac{\partial E(t)}{\partial w_{ji}} > 0 \\ +\Delta_{ji}(t) & \text{if } \frac{\partial E(t)}{\partial w_{ji}} < 0 \\ 0 & \text{else} \end{cases}$$

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t)$$

Entretanto existe uma exceção: se a derivada parcial muda de sinal, isto é, o passo anterior foi muito grande e o ponto de mínimo foi perdido, a atualização do peso é revertida:

$$\Delta w_{ji}(t) = -\Delta w_{ji}(t-1), \quad \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} < 0$$

Devido ao “backtracking” acima, a derivada pode mudar de sinal novamente no passo seguinte. Para evitar uma punição dupla da variável  $\Delta_{ji}$ , a atualização em dois passos seguintes é evitada. Na prática isto pode ser feito declarando  $\partial E(t-1) / \partial \omega_{ji} = 0$  na regra de adaptação da variável  $\Delta_{ji}$ .

As variáveis  $\Delta_{ji}$  e os pesos  $\omega_{ji}$  são atualizados uma vez por época (uma época significa que todos os padrões do conjunto de treinamento são apresentados uma vez).

### 3.3 Sistemas Híbridos

O sistema classificador proposto foi realizado numa estrutura série. Foram compostos dois classificadores híbridos: o Híbrido RPROP (Fig. 4); e o Híbrido kNN (Fig. 5). Tendo sido seus desempenhos comparados com as técnicas analisadas até o momento.

O funcionamento das estruturas híbridas dá-se da seguinte forma: o ponto de operação é primeiramente avaliado pelo primeiro classificador da estrutura série, qual seja o RPROP ou o kNN (*k-Nearest Neighbours* (8)), conforme seja escolhido o Híbrido RPROP ou o Híbrido kNN, respectivamente. Em seguida o resultado é avaliado pelo sistema neuro-fuzzy ANFIS. A saída do sistema híbrido resultará em classificação da condição de operação do sistema de potência em segura ou insegura.

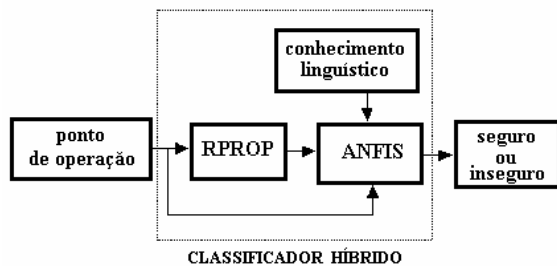


Figura 4. Sistema Classificador Híbrido RPROP.

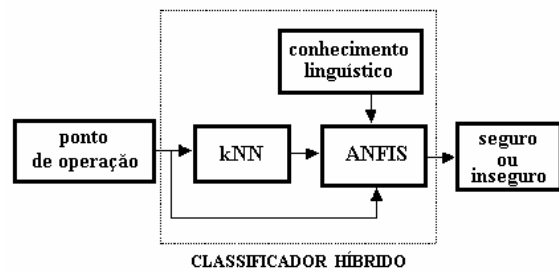


Figura 5. Sistema Classificador Híbrido kNN.

Cabe ressaltar que as propostas acima podem também aproveitar qualquer “conhecimento” que os operadores queiram incorporar ao sistema, como por exemplo: *If (intercâmbio é alto) then (segurança é mínima)*.

## 4.0 - RESULTADOS

O objetivo é classificar o ponto de operação do sistema como seguro ou inseguro. Essas condições são determinadas em função do Índice Margem obtido através do Método da Continuação. Para uma condição segura foi estabelecido que o limite de carregamento, a partir do ponto de operação do sistema, fosse maior que 5%, do contrário o sistema estaria operando numa condição insegura.

### 4.1 Sistema Norte-Nordeste

O Sistema Norte-Nordeste representa os subsistemas brasileiros do Norte e do Nordeste conjuntamente, inclusive com as interligações entre os subsistemas Norte, Nordeste e Sudeste no ano de 2010. Consiste de 482 barras operando nos níveis de tensão de 500, 230, 138, 69 e 13.8 kV, 14 usinas hidrelétricas, 7 térmicas e 10 parques eólicos.

A proposta é dividir o sistema em áreas e de cada área do sistema escolher só algumas barras para a construção do vetor padrão. Se apenas uma área é considerada insegura todo o sistema passa a ser inseguro. Para cada área deve haver uma lista de contingências exclusiva, a ser considerada para determinar-se a segurança ou não. Nessas listas devem constar também contingências que sejam de elementos que não pertençam à área, mas que afetem o seu máximo carregamento, como por exemplo, as interligações entre os subsistemas.

Neste trabalho a análise de desempenho dos sistemas classificadores foi executada somente para a área Leste do Sistema Norte-Nordeste.

A base de dados é construída a partir de 8 pontos de operação, já classificados em seguro e inseguro. Optou-se nesse trabalho por gerar-se várias bases de dados de forma que os seus vetores padrões fossem criados aleatoriamente com variações randômicas de 5%, 20%, 60% e 90%. Para gerar uma dessas bases parte-se de um ponto de operação e monta-se o vetor padrão, para tanto faz-se uso somente dos valores de tensão, ângulo e injeções de potência ativa e reativa por barra. A partir desse vetor padrão criam-se 200 outros de forma aleatória. Considerando-se 8 pontos de operação são criados 1600 vetores padrões, desses foram escolhidos 1120 vetores para treinamento e 480 para teste.

A partir da relação das barras críticas da Área Leste foi feita uma análise para se determinar quantas barras deveriam ser utilizadas para a formação do vetor padrão para treinamento do sistema classificador. Apesar do melhor desempenho ter sido apresentado para o vetor padrão construído com 17 barras, a seguir são apresentados também alguns resultados com os padrões de treinamento e teste construídos com 41 barras, para melhor exemplificar a superioridade do desempenho do classificador híbrido proposto.

#### 4.2 Resultados do Sistema Híbrido

O primeiro conjunto de resultados (Tabela 1) são para a base de dados formada com o vetor padrão de 17 barras. Para esse vetor padrão de 68 elementos foram geradas 4 bases de dados aleatórias distintas, uma com variação de 5%, outra com variação de 20% e as duas restantes com variações de 60% e 90%.

Nas Tabelas 1 e 2 aparecem ainda duas colunas denominadas **FS** e **FI**, essas colunas são o número de classificações **falso seguro** e **falso inseguro**, de cada classificador respectivamente. Uma classificação falso seguro é quando o sistema após ser apresentado à um dado de entrada classifica-o como seguro, sendo na verdade aquele ponto de operação um ponto inseguro.

O sistema ANFIS operando sozinho e não na estrutura híbrida, resulta num sistema fuzzy de 2 regras e 410 parâmetros a serem otimizados para um vetor de entrada de 68 elementos. Para o sistema ANFIS operando na estrutura do Híbrido RPROP têm-se um sistema fuzzy de 2 (duas) regras e 8 (oito) parâmetros a serem otimizados para um vetor de entrada de 1 (um) elemento. Isso faz com que o trabalho da lógica fuzzy e a incorporação do conhecimento lingüístico dos operadores seja facilitada. Em todos os casos testados a rede neural RPROP utilizada é formada por 5 (cinco) neurônios na camada escondida e 1 (um neurônio) na camada de saída.

Considerando o resultado para a base de dados aleatória com 90% de variação para os dois sistemas híbridos em estudo (o Híbrido RPROP e o Híbrido kNN) apresenta-se um resultado muito superior do Híbrido RPROP, pois o seu tempo de treinamento é de aproximadamente 1.57 minutos, contabilizando os 1.53 minutos de treinamento da rede neural RPROP e mais os 2.31 segundos da treinamento do neuro-fuzzy ANFIS. Considerando também a quantidade de classificações falso seguro (coluna FS) o Híbrido RPROP mostrou-se muito superior. Para esses resultados também foram testados o tradicional método de classificação kNN não tendo sido demonstrados resultados satisfatórios.

O segundo conjunto de resultados (Tabela 2) são para as bases de dados formadas com o vetor padrão de 41 barras. Para esses resultados com 41 barras o Híbrido RPROP apresenta também um desempenho superior aos outros sistemas classificadores. O tempo de treinamento é praticamente igual a 49 segundos, para a base de dados de variação de 90%, com a vantagem de se ter uma quantidade menor de classificações falso seguro, notadamente para a Base de Dados de variação de 60%.

Tabela 1. Resultados com vetor padrão de 17 barras e bases de dados de percentuais de variação  $\delta$ .

Sistemas	$\delta$	Tempo (s)	Acerto	FS	FI
ANFIS	5%	3.02	99.4 %	3	0
RPROP	5%	4.6	100 %		
Híb. RPROP	5%	$\cong$ 4.6	100 %		
ANFIS	20%	606	99.2 %	0	4
RPROP	20%	18.46	100 %		
Híb. RPROP	20%	$\cong$ 18.46	100 %		
ANFIS	60%	162	95.6 %	4	17
RPROP	60%	138	96.7 %	2	14
Híb. RPROP	60%	$\cong$ 138	98.8 %	0	6
ANFIS	90%	59.2	89.2 %	31	21
RPROP	90%	91.8	93.5 %	18	13
Híb. RPROP	90%	91.8 + 2.31	95.4 %	3	19
Knn	90%		74.8 %	61	60
Híb. kNN	90%		76.2 %	16	98

Tabela 2. Resultados com vetor padrão de 41 barras e bases de dados de percentuais de variação  $\delta$ .

Sistemas	$\delta$	Tempo (s)	Acerto	FS	FI
ANFIS	5%	19.06	100 %		
RPROP	5%	5.05	100 %		
ANFIS	20%	3300	99.6 %	1	1
RPROP	20%	4.61	100 %		
ANFIS	60%	1860	94.17 %	21	7
RPROP	60%	23.7	98.12 %	5	4
Híb. RPROP	60%	$\cong$ 23.7	98.54 %	3	4
ANFIS	90%	284.4	82.08 %	64	22
RPROP	90%	49.3	93.75 %	5	25
Híb. RPROP	90%	49.3 + 0.11 s	93.96 %	4	25

## 5.0 - CONCLUSÃO

Tendo sido estudadas e analisadas várias técnicas de IA conclui-se que essas novas ferramentas da engenharia são indispensáveis na tarefa da análise da segurança online. Acredita-se que a sua aplicação pode resultar numa simbiose fecunda com as outras técnicas já existentes. Sendo a principal vantagem das técnicas de IA sua facilidade de aplicação e implementação, não requerendo sistemas computacionais de grande porte nem requerendo algoritmos matemáticos de elevada complexidade.

Em relação à aplicação de técnicas de Inteligência Artificial para análise de segurança de sistemas de potência, pode-se dizer que o sistema classificador Híbrido RPROP mostrou-se ser o melhor arranjo entre todos. O processo de construção dos vetores padrões é peça chave no desempenho apresentado. Construção esta que levou em consideração a normalização dos vetores padrão e a facilidade de sua formação, desde que os seus elementos são apenas as grandezas elétricas do sistema. Nesse trabalho foi delineada uma metodologia para dividir o sistema de potência em áreas e trabalhar-se com um número reduzido de barras para a geração das bases de dados para treinamento e teste dos sistemas classificadores.

## 6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) Hatziaargyriou, *et al.*, “**Preliminary Results from the more advanced control advice project for secure operation of isolated power systems with increased renewable energy penetration and storage**”, *IEEE Porto Power Tech Conference 10<sup>th</sup>-13<sup>th</sup> September, 2001*, Porto, Portugal.
- (2) Repo, S. and Jarventausta, P., “**Implementation Issues of On-line Data-driven Voltage Stability Assessment**”, *ISAP - Intelligent Systems Application to Power Systems*, Lemnos, Greece 31st August- 3rd September, 2003.
- (3) Tomsovic, K. (Project Leader), Bose, A., Stuart, R., Williams, B., Willis, M., Chen, L., and Vaziri, M., “**Automated Operating Procedures for Transfer Limits**”, *PSERC – Power System Engineering Research Center*, Publication 01-05, May, 2001.
- (4) Sodré, E. de Aguiar, “**Avaliação da Estabilidade de Tensão através das Técnicas de Inteligência Artificial**”, Tese de Doutorado em Engenharia Elétrica pela Universidade Federal de Campina Grande, Paraíba, Brasil, abril 2006.
- (5) IEEE/PES, Power System Stability Subcommittee, Special Publication. “**Voltage Stability Assessment: Concepts, Practices and Tools**”, Final Document, 2002.
- (6) Jang, J.-S. R., “**ANFIS: Adaptive-Network-Based Fuzzy Inference System**”, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23, No. 3, pp. 665-685, 1993.
- (7) Riedmiller, M. and Braun, H., “**A direct adaptive method for faster backpropagation learning: The RPROP algorithm**” *Proceedings of the IEEE International Conference on Neural Networks, San Francisco, 1993*.
- (8) Beale and Jackson, T., ***Neural Computing: An Introduction***, Adam Hilger, 1990.

## 7.0 - DADOS BIOGRÁFICOS

### **Eduardo Sodré**

Nasceu em São José dos Campos, SP, em 1970. Doutorado (2006) em Eng. Elétrica na UFCG, Mestrado (1996) em Eng. Elétrica na UFSC e Graduação (1993) em Eng. Elétrica na UFPE. Trabalhou no Dept. de Eng. Elétrica da UFPE de 1996 a 1998 e com o Grupo de Inteligência Artificial do Centro de Informação da UFPE em um Projeto de Pesquisa para a Marinha Brasileira com Reconhecimento de Padrões de Imagem Radar. De 2000 a 2002 esteve na Companhia Energética de Pernambuco – CELPE trabalhando no planejamento da operação e da expansão dos sistemas de energia elétrica e no gerenciamento do Programa de P&D. Agora está na Companhia Hidroelétrica do São Francisco - CHESF, trabalhando no Planejamento da Expansão da Transmissão.

### **Wellington Santos Mota**

Nasceu no estado da Paraíba, Brasil, em 1946. Graduiu-se e fez o Mestrado em Engenharia Elétrica na UFCG (Universidade Federal de Campina Grande) em 1970 e 1972, respectivamente. Doutorou-se em 1981 em Engenharia Elétrica pela Universidade de Waterloo, Canadá. Desde 1971 tem estado no Departamento de Engenharia Elétrica da UFCG, onde atualmente é professor titular. De 1973 a 1977 trabalhou na CHESF.

### **Benemar de S. Alencar**

Nasceu na estado do Ceará em 1954. Fez o Doutorado, o Mestrado e a Graduação em Eng. Elétrica na UFCG (Universidade Federal de Campina Grande) em 1977, 1981 e em 1995 respectivamente. Atualmente é professor do Departamento de Engenharia Elétrica, UFCG. Suas atividades da pesquisa são principalmente otimização e inteligência artificial aplicados aos sistemas de potência.