

SISTEMA HÍBRIDO NEURO-FUZZY PARA ANÁLISE DE SEGURANÇA EM TEMPO REAL DE SISTEMAS DE POTÊNCIA

EDUARDO DE A. SODRÉ,

*DEPT – Divisão de Estudos do Sistema de Transmissão, CHESF
Rua Delmiro Gouveia, 333 – Bonji, Cep: 50761 – 901, Recife, PE, Brasil
E-mail: easodre@chesf.gov.br*

WELLINGTON SANTOS MOTA E BENEMAR DE S. ALENCAR

*DEE – Dept. de Engenharia Elétrica, UFCG
Av. Aprígio Veloso, nº 882 – Bodocongó, Caixa Postal 10.105, Campina Grande, PB, BRASIL
E-mails: wsmota@dee.ufcg.edu.br e benemar@dee.ufcg.edu.br*

Abstract— In this article is proposed a hybrid intelligent system to online voltage stability security assessment. The results are to the evaluation of the voltage stability security assessment of the real North-Northeast Brazilian system of 482 bus. The Classifiers, based on neural networks, adaptive neural-fuzzy system ANFIS and a hybrid combination of them, have been trained to give as output the secure condition of the system between one of two: alert or insecure. These conditions have been obtained based on the Margin Index calculated through the Continuation Method.

Keywords— Voltage Stability, Continuation Method, Pattern Recognition, Neuro-Fuzzy System, Hybrid Technique.

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 Classificadores foram treinados para dar como saída, de um conjunto de variáveis de entrada (ponto de operação), a condição de segurança do sistema. As condições possíveis são duas: “segura” e “insegura”, as quais são estabelecidas com base no Índice Margem calculado mediante o Método da Continuação.

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

1 Introdução

A estabilidade de tensão têm 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 suprir grande parte das dificuldades da implantação de módulos de avaliação online e contribuir de forma valiosa, como companhia indispensável, nessa tarefa.

Uma referência obrigatória é o trabalho desenvolvido no projeto europeu de P&D denominado MORE CARE, que contou com 18 pesquisadores de 5 países (Hatziaargyriou, *et al.*, 2001). 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 (Repo and Jarventausta, 2003) 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 (Tomsovic, *et al.*, 2001) foram investigadas as redes neurais Kohonen e MLP, tendo essa última se mostrado mais adequada. 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.

Na literatura constam alguns trabalhos utilizando sistemas neuro-fuzzy (Marannino, *et al.*, 2002), (Liu, Chang, and Su, 1998), os quais apresentaram resultados muito promissores.

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, 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.

Na Seção II é explicado o Método da Continuação, donde se extrai o Índice Margem baseado na análise da curva P-V utilizado para a construção dos dados de treinamento e teste. Na Seção III o Sistema Híbrido proposto é apresentado, com os respectivos resultados de seu desempenho como classificador apresentados na Seção IV. As conclusões seguem na Seção V.

2 Método da Continuação

O Índice Margem baseado na análise da curva P-V é uma das mais importantes indicações da segurança de tensão ou robustez do sistema em relação à Instabilidade de Tensão de Longo Termo envolvendo grandes distúrbios. Esse índice é obtido através do cálculo de uma suposta margem de carregamento do sistema quantificando a máxima carga que o sistema pode suportar até que o seu limite de estabilidade de tensão estática seja atingido.

O Método da Continuação emprega um esquema de predição-correção para determinar uma trajetória de soluções de um conjunto de equações de fluxo de potência, que tenham sido reformuladas para incluir um parâmetro de carga (λ) (Sodré, Almeida, e Salgado, 1997), (Cañizares, Souza, and Quintana, 1996).

O Método da Continuação consiste basicamente de duas etapas para traçar os pontos de equilíbrio enquanto um dos parâmetros do sistema muda. Partindo-se de uma solução conhecida efetua-se uma predição linear da nova solução para um especificado valor do parâmetro da continuação. Esta nova solução é então corrigida através da resolução de um fluxo de potência modificado.

A inclusão de uma variável adicional no conjunto de equações da rede elétrica requer a inclusão de uma equação a mais no conjunto de equações não-lineares a ser resolvido na etapa da correção via Método de Newton-Raphson.

A última questão relacionada ao cálculo da trajetória das soluções do fluxo de potência diz respeito ao critério de parada adotado. Desde que o interesse do método é determinar toda a parte superior da curva P-V até o ponto crítico, o incremento $\Delta\lambda$ seria positivo até o ponto crítico e negativo na parte inferior da curva.

3 Sistema Inteligente Híbrido

Em vista de suas similaridades, os sistemas fuzzy e as redes neurais são adequados para solução de muitos problemas semelhantes, e suas diferenças tem feito surgir um recente ímpeto de interesse na combinação de um sistema funcional para superar suas fraquezas individuais.

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. Todos esses classificadores foram escritos no ambiente MATLAB utilizando os Neural Network and Fuzzy Logic Toolboxes. Os resultados de seus desempenhos são comparados na Seção IV.

3.1 ANFIS - Adaptive Network-Based Fuzzy Inference System

A maioria dos sistemas neuro-fuzzy são baseados em regras fuzzy em que as técnicas de aprendizagem das redes neurais são utilizadas para ajustar de modo preciso e automático a resposta do sistema fuzzy.

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. 1 e a arquitetura ANFIS equivalente é apresentada na Fig. 2 (Jang, 1993). As funções dos nós de cada camada são descritas abaixo.

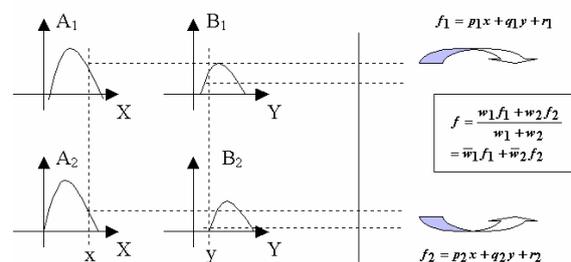


Figura 1. Sistema Fuzzy Tipo Takagi-Sugeno.

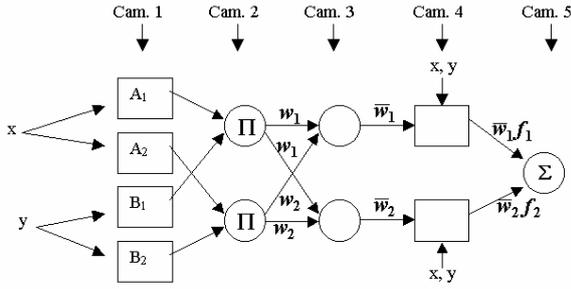


Figura 2. Arquitetura ANFIS.

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 treinamen-

to, 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 consequente.

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 se pode lançar mão dos algoritmos de treinamento das redes neurais para se ajustar os parâmetros do sistema fuzzy.

3.5 Rede Neural RPROP

RPROP, que segue de "resilient propagation" (Riedmiller and Braun, 1993) é um algoritmo de aprendizado extremamente eficiente que executa o cálculo do Δw_{ji} (atualização do peso de um neurônio) da rede MLP de forma direta, baseado no sinal do gradiente.

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 η , 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).

Para obter este algoritmo deve-se introduzir a variável Δ_{ji} que é denominada de “valor atualizado”. Cada peso $\Delta\omega_{ji}$ tem sua variável Δ_{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 Δ_{ji} é diminuída por um fator η^- . 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 ω_{ji} é diminuído pela sua variável Δ_{ji} . Se a derivada é negativa, o Δ_{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 Δ_{ji} , a atualização em dois passos seguintes é evitada. Na prática isto pode ser feito declarando $\frac{\partial E(t-1)}{\partial \omega_{ji}} = 0$ na regra de adaptação da variável Δ_{ji} .

As variáveis Δ_{ji} e os pesos ω_{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

Aproveitando-se das vantagens particulares de ambas as abordagens pretende-se ganhar o poder de “compressão” de uma grande massa de dados através da rede neural e com a abordagem fuzzy pretende-se obter uma estrutura onde possam ser incorporados o conhecimento lingüístico dos operadores.

O sistema classificador proposto foi realizado numa estrutura série. Foram compostos dois classificadores híbridos: o Híbrido RPROP (Fig. 3); e o Híbrido kNN (Fig. 4). Tendo sido seus desempenhos comparados com as técnicas analisadas até o momento.

A técnica dos k-vizinhos mais próximos (*k-Nearest Neighbours* k-NN) toma a decisão de classificação baseada nas classes a que pertencem os k exemplos mais próximos do padrão de teste (Beale and Jackson, 1990).

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, 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.

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)*.

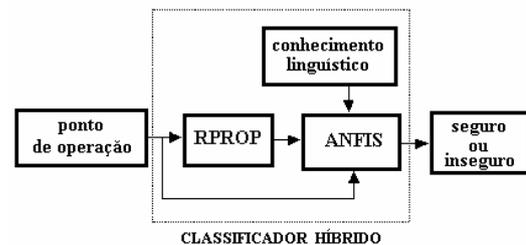


Figura 3. Sistema Classificador Híbrido RPROP.

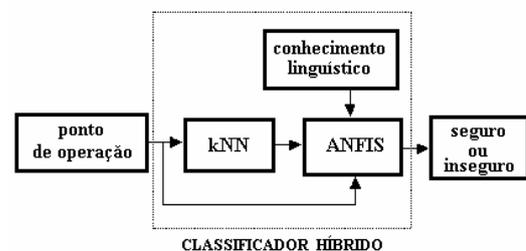


Figura 4. Sistema Classificador Híbrido kNN.

4 Resultados

O objetivo é classificar o ponto de operação do sistema como seguro ou inseguro. Essas condições são determinadas em função do Índice Margem obti-

do 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.

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.

Neste trabalho optou-se por separar o sistema em áreas conforme o Prof. Mendes (Mendes, 1999). Essa separação por área facilita a construção dos sistemas classificadores.

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. Após comparações com vetores de tamanhos diferentes se decidiu pela construção a partir de 17 barras da área leste, o que significa aproximadamente 20% do número de barras da área.

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.

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%.

Na Tabela 1 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.

As classificações falso inseguro (coluna FI da Tabela I) são o inverso das classificações falso seguro e podem ser consideradas como contribuindo para a segurança do sistema, desde que não degradem o desempenho da operação.

Para esse primeiro conjunto de resultados, considerando as variações aleatórias de 5% e 20%, foram comparados apenas os sistemas: ANFIS; RPROP; e o Híbrido RPROP. Tendo a rede neural com treinamento RPROP resultado numa taxa de acerto de 100%, conseqüentemente o Híbrido RPROP também apresenta como resultado uma taxa de acerto de 100%.

Tabela 1. Resultados com vetor padrão de 17 barras e bases de dados de percentuais de variação δ .

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

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, o que resulta em 350 parâmetros a serem otimizados.

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 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 esse vetor padrão de 164 elementos foram geradas também as 4 (quatro) Bases de Dados aleatórias com variação de 5%, 20%, 60% e 90%.

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 2. Resultados com vetor padrão de 41 barras e bases de dados de percentuais de variação δ .

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

5 Conclusão

Todos os sistemas classificadores considerados neste trabalho conduziram ao desenvolvimento de um arranjo vantajoso das duas principais técnicas de reconhecimento de padrão utilizadas, as redes neurais e os sistemas fuzzy.

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.

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.

Tendo sido estudadas e analisadas várias técnicas de IA conclui-se que essas novas ferramentas 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.

Referências Bibliográficas

- Beale and Jackson, T. (1990). *Neural Computing: An Introduction*, Adam Hilger.
- Cañizares, C. A., Souza, A. C., and Quintana, V. H. (1996), "Comparison of Performance Indices for Detection of Proximity to Voltage Collapse", *IEEE Transactions on Power Systems*, Vol. 11, No. 3, pp. 1441-1450.
- Hatzigargyriou, et al., (2001) "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 10th-13th September*, Porto, Portugal.
- Jang, J.-S. R. (1993) "ANFIS: Adaptive-Network-Based Fuzzy Inference System", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23, No. 3, pp. 665-685.
- Liu, C.W., Chang, C.-S., and Su, M.-C. (1998) "Neuro-Fuzzy Networks for Voltage Security Monitoring Based on Synchronized Phasor Measurements", *IEEE Transactions on Power Systems*, Vol. 13, No. 2, May.
- Marannino, P., Berizzi, A., Merlo, M., and Demartini, G. (2002) "A rule-based fuzzy logic approach for the voltage collapse risk classification", *Power Engineering Society Winter Meeting*, IEEE, Volume: 2, 27-31 Jan.
- Mendes, P. P. de C. (1999) "Aplicação de Redes Neurais Artificiais na Análise em Tempo Real da Estabilidade de Tensão de Regime Permanente de Sistemas Elétricos de Potência", julho, Tese de Doutorado, Coordenação dos Programas de Pós-Graduação em Engenharia – COPPE, Federal University of Rio de Janeiro.
- Repo, S. and Jarventausta, P. (2003) "Implementation Issues of On-line Data-driven Voltage Stability Assessment", *ISAP - Intelligent Systems Application to Power Systems*, Lemnos, Greece 31st August- 3rd September.
- Riedmiller, M. and Braun, H. (1993) "A direct adaptive method for faster backpropagation learning: The RPROP algorithm." *Proceedings of the IEEE International Conference on Neural Networks*, San Francisco.
- Sodré, E., Almeida K. C., e Salgado, R. (1997) "Avaliação Estática da Estabilidade de Tensão via Método da Continuação", *XIV SNPTEE*, Belém-PA.
- Tomsovic, K. (Project Leader), Bose, A., Stuart, R., Williams, B., Willis, M., Chen, L., and Vaziri, M. (2001) "Automated Operating Procedures for Transfer Limits", *PSERC – Power System Engineering Research Center*, Publication 01-05, May.