



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

22 a 25 Novembro de 2009
Recife - PE

GRUPO – IV

GRUPO DE ESTUDO DE ANÁLISE E TÉCNICAS DE SISTEMAS DE POTÊNCIA CA E CC - GAT

DESENVOLVIMENTO DE FERRAMENTA COMPUTACIONAL BASEADA EM TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA AVALIAÇÃO DE ESTABILIDADE DE TENSÃO

Ferdinando Fernandes Machado *
UFCG

Benemar Alencar de Souza
UFCG

Wellington Santos Mota
UFCG

Eduardo de Aguiar Sodré
CHESF

Michelle Ferreira Leite
UFCG

RESUMO

Este trabalho apresenta o desenvolvimento de uma ferramenta computacional capaz de avaliar a segurança de um sistema de potência em relação à instabilidade de tensão, utilizando técnicas de Inteligência Artificial (IA). Um sistema híbrido de uma Rede Neural Artificial (RNA) RPROP em série com uma *Levenberg-Marquardt* é proposto. Uma Base de Dados foi construída, objetivando o treinamento, validação e teste da RNA através do *software ANAREDE*[®]. O desempenho desse sistema foi verificado através dos recursos computacionais *Neural Network Toolbox* e *Fuzzy Logic Toolbox*, do MATLAB[®]. O *software* encontra-se em fase final de desenvolvimento e utiliza a linguagem de programação C++.

PALAVRAS-CHAVE

Estabilidade de Tensão, Técnicas de Inteligência Artificial, Base de Dados.

1.0 - INTRODUÇÃO

Os primeiros problemas de estabilidade de tensão foram notificados em 1920 e estavam associados ao suprimento de grandes centros metropolitanos através da geração hidrelétrica transmitida a longa distância (1). O modelo do setor elétrico vem sofrendo mudanças radicais durante os últimos anos, levando os sistemas de potência a operarem próximos à sua capacidade máxima de transmissão, aumentando assim o grau de complexidade dos problemas relacionados à estabilidade.

Como os estudos da instabilidade de tensão necessitam de uma análise de segurança desse fenômeno, é preciso levar em consideração muitos aspectos da operação e do funcionamento de um sistema de potência. Devido a isso, as técnicas de IA se tornaram viáveis para tais estudos, por apresentarem velocidade, precisão e eficiência maiores que as oferecidas pelos métodos tradicionais.

O índice de margem, baseado na análise da curva P-V, é uma das mais importantes indicações de segurança de tensão ou robustez do sistema em relação à estabilidade (2). Tal índice pode ser obtido através do cálculo de uma suposta margem de carregamento a partir de um ponto de operação até o ponto de máxima transferência de potência, quantificando a carga máxima que o sistema pode suportar até que seu limite de estabilidade de tensão estática seja atingido (3). O Método da Continuação pode ser aplicado para a obtenção das curvas P-V's.

O objetivo deste trabalho é desenvolver um sistema computacional baseado na combinação de RNA's, lógica *Fuzzy* e técnicas tradicionais para a avaliação da estabilidade de tensão nos sistemas de potência. O *software* será um produto de um contrato de P&D firmado entre a CHESF – Companhia Hidroelétrica do São Francisco, e a UFCG – Universidade Federal de Campina Grande.

(*) Rua Raimundo Alves da Silva, n° 148 – CEP 58.102-378 Campina Grande, PB – Brasil
Tel: (+55 83) 3322-7129 – Email: ferdinandofernandes@gmail.com.br

2.0 - MÉTODO DA CONTINUAÇÃO

O Método da Continuação (*Continuation Power Flow*) (4) emprega um esquema de predição-correção para determinar uma trajetória de soluções de um conjunto de equações de fluxo de potência, reformuladas para incluir um parâmetro de carga. Nesta metodologia mostra-se que a parametrização das equações convencionais da rede elétrica facilita a aproximação ao ponto crítico em termos de convergência via Método de *Newton-Raphson* (5).

2.1 Predição

A finalidade desta etapa é fornecer uma solução que sirva como ponto de partida para o método *Newton-Raphson*, que é aplicado na etapa de correção, a fim de prover a solução das equações do sistema para o novo nível de carregamento. Obtendo este ponto, realiza-se uma predição linear da nova solução para certo valor de parâmetro de carga. Após a predição, há a correção dessa nova solução por meio de um recálculo do fluxo de potência com modificação em suas equações tradicionais.

A expansão em série de *Taylor* do conjunto de equações $g(\vec{x}, \lambda) = 0$, no ponto $(\vec{x}, 1)$, ao longo da direção $(\Delta \vec{x}, \Delta \lambda)$ até o termo de primeira ordem, fornece os acréscimos nas variáveis de estado $\Delta \vec{x}$, expressas em função incremental do parâmetro de carga. Se no termo de primeira ordem o número de incógnitas supera o de equações, faz-se necessário especificar o valor de uma variável para que seja possível o cálculo de todas as outras. Isso equivale a resolver a seguinte equação:

$$\begin{bmatrix} [J] & \frac{\partial \vec{g}}{\partial \lambda} \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \Delta \vec{x} \\ \Delta \lambda \end{bmatrix} = \begin{bmatrix} 0 \\ \pm 1 \end{bmatrix} \quad (\text{Eq. 1})$$

Sendo J a matriz Jacobiana do fluxo de potência convencional, λ o parâmetro de carga e $\Delta \vec{u} = \begin{bmatrix} \Delta \vec{x} \\ \Delta \lambda \end{bmatrix}^t$ o vetor tangente de predição.

2.2 Correção e Escolha do Parâmetro da Continuação

A inserção do parâmetro de carga no conjunto de equações do fluxo de carga requer a inclusão de uma nova equação, a saber: $u_i - u_i^{pred} = 0$, sendo u_i o parâmetro da continuação e u_i^{pred} obtido através da adição do incremento calculado na Eq. 1 ao valor atual de u_i . O termo u_i que possuir a maior variação percentual no cálculo é selecionado como parâmetro da continuação. Tal escolha é realizada através da observação dos elementos do vetor tangente de predição.

2.3 Critério de Parada

A aproximação das soluções ao ponto crítico do sistema diminui gradativamente o valor de $\Delta \lambda$ até que ocorra sua troca de sinal, que já é um reflexo da não existência de soluções para o fluxo de carga, por ter sido atingido o limite máximo de variação das magnitudes de tensão do sistema. Dessa forma, o critério de parada é obtido quando $\Delta \lambda$ torna-se negativo, caso o intuito seja determinar apenas a parte superior da curva P-V. Para obtenção das duas partes desta curva permite-se que haja continuação do processo de soluções para o fluxo de carga, mesmo com o valor negativo de $\Delta \lambda$.

3.0 - TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Nos últimos anos a utilização de técnicas de IA tem sido proposta como um método alternativo de solução de problemas complexos, para os quais os métodos tradicionais não são suficientemente eficientes (6). Elas vêm sendo cada vez mais utilizadas na avaliação da segurança do sistema de potência em termos de estabilidade de tensão por se mostrarem mais eficientes. Dentre estas técnicas se incluem as Redes Neurais Artificiais – RNA's e a Lógica *Fuzzy*. Combinações dessas técnicas também têm sido largamente experimentadas, como por exemplo, os Sistemas *Neuro-Fuzzy* (ANFIS).

3.1 Redes Neurais Artificiais (RNA's)

A estrutura básica de uma RNA é formada por: unidades de processamento (UP's), topologia e algoritmo de treinamento, descritos a seguir:

- Unidades de Processamento (UP's):** A seção da RNA que engloba a maior parte da computação são as UP's, também chamadas de neurônios. Os sinais de entrada das UP's podem vir de uma RNA ou de outro neurônio. Cada neurônio possui um conjunto de sinapses (conexões), caracterizados pelo seu peso sináptico, que por sua vez indica o grau de influência da entrada do neurônio sobre a determinação de sua saída. Todas as conexões do neurônio passam por um somador, cuja função é realizar uma combinação linear dos sinais de entrada, ponderados de acordo com os pesos sinápticos de suas ligações. Uma função de ativação é aplicada à saída do somador, para limitar sua amplitude em um intervalo normalizado. Cada somador recebe uma entrada fixa denominada de polarização (*bias*), que tem o objetivo de aumentar o grau de liberdade da função de ativação e, conseqüentemente, a capacidade de aproximação da rede. O valor da polarização é ajustado da mesma maneira que os dos pesos sinápticos. O modelo de um neurônio artificial (7) é ilustrado na Figura 1 - (a).
- Topologia:** Uma RNA é constituída por diversos neurônios dispostos em camadas, denominadas: camada de entrada, camada oculta e camada de saída. A topologia de uma RNA é definida pela quantidade de neurônios e de camadas, como também pela forma de interligação dos neurônios. O tipo de RNA mais utilizado para aplicações em sistemas de potência é a *multilayer perceptron*, ou *perceptron* de múltiplas camadas (MLP). Esse tipo de topologia representa uma generalização da rede do tipo *perceptron* de camada única. Os sinais de entrada são propagados através das camadas até atingir a última, que se trata da camada de saída. Uma RNA tipo MLP (7) é apresenta na Figura 1- (b).
- Algoritmo de Treinamento:** o treinamento é caracterizado por um comportamento adaptativo que produz melhoria gradual no desempenho da rede. Para que seja possível realizar um treinamento supervisionado de uma RNA é necessário que um conjunto de dados entrada-saída com as informações relevantes ao perfil do problema seja apresentado a mesma. Vetores de entrada com seus respectivos vetores de saída desejados formam os padrões de treinamento. Dentre os diversos algoritmos de treinamento aplicados às RNA's, o algoritmo de retropropagação de erro (*backpropagation*) é amplamente utilizado.

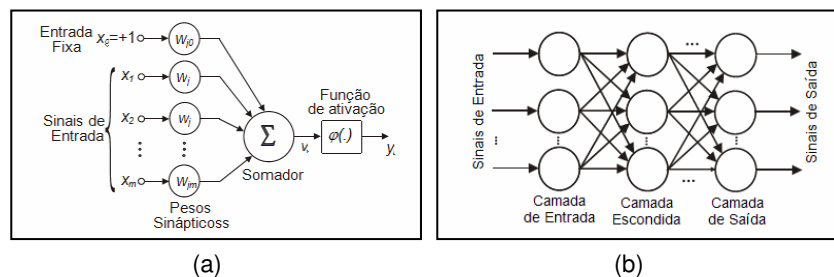


FIGURA 1 – (a) Modelo de Um Neurônio Artificial; (b) Rede *Multilayer Perceptron* (MLP)

3.1.1 Algoritmo de Treinamento *Resilient Propagation* (RPROP)

O algoritmo RPROP trata de uma modificação do algoritmo *backpropagation* (8). A diferença entre eles é que, no RPROP, o valor da atualização dos pesos é calculado pela avaliação do sinal do gradiente local de cada peso, e não de seu valor, de uma interação para outra. Isto elimina problemas encontrados com o algoritmo *backpropagation* e faz com que a convergência na fase de treinamento se torne rápida. O método realiza uma adaptação direta da taxa de aprendizado η , baseado no sinal do gradiente local de cada peso, e não de seu valor, de uma interação para outra, fazendo com que a convergência na fase de treinamento se torne rápida (8). Cada parâmetro de uma MLP possui uma atualização individual Δ_{ij} que determina o grau de ajuste deste peso e é feita do seguinte modo:

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \times \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial \xi_{med}^{(t-1)}}{\partial w_{ij}} \times \frac{\partial \xi_{med}^{(t)}}{\partial w_{ij}} > 0 \\ \eta^- \times \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial \xi_{med}^{(t-1)}}{\partial w_{ij}} \times \frac{\partial \xi_{med}^{(t)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (\text{Eq. 2})$$

em que $0 < \eta^- < 1 < \eta^+$, ξ_{med} é a função energia de erro média e $\Delta_{ij}^{(t-1)}$ é a taxa anterior de atualização dos pesos. Além de acelerar o processo de aprendizado, permitindo o tratamento de grandes massas de dados, para a maioria dos problemas não é necessário fazer alterações nos parâmetros do algoritmo para a obtenção da convergência ótima.

3.1.2 Algoritmo de Treinamento *Levenberg-Marquardt*

O algoritmo *Levenberg-Marquardt* representa uma aproximação do método de *Newton* (9), que é obtida introduzindo-se o parâmetro μ na equação original, o que resulta:

$$\Delta x = [J^T(x)J(x) + \mu I]^{-1} J^T(x)e(x), \quad (\text{Eq. 3})$$

sendo I a matriz identidade, J a matriz Jacobiana e $e(x)$ o erro. O parâmetro μ é multiplicado por um fator β , sempre que o ajuste dos pesos provocarem um aumento da função e é dividido por β , quando há uma redução. Portanto, o parâmetro μ tem a função de estabilizar o treinamento, ajustando a aproximação de forma a utilizar a rápida convergência do método de *Newton* e evitar passos muito grandes que possam levar a um erro de convergência.

O ponto principal do método *Levenberg-Marquardt* para o treinamento de redes neurais MLP's é o cálculo da matriz Jacobiana, que é realizado a partir de uma simples modificação do algoritmo *backpropagation*.

3.2 Sistema *Neuro-Fuzzy* (ANFIS)

Os Sistemas *Fuzzy* interpretam matematicamente informações imprecisas advindas de variáveis lingüísticas através de um conjunto de regras *If-then*. A criação dessas regras torna-se, em muitos casos, um trabalho lento e exaustivo, tendo em vista a necessidade de previsão de todas as entradas e saídas do sistema pelas regras geradas.

A finalidade dos sistemas denominados *Neuro-Fuzzy* (ANFIS) é aproveitar ao máximo os benefícios propostos individualmente, de forma que os utilizando em conjunto, o novo sistema seja mais eficiente. Grande parte dos Sistemas *Neuro-Fuzzy* são baseados em regras *Fuzzy* onde as RNA's ajustam de forma precisa e automática a resposta do *Fuzzy*.

O Sistema *Fuzzy* – apresentado na Figura 2 - (a), e a sua arquitetura ANFIS equivalente – apresentada na Figura 2 - (b) (10) possuem duas variáveis de entrada x e y , uma variável de saída z , assim como duas regras *If-then* do tipo *Takagi-Sugeno*. Uma base de regras para esse sistema é descrita a seguir:

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** $f_2 = p_2x + q_2y + r_2$

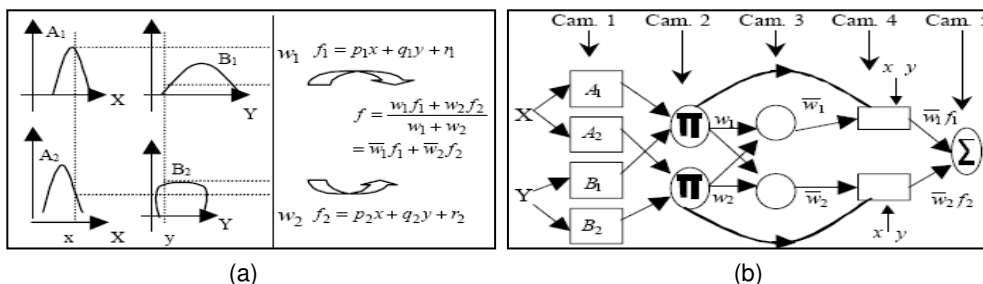


FIGURA 2 – (a) Sistema *Fuzzy* Tipo *Takagi-Sugeno*; (b) Arquitetura ANFIS

A primeira camada calcula o grau de pertinência para o qual as variáveis de entrada (x , y) satisfazem a função de pertinência. O valor que especifica o grau de pertinência é equacionado por $O_i^1 = \mu_{A_i}(x)$, em que i representa um nó, μ_{A_i} a função de pertinência e x uma entrada do sistema. Na segunda camada, os nós não sofrerão treinamento. Cada nó calcula o grau de ativação da regra correspondente. Os nós multiplicam os sinais de entrada através de $w_i = \mu_{A_i}(x) \times \mu_{B_i}(y)$, com $i = 1, 2$; enviando esse resultado para a saída. Na terceira camada é realizada

uma normalização, onde o i -ésimo nó calcula a razão entre o grau de ativação da i -ésima regra e a soma dos graus de ativação de todas as regras. Essa normalização é feita por $\bar{w}_i = w_i / (w_1 + w_2)$, com $i = 1, 2$. Já na quarta camada, as saídas dos nós são obtidas pela multiplicação entre os valores normalizados da camada antecedente e os valores conseqüentes da regra. Os nós utilizam a função $O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$, em que w se constitui saída da camada três. Por fim, a camada cinco contém apenas um nó que calcula a saída do sistema através de um somatório de todos os sinais de entrada através de $O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$.

3.4 Sistema Híbrido RPROP

Aproveitando as particularidades das abordagens neural e *fuzzy*, onde o poder de compressão de uma grande massa de dados é facilitado através da rede neural, juntamente com a abordagem *fuzzy* para a incorporação do conhecimento linguístico dos operadores, foi desenvolvido o sistema híbrido RPROP (5). Este sistema consiste numa estrutura série de uma rede neural com algoritmo de treinamento RPROP e a incorporação do Sistema Neuro-Fuzzy ANFIS.

Nesse classificador, o ponto de operação é primeiramente avaliado pelo sistema RPROP da estrutura série. Em seguida, o resultado é avaliado pelo sistema Neuro-Fuzzy ANFIS, gerando a saída do classificador. Veja a Figura 3.




FIGURA 3 – Sistema Classificador Híbrido RPROP.

3.4 Sistema Híbrido LM

O sistema híbrido LM constitui um arranjo série de uma rede neural RPROP com uma rede neural *Levenberg-Marquardt*. A primeira se trata de uma RNA com algoritmo de treinamento de alta eficiência no processo de aprendizado para grandes quantidades de dados e de elevada robustez com relação à escolha dos parâmetros iniciais. A segunda é uma rede de alta precisão para poucas centenas de parâmetros a otimizar.

Primeiramente, o ponto de operação é apresentado à rede neural RPROP, que trata a massa de dados para que seja apresentada em seguida, de forma reduzida, à rede neural *Levenberg-Marquardt*, viabilizando o uso deste último algoritmo, ilustrado na Figura 4.




FIGURA 4 – Sistema Classificador Híbrido LM.

4.0 - ESTUDO DE CASO – ÁREA LESTE DO SUBSISTEMA NORDESTE

Existem várias formas de se analisar o comportamento dos sistemas para estudos de índices e margens relativos à instabilidade de tensão. A abordagem utilizada no presente artigo levou em consideração o aumento total e uniforme das cargas em todas as barras do sistema, mantendo-se constante o fator de potência.

O objetivo das técnicas de IA é classificar o estado do sistema entre seguro ou inseguro quanto à estabilidade de tensão. O estado da seguridade do sistema é determinado previamente em função do índice margem da curva P-V, calculado através do Método da Continuação. Foi estabelecido que, para uma operação segura do sistema, seu máximo carregamento, a partir de um ponto de operação, fosse superior a 5%, caso contrário, o sistema era considerado como inseguro. Diante de uma indicação de operação insegura, não necessariamente o sistema estaria condenado à instabilidade, mas que o mesmo estaria em risco de ocorrência de tal fenômeno. No entanto, os operadores teriam que tomar providências necessárias para a normalização do sistema de potência.

A estratégia adotada para o caso da análise de estabilidade de tensão de sistemas de grande porte, foi a separação do mesmo em áreas (11). A partir destas áreas são escolhidas apenas algumas barras para a construção dos vetores padrões utilizados para o treinamento dos classificadores. Desta forma, obtemos um vetor padrão de dimensão reduzida, facilitando o processamento dos sistemas classificadores. Se apenas uma área é considerada insegura, todo o sistema em questão também é classificado como inseguro.

O Sistema Norte-Nordeste, mais precisamente a Área Leste do Subsistema Nordeste, foi a área escolhida para a extração das características do sistema de potência que formará a Base de Dados dos classificadores. Vale salientar que a pesquisa realizada para tal área seria a mesma para todas as outras áreas, com relação à metodologia de escolha do número de barras pertencentes ao vetor padrão e a escolha da melhor estrutura dos classificadores.

A Área Leste do Subsistema Nordeste é composta por 84 barras alimentadas principalmente por 500 kV da SE de Recife-2; 81 linhas de transmissão; 5 unidades geradoras, sendo 2 usinas termelétricas e 3 parques eólicos; e 103 transformadores, operando nos níveis de tensão de 500 kV, 230 kV, 138 kV, 69 kV.

4.1 Construção da Base de Dados

De posse dos dados referentes à Área Leste, fez-se uma análise de máximo carregamento para gerar os pontos de operação seguros e inseguros, para o caso de carga pesada no ano de 2010. Também foi realizada uma análise de contingências, onde foram escolhidas algumas que mais afetariam a estabilidade de tensão do sistema em questão. Logo, dado um ponto de operação, foi avaliado se para todas as contingências escolhidas o máximo carregamento do sistema encontrava-se dentro dos limites aceitáveis de operação. Para o ponto ser considerado como seguro é necessário que todas as contingências aplicadas atendam o requisito de máximo carregamento.

Algumas contingências consideradas para a Área Leste são as seguintes: saída da linha de transmissão que liga a barra S. Mesa – 500 kV à barra Correntina – 500 kV, saída da linha de transmissão que liga a barra Ribeiro Gonçalves – 500 kV à barra Colinas – 500 kV, saída da linha de transmissão que liga a barra P. Dutra – 500 kV à barra Boa Esperança – 500 kV, saída de um compensador síncrono de Recife II. Cada contingência considerada tem o seu índice margem específico, o que a faz pertencer à classe segura ou à dos padrões de alerta.

O programa ANAREDE[®] foi utilizado para a obtenção da Base de Dados, constituída pelos padrões de treinamento, validação e teste. Estes padrões são compostos pelas grandezas elétricas presentes na operação do sistema: tensão e ângulos das barras, injeções de potência ativa e reativa (valores em pu).

Levando em consideração que a construção de vetores padrão não possui dados de todas as 84 barras da Área Leste, foi feita uma análise para obtenção das barras mais sensíveis dessa parte do sistema: Mussurú, Sta Rita, Penedo, Pirapama, Bongji, Pau Ferro, Mirueira e Maceió. Todas operando no nível de tensão de 69 kV. Esta é a área que irá sofrer as piores consequências da instabilidade de tensão.

Um fator importante para a construção dos padrões de treinamento e teste é o número de barras sensíveis consideradas, visto que, quanto maior for a representação do sistema elétrico de potência, maior será o esforço computacional para o processamento do sistema classificador. Para esta pesquisa foram considerados vetores de dimensões 20, 68 e 164, que correspondem à utilização das grandezas elétricas de 5, 17 e 41 barras sensíveis do sistema, respectivamente. Também vale ressaltar que foi necessário realizar uma normalização dos dados dos padrões de treinamento, validação e teste, dividindo todos os elementos de cada vetor padrão pelo máximo valor registrado, de acordo com a grandeza elétrica que cada elemento descreve.

Com a Base de Dados montada, o desempenho dos Classificadores foram comparados através do uso dos recursos computacionais *Neural Network Toolbox* e *Fuzzy Logic Toolbox* do MATLAB®.

5.0 - RESULTADOS

Nesta seção são apresentados os resultados obtidos na classificação da seguridade da estabilidade de tensão da área Leste do Subsistema Nordeste. Considerou-se uma Base de Dados formada por um vetor padrão de 5 barras, 17 barras e 41 barras. Também são apresentados os resultados dos classificadores considerados e a comparação entre os mesmos.

A primeira etapa representa o desempenho dos sistemas de IA para a Base de Dados formada por um vetor padrão de 5 barras. Neste conjunto, o sistema híbrido LM apresentou o melhor resultado, com uma taxa de acerto de 92,08%.

Para o segundo conjunto de resultados, onde a Base de Dados é formada por um vetor padrão de 17 barras, o sistema híbrido LM também apresentou o melhor resultado, com taxa de acerto de 98,33%, porém o seu tempo de treinamento foi ligeiramente superior ao dos demais classificadores.

Por fim, o conjunto de resultados para a Base de Dados formada por um vetor padrão de 41 barras apresentou resultados semelhantes ao segundo conjunto de resultados, com a exceção de que o tempo de treinamento foi bem inferior aos demais casos. Justifica-se pelo fato de que, apesar do maior número de parâmetros a otimizar, esta Base de Dados possui a maior representação do sistema, o que facilita a convergência dos classificadores para o erro mínimo pré-estabelecido.

Apesar dos resultados da rede neural RPROP o classificar como o mais rápido, os demais classificadores apresentaram taxas de acertos superiores, sobretudo o sistema híbrido LM, que apresentou as maiores taxas de acertos. Os resultados finais estão resumidos na Tabela 1.

TABELA 1 – Resultados

Nº de Barras Sensíveis Consideradas	Sistema Classificador	Tempo de Treinamento (s)	Taxa de Acerto (%)
5 BARRAS	RPROP	247,66	91,04
	HÍBRIDO RPROP	261,83	91,87
	HÍBRIDO LM	253,77	92,08
17 BARRAS	RPROP	56,78	97,91
	HÍBRIDO RPROP	56,92	98,12
	HÍBRIDO LM	57,09	98,33
41 BARRAS	RPROP	5,25	98,12
	HÍBRIDO RPROP	5,37	98,12
	HÍBRIDO LM	5,69	98,33

6.0 - CONCLUSÕES

A avaliação da estabilidade de tensão dos sistemas de potência através do sistema híbrido LM apresentou a melhor capacidade de solução entre os classificadores pesquisados, embora tenha requerido um tempo de treinamento ligeiramente superior. Entretanto, considerando que o esforço computacional não é um fator crítico para a aplicação final a que esta pesquisa se destina, o algoritmo híbrido LM foi escolhido para o desenvolvimento da versão definitiva do *software* que é objetivo do projeto de P&D.

O processo de construção do Banco de Dados se mostrou um fator determinante para o desempenho dos sistemas avaliados. Processo esse que levou em consideração a extração apenas das características relevantes do sistema elétrico de potência, viabilizando o uso das técnicas de IA. Outro destaque também deve ser feito ao tratamento dos dados efetuado através da normalização dos vetores padrões, tendo como benefício a melhoria dos resultados obtidos.

A utilização do *Network Toolbox* e *Fuzzy Logic Toolbox* do software MATLAB®, teve um papel fundamental na avaliação dos classificadores, mediante a qual se decidiu pelo sistema híbrido LM. Atualmente esse sistema está em fase de desenvolvimento em linguagem de programação C++.

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) KUNDUR, P.; MORISON, K. On-line Dynamic Security Assessment of Power Systems. In: SIMPÓSIO DE ESPECIALISTAS EM PLANEJAMENTO DA OPERAÇÃO E EXPANSÃO ELÉTRICA, 6., 1998, Salvador. Anais do VI Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, 1998.
- (2) TAYLOR, C. W. *Power System Voltage Stability*. 2. ed. New York: McGraw-Hill, 1994.
- (3) SODRÉ, E.; MOTA, Wellington S. Um Sistema Neuro-Fuzzy para Análise de Segurança da Estabilidade de Tensão. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 13., 2000, Florianópolis. Anais do XIII Congresso Brasileiro de Automática, 2000. p. 2036-2041
- (4) AJJARAPU, V.; CHRISTY, C. The continuation power flow: A tool for steady state voltage stability analysis. *IEEE Transactions on Power Systems*, v. 7, p. 416-423, feb. 1992.
- (5) SODRÉ, E.. Avaliação da Estabilidade de Tensão através das Técnicas de Inteligência Artificial. Tese (Doutorado em Engenharia Elétrica). Universidade Federal de Campina Grande, Campina Grande, 2006.
- (6) TAYLOR, C. W. Survey of Advanced Angle Stability Control: progress report on behalf of CIGRÉ TF 38.02.17. In: SIMPÓSIO DE ESPECIALISTAS EM PLANEJAMENTO DA OPERAÇÃO E EXPANSÃO ELÉTRICA, 6., 1998, Salvador. *Proceedings* do VI Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, 1998.
- (7) SOUZA, B. A. et al. Classificação de Falhas Via Redes Neurais Artificiais. In: SEMINÁRIO BRASILEIRO SOBRE QUALIDADE DA ENERGIA ELÉTRICA, 5., 2003, Aracajú. Anais do V Seminário Brasileiro sobre Qualidade da Energia Elétrica, 2003. p. 163-168.
- (8) RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: The rprop algorithm. *Proceedings of the IEEE Int. Conf. on Neural Networks*, San Francisco, USA, p. 586-591, 1993.
- (9) HAGAN, M. T.; MENHAJ, M. B. Training Feedforward Networks with the Maquardt Algorithm. *IEEE Trans. On Neural Networks*, v. 6, n. 6, p. 989-993, nov. 1994.
- (10) JANG, J.-S. R. ANFIS: Adaptive-Network-Based Fuzzy Inference Systems. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 23, n. 3, p. 665-685, may/jun 1993.
- (11) MENDES, P. P. de C. Aplicação de Redes Neurais Artificiais na Análise em Tempo Real da Estabilidade de Tensão de Regime Permanente de Sistemas Elétricos de Potência. Tese (Doutorado em Engenharia Elétrica), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1999.

8.0 - DADOS BIOGRÁFICOS

Ferdinando Fernandes Machado

Nascido em Campina Grande, PB em 14 de agosto de 1983.

Mestrando em Engenharia Elétrica na UFCG e Graduado (2007) em Engenharia Elétrica, modalidade Eletrotécnica na UFCG.

Empresa: UFCG – Universidade Federal de Campina Grande, desde 2008.

Atua no Setor de Engenharia Elétrica da Prefeitura Universitária – SEE.