

Monitoração da Segurança Estática do Sistema Sul – Sudeste através da Tecnologia de Redes Neurais

José Folhadela Neto, Eduardo Sodr , Manoel Afonso de Carvalho Jr.
Departamento de Engenharia El trica e Sistemas de Pot ncia - UFPE - CTG
Av. Acad mico H lio Ramos, s/n – Cidade Universit ria
50740-530 Recife PE
E-mails: gge@nlink.com.br, macj@npd.ufpe.br

Abstract

This paper shows the effectiveness of Neural Network in the assessment of system security, as related to Long Term Voltage Instability. The system operating conditions are determined from the Margin index that is obtained through a Continuation Method. It is also demonstrated that, for the studied problem, a model with supervised learning, Multilayer Perceptron, shows better results than a model with non-supervised learning, such as the Kohonen neural net.

The methodology that is described is applied to actual system with 77 buses, derived from the South – Southwest Brazilian power network.

1. Introdu o

As estrat gias tradicionais para a solu o de problemas em Sistemas de Pot ncia s o caracterizadas pelo desenvolvimento de modelos matem ticos tratados atrav s de algoritmos computacionais envolvendo t cnicas de simula o, solu es num ricas, programaa o matem tica, t cnicas de controle, etc. Estas revelam-se, em alguns casos, demoradas e trabalhosas, ou at  mesmo invi veis. A mais nova abordagem dos problemas relacionados   opera o e ao planejamento dos sistemas el tricos, faz uso das novas t cnicas conhecidas como Intelig ncia Artificial (IA). As duas  reas de IA mais promissoras e de mais freq ente utiliza o s o os Sistemas Especialistas e as Redes Neurais (RN), com aplica es rotineiras nas empresas do setor el trico [1]. O potencial de utiliza o da tecnologia de Redes Neurais em Sistemas de Pot ncia inclui: previs o de carga, an lise de seguran a, diagn stico de falhas, estima o de estado, projetos de estabilizadores, comiss oamento de unidades geradoras, controle, etc [2].

A proposta deste artigo foi inspirado no estudo de um m dulo de an lise de seguran a baseado em Redes Neurais. O objetivo da rede neural proposta   classificar o ponto de opera o dentro de duas condi es distintas: seguro ou alerta. Tomando-se como base o sistema el trico Sul-Sudeste, o problema consiste em informar se sistema encontra-se em um estado SEGURO ou

INSEGURO (ALERTA), a partir de um dado padr o do mesmo.

2. M dulo de an lise de seguran a

O centro de controle de uma empresa de energia el trica (Energy Management System - EMS)   o  rg o respons vel pela supervis o e o controle do processo de gera o, transmiss o e distribui o de energia el trica. Al m disso serve como interface entre o processo el trico e outros setores da empresa, tais como planejamento e faturamento. As fun es normalmente encontradas num centro de controle s o: o Controle Autom tico de Gera o (CAG), o Controle Supervis rio (CS) ou SCADA e as Fun es da Seguran a em Tempo Real (FSTR).

A informa o sobre a seguran a do sistema utilizando a t cnica de Redes Neurais pode ser avaliada a cada nova varredura do sistema de aquisi o de dados SCADA, informando ao operador quando o sistema se encontra no estado INSEGURO, n o necessitando, assim, que ele determine, em intervalos de tempo indefinidos, o processamento de uma lista de conting ncias para ap s avalia o dos resultados, concluir sobre o estado de opera o do sistema. Como resultado do emprego da t cnica de Redes Neurais, obt m-se uma maior rapidez nas informa es sobre a seguran a do sistema.

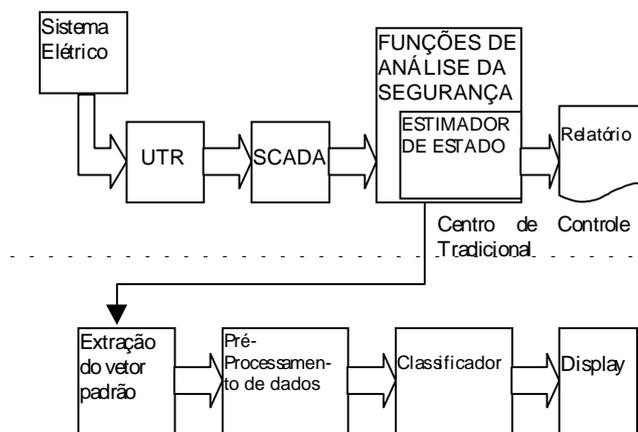


Figura 1- Diagrama de blocos simplificado (fase ON-LINE)

A figura 1 mostra um diagrama simplificado da técnica de redes neurais que pode ser implementada em um centro de controle em tempo real.

Após efetuado o treinamento da rede neural(fase OFF-LINE), que consiste em informar os possíveis pontos de operação do sistema(incluindo situações de contingência), esta rede pode ser colocada para operar em tempo real, lendo os valores das grandezas elétricas presentes na operação do sistema elétrico e classificando-os(fase ON-LINE). As entradas da rede podem ser obtidas de um estimador de estados, que fornece dados de maior confiabilidade, operando, portanto, de forma conjunta com o módulo de monitoração de segurança.

O presente artigo demonstra a viabilidade da utilização da tecnologia das Redes Neurais na determinação da segurança do sistema, em relação à Instabilidade de Tensão de Longo Termo, fazendo uso das facilidades de programação do pacote computacional MATLAB(toolbox de Redes Neurais)[6]. As condições do sistemas são determinadas em função do índice Margem obtido através do Método da Continuação utilizado por Sodré [7].

Também é demonstrado que um modelo com aprendizado supervisionado(Perceptron multicamadas), apresenta resultados melhores que um modelo com aprendizado não supervisionado(rede neural de Kohonen), para o problema acima definido.

São apresentados resultados obtidos com a aplicação da metodologia num sistema real de 77 barras da região sul do Brasil, o sistema Sul-Sudeste.

O Sistema Sul-Sudeste é a representação do sistema Sul do Brasil alimentado por Itaipu e pelo sistema do Sudeste do país. Consiste de 77 barras, 144 linhas de transmissão, 14 geradores, 7 transformadores com LTC, operando nos níveis de tensão de 750, 525, 230, 138, e 69 kV.

A área crítica indicada pelo vetor tangente de predição são as seguintes barras: S. Maria – 138; S. Vicente - 138 e Alegrete - 69. Esta é a área que irá sofrer as piores consequências da Instabilidade de Tensão. Os geradores relevantes para o sistema Sul-Sudeste são: Itaipu, Salto Santiago, Passo Fundo, Salto Osório, Jorge Lacerda, Charqueado e GBM Rocha.

Os elos de transmissão avaliados como os mais importantes são aqueles que ligam o sistema sul ao sudeste, particularmente o transformador Ivaiporã-525. Dentro do sistema sul, algumas das linhas mais importantes são: as LT's que estão conectadas à barra de Gravataí-525; a LT(92) que liga a barra FAreia-525 a barra Curitiba-525; a LT(102) da barra FAreia-525 a C.Largo-525 e também a LT(2) da barra Alegret2-230 a Bagé-2-230 [7].

3. Instabilidade de tensão de longo-termo

O fenômeno da instabilidade de tensão apresenta, como característica própria a progressiva depreciação da tensão (processo iniciado por um carregamento desordenado, ou contingência) atingindo, em certos casos, uma condição de equilíbrio cujos valores de magnitude são inaceitáveis, o que caracteriza o colapso de tensão .

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 [3], [4]. Este índice é quantificado numa suposta margem do ponto de operação ao ponto de máxima transferência de potência quantificando a máxima quantidade de carga que o sistema pode suportar até que o seu limite de estabilidade de tensão estática seja atingido.

A figura 2, ilustrando a obtenção deste índice, mostra duas curvas P-V's para duas situações diferentes: uma situação de operação corrente e um ponto de operação pós-distúrbio. A margem de carregamento MC_{oa} (operação atual) é maior que a margem de carregamento do ponto de operação pós-distúrbio, MC_{pd} . A curva P-V devida ao ponto de operação pós-distúrbio também apresenta uma relação de variação da tensão (ΔV) em relação à potência (ΔP), maior que a curva P-V devida à operação atual.

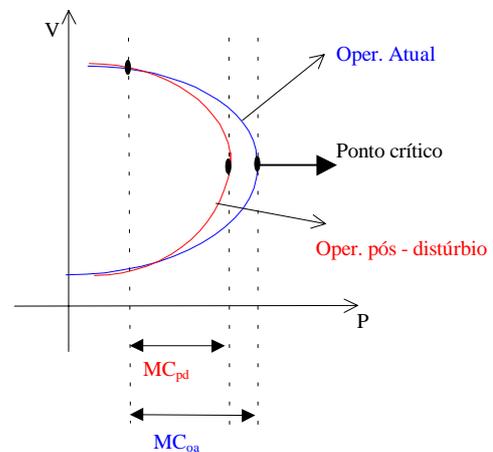


Figura 2 Curvas P-V's

Quanto menor for a distância do ponto de operação ao ponto crítico, maior a possibilidade do sistema apresentar problemas se for submetido a um distúrbio. Posto que, quanto mais próximo do ponto extremo da curva o ponto de operação estiver, mais as tensões apresentarão o comportamento de grande declínio em função de pequenas variações de carga. Estas variações de carga são devidas à grande parcela de potência reativa que se apresenta no pico de demanda do sistema.

4. Formulação do problema de diagnóstico

• **Problema:** efetuar o diagnóstico de estados operativos do Sistema Sul-Sudeste em relação à instabilidade de tensão.

Existem várias formas de se analisar o comportamento dos sistemas para estudos de índices e margens relativos à Instabilidade de Tensão. Pode-se aumentar uniformemente toda a carga do sistema (ativa e reativa) e, relacionadamente, aumentar-se as potências ativas de geração, ou então apenas a carga ativa e/ou reativa de algumas barras, mantendo-se, ou não, constante o fator de potência. 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 [9]. O modelo utilizado neste estudo para a representação da carga é o modelo de potência constante.

• **Saída:** O objetivo da Rede Neural proposta é classificar o ponto de operação do sistema entre uma de duas condições: seguro ou alerta. As condições do sistema são determinadas em função do Índice Margem obtido através do Método da Continuação. Para uma condição segura, foi estabelecido que o carregamento máximo, a partir do ponto de operação do sistema, fosse maior que 3%. No caso de uma condição alerta, o carregamento máximo estaria abaixo de 3%.

É importante observar que estes valores apenas servem como delimitadores de uma superfície de separação de classes. Tal índice, para ser efetivo, requer para sua solução apropriada, experiência, julgamento e sensibilidade por parte dos operadores do sistema. No caso de uma condição de operação do sistema ser classificada como alerta não necessariamente significa que o sistema estaria irremediavelmente fadado à Instabilidade de Tensão, mas sim que este teria uma forte propensão à mesma. Esta indicação serviria como alerta aos operadores, que estariam aptos a tomarem algumas das medidas importantes contra a Instabilidade de Longo Termo, resumidas em [4] por Carson Taylor.

• **Entradas:** Configuração do sistema, medidas de grandezas monitoradas ou calculadas.

Os elementos dos vetores \vec{x} - padrões de entrada -, são definidos com os valores das grandezas elétricas presentes na operação do sistema, as tensões e os ângulos de todas as barras, bem como todas as injeções de potência ativa e reativa (todos os valores em pu).

$$\vec{x} = [v_1 \ \theta_1 \ \dots \ v_n \ \theta_n \ p_1^{inj} \ q_1^{inj} \ \dots \ p_n^{inj} \ q_n^{inj}]^t$$

onde v_i , θ_i , p_i^{inj} e q_i^{inj} são as tensões, os ângulos e as injeções de potência ativa e reativa respectivamente,

para $i=1, \dots, n$; onde n é o número total de barras. As injeções de potência são definidas como

$$p_i^{inj} = p_i^{ger} - p_i^{carg}$$

onde p_i^{ger} é a geração de potência ativa da barra i e p_i^{carg} é a carga ativa da barra i (da mesma forma para a potência reativa).

Tais padrões são determinados através de uma aproximação da curva de carga diária do sistema e avaliados no intervalo de tempo da curva onde o sistema se encontra mais carregado (horário de pico), posto que os incidentes de Instabilidade de Tensão relatados na literatura acontecem prioritariamente neste momento [3]. Foram simulados dois dias de operação para extração dos vetores \vec{x} que fazem parte dos conjuntos de treinamento e teste. A diferença entre as duas curvas de carga diárias foi a mudança dos fatores de potência mostrado na Tabela 1.

Tabela 1 – Fatores de potência de algumas barras do sistema

BARRAS	Fator de	Fator de
	Potência	Potência
	1º dia	2º dia
Alegrete-2-69	0.956	0.820
Alegrete-1-69	0.970	0.810
Bagé-2-230	0.947	0.819
Jacuí-138	0.928	0.808
S. Maria-1-138	0.918	0.813
S. Maria -3-230	0.922	0.820
S. Vicente-138	0.917	0.809
MÉDIA	0.937	0.814

Algumas das barras escolhidas para a mudança do fator de potência pertencem à área crítica do sistema. É considerada também uma Análise de Contingências, onde foram escolhidas algumas contingências entre os elementos do sistema mais importantes na manutenção da estabilidade de tensão (seção 2). Algumas outras contingências foram escolhidas dentro da área crítica indicada pelo vetor tangente de predição. E, algumas outras, foram escolhidas para que o conjunto dos elementos para teste e treinamento fosse representativo. Não estão sendo levadas em consideração, nesta análise de contingências, o atendimento a algumas das restrições operacionais tais como magnitude de tensão e fluxo nos equipamentos de transmissão.

Algumas das contingências que devem ser ressaltadas são a saída dos Geradores da Usina Termelétrica de Jorge Lacerda, citada como contingência característica dos incidentes de Instabilidade de Tensão na região Sul [9]; saída das unidades geradoras de S. Osório, Passo Fundo e Jacuí; saída da Linha de Transmissão que liga a barra S. Vicente - 138 a barra Alegrete1 - 138; saída da Linha de Transmissão que liga a barra C. Ind. - 230 a barra Pelotas - 230.

Cada contingência considerada tem o seu Índice Margem específico, o que a faz pertencer à classe segura ou à classe dos padrões alerta. A figura 3 apresenta três curvas P-V's da barra S. Vicente - 138, relativas a um ponto de operação do sistema com duas condições de contingência (curvas 2 e 3). A curva 3 tem um Índice Margem menor que 3%, o que faz com que esta condição de operação do sistema pertença à classe alerta. As contingências consideradas para a curva 3 foram as saídas conjuntas das unidades geradoras de Jacuí e Itaúba.

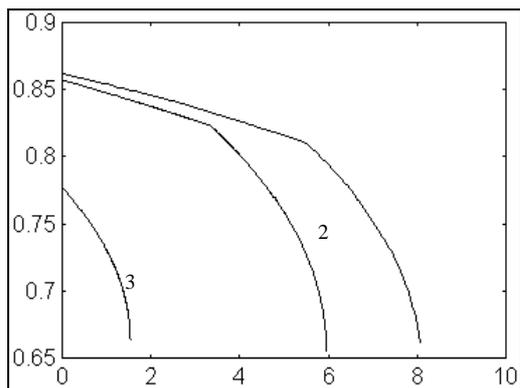


Figura 3 – Curvas P-V's da barra S. Vicente-138

Para uma operação eficiente, os padrões foram normalizados de forma tal que os valores de entrada da rede estivessem entre -1 e +1. A normalização dos dados atua no sentido de evitar que a rede dirija-se excessivamente à saturação.

É importante ressaltar a forma como foi feita a normalização dos dados e a melhora dos resultados obtidos com esta normalização. Todos os elementos dos conjuntos de treinamento e teste (vetores padrões) são normalizados pelo mesmo valor, ou seja, divide-se todos os valores de tensão de todos os vetores pela maior tensão verificada. Tal procedimento também aplica-se a ângulos e injeções de potência ativa e reativa.

Na geração dos elementos para o estudo assegurou-se também, além da normalização, que cada ponto de operação (ponto da curva de carga diária) tivesse uma contingência que pertencesse à classe segura e outra contingência que levasse o sistema à uma condição de operação alerta.

Estas considerações garantiram, conforme verificado, a menor margem de erro nos testes com as MLP's consideradas

5. Resultados

5.1. Perceptron multi-camadas

Esta rede possui sentido único de informação, que se dá na direção da camada de entrada até a camada de saída [8]. De maneira geral, a MLP possui uma camada

de entrada (*input layer*), uma camada de saída (*output layer*) e uma ou mais camadas escondidas (*hidden layer*). Cada camada terá uma ou mais unidades de processamento (*neurônios*). A soma das entradas, multiplicadas pelos seus respectivos pesos, representam a entrada total do neurônio.

Uma MLP é simplesmente uma interconexão de camadas formadas por estas unidades de processamento (Figura 4).

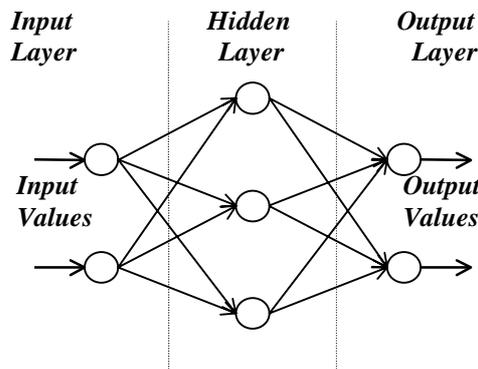


Figura 4 - Perceptron multi - camadas com uma camada oculta

5.1.1. Processo de treinamento

O treinamento foi realizado utilizando o algoritmo *backpropagation* com termo *momentun* constante $\alpha=0.95$, conjuntamente a um algoritmo adaptativo para a variação dinâmica do coeficiente de aprendizado $\eta(t)$, onde t é o contador do número de ciclos de aprendizado (*épocas*).

O algoritmo Backpropagation é, na verdade um método para implementar o processo de *gradiente descendente* no espaço dos pesos para o treinamento da Rede. O objetivo do método é, através do cálculo das derivadas ($\frac{\partial E_p}{\partial w_{ij}}$), ajustar os pesos, garantindo assim, a minimização do erro na camada de saída.

A variação dinâmica do coeficiente de aprendizado $\eta(t)$ foi realizada da seguinte forma (inicializando-se em $\eta(0)=0.2$):

$$\text{Se } E_p(t) < E_p(t-1), \text{ então } \eta(t) = 1.005 \cdot \eta(t-1).$$

Se $E_p(t) > 1.04 \cdot E_p(t-1)$, então não é considerado o último passo de aprendizado e $\eta(t) = 0.07 \cdot \eta(t-1)$.

Se $E_p(t-1) < E_p(t) < 1.04 \cdot E_p(t-1)$, então permanece o coeficiente de aprendizado anterior.

A Rede Neural com os pesos inicializados randomicamente no intervalo de $[-0.3;0.3]$ é treinada através da apresentação repetitiva dos padrões de treinamento até que o erro esteja abaixo da tolerância especificada $\varepsilon = 0.001$ ou que o número máximo de épocas seja atingido.

5.1.2 Arquitetura final e testes

A arquitetura final definida nos estudos realizados tem apenas uma camada escondida (hidden layer) com 6 neurônios e um único neurônio na camada de saída (output layer). Esta Rede apresentou uma taxa de acerto de 95%. Esta taxa de acerto foi obtida usando um comparador ao final da saída da Rede. Este bloco não faz parte da Rede e seu limiar é ajustado convenientemente para eliminar imperfeições resultantes na saída, como:

Se saída > 0.5, então entrada pertence à classe dos padrões alerta;

Se saída < 0.5, então entrada pertence à classe dos padrões seguros.

A Figura 5 demonstra a importância de se considerar a variação dinâmica do coeficiente de aprendizado. Pode-se observar a grande mudança de valores do coeficiente enquanto o treinamento da Rede está sendo executado. O coeficiente de aprendizado para várias épocas tem valores muito altos e para outras chega a apresentar valores da ordem de 10^{-3} .

O tamanho da Rede revelou-se muito pequeno em virtude principalmente do processo de formação utilizado nos elementos dos conjuntos de treinamento e teste. Foi visto que a geração dos elementos executada como citado anteriormente conduz à uma quase independência em relação às arquiteturas das MLP's testadas, como também pode ser visto em [10].

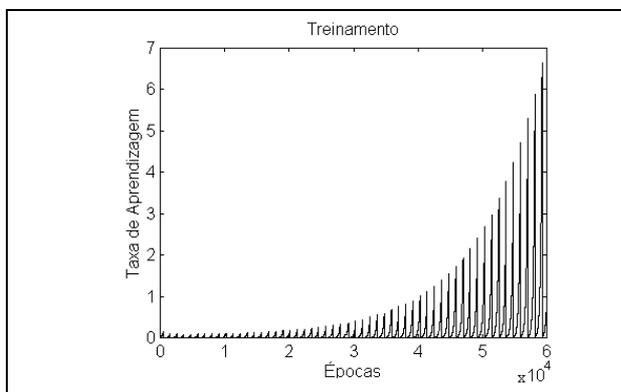


Figura 5 – Variação dinâmica do coeficiente de aprendizado

Também devemos considerar os poucos dados usados no treinamento e no teste (apenas dois dias), contabilizando 70 condições de operação. Estas estão divididas entre os pontos de operação da curva de carga diária e suas condições obtidas através de contingências. Apesar disto, não foram inviabilizadas as valiosas conclusões extraídas deste estudo. Conclusões estas que nos fazem estar seguros de que a tecnologia das Redes Neurais é uma das melhores opções para a avaliação da segurança dos Sistemas de Potência, e que o tratamento dos dados (normalização e geração de casos seguros e alertas para o mesmo ponto de operação) é de fundamental importância para o sucesso do projeto da Rede.

5.2. Rede neural de Kohonen

Na maioria das aplicações tem-se usado o aprendizado supervisionado, onde pelo uso de padrões de entrada e saídas desejadas treina-se uma rede para aprender um mapeamento entrada-saída. O aprendizado supervisionado necessita, entretanto, do conhecimento dos objetivos desejados nos padrões de treinamento, o que nem sempre é de fácil obtenção. Sob este ponto de vista, o treinamento não supervisionado é a escolha mais apropriada e, dentre estes esquemas de treinamento, o mapeamento auto-organizável de Kohonen é o de uso mais difundido[5].

Os mapeamentos de Kohonen são redes neurais de alimentação para a frente não supervisionada que podem mapear não-linearmente vetores n-dimensionais em uma rede bi-dimensional. Os dados que apresentam características similares são mapeados para os mesmos grupos. Esta projeção não-linear torna a relação de vizinhança topológica geometricamente explícita no espaço de atributos de mesma dimensão. Na rede de Kohonen o aprendizado competitivo é o identificador primário. O esquema básico de um modelo de Kohonen e representado na Figura 6.

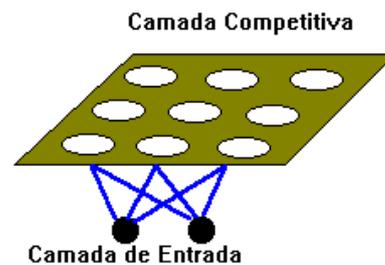


Figura 6 – Esquema básico de um modelo de Kohonen

5.2.1. Processo de treinamento

Sinteticamente, o mecanismo de Kohonen funciona da seguinte forma: os pesos sinápticos iniciam contendo valores aleatoriamente baixos e um sinal de entrada \vec{x} (com valores que representam uma informação qualquer) é provido para a rede sem que se especifique a saída desejada (característica da rede não supervisionada). O sinal de entrada \vec{x} é descrito como:

$$\vec{x} = \{x_1, x_2, x_3, \dots, x_n\}$$

Conforme o sinal de entrada, um neurônio de saída y deverá responder melhor para a entrada respectiva, e, então, será o vencedor. Isto faz com que este neurônio seja disparado sempre que essa entrada específica for apresentada à rede neural.

O ajuste dos pesos sinápticos acontece da seguinte forma, primeiro procura-se descobrir qual é o neurônio vencedor para a entrada apresentada, ou seja, qual é o neurônio que possui a menor distância Euclidiana, em relação ao padrão de entrada apresentado:

$$d_j = \sum_{i=1}^N (x_i(t) - w_{ji}(t))^2$$

onde: t = instante t no tempo; j = indexação do neurônio; i = indexação das entradas e dos pesos; N = número de entradas (quantidade de x e, respectivamente, quantidade de w por neurônio); $x_i(t)$ = entrada j no tempo t ; $w_{ji}(t)$ = peso i do neurônio j no tempo t ; e $d_j(t)$ = distância do neurônio no tempo t .

Em cada passo do aprendizado, o neurônio que melhor responder deverá ser ajustado para responder com valores ainda maiores àquela entrada, e, conjuntamente, todos os neurônios dentro da vizinhança V_i serão alterados. Os neurônios que estiverem fora do subconjunto de vizinhança não serão alterados. A adaptação dos neurônios é muito simples. Basicamente, toma-se a diferença entre os dois vetores (\vec{x} e \vec{w}) e soma-se uma fração desta diferença ao vetor de pesos original (\vec{w}):

$$\vec{w}_j(t+1) = \begin{cases} \vec{w}_j(t) + \eta(t) [\vec{x}(t) - \vec{w}_j(t)] & \text{se } j \in V_n(t) \\ \vec{w}_j(t) & \text{se } j \notin V_n(t) \end{cases}$$

O neurônio vencedor y , e seu conjunto de vizinhos (V_y), terão seus pesos sinápticos ajustados para responder melhor do que antes à entrada apresentada \vec{x} . A rede é considerada treinada depois de todo o conjunto de treinamento ter sido apresentado à rede, e os critérios de treinamento terem sido satisfeitos.

O critério de parada utilizado foi de 500 interações para cada neurônio na camada de saída. Vale ressaltar que esses parâmetros não são regras. Nada impede que se obtenha sucesso com menos ou mais iterações.

A taxa de aprendizado $\eta(t)$ foi fixada em 0,95.

5.2.2. Testes

Realizado o ordenamento geral da rede, é preciso saber quais são os neurônios vencedores, para que, apropriadamente, recebam o rótulo devido. Como rótulo, entende-se o nome do fato.

O método proposto neste trabalho utiliza a característica de que as Redes Kohonen têm de capturar similaridades nos seus padrões de entrada afim de classificar o ponto de operação do sistema. Então, a idéia é que, após o mapeamento fornecido pelo treinamento, fossem destacadas duas regiões de segurança específicas: uma região rotulada como SEGURA e uma outra como ALERTA. Mas foi observado que o agrupamento dos padrões similares se deu pelo carregamento do sistema.

Para um mesmo carregamento no conjunto de treinamento, existem casos em condição segura e casos em condição alerta. Conclui-se assim que uma rede neural de Kohonen é inadequada para tal problema.

6. Conclusão

A abordagem do problema da avaliação da segurança dos Sistemas de Potência em relação à Instabilidade de Tensão através da tecnologia das Redes Neurais Artificiais - MLP's -, apresentou uma capacidade de solução satisfatória. As características de generalização e abstração inerentes às Redes Neurais, conduzem à uma alta qualidade de velocidade e resposta viabilizando a implantação "on-line" nos Centros de Operação dos Sistemas de Energia Elétrica.

Para muitas tarefas em Sistemas de Potência, nenhum modelo neural domina o outro. A escolha do melhor modelo deve ser feita de acordo com a natureza da aplicação. Nós devemos tentar entender as capacidades, suposições e aplicabilidade das várias abordagens e explorar ao máximo suas vantagens complementares para alcançar desempenhos ainda melhores para problemas desafiantes.

7. BIBLIOGRAFIA

- [1] - Marcos A. P. Lafévre, "Sistemas Inteligentes e sua Aplicação na Operação de Itaipu Binacional", *XIII SNPTEE*, Bal. Camboriú, SC, outubro de 1995.
- [2] - M. T. Schilling, *et al*, "Problemas e Estratégias Emergentes em Sistemas de Potência", *Proceedings of V SEPOPE*, Recife, Brazil, May 1996.
- [3] - Carson W. Taylor, *Power System Voltage Stability*, McGraw-Hill, Inc., 1994.
- [4] - Carson W. Taylor, "Optimizing Voltage Stability: Finding Effective Voltage Instability Countermeasures", *Proceedings of V SEPOPE*, Recife, Brazil, May 1996.
- [5] Alencar, R. J. N.; Bezerra, U. H.; Garcez, J. N. *et al*, "Monitoração da segurança estática do sistema eletronorte através de mapeamento auto - organizável", *XIV SNPTEE*, Belém-PA, outubro de 1997..
- [6] - Neural Network Toolbox User's Guide - For Use with MATLAB, January 1994.
- [7] - Eduardo Sodr , Katia C. Almeida, e Roberto Salgado, "Avaliação Estática da Estabilidade de Tensão via Método da Continuação", *XIV SNPTEE*, Belém-PA, outubro de 1997.
- [8] - Simon Haykin, *Neural networks: a comprehensive foundation*, Macmillan College Publishing Company, New York, 1994.
- [9] - Vera Lúcia de Castro Soares, e Geraldo Pereira Caldas, "Estabilidade de Tensão - Estudo do Sistema Sul", *XIV SNPTEE*, Belém-PA, outubro de 1997.
- [10] - A. A. El-Keib, and X. Ma, "Application of Artificial Neural Networks in Voltage Stability Assesment", *IEEE Transactions on Power Systems*, Vol. 10, N. 4, pp. 1890-1896, April 1995.