

## 1º Congresso Brasileiro de Redes Neurais

Escola Federal de Engenharia de Itajubá  
Itajuba, 24 a 27 de outubro de 1994

### Diagnose em Sistemas de Potência utilizando Redes Neurais

Victor Navarro A. L. da Silva<sup>(1)</sup>

navarro@fund.cepel.br

Guilherme Nelson F. de Souza<sup>(1)</sup>

gnelson@fund.cepel.br

Resumo : O principal objetivo deste trabalho é estudar a aplicação de Redes Neurais para diagnose em Sistemas de Potência auxiliando o operador a determinar os motivos que originaram estes distúrbios.

Para tal, será apresentada em detalhes uma análise do treinamento e simulação em um sistema elétrico simplificado. Este protótipo é capaz de diagnosticar não somente falhas simples mas também falhas múltiplas. Além de ser apto a diagnosticar falhas mesmo quando o conjunto de alarmes que a caracterizam estiver incompleto.

Os resultados obtidos demonstram que a Rede Neural é uma técnica extremamente viável e promissora para solução deste e de outros problemas semelhantes existentes no setor elétrico.

#### I - Introdução:

Os Sistemas Elétricos de Potência vêm passando por um grande desenvolvimento nas últimas décadas, procurando melhorar cada vez mais o processo de produção, transmissão e entrega de energia elétrica.

Esta evolução acarretou um aumento crescente da complexidade dos Sistemas Elétricos, exigindo o desenvolvimento de sistemas de supervisão, controle e automação cada vez mais sofisticados com o objetivo de garantir um funcionamento seguro e confiável.

Entretanto os Sistemas Elétricos continuam sujeitos a distúrbios e normalmente quando eles ocorrem, os

operadores destes sistemas tentam solucioná-los desenvolvendo três atividades básicas: *detecção dos problemas existentes, diagnóstico e determinação das ações corretivas.*

Na detecção dos problemas existentes, os operadores contam com o auxílio do sistema de supervisão que lhes informa todos os alarmes gerados. Normalmente esta quantidade de alarmes é elevada dificultando enormemente o trabalho de identificação das falhas que podem ter gerado tais alarmes (diagnóstico).

Em relação ao diagnóstico, os operadores dependem quase que exclusivamente das suas experiências e conhecimentos e precisam varrer toda a lista de alarmes gerada para

(1) CEPEL - Centro de Pesquisas de Energia Elétrica  
Caixa Postal: 2754 CEP: 20.001-970  
Rio de Janeiro - Brasil  
Tel: 598-2134 Fax: 260- 1340 / 260 - 6211

poder chega a uma explicação razoável sobre as causas dos distúrbios (falhas).

Por último, as ações corretivas são determinadas a partir do diagnóstico alcançado anteriormente e mais uma vez, da experiência e conhecimento do especialista.

Assim, vários fatores podem acabar levando os operadores a fazerem um diagnóstico errado, como a quantidade excessiva de alarmes, a fadiga, o estresse, a falta de experiência, a dificuldade natural em lidar com situações não usuais entre outros. Este diagnóstico falho acaba retardando a tomada das ações corretivas apropriadas, prejudicando a segurança e eficiência de operação do sistema.

Devido a estes motivos, tem-se notado um interesse cada vez maior no desenvolvimento de sistemas que possam ajudar o operador nas etapas de diagnóstico e determinação das ações corretivas [Wollenberg 86], [Tanaka *et. al.* 89], [Kim *et. al.* 91], [Rodriguez 92].

Este trabalho pretende analisar a utilização de Redes Neurais Artificiais na solução deste problema e com isso, contribuir para melhorar o desempenho e reduzir o estresse do operador dando-lhe mais segurança e agilidade no processo de tomada de decisão sobre a causa do distúrbio.

Na próxima seção, faremos uma breve introdução à Redes Neurais. Na seção III, mostraremos como aplicar as Redes Neurais na Diagnose de Sistemas de Potência. Para tal, será apresentada em detalhes uma análise do treinamento e simulação em um sistema elétrico simplificado de uma usina. Finalmente na seção IV, apresentaremos algumas conclusões, sugerindo algumas melhorias e pesquisas futuras.

## II - Redes Neurais Artificiais:

O Cérebro humano possui dezenas de bilhões de neurônios densamente interconectados (*Redes Neuronais*)<sup>1</sup>, que

<sup>1</sup> Segundo nomenclatura atualmente utilizada: *Redes Neurais* é a interconexão de elementos processadores que simulam o comportamento dos neurônios biológicos encontrados nas *Redes Neuronais*.

demonstram grande capacidade para armazenar e processar informações.

O conhecimento sobre o funcionamento de um neurônio, infelizmente, ainda não é o bastante para explicar tarefas extremamente complexas (tais como entender, lembrar, memorizar, generalizar entre outras) que o cérebro é capaz de realizar. Entretanto, o que deve ser destacado é que o cérebro realiza todas essas tarefas de forma eficaz, apesar dos neurônios serem sensivelmente mais lentos que os processadores usados nos computadores atualmente. Possivelmente, toda essa eficiência não está na capacidade individual de um neurônio mas sim no conjunto formado pela quantidade muito grande deles (dezenas de bilhões) e pela forma como eles estão conectados.

Estas características acabaram motivando os cientistas a tentar imitar o modo de funcionamento do cérebro, procurando reproduzir artificialmente as redes neuronais biológicas e usá-las como ferramenta de computação em diversas áreas.

Uma Rede Neural Artificial consiste de vários neurônios (denominados de elementos processadores) organizados em Camadas. Uma rede típica possui uma seqüência de camadas interligadas totalmente ou aleatoriamente com as camadas adjacentes.

Existem três tipos de camadas: Entrada, Saída e Escondida. As camadas de entrada e saída são respectivamente aquelas de apresentação das informações da rede e de visualização dos resultados. A camada escondida ou intermediária são todas as camadas entre a de saída e a de entrada.

Diferentemente dos esquemas simbolistas normalmente utilizados nos sistemas de Inteligência Artificial convencionais, onde o conhecimento deve ser representado na forma de regras e/ou algoritmos, as Redes Neurais Artificiais aprendem através de exemplos, ou seja, o problema é modelado informalmente através da apresentação exaustiva de casos típicos.

A partir deste aprendizado, as redes tendem a generalizar o seu conhecimento e passam a responder corretamente a casos

novos, desde que parecidos com os exemplos apresentados. Outras importantes propriedades das Redes Neurais advém do fato da "memória" da rede estar distribuída, ou seja, o conhecimento está espalhado pelos diversos neurônios na forma de pesos.

A distribuição de sua memória, torna as Redes Neurais Artificiais tolerante a falhas, ou seja, a perda de alguns neurônios, não trará como consequência a destruição de uma quantidade considerável de informação.

Tais propriedades, fazem com que as Redes Neurais Artificiais possuam um escopo muito grande de aplicações, dentre os quais podemos citar o setor elétrico [CIGRE93], [Souza *et. al.* 93]. Dentre as áreas consideradas promissoras para utilização de Redes Neurais no setor elétrico podemos destacar a diagnose de faltas e o processamento de alarmes.

O grande objetivo destas duas áreas é fornecer ao operador do Sistema Elétrico, informações precisas do estado atual do sistema, auxiliando-o a identificar e corrigir qualquer problema existente. Esta tarefa pode ser vista simplesmente como um problema de reconhecimento e classificação de padrões pois, ao reconhecer corretamente um padrão particular de alarmes, consegue-se caracterizar corretamente qual o problema que originou estes alarmes (figura 1).

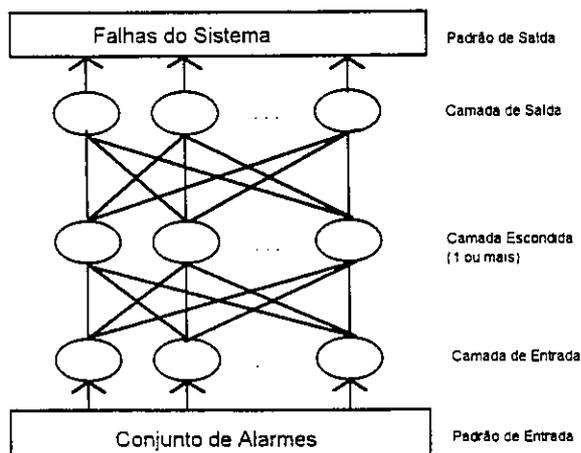


Figura 1 : Diagnose de Faltas como um problema de reconhecimento e classificação de padrões

A tarefa de reconhecer e classificar padrões é realizada facilmente com sucesso pelas Redes Neurais, inclusive devido a sua capacidade de distribuição de memória, ela consegue classificar padrões de entrada incompletos ou com ruído. É claro, que a precisão da classificação decai, mas ainda assim, é feita com sucesso.

Outra vantagem é a sua alta velocidade de processamento proporcionada pela capacidade de processamento paralelo (originada da densa rede de conexões entre os neurônios), requisito imprescindível para um rápido reconhecimento dos problemas existentes no sistema elétrico.

### III - Aplicação em Diagnose de Sistemas de Potência:

Mostraremos como caso exemplo, um sistema elétrico simplificado de uma usina (figura 2). Este sistema elétrico é composto por duas unidades geradoras, dois transformadores e seus respectivos disjuntores, dois barramentos (barra principal e barra auxiliar) e dois alimentadores (também com seus respectivos disjuntores).

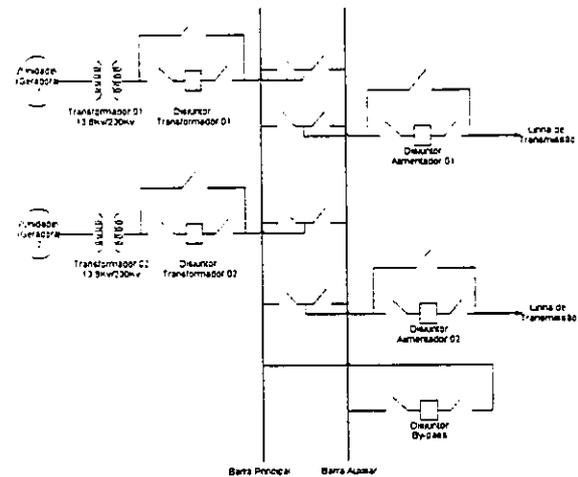


Figura 2 : Configuração do Sistema Elétrico de uma usina

Cada transformador possui três pontos de monitoração: Abertura do disjuntor (indica se o disjuntor está aberto ou não), Sobrecarga (mostra que ocorreu sobrecarga no

transformador) e Auxiliar (informa se o transformador está operando com o disjuntor de by-pass, ou seja, seu próprio disjuntor está em manutenção).

Já cada alimentador possui seis pontos de monitoração: Abertura do disjuntor (indica se o disjuntor está aberto ou não), Fase (mostra que ocorreu sobrecorrente na linha de fase), Terra (informa que ocorreu sobrecorrente na linha de terra), Temporizado (significa que ocorreu uma falha distante ao alimentador), Instantâneo (revela que ocorreu uma falha próxima ao alimentador) e Auxiliar (informa se o alimentador está operando com o disjuntor de by-pass, ou seja, seu próprio disjuntor está em manutenção).

A partir destes pontos de monitoração foi criada uma lista de descrição de problemas (falhas) deste sistema, onde cada falha está associado a um grupo de alarmes. Deste modo, a falha próxima ao alimentador 01 f/f é caracterizada pela atuação dos alarmes: abertura do disjuntor do alimentador 01, fase do alimentador 01 e instantâneo do alimentador 01 e assim por diante.

Durante a implementação, nosso objetivo será utilizar este exemplo para procurar uma explicação para um conjunto de alarmes atuados. Assim, quando o sistema apresentar os seguintes alarmes atuados: abertura do disjuntor do alimentador 01, terra do alimentador 01 e instantâneo do alimentador 01, ele deve ser capaz de diagnosticar que uma falha próxima ao alimentador 01 f/t está ocorrendo.

Devemos destacar, que o sistema deve ser capaz de diagnosticar não somente falhas simples mas também falhas múltiplas. Além, de ser apto a diagnosticar falhas mesmo quando o conjunto de alarmes que a caracterizam estiver incompleto. Deste modo, se somente os alarmes terra do alimentador 02 e temporizado do alimentador 02 estiverem atuados, o sistema deve ter a habilidade de diagnosticar que a falha distante ao alimentador 02 f/t está ocorrendo mesmo sem a presença do alarme de abertura do disjuntor do alimentador 02 já que esta falha é a que melhor justifica a atuação conjunta

destes dois alarmes. Devemos notar, que esta característica aumenta consideravelmente a complexidade do problema.

### III.1 - Representação do Sistema:

Baseado no sistema elétrico mostrado acima, implementamos um processador inteligente de alarmes empregando o modelo "back-propagation", onde cada neurônio de entrada representa um alarme e cada neurônio de saída representa uma falha do sistema.

A forma de representação escolhida para os vetores de entrada e saída foi a binária. Assim, quando queremos representar que um alarme está ativo ou não, basta associá-lo aos valores 1 e 0 respectivamente.

Para ensinar a rede, foi criado um arquivo de treinamento, que continha falhas simples e duplas num total de 238 padrões (deve-se notar que denominamos de falhas duplas, a conjunção de duas falhas simples). Este arquivo foi então, apresentado a rede neural (figura 3) e seu treinamento foi realizado utilizando o software de simulação de rede neural NeuralWorks Professional II/Plus [Neuralware 91] em um micro-computador IBM PC/AT compatível.

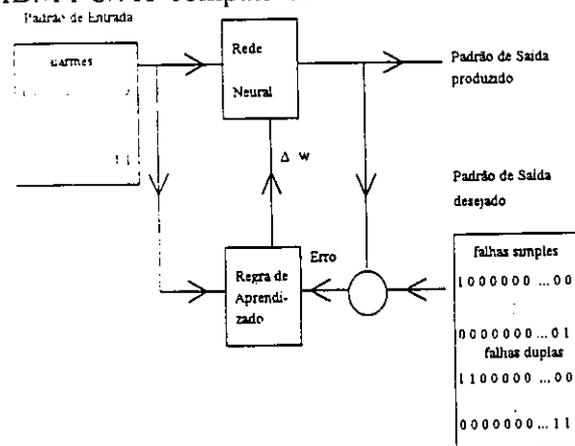


Figura 3 : Treinamento de um processador inteligente de alarmes para o sistema elétrico simplificado de uma usina

### III. 2 - Performance:

A partir do arquivo de treinamento, passamos a testar neste software, quais os

parâmetros que poderiam dar uma melhor performance para a rede.

Primeiramente, procuramos descobrir o melhor dimensionamento da rede. Para isto, variamos apenas o número de camadas intermediárias (uma ou duas) e o número de neurônios em cada uma dessas camadas (5, 10, 20 e 30 neurônios).

Os resultados demonstraram que o erro de aprendizado utilizando duas camadas intermediárias era 10% maior que o empregando apenas uma camada e neste grupo, a melhor performance foi obtida pelo treinamento com 5 neurônios na camada intermediária (figura 4).

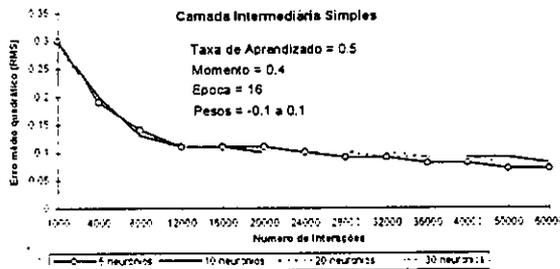


Figura 4 : Resultados de aprendizado com uma única camada intermediária

Passamos então, a variar outros parâmetros característicos da rede (taxa de aprendizado, momento e época) com o objetivo de diminuir o erro de aprendizado aprimorando ainda mais o resultado do treinamento.

Inicialmente, foram testadas várias taxas de aprendizado e a melhor performance foi obtida pela taxa de aprendizado igual a 0,90 (figura 5).

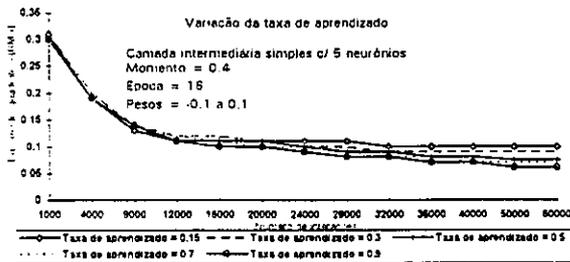


Figura 5 : Resultados variando a taxa de aprendizado

Em seguida, variamos o valor do momento e o momento com valor igual a 0,8 obteve o melhor resultado, fazendo cair significativamente o erro (figura 6).

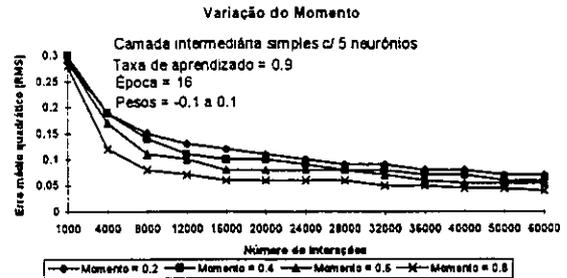


Figura 6 : Resultados variando o momento

Finalmente, passamos a alterar o valor da época (tamanho do conjunto de padrões de entrada após o qual deve ser atualizado os pesos das ligações) e o menor erro rms de aprendizado foi obtido pela época igual a 11 (figura 7).

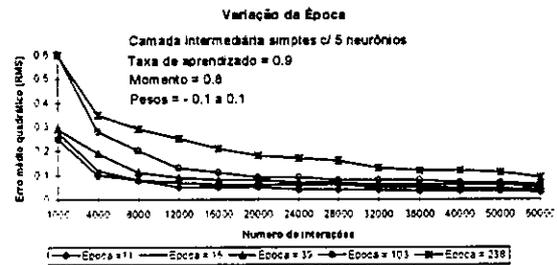


Figura 7: Resultados variando o valor da época

Deste modo, os parâmetros da rede que obtiveram o melhor resultado no treinamento foram : Camada intermediária simples com 5 neurônios, Taxa de aprendizado = 0,9, Momento = 0,8, Época = 11 e Intervalo dos pesos entre -0,1 a 0,1.

Estes resultados foram obtidos durante o treinamento da rede mas para verificar se a rede realmente aprendeu, precisamos testá-la não só com os padrões de treinamento como também, com outros padrões diferentes denominados de padrões de teste para verificar a capacidade de generalização da rede.

Os testes foram realizados com quatro tipos de padrões diferentes :

- treinamento → contém todos os padrões de treinamento (238 padrões).

- falhas múltiplas → contém todas as falhas triplas e quádruplas possíveis, onde classificamos de falhas triplas e quádruplas, a conjunção de três e quatro falhas simples diferentes (580 padrões).
- falhas simples com ruído → contém todas as falhas simples com ruído na entrada. Deve-se notar que denominamos de ruído, a ausência de um dos alarmes que caracterizasse as respectivas falhas (92 padrões).
- falhas duplas com ruído → contém falhas duplas com ruído na entrada (745 padrões).

Durante estes testes, a rede apresentou uma taxa de erro de 2,96% sendo este resultado bastante promissor, mostrando que a rede é capaz de diagnosticar falhas mesmo quando submetida a novos padrões (padrões diferentes dos padrões de treinamento).

Devemos também destacar que o tempo de resposta da rede neural independe do número de alarmes ativados, sendo este de aproximadamente um segundo.

#### IV - Conclusão:

Os resultados obtidos foram bastante satisfatórios pois quando não ocorre ausência de alarmes, a taxa de acerto é de 100 % entretanto quando o conjunto de alarmes estava incompleto a taxa global de acerto decaiu para 97%, o que é ainda bastante bom.

Isto nos encoraja a dar prosseguimento a este trabalho. Para tal, novos tópicos devem ser avaliados para melhorar o diagnóstico como a caracterização da ordem temporal dos alarmes bem como a implementação de um sistema híbrido (Conexionista + Simbolista) onde a rede neural informa quais os problemas que estão ocorrendo e um sistema especialista explica os motivos associados a cada problema. Inclusive, um sistema especialista utilizando lógica não-monotônica já foi desenvolvido com sucesso [Silva 94] para este mesmo caso exemplo faltando apenas realizar sua integração com a rede neural.

#### V - Bibliografia :

- [CIGRE 93] CIGRE, "Artificial Neural Networks for Power Systems - A Literature Survey", CIGRE - 1993 Session, July 1993, Ref. Task Force 38.06.06.
- [NeuralWare 91] NeuralWare Inc., "NeuralWorks Professional II/Plus and Neural Works Explorer - Reference Guide", 1991.
- [Kim *et. al.* 91] K. Kim, J. Park, "Application of Hierarchical Neural Network to Fault Diagnosis of Power Systems", Third Symposium on Expert Systems Applications to Power Systems, Tokyo, April 1991, pp 323-327.
- [Rodriguez *et. al.* 92] C. Rodriguez, S. Rementeria, C. Ruiz, A. Lafuente, J. I. Martin, J. Murgueza, "A Modular Approach to the Design of Neural Networks for Fault Diagnosis in Power Systems", International Joint Conference on Neural Networks, Baltimore, June 1992, vol.III, pp 16-23.
- [Silva 94] Victor N. A. L. da Silva, "Diagnose em Sistemas de Potência utilizando Lógica Não-monotônica e Redes Neurais", Tese de M. Sc., COPPE-UFRJ, Abril 1994.
- [Souza *et. al.* 93] G. N. F. de Souza, N. de M. Roehl, M. Moszkowicz, "Experiência de Aplicação de Redes Neurais ao Setor Elétrico", V ERLAC - Encontro Regional Latino-Americano da CIGRE, 1993.
- [Tanaka *et. al.* 89] H. Tanaka, S. Matsuda, H. Ogi, Y. Izui, H. Taoka, T. Sakaguchi, "Design and Evaluation of Neural Network for Fault Diagnosis", Second Symposium on Expert System Applications to Power Systems, Seattle, Washington, July 1989, pp.378-384.
- [Wollenberg 86] B. F. Wollenberg, "Feasibility for an Energy Management System - Intelligent Alarm Processor", IEEE Transactions on Power Systems, Vol. 1, No. 2, May 1986, pp. 241-247.