



XVI SNTPEE
Seminário Nacional de Produção e
Transmissão de Energia Elétrica

GRUPO V

GPC/001

21 a 26 de Outubro de 2001
Campinas - São Paulo - Brasil

ESTUDO DE PROTEÇÃO, MEDIÇÃO E CONTROLE EM SISTEMAS DE POTÊNCIA

UMA ABORDAGEM BASEADA EM REDES NEURAIS ARTIFICIAIS PARA IDENTIFICAÇÃO DE TRECHOS SUBMETIDOS A CURTOS-CIRCUITOS EM SISTEMA DE DISTRIBUIÇÃO

Edison Aparecido Goes

José Francisco Rodrigues

Ivan Nunes da Silva

UNESP

UNESP

UNESP

RESUMO

A identificação do local de um curto-circuito em uma linha de distribuição de energia elétrica é muito importante para um rápido restabelecimento do suprimento de energia elétrica. Este trabalho mostra a aplicação de uma arquitetura de Rede Neural Artificial (RNA) tipo perceptron multicamadas, operando como classificadora de padrões, para identificar um ramo (trecho) de uma linha de distribuição classe 15 kV, submetida a um curto-circuito fase-terra. A configuração (ver Figura 5) utilizada contém três trechos de comprimentos diferentes e as faltas (curtos-circuitos) foram simuladas através do software Alternative Transient Program (ATP) (1).

PALAVRAS-CHAVE: Localização de falta, Linhas de Distribuição, Redes Neurais Artificiais

1.0 - INTRODUÇÃO

A crescente demanda de energia elétrica no Brasil nas últimas duas décadas, bem como a quantidade e rapidez da informação pelos meios de comunicação e ainda a exigência e confiabilidade no fornecimento de energia elétrica, impôs novos rumos em âmbito nacional, com respeito aos programas de Geração, Transmissão e principalmente Distribuição de Energia Elétrica. Devido ao aumento substantivo em complexidade e diversidade do mercado consumidor, o Sistema Elétrico de Potência (SEP) tem exigido uma considerável atualização e também uma significativa melhoria dos equipamentos de monitoramento, controle e proteção. Atualmente devido a escassez de investimentos no setor elétrico, é sugerido a economia

em equipamentos, controle de qualidade, mão-de-obra, etc., porém o que nunca se deve perder de vista é o comprometimento da qualidade que está atrelada aos índices mínimos de confiabilidade e segurança desejados no SEP.

Dentro de um SEP encontram-se as linhas de distribuição, classe 15 kV, onde estão a grande maioria dos consumidores. Neste segmento do SEP, a ocorrência de faltas é muito grande, principalmente quando das alterações climáticas, tais como: temporais, ventos e épocas de secas, as quais neste caso submetem o sistema às conseqüências danosas das queimadas (fogo sob a linha). No sistema de transmissão, onde a classe de tensão é da ordem de dez ou mais vezes superior ao sistema de distribuição, estes inconvenientes também ocorrem, porém o restabelecimento de energia é mais rápido: primeiro devido a configuração deste; e segundo, para encontrar o ponto de falta, os relés de proteção destas linhas possuem a função localização de faltas.

Ultimamente tem-se observado um significativo avanço nas pesquisas em aplicar sistemas inteligentes na resolução de problemas relacionados aos Sistemas Elétricos de Potência (SEPs). Os sistemas inteligentes utilizam as Redes Neurais Artificiais (RNAs) que é uma metodologia confiável, permitindo sua aplicação em vários estudos. Percebendo o potencial das RNAs em resolver problemas desta natureza, conforme mostra as publicações sobre o assunto, surgiu então o interesse de aplicá-las em uma determinada configuração (ver Figura 5) de um sistema de distribuição de energia elétrica (SDEE), com o objetivo de identificar um trecho (ramal) sob falta.

2.0 - REDES NEURAIS ARTIFICIAIS

2.1 - Introdução

O propósito da computação neural é a obtenção dos princípios gerais em que se baseiam as soluções do cérebro humano para estes problemas e aplicá-los aos sistemas computacionais. Os pesquisadores de RNAs acreditam que o cérebro, constituído de neurônios, constrói suas próprias estratégias de processamento de informações, através do que é usualmente chamado de “experiência”.

As RNAs tem sido utilizadas em várias aplicações, tais como: Reconhecimento de Padrões, Processamento de Sinais, Processamento de Fala, Robótica, Otimização de Sistemas e em vários setores dos SEPs (2-4). As características que tornam a metodologia das RNAs interessante do ponto de vista da solução de problemas são:

a) Capacidade de “aprender” através da experiência; diz-se que tal “aprendizado” ocorre quando a rede consegue mapear soluções generalizadas para uma classe de problema;

b) Desempenho eficiente em processos onde há ausência de conhecimento explícito sobre como identificar uma solução factível;

c) Não necessita de identificação de eventuais modelos matemáticos que descrevem o comportamento do sistema analisado;

d) Elevada imunidade ao ruído, isto é, o desempenho da rede não entra em colapso em presença de eventuais informações incorretas ou ausentes.

2.2 - Neurônio Biológico

A origem da teoria das RNAs remonta aos modelos matemáticos e aos modelos de engenharia dos neurônios biológicos. A célula nervosa ou neurônio foi identificado anatomicamente e descrito com notável detalhe, pelo neurologista espanhol Ramón Cajal no século XIX. O neurônio possui um corpo celular ou soma, dentro do qual encontram-se a maioria dos seus orgânulos. Do somador de cada neurônio partem prolongamentos que podem ser funcionalmente divididos em conexões denominadas dendritos e axônios (5), conforme mostrado na Figura 1.

O neurônio é uma célula altamente especializada, capaz de receber impulsos elétricos a partir de seus dendritos, processá-los no somador e finalmente, transmiti-los através de seu axônio (geralmente único) para os dendritos (ou mesmo para o somador) de outros neurônios. A conexão entre um axônio de um neurônio e um dendrito de outro é denominado sinapse, como mostrado na Figura 2. A sinapse é a unidade funcional básica para a construção de circuitos neurais biológicos e envolve a posição das membranas plasmáticas de dois neurônios de modo que forma uma junção pontual (o tamanho de uma junção sináptica é menor do que neurônio pós-sináptico).




FIGURA 1 - Esquema simplificado de um neurônio




FIGURA 2 - Esquema simplificado de uma conexão sináptica

Uma RNA é composta por um elevado número de elementos processadores, também denominados unidades de processamentos, amplamente conectados entre si. Cada uma das conexões interliga somente dois elementos processadores, geralmente em um único sentido, e possui um valor que determina o grau de conectividade entre estes, denominados pesos da conexão. Deste modo, todo o processamento é realizado distributivamente entre os elementos processadores da rede, enviando o seu resultado para outras unidades através das conexões entre eles. Por isso as RNAs são conhecidas como sistema de processamento distribuído e paralelo (PDP). A forma pela qual os elementos processadores estão interligados é denominada topologia ou padrão de interconexão. A modificação dos pesos sinápticos de uma RNA não representa um grande problema do ponto de vista matemático, pode representar um sério problema na prática, pois os recursos computacionais são limitados e o tempo de processamento é proporcional à quantidade de recursos necessários.

O processo de treinamento de uma RNA deve ser capaz de modificar gradualmente um padrão de interconexão inicial, de modo a adaptá-lo à resolução deste problema. Para o treinamento de uma RNA podem ser utilizados mecanismos distintos de aprendizado: supervisionado, quando são fornecidos integralmente os resultados desejados e não supervisionado, quando a própria RNA é capaz de ajustar o seu funcionamento. A maioria das RNAs

utiliza o aprendizado supervisionado que pode ser considerado como a capacidade que a rede possui de modificar o seu desempenho a partir da comparação entre a resposta obtida e a resposta desejada.

As RNAs são treinadas com dados experimentais para aprendizagem. A qualidade dos dados é importante para o aprendizado, exercendo forte influência no desempenho das redes. O aprendizado é uma etapa prévia e consiste em ajustar os pesos e bias das RNAs cujas funções de transferência e estrutura de neurônios tenham sido pré-definidos. Uma vez a RNA treinada, a mesma é utilizada para reprodução de dados de saída correspondentes a novos dados de entrada. Nesta etapa verifica-se a performance da RNA.

Todas as RNAs são compostas por elementos matemáticos denominados neurônios, que pode ser entendido conforme a Figura 3.




FIGURA 3 - Esquema de um neurônio

Um neurônio recebe como entrada um sinal (número) p multiplicado por um peso w e um termo linear o bias b . Esta entrada é somada e tratada por uma função F do neurônio, produzindo na saída o sinal, ou seja, o número a . Em termos matemáticos:

$$a = F(wp + b) \quad (1)$$

O peso w e o bias b são parâmetros ajustáveis do neurônio e da RNA. Utilizando agora um modelo geral do neurônio artificial, conforme está mostrado na Figura 4, temos:

$x_1, x_2 \dots x_N$: são os sinais de entrada.

$w_1, w_2 \dots w_N$: são os pesos.

θ é a polarização associada ao neurônio.

u é a saída do combinador linear.

$g(\cdot)$ é a função de ativação do neurônio.

y é o sinal de saída do neurônio ou estado de ativação do neurônio.

Neste modelo, os sinais de entrada x_i são ponderados (multiplicados) pelos respectivos pesos w_i (sinapses); se o valor de w_i for positivo a sinapse será excitatória, caso contrário a sinapse será inibitória. Em seguida, o valor de polarização θ e os sinais de entrada x_i , ponderadas pelas respectivas sinapses w_i do neurônio, são somados e o valor de u é aplicado à

função de ativação $g(\cdot)$ com o objetivo de limitar o valor do sinal de saída y do neurônio. Em termos matemáticos têm-se:

$$u = \sum_{i=1}^N w_i \cdot x_i + \theta \quad (2)$$

$$y = g(u) \quad (3)$$




FIGURA 4 - Modelo de um neurônio artificial

A partir das eqs. (2) e (3), verifica-se que a função de ativação $g(\cdot)$ simplesmente processa o conjunto de entradas recebidas e o transforma em estado de ativação. Normalmente, a faixa de variação da saída do neurônio pertence ao intervalo $[0,1]$ ou $[-1,1]$.

As funções de ativações mais típicas são:

a) Função degrau:

Neste tipo de função de ativação tem-se:

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (4)$$

b) Função sigmóide

Neste tipo de função de ativação tem-se:

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (5)$$

onde β é a tangente no ponto de inflexão

c) Função tangente hiperbólica

Neste tipo de função de ativação tem-se:

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (6)$$

Para esta função de ativação, a saída do neurônio pode assumir valores reais negativos e positivos no domínio de -1 e 1

3.0 - LOCALIZAÇÃO DE FALTAS NO SEP

Um localizador de faltas pode ser implementado de três maneiras (6):

a) Como um dispositivo stand-alone – o localizador de faltas possui um hardware similar ao de um relé digital;

b) Como parte de um relé de proteção digital – neste caso o algoritmo do localizador de faltas é incluído juntamente com o algoritmo do relé de proteção;

c) Como um algoritmo independente – aproveita o registrador de perturbação, usando os dados de pós-falta obtidos através do mesmo.

Os localizadores de faltas podem até trabalhar off-line. Isto é vantajoso, porque seu algoritmo pode ser mais “pesado”, logicamente exigindo maior tempo de processamento, contudo, obtém-se grandes melhorias na precisão. O hardware básico de um localizador de faltas consiste de:

a) Módulo de Interface - transformadores de corrente e potencial e filtros passa-baixa visando atenuar as altas frequências e o efeito aliasing (8 e 10);

b) Módulo de Sincronização - contendo multiplexador e sample and hold;

c) Conversor Analógico Digital (A/D);

d) Dispositivos de Memória - possui a função de registrar os dados da falta após a conversão A/D;

e) Microcomputador - que irá processar o algoritmo localizador de faltas, após receber todas as informações do registrador de faltas.

4.0 - SIMULAÇÕES NO SEP

A configuração utilizada neste trabalho consiste de três ramos (trechos) de comprimento diferentes: ramo $P-T$ com 16 km, ramo $T-Q$ com 24 km e ramo $T-R$ com 11,8 km. A alimentação é feita pela barra P , com uma tensão de 11,4 kV entre fases, aqui denominadas fases A, B e C (ver Figura 5).




FIGURA 5 - Configuração de uma linha de distribuição utilizada nas simulações

As grandezas elétricas obtidas das simulações foram tensões e correntes trifásicas. Na barra P foram amostrados sinais de tensões e correntes, enquanto nas barras Q e R foram amostrados apenas sinais de

tensões. Atualmente, efetuar medições de tensões e correntes em qualquer ponto de um alimentador de distribuição é perfeitamente possível com a utilização de sensores instalados nos isoladores das estruturas. Concessionárias de Energia Elétrica como a Companhia de Eletricidade do Paraná (COPEL) conjuntamente com a Universidade Federal do Paraná (UFPR) e a empresa Relm Chatral especializada em tecnologia de radiocomunicação (7) desenvolveram e estão testando um tipo destes sensores. Na configuração (Figura 5) estão instaladas cargas resistivas e indutivas nas barras T , Q e R . As faltas simuladas foram fase-terra, com resistência de falta de cinco ohms e ângulo de incidência da falta de 90 graus. Outro ponto a ser considerado foi a utilização das capacitâncias shunt, calculadas através da rotina Line Constants do software (ATP) (1).

4.1 - Formação dos padrões de treinamento

Na primeira etapa realizou-se 12 simulações em cada trecho (ramal), num total de 36 simulações. Os sinais do ATP (1) foram amostrados a 50 kHz. Em seguida estes sinais foram reamostrados a uma frequência de 3840 Hz. O tempo de simulação foi de 64 ms, (ver Figura 6). Utilizou-se uma rotina para verificar o ponto de ocorrência da falta: compara-se uma amostra com a sua correspondente um ciclo adiante. Se a diferença entre elas ultrapassar um valor previamente adotado, faz-se uma pesquisa com as três amostras seguintes para verificar se o nível da corrente continua subindo. Verificado isto tem-se a confirmação do defeito. Toma-se então uma janela com sete amostras a partir do ponto de identificação da falta.

A Tabela 1 apresenta o trecho de um arquivo, contendo as colunas referente as correntes das fases A , B e C , resultado de um curto-circuito fase A para terra, medido na barra da subestação.

Com as 36 simulações realizadas a matriz de treinamento ficou 252 linhas per 12 colunas.

TABELA 1 - Trecho de um arquivo contendo as correntes de curto-circuito das fases A , B e C .

9.8965	7.9712	0.9590
13.4640	7.5045	2.0242
22.6454	7.1869	3.2908
41.6638	7.1208	4.8462
72.5507	7.1968	6.5654
111.5936	7.0440	8.0617
149.5860	6.3568	9.0141
177.6815	5.3350	9.6065

A Figura 6 mostra os sinais de tensões medidos na barra Q para uma simulação de falta no ramo $P-T$.




FIGURA 6 - Formas de ondas das tensões das fases A, B e C medidas no barramento Q, para uma falta no ramo P-T

4.2 - Arquitetura da RNA utilizada

A arquitetura utilizada neste estudo foi a perceptron multicamadas, com técnica de aprendizado tipo backpropagation. A maioria das publicações nesta área reconhecem este tipo de arquitetura com uma das que mais se adaptam. O software utilizado para o treinamento da RNA foi o Matlab (9) que tem como opção de trabalho o algoritmo de Levenberg - Marquardt (11) que é o algoritmo backpropagation otimizado, ou seja, a utilização técnicas de otimização a fim de reduzir o seu tempo de convergência. O tempo de processamento no período de treinamento foi relativamente reduzido, sendo que para um erro quadrático médio de $0.5 \cdot 10^{-5}$ a RNA realizou 178 épocas. A topologia utilizada foi de 16 neurônios na primeira camada escondida, oito neurônios na segunda camada escondida e três unidades na camada de saída (ver Figura 7).




FIGURA 7 - Arquitetura da RNA utilizada no esquema de localização de falta proposto.

Foram utilizadas as funções de ativação tansig, purelin, do Matlab (9), nas 1ª, 2ª e 3ª camadas, respectivamente.

5.0 - RESULTADOS OBTIDOS

Foi estipulado um padrão de resposta desejado para cada trecho, conforme apresentado a seguir:

- Trecho P-T : **1 0 0**
- Trecho T-Q : **0 1 0**
- Trecho T-R : **0 0 1**

Para verificar o desempenho da RNA em localizar o trecho defeituoso, esta foi submetida a uma série de 18 curtos-circuitos (diferentes daqueles utilizados no treinamento). A RNA identificou corretamente todos os trechos. A seguir são apresentados alguns destes resultados.

TABELA 2 - Resposta da rna para uma falta no ramo P-T

AMOSTRA DO SINAL	CÓDIGO		
1ª.	1	0	0
2ª.	1	0	0
3ª.	1	0	0
4ª.	1	0	0
5ª.	1	0	0
6ª.	1	0	0
7ª.	1	0	0

A Tabela 2 mostra a saída da RNA após o treinamento quando de uma falta fase A para terra na configuração estudada (Figura 5), a uma distância de 0,35 km da barra da subestação (barramento P). As Tabelas 3, 4 e 5 apresentam, respectivamente, as respostas para o mesmo tipo de falta, com as distâncias de 16,45 km do barramento T, trecho T-Q, 4,7 km do barramento T, trecho T-R e 11,6 km do barramento T, também do trecho T-R.

TABELA 3 - resposta da rna para uma falta no ramo T-Q

AMOSTRA DO SINAL	CÓDIGO		
1ª.	1	0	0
2ª.	0	1	0
3ª.	0	1	0
4ª.	0	1	0
5ª.	0	1	0
6ª.	0	1	0
7ª.	0	1	0

TABELA 4 - resposta da rna para uma falta no ramo
T-R

AMOSTRA DO SINAL	CÓDIGO		
1 ^a .	0	0	1
2 ^a .	0	0	1
3 ^a .	0	0	1
4 ^a .	0	0	1
5 ^a .	0	0	1
6 ^a .	0	0	1
7 ^a .	0	0	1

TABELA 5 - Resposta da rna para uma falta no ramo
T-R

AMOSTRA DO SINAL	CÓDIGO		
1 ^a .	0	0	1
2 ^a .	0	0	1
3 ^a .	0	0	1
4 ^a .	0	0	1
5 ^a .	0	0	1
6 ^a .	0	0	1
7 ^a .	0	0	1

6.0 - CONCLUSÕES

A RNA, após treinada, conseguiu uma boa performance na localização dos trechos em curto-circuito. Em alguns casos ela não conseguiu acertar todas as sete amostras, porém acertou mais que 86%, como pode ser visto na 1^a amostra da Tabela 3. Este resultado é satisfatório.

A escolha da quantidade de amostras pós-falta contribuiu eficazmente no tempo de processamento durante o treinamento da RNA.

O método utilizado independe das condições da falta, bem como das condições do sistema. Destaca-se deste modo a fácil adequação das RNAs nos estudos deste tipo, não havendo a necessidade de lançar mão de equações das linhas aéreas de energia elétrica para o ponto de localização da falta, necessitando apenas que se faça uso de um software simulador de faltas de excelente desempenho e uma boa análise para extrair as características dos sinais.

Uma outra vantagem é a facilidade de implementação deste algoritmo localizador num Centro de Operação e Controle.

A metodologia aqui empregada foi para uma configuração contendo três ramais, simulação de defeito da fase A para a terra, impedância de falta de cinco ohms e ângulo de incidência de falta de 90 graus. A abordagem permite também generalizar o estudo para outros tipos de configurações, bem como

variações no tipo de falta e valores das resistências de falta e, ainda, localizar a distância do ponto de falta relativo à subestação, fatos estes pretendidos em outros trabalhos.

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

(1) ATP. Alternative Transient Program - Rule Book, Leuven EMTP Center (LEC), 1987.

(2) D.V. Coury and D.C. Jorge, "Artificial neural network approach to distance protection of transmission lines", IEEE Trans. on Power Delivery, vol. 13, no. 1, Jan. 1998, pp. 102-108.

(3) M. Oleskovics, "Redes Neurais Artificiais: Uma alternativa para proteção de linhas de transmissão", Dissertação de Mestrado, EESC/USP, São Carlos-SP, Dez. 1997.

(4) H. Yang, W. Chang and C. Huang, "Power system distributed on-line fault section estimation using decision tree based neural nets approach", IEEE Trans. on Power Delivery, vol. 10, no. 1, Jan. 1995, pp. 540 - 546

(5) Z.L. Kovács, Redes Neurais Artificiais, Edição Academica São Paulo: 1996.

(6) P.J. Moore, C. Öhlén and R.K. Aggarwal apud E.T. Domingues, "Localizador digital de faltas para linhas de transmissão de múltiplos terminais", Dissertação de Mestrado, EESC/USP, São Carlos-SP, Maio 1998.

(7) Eletricidade Moderna, "Localização de faltas em redes de distribuição", Aranda Editora, SP, no.66, 1999, pp. 66-67.

(8) A.V. Oppenheim and R.W. Schafer, Discret-Time Signal Processing, Englewood Cliffs, NJ: 1989, p. 845.

(9) Matlab, The Language of Technical Computing, The MathWorks Inc., version 5.2, Natick, Massachusetts, Usa, 1998.

(10) A.G. Phake and J.S.Thorp, Computer Relaying for Power System, Research Studies Press Ltda, England: 1988, pp. 17-24, 85.

(11) M.T.Hagan and M.B. Menhaj, "Training feedforward networks with the Marquardt algorithm", IEEE Trans. on Neural Networks, vol.5, no. 6, Nov. 1994, pp.989-993.