

TESTE DE TOPOLOGIAS DE REDES NEURAIS ARTIFICIAIS NA DETECÇÃO DE FALTAS MONOFÁSICAS DE ALTA IMPEDÂNCIA EM SISTEMA DE DISTRIBUIÇÃO DE ENERGIA¹

Eliseu Kotlinski², Manuel Martín Pérez Reimbold³.

¹ Relatório técnico científico

² Docente curso de Engenharia Elétrica, UNIJUI

³ Docente do curso de Mestrado em Modelagem Matemática, doutor em Microeletrônica, UNIJUI

RESUMO:

Em redes de distribuição de energia as faltas monofásicas de alta impedância, são eventos transitórios que acontecem em 63% dos casos, entre os tipos de faltas que podem acontecer no sistema. Os prejuízos, em termos financeiros e a possível agressão à vida das pessoas envolvidas neste tipo de evento, são motivos de preocupação e pesquisa por parte das concessionárias de energia. Objetivando fazer com que o problema seja detectado o mais rápido possível, de forma que as equipes de apoio possam restabelecer o fornecimento de energia ou isolar a região afetada pela falta, técnicas de inteligência artificial como Redes Neurais são empregadas neste caso. Este trabalho tem por objetivo testar topologias de Redes Neurais Artificiais na detecção de falta de alta impedância em um sistema de distribuição de energia, tomado como referência. O sistema será simulado observando seu comportamento frente a uma falta monofásica de alta impedância variável a terra e as Redes Neurais serão projetadas, treinadas e testas usando as ferramentas computacionais Simulink® e Matlab®, respectivamente.

INTRODUÇÃO:

Em um sistema de distribuição de energia, a intensidade das correntes, no momento em que ocorre uma falta de alta impedância, podem atingir valores que não são suficientes para ser detectada por relés de sobre corrente. Os relés de sobre corrente tem a função de proteger o sistema contra eventos desta natureza. No momento em que a falta acontece, essas correntes podem ser confundidas com aquelas produzidas por flutuações comuns à rede como no caso da inserção/remoção de cargas, chaveamento de capacitores entre outros.

Juntas, as faltas trifásicas, bifásicas e bifásicas para a terra acontecem em 37% dos casos, enquanto as faltas monofásicas para a terra acontecem em 63% dos eventos transitórios nos sistemas de distribuição de energia (Kinderman, 2007). Os danos contra vida das pessoas, causadas por este tipo

de falta, além do problema da interrupção no fornecimento de energia aos consumidores tem sido preocupações das concessionárias de energia.

Muitas são as técnicas estudadas para minimizar o problema das faltas em sistemas de distribuição. (Magnago, 2009) apresenta uma técnica de localização de faltas para sistemas de distribuição de energia radiais com base em sinais de corrente e tensão de alta frequência da rede. O método baseia-se na teoria de ondas progressivas e utiliza os sinais transitórios gravados durante a falta. O procedimento proposto por (Borghetti, 2007) utiliza a análise de wavelet contínua aplicada para as formas de onda de tensão gravadas durante a falta em um barramento de rede.

Visando superar as dificuldades encontradas na detecção de faltas monofásicas de alta impedância, as Redes Neurais Artificiais (RNA) aparecem como uma alternativa atrativa, pela facilidade na implementação, velocidade de resposta, entre outras vantagens. Esta técnica também apresenta algumas desvantagens em relação às técnicas convencionais. Cita-se a dificuldade em determinar a topologia ideal no projeto da rede e o algoritmo de aprendizagem no treinamento, afim de que ela consiga assimilar a rotina de identificação dos transitórios ocorridos no sistema (Cardoso, 2004).

Este trabalho tem por objetivo avaliar o efeito da adição de camadas intermediárias na topologia de redes na detecção de falta de alta impedância em um Sistema de Distribuição de Energia na configuração radial.

METODOLOGIA:

Tomando por base o sistema de distribuição de energia proposto por (Zamora, 2007), os seguintes passos foram seguidos na realização do presente trabalho:

i) Simulação do funcionamento do sistema na presença de uma falta monofásica variável de alta impedância:

Uma falta monofásica de alta impedância variável, cujo valor variou entre 2×10^{-3} (ohms) e 5×10^{-3} (ohms) foi simulada no sistema junto à carga 59, e no alimentador 5. A simulação do sistema foi feita usando a ferramenta computacional Simulink®. Na figura 1 é mostrado o diagrama do sistema, bem como o ponto onde foi posicionada a falta e a rede neural.

ii) Uma Rede Neural Perceptron Multicamadas (MLP) é posicionada junto ao barramento da subestação afim de avaliar a capacidade da rede em detectar a falta simulada:

O algoritmo de treinamento foi o Backpropagation em conjunto com o algoritmo de otimização no ajuste da razão de aprendizagem Fletcher-Powell Conjugate Gradient Backpropagation (CGF). A ferramenta computacional utilizada na simulação da rede foi o Matlab®.




Figura 1 - Diagrama ilustrativo do sistema. (fonte: Elaborado pelo Autor)

Na figura 2 é mostrado em um gráfico os valores instantâneos da corrente na fase A do alimentador 5, durante o intervalo de tempo em que o sistema ficou submetido à falta de alta impedância variável.




Figura 2 - Gráfico da corrente instantânea no alimentador 5, na fase A. (fonte: Elaborado pelo Autor)

iii) Classificação dos estados do sistema pelas RNA:

Analisando-se a figura 2, que mostra os valores instantâneos da corrente na fase A, a falta está presente no sistema do instante 0,15s até 0,35s. Durante este período observa-se sub e sobre correntes em função do valor variável instantâneo da falta. Fora deste intervalo o sistema operou normalmente. A classificação matemática a ser feita pela rede consiste em atribuir valor 0 (zero) quando o sistema opera normalmente, 1 (um) quando sistema opera em ambiente de falta durante uma sobre corrente e -1 (menos um) quando sistema opera em ambiente de falta durante uma sub corrente.

iv) Topologia, treinamento e teste da RNA:

Três topologias de rede foram treinadas e posteriormente testadas. A primeira rede teve duas camadas intermediárias. Em seguida a arquitetura foi modificada chegando a três camadas e finalmente quatro camadas intermediárias. Foram testadas somente estas três arquiteturas de redes porque o vetor com os estados do sistema tem dimensão $[4000 \times 1]$ e o número de interconexões das redes projetadas deve ser 100 vezes menor que o vetor com as informações apresentadas para a rede. Esta é a regra adotada no projeto das topologias das redes. Na tabela 1 é mostrada a topologia das redes que foram testadas neste trabalho. Seguindo a nomenclatura proposta por (Haykin, 2007) que descreve a arquitetura das redes, (in) representa o número de neurônios da camada de entrada, $h1 - \dots - hn$ identifica o número de neurônios na camada intermediária e (out) o número de neurônios da camada de saída.

Modalidade do trabalho: Relatório técnico-científico
Evento: XIX Jornada de Pesquisa

Identificação da Rede	Dimensão da rede (<i>in</i>) ($h_1 - \dots - h_n$) (<i>out</i>)
RNN1	1 – 10 – 1 – 1
RNN2	1 – 10 – 5 – 1 – 1
RNN3	1 – 20 – 10 – 5 – 1 – 1

Tabela 1 - Topologia das redes testadas. (fonte: Elaborado pelo Autor)

Na fase de treinamento da rede, o erro médio quadrático tolerado entre a resposta desejada e a resposta da rede não deve ser superior a 1×10^{-4} até 5000 iterações. Na tabela 2 é mostrado o desempenho das redes durante a fase de treinamento e é mostrado o erro médio quadrático, o tempo empregado no treinamento e o número de iterações executadas.

	RNN1	RNN2	RNN3
Erro	5.03e-3	4,00e-3	5,49e-5
Tempo	0:01:15	0:04:33	0:13:37
Iterações	187	588	945

tabela 2 - Desempenho das redes no treinamento. (fonte: Elaborado pelo Autor)

RESULTADOS E DISCUSSÃO:

Após o treinamento das redes, os padrões com as situações transitória do sistema, foram apresentadas às redes para fazer a classificação. Na figura 3, observa-se que a RNN1 com duas camadas intermediárias, faz uma classificação pobre dos padrões que mostram a situação transitória do sistema. Nos dois casos, quando o sistema opera normalmente e quando circula uma sobre corrente, a classificação realizada pela rede é confusa. Neste caso, o erro médio quadrático entre a resposta desejada para classificação dos transitórios e a classificação feita pela rede ficou em $6,00 \times 10^{-3}$.




Figura 3 - Classificação das situações transitórias realizada pela rede 1. (fonte: Elaborado pelo Autor)

No caso da rede RNN2 com três camadas intermediárias, observa-se que a classificação realizada melhorou pouco em comparação com a classificação feita pela RNN1, uma vez que o erro médio quadrático associado a RNN2 ficou em $1,26 \times 10^{-3}$. Para o caso da rede com quatro camadas intermediária (RNN3), a capacidade de classificação melhorou. O erro médio quadrático ficou em $1,67 \times 10^{-4}$. Esta afirmação pode ser verificada observando-se o gráfico mostrado na figura 4. As duas situações transitórias simuladas foram classificadas de forma correta pela rede.




Figura 4 - Classificação das situações transitórias realizada pela rede 3. (fonte: Elaborado pelo Autor)

CONCLUSÕES:

A partir da tabela 2, constata-se que as redes RNN1 e RNN2 tiveram o treinamento interrompido após 187 e 588 iterações, o erro médio quadrático chegou a $5,03 \times 10^{-3}$ e a $4,00 \times 10^{-3}$ respectivamente, não atingindo o erro limite de aprendizagem estabelecido. Este fato aconteceu pela própria característica do algoritmo de otimização Fletcher-Powell Conjugate Gradient Backpropagation (CGF) que é sensível a mínimos locais e requerem o ajuste no coeficiente de

Modalidade do trabalho: Relatório técnico-científico

Evento: XIX Jornada de Pesquisa

aprendizagem (beta). O problema foi contornado com a adição de mais uma camada intermediária, representado pela rede RNN3, sendo que neste caso o erro limite de aprendizado foi atingido chegando a $5,49 \times 10^{-5}$. O tempo máximo de treinamento ficou em 13 minutos e 37 segundos após 945 iterações. Este comportamento das redes, durante a fase de treinamento, pode ser verificado na fase de teste quando o transitório do sistema foi apresentado á elas para executarem a classificação. À medida que as camadas foram adicionadas a classificação feita melhorou, sendo que a rede RNN3 apresentou os melhores resultados. Como trabalhos futuros recomenda-se a simulação de novas situações transitórias como a remoção/adição de cargas, analisar o comportamento das redes no caso quando se tem a superposição dos efeitos transitórios no sistema tais como falta monofásica de alta impedância mais remoção/adição de cargas. A realização de novos testes com outros algoritmos de otimização nas redes, tais como o algoritmo de Levenberg-Marquardt Backpropagation (LM), Resilient Backpropagation (RP), BFGS Quasi-Newton Backpropagation (BFG) que podem dar bons resultados.

PALAVRAS-CHAVE:

Sistemas de Potência; Identificação de Sistemas; Inteligência Artificial.

REFERÊNCIAS BIBLIOGRÁFICAS:

BORGHETTI, A.; BOSETTI, M.; DI SILVESTRO, M.; NACCI, C. A.; PAOLONE, M; “Continuous-Wavelet Transform for Fault Location in Distribution Power Networks: Definition of Mother Wavelets Inferred From Fault Originated Transients,” International Conference on Power Systems Transients (IPST’07), pp. 1-9, Lyon, France, June 4-7 2007.

CARDOSO J, G.; ROLIM, J. G.; ZÜRN, H. H. Diagnóstico de Falhas em Sistemas de Potência: Definição do Problema e Abordagens Via Inteligência Artificial. Revista Controle & Automação/Vol.15 no.2/Abril, Maio e Junho de 2004.

HAYKIN, S. Redes Neurais Princípios e Práticas. 2a. Edição. Porto Alegre: Editora Bookman, 2007.

KINDERMAN, G. Curto – Circuito. 2 ed. Ed. Sagra Luzzato, 2007.

MAGNAGO, F. H.; ABUR, A. “A New Fault Location Technique for Radial Distribution Systems Based on High Frequency Signals,” IEEE Power Engineering Society Summer Meeting, vol. 1, pp. 426-431, Edmonton, Canada, 2009.

ZAMORA, I.; MAZÓN, A. J.; SAGASTABEITIA, K.J.; ZAMORA, J. J. New Method For Detecting Low Current Faults in Electrical Distribution Systems. In: IEEE Transactions On Power Delivery, Vol. 22, No 4, October 2007.



Câmpus Ijuí, Santa Rosa,
Panambi e Três Passos

Modalidade do trabalho: Relatório técnico-científico
Evento: XIX Jornada de Pesquisa