

INTELIGÊNCIA ARTIFICIAL APLICADA À PROTEÇÃO DE TRANSFORMADORES DE POTÊNCIA

ÊNIO C. SEGATTO, DENIS V. COURY

Laboratório LSEE, Departamento de Engenharia Elétrica, Escola de Engenharia de São Carlos - USP
Av. Trabalhador São-carlense, 400, CEP 13566-590, São Carlos, SP, Brasil
E-mails: segatto@sel.eesc.usp.br, coury@sel.eesc.usp.br

Abstract— This paper presents a complete differential protection system for power transformers, applying the Artificial Neural Network (ANN) theory. The proposed approach treat the classification of the protection system as a problem of pattern recognition and as an alternative method to the conventional algorithms. Several factors such as, for example, transformer energization and CT saturation can cause an inadequate operation of the protection relay. A complete protection system was developed, including an ANN-based device in substitution to harmonic filters in use in the conventional algorithm. Some approaches concerning the reconstruction of the distorted signals caused by the CTs saturation are also proposed. These routines are added to the final protection algorithm. With the use of artificial intelligence tools in a complete power transformer protection algorithm, a very precise, fast and efficient solution was obtained, if compared to the conventional methods.

Keywords— Differential Protection; Artificial Neural Networks; Power Transformers; CT Saturation.

Resumo— Este trabalho apresenta um sistema eficiente de proteção diferencial para transformadores de potência, através da teoria de Redes Neurais Artificiais (RNAs). O método proposto trata a classificação do sistema de proteção como um problema de reconhecimento de padrões e constitui um método alternativo aos algoritmos convencionais. Muitos fatores, tais como a energização do transformador e a saturação dos TCs, podem causar uma operação inadequada do relé de proteção. Um sistema de proteção alternativo foi desenvolvido, incluindo um módulo baseado em RNA em substituição aos filtros harmônicos, usados no algoritmo convencional. Abordagens baseadas na reconstrução dos sinais distorcidos causados pela saturação dos TCs são também propostas. Essas rotinas são adicionadas ao algoritmo final de proteção. Com a utilização de ferramentas de inteligência artificial em um algoritmo completo de proteção de transformadores, uma solução precisa, rápida e eficiente foi obtida, se comparada aos métodos convencionais.

Palavras-chave— Proteção Diferencial, Redes Neurais Artificiais, Transformadores de Potência, Saturação do TC.

1 Introdução

Transformadores são dispositivos que requerem manutenção especial devido a sua importância ao sistema elétrico no qual eles são conectados. Geralmente, relés diferenciais são usados na proteção primária de grandes transformadores, onde as correntes diferenciais são comparadas a um patamar preestabelecido e no caso de uma falta interna, o transformador deverá ser desconectado do sistema. Entretanto, a simples detecção de uma corrente diferencial não é suficiente para distinguir faltas internas de outras situações como a energização do transformador (correntes de *inrush*), saturação do TC (transformador de corrente), entre outras, as quais podem resultar em um *trip* incorreto (Horowitz e Phadke, 1995).

A correta e rápida distinção de faltas internas de outras situações mencionadas é um dos principais desafios da proteção de transformadores. Com relação à identificação entre faltas internas e correntes de *inrush*, o método tradicionalmente utilizado é a lógica diferencial com restrição harmônica, no qual a corrente do transformador devido a energização é reconhecida com base nas componentes de segundo harmônico. Entretanto, o método de filtragem pode eventualmente atrasar o processo de proteção. Em adição a isso, componentes de segunda harmônica podem também estar presentes em faltas internas.

Novos métodos com o objetivo de melhorar a seletividade, sensibilidade e a operação de relés diferenciais têm sido estudados nos últimos anos (Yu et alii, 1999; Yu et alii, 2001; Kang et alii, 1996; Kang et alii, 1997; Jamali e Radji, 1997; Sidhu et alii, 1999).

Este trabalho apresenta um método alternativo utilizando Redes Neurais Artificiais (RNAs) com o objetivo de melhorar o desempenho da proteção de transformadores de potência com relação à correta identificação de faltas internas e correntes de *inrush*. O programa ATP (Alternative Transients Program Rule Book, 1987) foi usado para modelar o transformador de potência no sistema elétrico. Esse modelo foi usado para a geração de dados com e sem a consideração da saturação de TCs para o treinamento das RNAs, bem como para os testes das abordagens propostas.

2 A Proteção Diferencial de Transformadores

O diagrama ilustrando a lógica diferencial usada na proteção de transformadores de potência é mostrado na Figura 1. A figura mostra também a conexão dos transformadores de corrente (TCs) acoplados aos ramos primário e secundário. Sob condições normais e de faltas externas ao transformador, as correntes i_{1S} e i_{2S} (correntes secundárias dos TCs) são iguais. Porém, no caso de faltas internas, a diferença entre elas torna-se significativa, causando a atuação do relé.

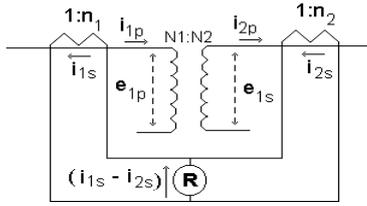


Figura 1. Esquema diferencial da proteção de transformadores de potência

Portanto, a corrente diferencial

$$i_d = i_{1s} - i_{2s} \quad (1)$$

fornece uma medida precisa da corrente de falta.

A fim de corrigir erros introduzidos pelos TCs e pelas mudanças de *tap* do transformador, um patamar é fixado para que uma pequena corrente diferencial possa ser tolerada, sem desconectar o sistema. Essa relação é mostrada na equação 2.

$$i_d \geq K(i_{1s} + i_{2s})/2 \quad (2)$$

onde K é a inclinação da curva diferencial.

A Figura 2 mostra a característica diferencial do relé incluindo as zonas de operação e restrição. São apresentados ajustes para K (15%, 25% e 40%).

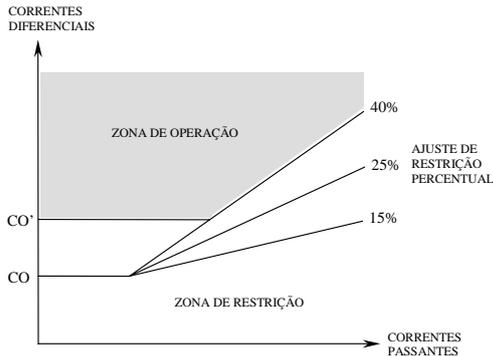


Figura 2. Curva característica diferencial

Durante a energização do transformador, a corrente diferencial pode alcançar valores suficientemente altos, originando uma operação indevida do relé. A modelagem de tal situação tem sido estudada, mostrando a predominância do componente de 2ª harmônica nesta situação. (Cummins *et alii*, 2000; Chen e Glad, 1991).

Alguns outros fenômenos podem originar falsas correntes diferenciais, tais como remoção de falta externa, sobreexcitação e a saturação dos TCs.

3 A Saturação dos TCs

Os TCs são empregados para fornecer a redução das correntes primárias, bem como permitir isolamento entre o sistema elétrico e os equipamentos conectados ao secundário do TC. As correntes fornecidas pelo lado secundário dos TCs devem ser reproduções fiéis das correntes do lado primário. Quando faltas ocorrem, além das correntes atingirem níveis elevados,

podem conter altas parcelas do componente CC. Tais fatores podem causar a saturação do núcleo do TC e produzir distorção na forma de onda secundária de corrente (Horowitz e Phadke, 1995), podendo levar os relés a operar incorretamente. A Figura 3 mostra um caso de falta interna simulada com um TC ideal. A Figura 4 mostra o mesmo caso onde as distorções causadas pela saturação podem ser observadas.

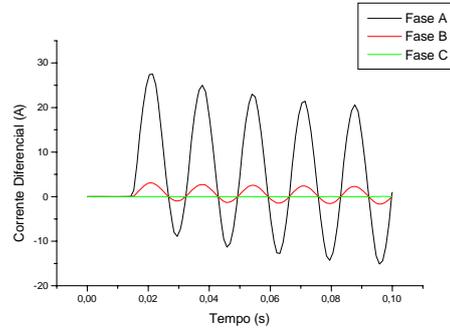


Figura 3. Caso de falta interna sem a saturação do TC

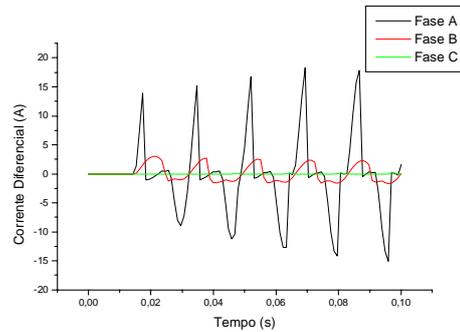


Figura 4. Caso de falta interna com a saturação do TC

Embora muitos trabalhos abordem o problema da saturação de TCs (Kang *et alii*, 1996; Kang *et alii*, 1997; Jamali e Radji, 1997; Sidhu *et alii*, 1999), os métodos disponíveis apresentam certas limitações.

Quando a saturação do TC é elevada, poderá causar atraso ou até mesmo evitar a operação de *trip*. Esse tipo de problema tem sido discutido na literatura (Chen e Glad, 1991; Barnett *et alii*, 1993).

Alguns trabalhos têm sido realizados na tentativa de reconstrução dos sinais distorcidos pelos TCs utilizando Redes Neurais Artificiais (Yu *et alii*, 1999; Yu *et alii*, 2001; Cummins *et alii*, 2000).

Neste estudo, um sistema baseado em RNAs Recorrentes foi elaborado para corrigir os sinais saturados.

4 Redes Neurais Artificiais - RNAs

Uma RNA consiste de um conjunto de células conectadas e com uma regra de propagação.

Cada neurônio recebe suas entradas com pesos, vindos de outros neurônios e seu estado de ativação é

determinado pela função de saída ou transferência. A saída do neurônio trafega até a próxima célula. Assim, uma RNA é formada por um conjunto de neurônios dispostos em camadas, conectados por ligações de pesos variados (SNNS User Manual, 1995).

Na fase de treinamento da rede, há a determinação e a correção dos pesos e dos *bias*, para que a mesma responda de uma forma desejada.

Alguns algoritmos não são capazes de implementar mapeamentos dinâmicos, isto é, possuir memória (Elman, 1990). Podem-se definir redes recorrentes como aquelas que possuem conexões de realimentação que proporcionam comportamento dinâmico. Nas redes de Elman, há também unidades de contexto. As unidades de entrada e saída interagem com o ambiente externo, enquanto as unidades intermediárias e de contexto não o fazem. As unidades de contexto são usadas apenas para memorizar as ativações anteriores das unidades intermediárias.

Após o início do treinamento, as ativações das unidades intermediárias são reintroduzidas através das ligações recorrentes nas unidades de contexto, sendo salvas nestas unidades para o próximo passo do treinamento (Carvalho *et alii*, 2000).

A Figura 5 ilustra a operação da rede de Elman.

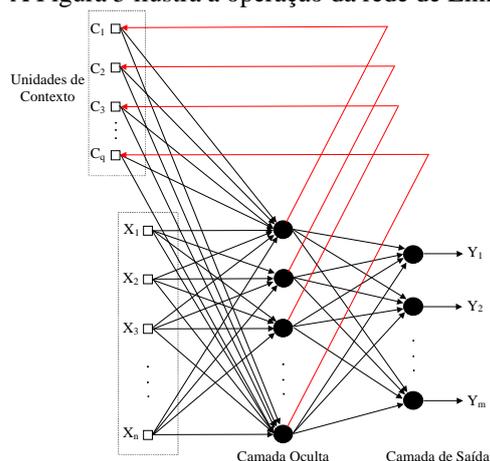


Figura 5. Rede neural recorrente de Elman

5 A Simulação do Sistema Elétrico

A Figura 6 mostra a representação do sistema elétrico simulado pelo programa ATP (Coury *et alii*, 1998) com o intuito de geração dos bancos de dados utilizados no treinamento e testes das RNAs.

O sistema é composto de um equivalente de geração de 138 kV e 30 MVA, um transformador de 138/13,8 kV Δ/Y e 25 MVA, uma linha de transmissão de 5 km seguida de uma carga de 10 MVA e fator de potência 0,92 indutivo.

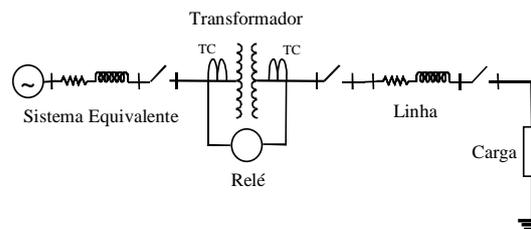


Figura 6. Sistema elétrico simulado

Um segundo transformador foi modelado para fins comparativos e uma melhor validação do trabalho. Tal transformador é idêntico ao anterior, porém com potência de 6,25 MVA e 69:13,8 kV e foi empregado na fase final do trabalho, onde foi testado o algoritmo proposto.

Um total de 2595 casos foi simulado para cada transformador usando janelas móveis de dados com três amostras, totalizando 7,785 padrões (108 casos de energização, 216 casos de faltas internas espira-terra, 216 casos de faltas internas entre espiras em ambos os lados do transformador, 162 casos de faltas externas ao transformador, 81 casos de faltas ocorrendo entre o transformador e o TC secundário, 72 casos energização com a presença de falta interna, 45 casos de sobreexcitação do transformador, 15 casos de energização de bancos de capacitores, 54 casos de rejeição de carga, 324 casos de remoção de faltas externas e 5 casos de regime permanente). Após o processo de simulação, os dados foram organizados para a utilização no estágio de treinamento da RNA.

6 Reconhecimento de Padrões com a Saturação dos Transformadores de Corrente

Os casos envolvidos nesta etapa representam somente as situações que ocasionam correntes diferenciais relevantes ao relé de proteção, ou seja, as situações de energização de bancos de capacitores e de regime permanente não foram incluídas nesta etapa. Assim, construiu-se um conjunto de dados contendo um total de 7668 padrões, ou 2556 casos, considerando-se a janela de dados móveis de 3 movimentos.

Após a simulação dos dados, estes foram divididos em conjuntos de treinamento, validação e testes. Foram utilizadas quatro amostras por fase das correntes diferenciais no treinamento, com frequência amostral de 1 kHz. Uma janela móvel de dados foi então aplicada gerando três padrões para cada caso simulado.

As três janelas de dados móveis são:

Primeira janela - $i_{A1}, i_{A2}, i_{A3}, i_{A4}$

Segunda janela - $i_{A2}, i_{A3}, i_{A4}, i_{A5}$

Terceira janela - $i_{A3}, i_{A4}, i_{A5}, i_{A6}$

onde $i_{A1}, i_{A2}, i_{A3}, i_{A4}, i_{A5}$ e i_{A6} são os valores discretos de corrente diferencial da fase A. O procedimento é similar para as fases B e C.

Nas etapas de treinamento e validação, 50% dos casos consideraram o fenômeno de saturação causa-

do pelos TCs. A divisão da camada de entrada das redes neurais estudadas, em função dos sinais de correntes diferenciais gerados para cada fase e submetidos à janela de dados móveis é mostrada na Figura 7.

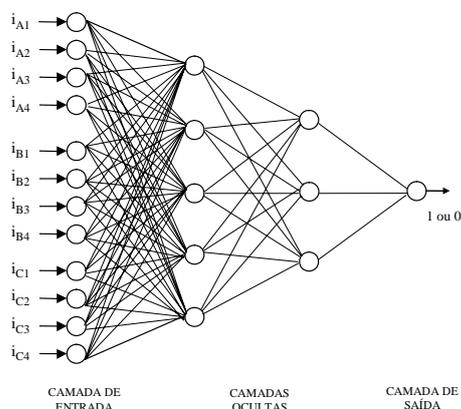


Figura 7. Entradas e saídas das RNAs

Para a aplicação de Redes Neurais Artificiais nesta fase, convencionou-se, para as respostas das redes, que saídas menores ou iguais a 0,5 indicariam situações de bloqueio do relé e que saídas maiores que 0,5 corresponderiam a situações de *trip*.

A melhor rede neural obtida foi do tipo MLP *Backpropagation* e conteve duas camadas intermediárias ou ocultas. A primeira camada constituiu-se de 8 células e a segunda, de 5 neurônios. Esta configuração foi a mais simples alcançada e capaz de fornecer 97,19% de acertos na distinção entre as situações estudadas, fornecendo 2484 respostas corretas.

7 Correção dos Sinais Distorcidos pela Saturação dos TCs Através de RNAs

O processo de treinamento para estes casos foi idêntico àquele descrito no item anterior, porém com a inclusão dos casos de energização de bancos de capacitores (30 casos) e de regime permanente (9 casos). O banco de dados total para este etapa totalizou, portanto, 2595 casos ou 7785 vetores, considerando-se a janela de dados móveis de 3 movimentos. Para os processos de treinamento e validação, 50% dos casos consideraram o fenômeno de saturação.

O método de treinamento de Elman foi executado e as camadas de entrada e saída da RNA contiveram 24 neurônios cada uma (meio ciclo de dados). Nessa fase, a melhor topologia obtida conteve 24 neurônios na camada de entrada, 20 neurônios na camada oculta, 24 neurônios na camada recorrente e 24 neurônios na camada de saída, a qual reconstruiu o sinal de entrada.

Um total de 2595 padrões foi empregado para testar as arquiteturas empregadas. Esses dados não foram usados na etapa de treinamento.

Para exemplificar os resultados obtidos nos testes das RNAs em questão, é mostrado a seguir um caso de reconstrução de sinal através da correção

efetuada pela rede neural. A figura 8 mostra um sinal de falta interna ao transformador contendo distorção causada pela saturação do TC primário.

A seguir, na figura 9, é ilustrado o sinal ideal desejado para o mesmo caso, ou seja, sem conter a saturação do TC. Na próxima figura 10, pode-se observar o caso em questão corrigido pela rede neural.

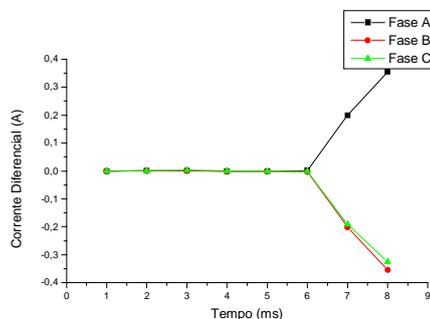


Figura 08. Sinal de falta interna distorcido por saturação

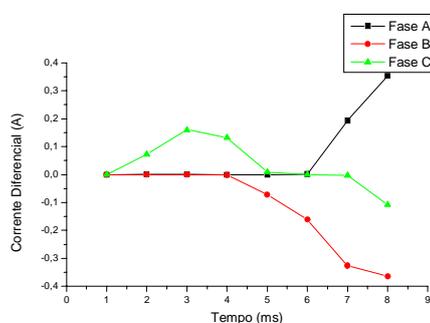


Figura 09. Sinal de falta interna com TC ideal

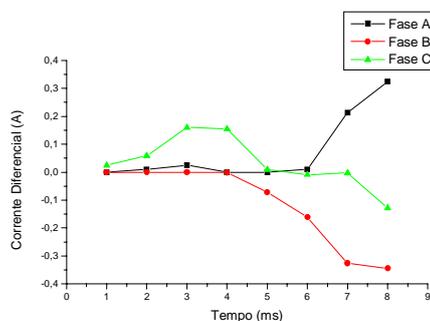


Figura 10. Sinal de falta interna reconstruído pela RNA

A RNA de Elman obteve uma precisão de 98,5% na tarefa de reconstrução de sinais distorcidos, tornando os sinais corrigidos muito próximos das situações desejadas. Esta é uma contribuição significativa com relação à proteção do transformador que será evidenciada na eficiência do algoritmo mostrado na seção seguinte. Deve também ser ressaltado o ganho com relação à oscilografia associada ao equipamento (Segatto e Coury, 2006).

8 O Esquema Proposto

O algoritmo da Figura 14 ilustra o princípio lógico proposto para o relé diferencial, considerando o emprego das ferramentas baseadas em Redes Neurais Artificiais em substituição ao procedimento de extração de componentes harmônicos tradicional. Neste algoritmo, é realizada a reconstrução dos sinais através do módulo específico de RNAs recorrentes. Após esta etapa, o relé verifica a ocorrência de correntes diferenciais consideráveis no sistema, analisando a área de operação do dispositivo em função da característica diferencial escolhida. Caso confirmada a corrente diferencial, é verificada a condição de abertura ou bloqueio do disjuntor através da rede neural MLP. Tal ferramenta substitui então, no algoritmo proposto, a lógica convencional de restrição harmônica baseada na decomposição por Fourier. Se confirmada a condição de acionamento do relé, o algoritmo faz o acréscimo na contagem de sinais de falta e verifica o valor limite para que o contador envie o sinal de desligamento ao disjuntor correspondente.

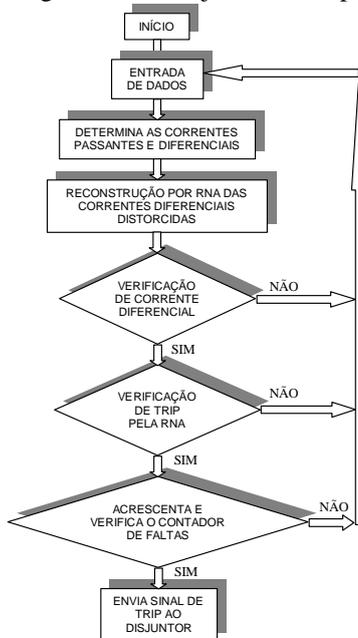


Figura 14. Algoritmo de proteção proposto

As ferramentas de inteligência artificial empregadas realizam a distinção de situações de acionamento ou bloqueio do disjuntor, respondendo inclusive a dados saturados.

Desta forma, o primeiro módulo baseado em RNAs realiza a reconstrução dos sinais e o segundo toma a decisão de abertura ou bloqueio do disjuntor correspondente. Apesar de o algoritmo ilustrado conter duas estruturas neurais implementadas, pretende-se, com essa abordagem, obter uma maior precisão nas respostas finais do algoritmo, devido à eficiência esperada pelo emprego do módulo de reconstrução de sinais distorcidos.

9 Avaliação do Algoritmo Proposto

Neste item é analisado o desempenho do algoritmo proposto no trabalho e ilustrado na Figura 14. O banco de dados utilizado para esta tarefa consistiu de 2595 padrões, sendo que os casos testados envolveram 50% de sinais com a presença de saturação dos dispositivos transformadores de corrente. É importante ressaltar que o banco de dados utilizado nesta fase foi elaborado a partir dos sistemas elétricos simulados com os transformadores de 25 e 6,25 MVA.

A Tabela I ilustra o desempenho do algoritmo proposto, que utiliza o reconhecimento de padrões (rede MLP) aliado à reconstrução de sinais distorcidos (rede de Elman) para o transformador de 25 MVA. A Tabela II mostra o desempenho do mesmo algoritmo para o transformador de 6,25 MVA.

Tabela I. Desempenho do Algoritmo Proposto – Transformador de 25 MVA

ALGORITMO 2 - TRANSFORMADOR DE 25 MVA			
CASOS TESTADOS	NÚMERO DE PADRÕES	ACERTOS	ERROS
Energização	216	216	0
Faltas Internas	864	863	1
Faltas Externas	324	324	0
Faltas entre Transformador e TC	162	162	0
Energização com Falta Interna	144	143	1
Sobre-excitação	90	90	0
Energização de Bancos de Capacitores	30	30	0
Rejeição de Cargas	108	108	0
Remoção de Faltas Externas	648	648	0
Regime Permanente	9	9	0
TOTAL	2595	2593	2
TOTAL (%)	100,00	99,92	0,08

Tabela II. Desempenho do Algoritmo Proposto – Transformador de 6,25 MVA

ALGORITMO 2 - TRANSFORMADOR DE 6,25 MVA			
CASOS TESTADOS	NÚMERO DE PADRÕES	ACERTOS	ERROS
Energização	216	213	3
Faltas Internas	864	859	5
Faltas Externas	324	322	2
Faltas entre Transformador e TC	162	161	1
Energização com Falta Interna	144	143	1
Sobre-excitação	90	90	0
Energização de Bancos de Capacitores	30	30	0
Rejeição de Cargas	108	106	2
Remoção de Faltas Externas	648	644	4
Regime Permanente	9	9	0
TOTAL	2595	2577	18
TOTAL (%)	100,00	99,31	0,69

Pode-se notar que, apesar de a ferramenta ter sido testada também com dados gerados por um sistema elétrico de configuração diferente daquele utilizado para obter os dados de treinamento das RNAs em questão, o desempenho do algoritmo mostrou-se muito elevado para ambos os transformadores.

O algoritmo tradicional de proteção de transformadores com rotinas baseadas na filtragem harmônica do sinal foi também testado com o mesmo banco de dados utilizado nos testes anteriores. Porém seu índice de precisão para o transformador de 25 MVA foi de 73,76%, enquanto que para o segundo transformador de 6,25 MVA a taxa de acertos foi de apenas 71,60%. Ambos os testes consideraram a inclinação de 25% na curva característica do relé diferencial e um conteúdo de 2º harmônico de 20% em relação ao conteúdo de componente fundamental para a operação de restrição.

10 Conclusões

Este trabalho apresentou o desenvolvimento e a implantação de um sistema eficiente de proteção diferencial de transformadores de potência aplicando-se as técnicas de Redes Neurais Artificiais. Os métodos propostos tratam o esquema de proteção diferencial como um problema de reconhecimento e reconstrução de padrões, representando uma solução alternativa aos algoritmos convencionais.

O algoritmo proposto realizou o reconhecimento de padrões através da rede MLP com o auxílio de um segundo módulo de RNAs, utilizado na reconstrução dos sinais saturados. Nesta aplicação, o índice de respostas corretas fornecido foi de 99,92% e 99,31% para os transformadores de 25 MVA e 6,25 MVA respectivamente, embora a resposta seja fornecida após a computação de ½ ciclo de dados, ou seja, 8,33 ms.

É preciso considerar que a metodologia baseada na decomposição harmônica de Fourier necessita de, no mínimo, um ciclo de dados a fim de fornecer a resposta a um sinal de entrada, tempo este muito superior ao obtido pelo algoritmo proposto.

Resultados encorajadores, conseguidos pela implementação do algoritmo baseado em inteligência artificial, foram gerados por testes realizados com dados advindos, inclusive, de um sistema elétrico diferente daquele empregado no treinamento das Redes Neurais Artificiais, atestando, desta forma, a flexibilidade do método estudado.

Agradecimentos

Os autores gostariam de agradecer o Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos – Universidade de São Paulo, pelo apoio à pesquisa realizada, bem como o suporte financeiro concedido pela FAPESP – Fundação de Amparo a Pesquisa do Estado de São Paulo.

Referências Bibliográficas

Alternative Transients Program Rule Book (1987), Leuven EMTP Center.

Barnett, C.W. ; Chadwick, J.W. et al. (1993). Relay Performance Considerations with Low Ratio CTs and High Fault Currents, *IEEE Transactions on Power Delivery*, v.8, n.3, pp. 884-887.

Carvalho, A.C.P.L.F. ; Braga, A.P. and T.B. Ludermir (2000), *Redes Neurais Artificiais: Teorias e Aplicações*, Rio de Janeiro, Livros Técnicos e Científicos, 262 p.

Chen, K.W. and S.T. Glad (1991). Estimation of the Primary Current in a Saturated Transformer, *Proceedings of the IEEE Conference on Decision and Control*, pp. 116-124.

Coury, D.V.; Campos, P.G. and M.C. Tavares (1998). Modelling a Power Transformer for Investigation of Digital Protection Schemes. *8th International Conference on Harmonics and Quality of Power (ICHQP'98)*, pp. 489-494.

Cummins, J.C. ; Yu, D.C. and L.A. Kojovic (2000). Simplified Artificial Neural Network Structure with the Current Transformer Saturation Detector provides a Good Estimate of Primary Currents, *2000 Power Engineering Society Summer Meeting*, v.3.

Elman, J.L. (1990). Finding Structure in Time. *Cognitive Science*, n.14, pp.179-211.

Horowitz, S. H. and A.G. Phadke (1995). *Power System Relaying*, Research Studies Press Ltd., 2nd ed., England.

Jamali, S. and K.M. Radji (1997). A Digital Compensating Technique for the Saturation of Protective Current Transformers, *Proceedings of Thirty Second Universities Power Engineering Conference*, v.1, pp. 10-12.

Kang, Y.C. ; Kang, S.H. ; Park, J.K. ; Johns, A.T. and R.K. Aggarwal (1997). Algorithm for Compensating Secondary Currents of Current Transformers, *IEEE Transactions on Power Delivery*, v.12, n.1, p. 116-124.

Kang, Y.C. ; Kang, S.H. ; Park, J.K. ; Johns, A.T. and R.K. Aggarwal (1996). Development in Hardware Implementation of a Compensating Algorithm for the Secondary Current of Current Transformers, *IEEE Proceedings in Electric Power Applications*, v.143, n.1, pp. 41-49.

Segatto, E.C. and D.V. Coury (2006). Redes Neurais Artificiais Recorrentes Aplicadas na Correção de Sinais Distorcidos pela Saturação de Transformadores de Corrente, *SBA - Controle & Automação*, v.17, n. 4, v. 17, pp.424-436.

Sidhu, T.S. ; Gill, H.S. and M.S. Sachdev (1999). A Power Transformer Protection Technique with Stability during Current Transformer Saturation and Ratio-mismatch Conditions, *IEEE Transactions on Power Delivery*, v.14, n.3, pp. 798-804.

SNNS User Manual (1995). Institute for Parallel and Distributed High Performance Systems, University of Stuttgart.

Yu, D.C. ; Cummins, J.C. ; Wang, Z. ; Yoon, H.J. and L.A. Kojovic (2001). Correction of Current Transformer Distorted Secondary Currents due to Saturation using Artificial Neural Networks, *IEEE Transactions on Power Delivery*, v.16, n.2, pp.189-194.

Yu, D.C. ; Wang, Z. ; Cummins, J.C. ; Yoon, H.J. and L.A. Kojovic (1999). Neural Network for Current Transformer Saturation Correction, *Proceedings of IEEE Power Engineering Society – Transmission and Distribution Conference*, v.1, pp. 441-446.