



**SNPTEE
SEMINÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

GPC - 01
16 a 21 Outubro de 2005
Curitiba - Paraná

GRUPO V

GRUPO DE ESTUDO DE PROTEÇÃO, MEDIÇÃO E CONTROLE EM SISTEMAS DE POTÊNCIA - GPC

CORREÇÃO DA SATURAÇÃO DE TCS ATRAVÉS DE REDES NEURAS ARTIFICIAIS RECORRENTES

Ênio Carlos Segatto

Denis Vinicius Coury

EESC - USP

EESC - USP

RESUMO

Este trabalho apresenta uma técnica alternativa para a correção de ondas distorcidas provenientes da saturação dos transformadores de corrente (TCs) através de ferramentas inteligentes baseadas em Redes Neurais Artificiais (RNAs) recorrentes. Os TCs estão presentes em Sistemas Elétricos de Potência com a finalidade de proteção e medição, sendo altamente susceptíveis à saturação. O programa EMTP-ATP – *Electromagnetic Transients Program* foi escolhido como ferramenta computacional para a simulação de um sistema elétrico utilizado na geração de dados de treinamento e testes para as RNAs. Muitas arquiteturas de redes neurais artificiais foram treinadas e testadas. Resultados promissores relativos ao novo método são apresentados.

PALAVRAS-CHAVE

Transformadores de Corrente, Saturação, Redes Neurais Artificiais, Transformadores de Potência.

1.0 - INTRODUÇÃO

Conforme os Sistemas Elétricos de Potência crescem em tamanho e complexidade, apresentando aumento nos níveis das correntes de falta, os relés de proteção e os equipamentos de medição passam a desempenhar um papel cada vez mais importante. Para tal finalidade, eles requerem uma reprodução precisa das correntes do sistema. Assim, os transformadores de corrente (TCs) são empregados na redução das correntes primárias do sistema, bem como no fornecimento de isolamento galvânica entre a rede elétrica e os relés e outros instrumentos conectados ao enrolamento secundário do TC.

Os transdutores devem ser projetados para tolerar valores maiores oriundos de condições anormais de operação do sistema. Assim, os TCs são concebidos para suportar correntes de falta e outros surtos por poucos segundos, que podem atingir valores de até 50 vezes a magnitude da corrente de carga (1).

As correntes fornecidas pelo lado secundário dos transdutores devem ser reproduções fiéis das correspondentes correntes do seu lado primário. Embora os dispositivos modernos atendam a essa condição satisfatoriamente bem, na maior parte dos casos, o projeto de proteção necessita levar em consideração o correto ajuste dos transdutores, bem como os erros de transformação eventualmente introduzidos pelos TCs.

Quando faltas ocorrem, além dos valores de corrente atingirem níveis elevados, podem conter substanciais parcelas do componente CC e, ainda, pode existir fluxo remanescente no núcleo do TC. Todos esses fatores podem levar à saturação do núcleo do transformador de corrente e produzir significativa distorção na forma de onda secundária de corrente do dispositivo (1).

Um dos grandes problemas dos Sistemas Elétricos de Potência reside na saturação de alguns de seus componentes. Nestes casos, a corrente secundária de um TC pode não representar precisamente sua corrente

primária. Os relés que dependem desta corrente podem facilmente operar de forma incorreta durante este período, comprometendo a eficiência da proteção do equipamento em questão.

A Figura 1 e a Figura 2 ilustram a condição de falta interna a um transformador de potência sem e com a presença de saturação dos TCs respectivamente. Nota-se a diferença no formato de onda do sinal para a mesma situação analisada. Os sinais foram simulados no programa ATP (2).




FIGURA 1 - Situação de falta interna ao transformador sem a presença de saturação dos TCs




FIGURA 2 - Situação de falta interna ao transformador com a presença de saturação dos TCs

A possibilidade de saturação destes dispositivos deve ser altamente considerada no projeto de um sistema de proteção em termos do desempenho dos relés.

Este trabalho propõe uma técnica alternativa para a correção de formas de ondas distorcidas pela saturação dos TCs baseada no uso de Redes Neurais Artificiais Recorrentes. Resultados bastante promissores são alcançados com a utilização desta metodologia e são apresentados a seguir.

2.0 - A SATURAÇÃO DOS TRANSFORMADORES DE CORRENTE

Embora muitos trabalhos abordem o problema da saturação dos transformadores de corrente (3)(4)(5)(6)(7)(8)(9), os métodos disponíveis até agora apresentam certas limitações.

O aumento na seção transversal do núcleo dos TCs permite uma maior acomodação de fluxo, causando, porém, certa diminuição em sua sensibilidade.

Tem havido muitas propostas para a redução da seção transversal requerida para o TC (10)(11) sem afetar a habilidade do dispositivo em lidar com grandes trocas de fluxo.

2.1 Efeitos da saturação do TC na operação do relé

A maioria dos relés de proteção toma as decisões de operação baseados no valor RMS da corrente de falta. Se o sinal fornecido pelo TC é distorcido por saturação, o valor RMS detectado será muito menor que o valor real de corrente de falta, podendo atrasar a operação do relé. Quando a saturação é elevada, sua presença pode até mesmo evitar que o relé opere. Este tipo de problema tem sido amplamente discutido na literatura relativa a vários tipos de proteção (4)(10)(12)(13)(14)(15).

2.2 Estimadores existentes para a correção da saturação dos TCs

O trabalho (4) mostra uma técnica de compensação que estima matematicamente a corrente secundária do TC.

Se a característica da saturação do TC é conhecida, uma estimativa da corrente de entrada na situação onde o TC satura pode ser encontrada (14). Porém, a maioria das correntes de falta não terá a característica simétrica necessária para essa estimativa.

Outras abordagens presentes na literatura têm usado filtros de Kalman e processos iterativos para a correção da saturação (4)(12). Estes métodos não são convenientes para aplicações em tempo real.

Alguns trabalhos têm sido realizados na tentativa de reconstrução dos sinais distorcidos pelos TCs utilizando Redes Neurais Artificiais.

O trabalho apresentado em (6) emprega dois conjuntos de coeficientes para as RNAs a fim de lidar com diferentes faixas de correntes de falta.

A técnica proposta em (9) permanece estável durante as condições de saturação e de erro nas relações dos TCs, utilizando somente dados saturados de falta na etapa de treinamento das RNAs.

Em (8), redes neurais artificiais foram treinadas para obter a função de transferência inversa dos TCs e estimar as correntes secundárias distorcidas pela saturação dos mesmos.

3.0 - REDES NEURAIS ARTIFICIAIS

A rede de neurônios artificiais foi inspirada no pouco que o homem já conhece sobre o cérebro humano. O primeiro modelo artificial de um neurônio biológico foi fruto do trabalho pioneiro de Warren McCulloch e Walter Pitts (16).

A descrição do algoritmo de treinamento *Backpropagation* (17), mostrou que as RNAs de múltiplas camadas são capazes de resolver problemas complexos.

Uma RNA é formada por um conjunto de neurônios dispostos em uma ou mais camadas, conectados por ligações de pesos variados (18). Na fase de treinamento da rede, há a determinação e a correção dos pesos e dos bias, para que a mesma responda de forma desejada. A característica da RNA é, então, considerar o conhecimento adquirido durante o treinamento e responder a novos dados de entrada da maneira mais apropriada, concluindo assim, a generalização do problema.

3.1 Redes neurais recorrentes

Muitos algoritmos de treinamento das RNAs não são capazes de implementar mapeamentos dinâmicos, como por exemplo o algoritmo *Backpropagation* simples. A principal questão é como estender a estrutura das redes MLP para que assumam um comportamento que varie com o tempo, sendo assim capaz de tratar sinais temporais (19). Para uma RNA ser considerada dinâmica, é preciso que possua memória (20).

Podem-se definir redes recorrentes como aquelas que possuem conexões de realimentação que proporcionam comportamento dinâmico.

3.2 Redes de Elman

Elman introduziu memória às RNAs (20). Nas redes de Elman, além das unidades de entrada, intermediárias e de saída, 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 saída são unidades lineares que somam os sinais que recebem. As unidades de contexto são usadas apenas para memorizar as ativações anteriores das unidades intermediárias e podem ser consideradas como atraso no tempo em um passo.

Inicialmente, as ativações das unidades intermediárias e as entradas correntes são utilizadas como entradas da rede. Em um primeiro estágio, estas entradas são propagadas para frente a fim de produzir as saídas. Posteriormente, a rede é treinada com o algoritmo de aprendizagem *Backpropagation* padrão.

Após este passo de 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. A recorrência na rede de Elman, portanto, é feita da camada oculta para as entradas.

A Figura 3 ilustra o modo de operação de uma rede de Elman.

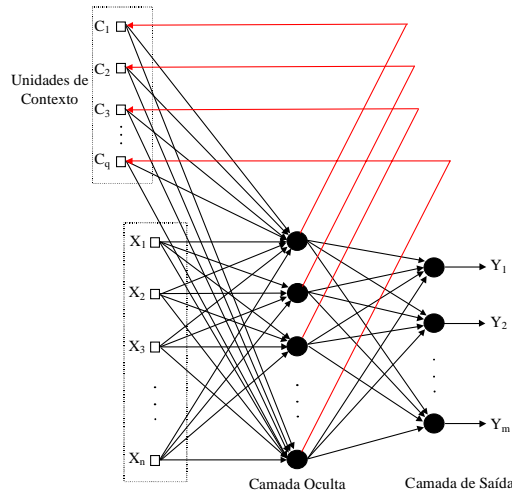


FIGURA 3 – Rede neural de Elman

4.0 - O SISTEMA ELÉTRICO SIMULADO

A Figura 4 mostra a representação do sistema elétrico simulado pelo programa ATP (2)(21), com o intuito de geração do banco de dados utilizado 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 e potência de 25 MVA, uma linha de transmissão de 5 km seguida de uma carga de 10 MVA e fator de potência 0,92 indutivo.




FIGURA 4 – Sistema elétrico simulado

O transformador trifásico é conectado em configuração delta-estrela e seu modelo no ATP foi implementado utilizando-se três transformadores monofásicos.

Foram simulados 270 casos de energização do transformador, 162 casos de faltas internas de espira para terra (10, 50 e 90% do enrolamento envolvido) e 162 casos de faltas internas entre espiras (10, 30 e 70% do enrolamento envolvido), formando um banco de dados de 1782 vetores, empregados com uma janela de dados móveis de três movimentos.

Na formação do banco de dados relativo aos casos de falta, variaram-se os valores de tensão, carga do sistema, percentagem do enrolamento envolvido na aplicação da falta e o ângulo de incidência da mesma. Estes casos envolveram situações de faltas internas de espiras a terra e também de faltas internas entre espiras.

Para os casos de energização, os parâmetros variados foram a tensão e o instante de fechamento das chaves trifásicas.

Após o processo de simulação, os dados foram organizados a fim de serem empregados na etapa de treinamento das RNAs, descrita na próxima seção.

5.0 - REDES NEURAIAS NA CORREÇÃO DE SINAIS DISTORCIDOS PROVENIENTES DA SATURAÇÃO DE TCS

O programa SNNS - *Stuttgart Neural Network Simulator* (18) foi utilizado para treinar e testar as diferentes arquiteturas, a fim de corrigir os sinais distorcidos pela saturação dos TCs. O simulador SNNS foi escolhido devido à sua comprovada eficiência e simplicidade, bem como a amigável interface gráfica.

5.1 O processo de treinamento

Após a simulação dos dados, estes foram divididos em conjuntos de treinamento, validação e testes. Um total de quatro amostras por fase das correntes diferenciais foi utilizado no treinamento com frequência amostral de 1 kHz. Ainda, para cada fase, uma janela de dados móveis foi empregada.

As janelas de dados móveis para a fase A 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.

Após a adequação dos vetores ao simulador SNNS, executou-se o processo de treinamento da rede neural. Nesta fase, empregaram-se 1600 vetores, onde 800 foram usados no treinamento e 800 na fase de validação.

As camadas de entrada e saída das redes neurais contiveram em cada uma 24 dados, pois foram utilizados os oito primeiros pontos (meio ciclo de dados) de cada uma das três fases dos sinais diferenciais.

A melhor topologia de rede neural obtida foi a 24+20+24 do tipo Elman, ou seja, 24 neurônios na camada de entrada, 20 neurônios na camada oculta, 24 neurônios na camada recorrente e 24 células na camada de saída, a qual reconstruiu o sinal.

5.2 Resultados obtidos

Na fase de testes da rede neural melhor classificada na tarefa de reconstrução dos sinais distorcidos, utilizou-se um conjunto de dados com 182 vetores, diferentes daqueles empregados nas fases de treinamento e validação. Destaca-se que as redes neurais obtiveram um índice de acerto médio da ordem de 99 %.

Para a confirmação dos resultados obtidos, são mostrados a seguir os gráficos dos sinais gerados através da correção efetuada pela rede neural. A Figura 5 mostra o sinal de um caso de energização do transformador contendo distorção causada pela saturação do TC primário.

Na Figura 6, é ilustrado o sinal ideal para o mesmo caso, ou seja, sem conter a saturação do TC.

Na próxima Figura 7, pode-se observar o caso em questão corrigido pela rede neural recorrente. Salienta-se que os sinais das três fases de cada figura foram tomados em sincronismo.




FIGURA 5 - Sinal de energização distorcido por saturação




FIGURA 6 - Sinal de energização com TC ideal




FIGURA 7 - Sinal de energização reconstruído pela RNA

As próximas ilustrações, Figura 8, Figura 9 e Figura 10, mostram situações análogas às anteriores, porém para um caso de falta interna ao transformador.




FIGURA 8 - Sinal de falta interna distorcido pela saturação




FIGURA 9 - Sinal de falta interna com TC ideal




FIGURA 10 - Sinal de falta interna reconstruído pela RNA

6.0 - CONCLUSÃO

Este trabalho apresentou uma técnica alternativa para a correção de ondas distorcidas provenientes da saturação dos dispositivos transformadores de corrente através das ferramentas inteligentes baseadas em Redes Neurais Artificiais Recorrentes.

Os TCs estão presentes em sistemas elétricos de potência com a finalidade de proteção e medição, sendo altamente suscetíveis à saturação. A simulação de um transformador de potência foi realizada a fim de gerar os dados de treinamento e testes para as RNAs. Muitas arquiteturas de redes neurais artificiais foram treinadas e testadas, sendo que as melhores configurações obtidas foram as arquiteturas recorrentes de Elman.

A melhor RNA apresentada a fim de reconstruir as formas de ondas distorcidas obteve convergência mais rápida e resultados de testes precisos. Destaca-se que nenhum pré-processamento dos sinais foi requerido no trabalho. O método desenvolvido mostrou-se eficiente em busca do objetivo proposto. Resultados promissores relativos à aplicação são apresentados. A aplicação da ferramenta Redes Neurais Artificiais constitui uma nova e importante etapa na metodologia de análise de sinais oriundos de transformadores de corrente na busca de um melhor desempenho de funções como proteção, medição e oscilografia de sistemas elétricos de potência.

7.0 - AGRADECIMENTOS

Os autores agradecem o Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos – EESC da Universidade de São Paulo - USP e a Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP pelo apoio na realização do trabalho.

8.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) S.H. Horowitz e A.G. Phadke, *Power System Relaying*, Research Studies Press Ltd., 2nd ed., England, 1995.
- (2) *Alternative Transients Program Rule Book*, Leuven EMTP Center, 1987.
- (3) Y.C. Kang, S.H. Kang, J.K. Park, A.T. Johns e R.K. Aggarwal, *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, 1996, pp. 41-49.

- (4) Y.C. Kang, S.H. Kang, J.K. Park, A.T. Johns e R.K. Aggarwal, *Algorithm for Compensating Secondary Currents of Current Transformers*, IEEE Transactions on Power Delivery, v.12, n.1, 1997, pp. 116-124.
- (5) S. Jamali e K.M. Radji, *A Digital Compensating Technique for the Saturation of Protective Current Transformers*, Proceedings of Thirty Second Universities Power Engineering Conference, v.1, 1997, pp. 10-12.
- (6) D.C. Yu, Z. Wang, J.C. Cummins, H.J. Yoon e L.A. Kojovic, *Neural Network for Current Transformer Saturation Correction*, Proceedings of IEEE Power Engineering Society – Transmission and Distribution Conference, v.1, 1999, pp. 441-446.
- (7) T.S. Sidhu, H.S. Gill e M.S. Sachdev, *A Power Transformer Protection Technique with Stability during Current Transformer Saturation and Ratio-mismatch Conditions*, IEEE Transactions on Power Delivery, v.14, n.3, 1999, pp. 798-804.
- (8) J.C. Cummins, D.C. Yu e L.A. Kojovic, *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, 2000.
- (9) D.C. Yu, J.C. Cummins, Z. Wang, H.J. Yoon e L.A. Kojovic, *Correction of Current Transformer Distorted Secondary Currents due to Saturation using Artificial Neural Networks*, IEEE Transactions on Power Delivery, v.16, n.2, 2001, pp.189-194.
- (10) B. Bozoki e C.M. Calhoun, *Gapped Core Transformer Characteristics and Performance*, IEEE Power System Relaying Committee, IEEE Transactions PWRD, v.5, n.4, 1990, pp. 1732-1740.
- (11) L. Masson, *Circuit for the Dynamic Control of Magnetic Flux in Current Transformers*, IEEE Transactions PAS, v.98, n.6, 1979, pp. 1990-1995.
- (12) K.W. Chen e S.T. Glad, *Estimation of the Primary Current in a Saturated Transformer*, Proceedings of the IEEE Conference on Decision and Control, 1991, pp. 116-124.
- (13) M. Kezunovic, L.A. Kojovic, C.W. Fromen, D.R. Sevcik e F. Phillips, *Experimental Evaluation of EMTP-based Current Transformer Models for Protective Relay Transient Study*, 93 WM 041-4 PWRD, IEEE/PES Winter Meeting, New York, 1993.
- (14) C.W. Barnett, J.W. Chadwick et al., *Relay Performance Considerations with Low Ratio CTs and High Fault Currents*, IEEE Transactions on Power Delivery, v.8, n.3, 1993, pp. 884-887.
- (15) M.T. Glinkowski e J. Esztergalyos, *Transient Modeling of Electromechanical Relays, Part 1: Armature Type Overcurrent Relay*, IEEE Transactions on Power Delivery, v.11, n.2, 1996.
- (16) W.S. McCulloch e W. Pitts, *A Logical Calculus of the Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics, n.5, 1943, pp. 115-133.
- (17) D.E. Rumelhart, G.E. Hinton e R. J. Williams, *Learning Representations by Back-propagation Errors*, Nature, n.323, 1986, pp. 533-536.
- (18) *SNNS User Manual*, Institute for Parallel and Distributed High Performance Systems, University of Stuttgart, 1995.
- (19) A.C.P.L.F. Carvalho, A.P. Braga e T.B. Ludermir, *Redes Neurais Artificiais: Teorias e Aplicações*, Rio de Janeiro, Livros Técnicos e Científicos, 262 p., Brasil, 2000.
- (20) J.L. Elman, *Finding Structure in Time*, Cognitive Science, n.14, pp.179-211, 1990.
- (21) D.V. Coury, P.G. Campos e M.C. Tavares, *Modelling a Power Transformer for Investigation of Digital Protection Schemes*, 8th International Conference on Harmonics and Quality of Power, 1998, pp. 489-494.