

# Redes Neurais e Neuro-Fuzzy Aplicadas a Modelagem Térmica de Transformadores de Potência

Michel Hell, Luiz Secco, Pyramo Costa Jr., *Member, IEEE*, and Fernando Gomide, *Member, IEEE*

**Resumo**—Neste artigo, cinco diferentes técnicas de modelagem são aplicadas ao problema de modelagem térmica de transformadores de potência, com a finalidade de se verificar qual delas apresenta um melhor desempenho na solução do problema proposto. Assim, cinco modelos foram criados, sendo o primeiro formado por uma rede perceptron de múltiplas camadas (MLP), o segundo por uma rede neural de função de base radial (RBF), o terceiro por uma rede neuro-fuzzy estática (SNF), o quarto por uma rede recorrente de Elman (ELM) e o quinto por uma rede neuro-fuzzy recorrente (RNF). Todos eles foram utilizados na modelagem do comportamento térmico de transformadores de potência, sendo que seus resultados foram comparados entre si e ainda ao modelo determinístico proposto por [1]. Os resultados experimentais com dados reais reportados na literatura mostram que o modelo baseado na rede recorrente neurofuzzy requer um menor esforço computacional, e é mais robusto e eficiente que as demais abordagens.

**Palavras Chave**— Transformadores de Potência, redes neurais, redes recorrentes, sistemas neuro-fuzzy, modelagem de sistemas dinâmicos.

## I. INTRODUÇÃO

Transformadores de potência são peças importantes nos sistemas de transmissão e distribuição de energia elétrica e o seu correto funcionamento é vital para a operação destes sistemas. A perda de uma unidade estratégica pode ter um grande impacto na segurança, na confiabilidade e no custo do fornecimento de energia.

Um dos principais fatores a ser observado na operação dos transformadores de potência é a temperatura de trabalho, mais especificamente a temperatura do ponto mais quente, ou temperatura de *hot-spot*, no topo ou no centro dos enrolamentos de alta ou baixa tensão, que tem uma importante influência no envelhecimento do isolamento e, conseqüentemente, na vida útil do equipamento. O conhecimento da temperatura de *hot-spot* é vital para o desenvolvimento de proteções de sobrecarga para os transformadores, uma vez que um aumento na temperatura de *hot-spot* produz uma aceleração exponencial no envelhecimento do equipamento. O monitoramento desta temperatura é essencial para avaliar a redução na vida do isolamento e para indicar a possível existência de bolhas de gás

próximas ao *hot-spot* na presença de condições de emergência causadas por abruptas elevações de carga.

Neste contexto, a modelagem dinâmica do comportamento térmico pode ser considerada como um dos mais importantes aspectos no monitoramento das condições dos transformadores de potência. A comparação entre os valores medidos e preditos das temperaturas de operação podem fornecer um indicativo das condições do equipamento, bem como indicar possíveis anormalidades.

O carregamento dos transformadores pode ser calculado pela aplicação de equações de transferência de calor que usam características térmicas específicas do equipamento, conforme apresentado em [1]. Atualmente, o cálculo convencional das temperaturas internas dos transformadores não é apenas uma tarefa de grande complexidade, como também leva a estimativas conservativas baseadas em algumas suposições das condições de operação. Neste cálculo são adotados fatores de segurança extremamente conservativos, visando proteger o equipamento, fazendo com que a transferência máxima de potência seja de 20 a 30% menor que a sua capacidade nominal, com a finalidade de aumentar a sua vida útil e reduzir os riscos durante a operação [2].

Com o objetivo de aumentar as margens operativas do equipamento devido a solicitação do sistema elétrico, torna-se necessário a adoção de novas abordagens para o carregamento de transformadores acima dos valores nominais, por curtos ou longos períodos de tempo. Tal procedimento possibilita mudança de seu carregamento, permitindo utilizar sua capacidade plena, melhorando seu aproveitamento e reduzindo o custo de operação.

Dentre as técnicas utilizadas na modelagem, pode-se citar as redes neurais estáticas, amplamente utilizadas, devido a sua capacidade de aprendizado na modelagem de relações complexas e não lineares [3]. Nesta categoria incluem-se as redes perceptron de múltiplas camadas (MLP), as redes neurais de função de base radial (RBF), entre outras.

Entretanto, nestes modelos além de não se conhecer sua dinâmica interna, uma vez que todo seu processo de aprendizado baseia-se apenas em dados históricos de entrada/saída do sistema a ser modelado, é possível obter-se resultados que não são necessariamente compatíveis com a realidade física, eventualmente fornecendo resultados inadequados devido, principalmente, a imprecisões e inadequação dos dados históricos [4], [5].

Uma abordagem atrativa para este problema é o uso de redes neurais recorrentes, onde o treinamento não se baseia

M. Hell and F. Gomide pertencem ao Departamento de Engenharia de Computação e Automação Industrial (DCA), Faculdade de Engenharia Elétrica e Computação (FEEC), Universidade Estadual de Campinas, Campinas-SP, Brasil, e-mail: {mbhell, gomide}@dca.fee.unicamp.br

P. Costa Jr. e L. Secco pertencem ao Programa de Pós Graduação em Engenharia Elétrica, Pontifícia Universidade Católica de Minas Gerais (PPGEE, PUC-MG), Belo Horizonte-MG, Brasil, e-mail: pyramo@pucminas.br

apenas nas relações entrada/saída em um determinado instante, mas também nas relações entre instantes distintos de tempo, fazendo com que a rede consiga acompanhar o comportamento temporal do sistema a ser modelado [6], [7].

Outra abordagem atrativa é o uso de sistemas neuro-fuzzy, devido a sua habilidade de tratar a imprecisão e a incerteza presente na informação disponível e na dinâmica do próprio sistema [9]. Contudo, o uso de redes neuro-fuzzy estáticas ainda é restrito, devido à sua estrutura não recorrente e à carência de algoritmos eficientes de aprendizagem. A incorporação de recorrência em sistemas neuro-fuzzy faz com que estes sistemas sejam capazes de tratar problemas que envolvem relações temporais, já que a presença de realimentação permite a criação de representações internas e os mecanismos de memória necessários para processar e armazenar este tipo de informação [8].

Redes neuro-fuzzy recorrentes constituem uma nova abordagem na modelagem de sistemas dinâmicos. Em particular, a aplicação desta abordagem ao problema de modelagem térmica de transformadores de potência não possui precedentes na literatura, sendo proposta inicialmente neste trabalho. Tal proposição está relacionada ao fato de que o comportamento de transformadores de potência envolve parâmetros imprecisos e conhecimento parcial que não são plenamente capturados por modelos analíticos derivados das leis naturais (físicas).

Neste trabalho, todas as abordagens citadas anteriormente foram utilizadas na modelagem do comportamento térmico de transformadores de potência. Desta forma, cinco modelos, sendo eles um modelo neural estático utilizando uma rede Perceptron de múltiplas camadas (MLP), um modelo neural estático utilizando uma rede de função de base radial (RBF), um modelo neural recorrente utilizando uma rede de Elman (ELM), um modelo neuro-fuzzy estático (SNF) e um modelo neuro-fuzzy recorrente (RNF), foram testados, a fim de identificar-se qual destes modelos possui melhor desempenho na solução do problema proposto.

O artigo está organizado da seguinte forma. A próxima seção apresenta uma breve discussão sobre o modelo determinístico convencional utilizado no cálculo da temperatura de *hot-spot*. A seção III apresenta as técnicas utilizadas na construção dos modelos desenvolvidos. Os resultados, análise e síntese dos experimentos realizados são apresentados na seção IV. Na seção V é apresentada a conclusão do estudo.

## II. MODELO DETERMINÍSTICO

Conforme mencionado anteriormente, atualmente a capacidade de carregamento de transformadores de potência é calculada usando-se equações de transiente de calor, que utilizam características e parâmetros específicos do transformador. Este cálculo é feito com base em curvas de carga e condições de operação (principalmente a temperatura de operação), sendo que os valores usados são extremamente conservativos.

Assim, conforme apresentado em [1], as equações para o cálculo da temperatura do *hot-spot* são:

$$\begin{cases} \tau_{TO} \frac{d\Theta_{TO}}{dt} = [\Delta\Theta_{TO,U} + \Theta_A] - \Theta_{TO} \\ \tau_H \frac{d\Delta\Theta_H}{dt} = \Delta\Theta_{H,U} - \Delta\Theta_H \\ \Delta\Theta_{TO,U} = \Delta\Theta_{TO,R} \left[ \frac{K^2 R + 1}{R + 1} \right]^n \\ \Delta\Theta_{H,U} = \Delta\Theta_{H,R} K^{2m} \\ \Theta_H = \Theta_{TO} + \Delta\Theta_H \end{cases} \quad (1)$$

onde  $\tau_{TO}$  é a constante de tempo da temperatura de topo de óleo,  $\Theta_{TO}$  é a temperatura de topo de óleo,  $\Delta\Theta_{TO,U}$  é a elevação máxima da temperatura de topo de óleo,  $\Theta_A$  é a temperatura ambiente,  $\tau_H$  é a constante de tempo da temperatura de *hot-spot*,  $\Delta\Theta_H$  é a elevação da temperatura de *hot-spot* acima da temperatura de topo de óleo,  $\Delta\Theta_{H,U}$  é a elevação máxima da temperatura de *hot-spot*,  $\Delta\Theta_{TO,R}$  é a elevação nominal da temperatura de topo de óleo acima da temperatura ambiente,  $K$  é a corrente de carga,  $R$  é a razão entre perda de carga em relação a carga nominal e carga não perdida, para uma determinada posição de tap,  $\Delta\Theta_{H,R}$  é a elevação nominal da temperatura de *hot-spot* acima da temperatura de topo de óleo,  $\Theta_H$  é a temperatura de hot-spot no enrolamento e  $m$  e  $n$  são constantes obtidas empiricamente e que dependem do método de refrigeração do equipamento.

O modelo apresentado em (1) é baseado em algumas suposições simplificadora tais como: o perfil de temperatura do óleo dentro do enrolamento aumenta linearmente do fundo ao topo; a diferença entre a temperatura do enrolamento e a temperatura do óleo é constante ao longo do enrolamento; a elevação da temperatura de *hot-spot* é maior que a elevação de temperatura do condutor no topo do enrolamento, introduzindo um fator de correção conservativo; a temperatura ambiente leva a temperatura do óleo para cima ou para baixo com a mesma constante de tempo, assim como a temperatura no enrolamento; a incidência de radiação solar não é considerada.

Desta forma, o uso deste método pode produzir erros substanciais na determinação da temperatura de *hot-spot*. Assim, torna-se necessária a adoção de novos métodos, mais precisos na determinação desta variável, conforme apresentado a seguir.

## III. TÉCNICAS DE MODELAGEM

Nesta seção são apresentadas as técnicas utilizadas na construção dos modelos utilizados na predição da temperatura de *hot-spot*.

### A. Modelos Neurais Estáticos

Conforme mencionado anteriormente, as redes neurais estáticas são muito utilizadas devido principalmente a sua capacidade de aprendizado na modelagem de relações complexas e não lineares.

Neste trabalho utilizou-se dois tipos de redes neurais estáticas: Uma rede perceptron de múltiplas camadas (MLP) e uma rede neural de função de base radial (RBF). A escolha destes dois modelos baseia-se em sua grande aplicação na modelagem de sistemas não lineares em geral.




Fig. 1. Estrutura do Modelo MLP

1) *Rede Perceptron de Múltiplas Camadas - MLP*: A estrutura da rede MLP utilizada neste trabalho é apresentada na Figura 1, sendo que o número de neurônios da camada intermediária foi empiricamente determinado ( $n = 9$ ).

Inicialmente, as entradas da rede foram tomadas como sendo a corrente de carga ( $K$ ) e a Temperatura de Topo de Óleo ( $\Theta_{TO}$ ) e a saída definida como sendo a Temperatura de *hot-spot* ( $\Theta_H$ ). Como a rede MLP não possui armazenamento do comportamento temporal do modelo, foi necessário introduzir uma terceira entrada no modelo, sendo ela a corrente de carga dotada de um atraso de tempo. Assim, as entradas da rede MLP foram definidas como sendo o instante atual de  $K$ , o instante anterior de  $K$  e a temperatura de topo de óleo, e a saída como sendo a temperatura de *hot-spot*.

A rede foi treinada usando-se o algoritmo backpropagation, e os resultados são apresentados na seção IV.

2) *Rede Neural de Função de Base Radial - RBF*: A arquitetura da rede RBF utilizada é apresentada na Figura 2, sendo que as entradas e saída são as mesmas definidas para o modelo MLP, e o número de neurônios da camada intermediária foi definido como sendo  $n = 32$ .




Fig. 2. Estrutura do Modelo RBF

O treinamento dos pesos da RBF utilizado foi o treinamento híbrido, onde a primeira camada de conexões é ajustada através de um algoritmo de cluster não supervisionado, neste caso o algoritmo de classificação de Adeli-Hung [9], onde o número de centros vai sendo adicionado até obter-se um comprometimento entre a complexidade do modelo e o erro apresentado. Os  $n$  vetores de pesos desta primeira camada, representam os centros que serão utilizados pela função de transferência aplicada pelos  $n$  neurônios ocultos.

A segunda camada de conexões, foi treinada de forma supervisionada, através do método da Pseudo-inversa, devido ao seu desempenho rápido e eficiente em aplicações de classificação de dados por RBF's.

Da mesma forma que para a MLP, esta estrutura foi aplicada ao problema de modelagem térmica de transformadores de potência e seus resultados podem ser vistos na seção IV.

**B. Modelo Neural Recorrente**

Como modelo neural recorrente utilizou-se neste trabalho a rede recorrente de Elman [6], devido a sua característica de modelagem não apenas das características entrada/saída, mas também das relações temporais entre os padrões de treinamento.

A estrutura básica da rede de Elman é composta por 4 camadas: camada de entrada, camada oculta, camada contextual e camada de saída, conforme mostrado na Figura 3. Geralmente, este tipo de rede é considerado um tipo especial de rede neural *feedforward*, com neurônios adicionais e realimentação local [11].

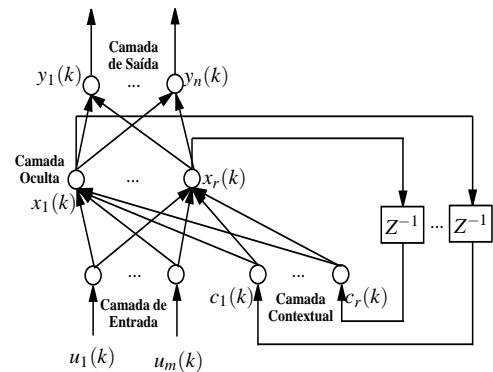


Fig. 3. Estrutura da Rede de Elman

Os laços de realimentação dos neurônios contextuais na rede de Elman fazem com que ela seja sensível ao histórico dos dados de entrada, o que é altamente útil na modelagem de sistemas dinâmicos [3].

O treinamento deste tipo de rede é feito através de uma modificação do algoritmo backpropagation, chamada *recurrent backpropagation*.

Como neste caso existe armazenamento da informação temporal na camada contextual, as entradas neste modelo serão apenas a corrente de carga e a temperatura de topo de óleo. Os resultados também são apresentados na seção IV.

**C. Modelo Neuro-Fuzzy Estático**

Para a construção do modelo neuro-fuzzy estático utilizou-se a estrutura neuro-adaptativa proposta por Jang [12], chamada ANFIS (*Adaptive Neuro Fuzzy Inference System*). Neste sistema, inicialmente utilizam-se técnicas de agrupamento (neste caso a regra de aprendizado de Kohonen [10]) para granularizar o espaço de entrada. Desta forma, para cada uma das variáveis de entrada são criadas funções de pertinência a fim de se implementar um sistema de inferência fuzzy, conforme descrito em [13].

Neste trabalho foram utilizadas funções de pertinência do tipo *sino*. Assim, as variáveis de entrada foram granularizadas conforme mostrado na Figura 4, sendo que estas são as mesmas variáveis de entrada usadas nos modelos neurais estáticos.

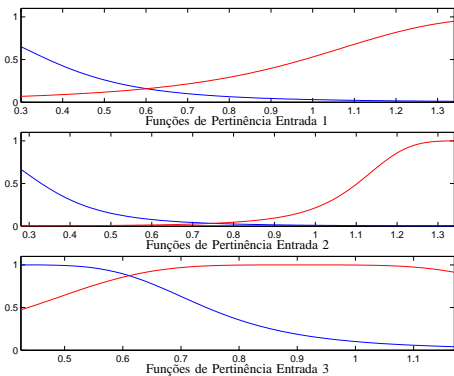


Fig. 4. Granularização do Espaço de Entrada

Uma vez implementado o sistema de inferência fuzzy, técnicas de aprendizado neural são utilizadas a fim de ajustar as funções de pertinência das variáveis de entrada para que o sistema de inferência melhor se adapte ao conjunto de dados entrada/saída. Este método é apresentado em [12].

Assim, a estrutura do modelo ANFIS implementada neste trabalho é apresentada na Figura 5, e seus resultados apresentados na seção IV.




Fig. 5. Estrutura do Modelo SNF

**D. Modelo Neuro-Fuzzy Recorrente**

A estrutura da rede neuro-fuzzy recorrente utilizada neste trabalho contém duas partes, sendo um sistema de inferência fuzzy e uma rede neural clássica, compondo uma estrutura neural híbrida (Figura 6). Esta estrutura e o processo de aprendizagem, são apresentados em [8] e suas referências.

O sistema de inferência é composto pelas camadas de entrada e intermediária. A camada de entrada consiste de neurônios cujas funções de ativação são as funções de pertinência dos conjuntos fuzzy que formam a partição do espaço de entrada. Para cada dimensão  $x_i(t)$  do vetor de entrada  $n$ -dimensional  $\mathbf{x}(t)$  existem  $N_i$  conjuntos fuzzy  $A_i^{k_i}, k_i = 1, \dots, N_i$  cujas funções de pertinência são as correspondentes

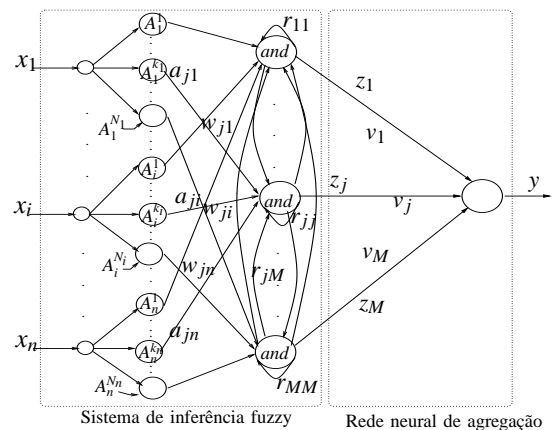


Fig. 6. Rede neurofuzzy recorrente.

funções de ativação dos neurônios da camada de entrada. A variável  $t$  denota o tempo discretizado, isto é,  $t = 1, 2, \dots$  e será omitida no decorrer do artigo para simplificar a notação. Deste modo, os graus de pertinência associados aos padrões de entrada são  $a_{ji} = \mu_{A_i^{k_i}}(x_i)$ ,  $i = 1, \dots, n$  e  $j = 1, \dots, M$ ; onde  $M$  é o número de neurônios da camada intermediária.

Os neurônios da camada intermediária são neurônios lógicos do tipo *and* (Figura 7), cujas entradas  $a_{ij}$  são ponderadas pelos pesos  $w_{ji}$  e as conexões de realimentação são ponderadas pelos pesos  $r_{jl}, l = 1, \dots, M$ . Os neurônios lógicos são implementados utilizando as normas triangulares, isto é, o operador *and* é representado por uma  $t$ -norma e o operador *or* representado por uma  $s$ -norma; diversas definições destas normas encontram-se em [13].




Fig. 7. Neurônio lógico recorrente.

A arquitetura apresentada tem como vantagens a geração automática da topologia da rede, flexibilidade quanto à utilização de diversas normas triangulares e a possibilidade de extração de regras diretamente da topologia [8].

Dois conceitos diferentes são utilizados para o ajuste dos pesos: aprendizagem por reforço associativo para os pesos  $w_{ji}$  e  $r_{jl}$ , e o método do gradiente para os pesos  $v_j$ , conforme apresentado em [8].

Esta técnica também foi aplicada ao problema de modelagem térmica de transformadores de potência, sendo que seus resultados são apresentados na seção IV.

**IV. RESULTADOS DE SIMULAÇÃO**

Nesta seção, os modelos desenvolvidos são empregados para estimar a temperatura de *hot-spot* de um equipamento real. Os dados utilizados neste trabalho, conforme apresentados a seguir, são os mesmos utilizados em [2] e foram extraídos a partir de medições feitas em um equipamento experimental,

cujas características são detalhadas em [2]. Os resultados obtidos são comparados entre si e com o modelo determinístico (MD) apresentado na seção II.

Os sistemas são inicialmente treinados para um conjunto de dados amostrados (dados de treinamento) que descrevem o comportamento da temperatura de *hot-spot* do equipamento para um carregamento de 24 horas, com amostras registradas a cada 5 minutos. Estes dados são apresentados na Figura 8, onde o eixo horizontal representa as amostras obtidas e o eixo vertical representa os dados de entrada ( $K$  e  $\Theta_{TO}$ ) bem como a saída desejada ( $\Theta_H$ ) da rede, todos em p.u. .




Fig. 8. Dados de Treinamento

Após esse passo a capacidade de generalização da rede é testada para dois conjuntos de dados (dados de teste) descrevendo situações diferentes de carregamento, com e sem sobrecargas no sistema, conforme apresentado na Figura 9, onde os eixos e linhas são definidos da mesma forma que na Figura 8. Cada um dos dois conjuntos de teste contém dados colhidos durante 24 horas para as diferentes condições de carregamento [2].




Fig. 9. Dados de Teste: (a) sem sobrecarga (b) com sobrecarga

As Figuras 10 e 11 apresentam os resultados obtidos pelos modelos implementados, conforme descrito na seção anterior, sendo que a Figura 10 mostra a saída desejada do transformador e as saídas correspondentes obtidas pelos modelos em uma situação onde não há sobrecarga no transformador, enquanto que a Figura 11 mostra as mesmas saídas, entretanto em uma situação de sobrecarga.

Na Tabela I é apresentada uma comparação entre os índices de desempenho de todos os modelos implementados, onde

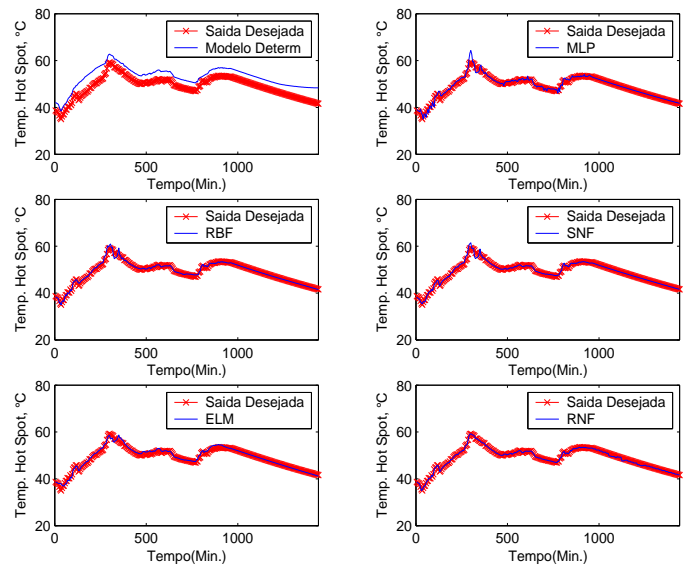


Fig. 10. Saídas do Transformador e dos Modelos sem sobrecarga

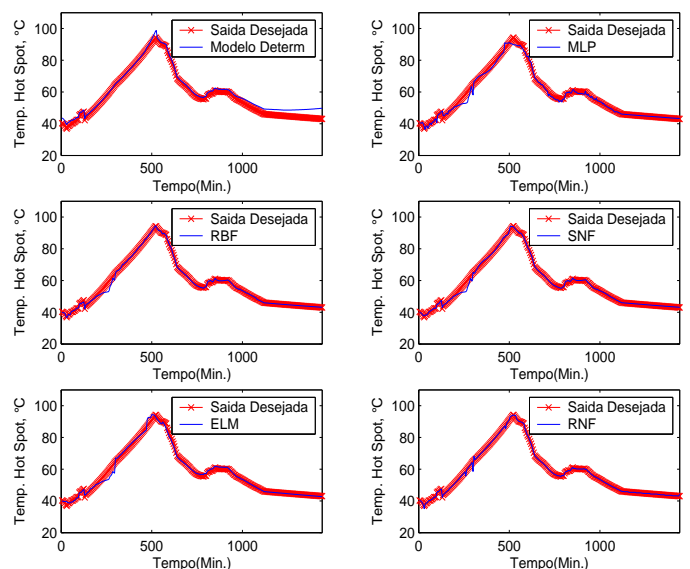


Fig. 11. Saídas do Transformador e dos Modelos com sobrecarga

a coluna  $Eqm - Dts1$  apresenta o Erro Quadrático Médio obtido pelos modelos quando aplicados ao primeiro conjunto de dados de teste (sem condição de sobrecarga),  $Eqm - Dts2$  apresenta o Erro Quadrático Médio obtido pelos modelos quando aplicados ao segundo conjunto de dados de teste (com condição de sobrecarga) e a coluna  $Eqm - Dts$  apresenta o Erro Quadrático Médio para os dois conjuntos de dados de teste.

Nota-se nas Figuras 10 e 11 que todos os modelos neurais implementados obtiveram bons resultados ao modelar a temperatura de *hot-spot*, apesar de alguns deles apresentarem processos de treinamento mais complexos, como é o caso dos modelos neurais estáticos.

Entretanto, se os padrões de treinamento forem formados por dados que não representem a totalidade do comportamento do sistema a ser modelado, é possível verificar que os modelos recorrentes se mostram mais robustos do que os modelos



TABELA I  
RESULTADOS DE SIMULAÇÃO

Model	Learning Time (seg.)	MSE-Dt1	MSE-Dt2	MSE-Dt3
MD	-	17,3489	6,7434	12,0462
MLP	92,76	0,7900	2,4880	1,6390
RBF	82,63	0,2565	0,9914	0,6239
SNF	61,50	0,2689	1,1025	0,6857
ELM	59,39	0,4780	2,1069	1,2925
RNF	31,37	0,0481	0,2635	0,1557

estáticos apresentados.

Para comprovar este importante fato, tomou-se como dados de treinamento um conjunto que não representava completamente a dinâmica do sistema e usou-se os modelos apresentados, comparando-os mais uma vez. Assim, tomou-se o conjunto de dados apresentados na Figura 9(a) como conjunto de treinamento de todos os sistemas apresentados e verificou-se sua capacidade de generalização para os dados da Figura 9(b).

A Figura 12 mostra os resultados obtidos pelos modelos implementados quando dados não ideais são aplicados no processo de treinamento. A Tabela II apresenta o erro médio quadrático obtido pelos modelos neste caso. É possível verificar que os modelos estáticos sofreram grandes alterações de comportamento, enquanto que os modelos recorrentes mantêm seus desempenhos na modelagem do problema proposto, demonstrando assim maior robustez a dados não ideais, sendo que a rede neuro-fuzzy recorrente apresenta, ainda, um processo de treinamento mais rápido e simples, se comparado aos demais modelos.

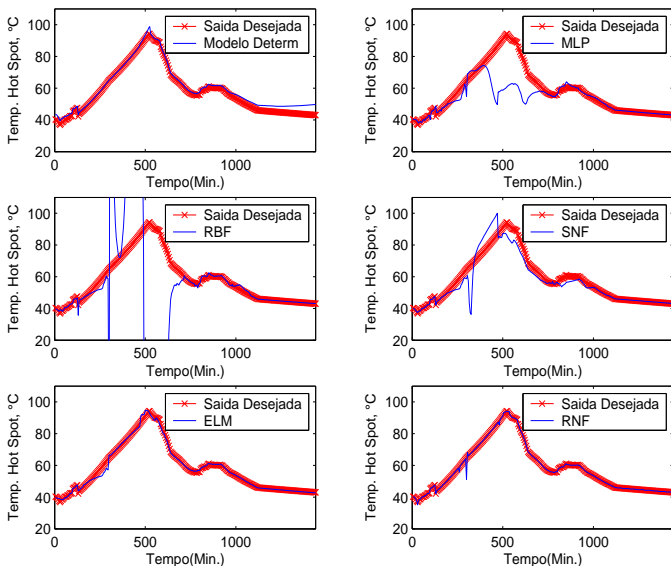


Fig. 12. Avaliação da Robustez dos Modelos

TABELA II  
RESULTADOS USANDO DADOS DE TREINAMENTO NÃO IDEAIS

	MD	MLP	RBF	SNF	ELM	RNF
MSE	6,7434	$1,2487 \times 10^2$	$4,6579 \times 10^4$	$0,2804 \times 10^2$	1,8986	0,7912

V. CONCLUSÕES

Neste trabalho foram implementados cinco diferentes técnicas a fim de modelar o comportamento térmico de transformadores de potência. Em especial, uma nova abordagem baseada em uma rede neuro-fuzzy recorrente é proposta. Simulações experimentais mostraram que os modelos recorrentes apresentam maior robustez, quando dados não ideais são utilizados no treinamento dos sistemas. Este fato se dá devido a capacidade deste tipo de rede de não armazenar apenas relações entrada/saída para os padrões de treinamento, mas também de armazenar as relações temporais entre os diversos padrões que compõem os dados de treinamento. Pode-se observar ainda que, dentre os modelos recorrentes, a rede recorrente neuro-fuzzy se mostrou ainda mais robusta, requerendo um baixo esforço computacional, devido ao seu rápido e simples processo de treinamento. Assim, este modelo é um forte candidato para o uso na predição em tempo real das condições de carga e temperaturas de hot spot de transformadores de potência, principalmente em períodos de sobrecarga.

AGRADECIMENTOS

Os autores agradecem a FAPESP, Fundação de Amparo a pesquisa do Estado de São Paulo, pelo fomento 03/05042-1, ao CNPq, Conselho Nacional de Pesquisa e Desenvolvimento (300729/86-3), e a Álvaro Martins e Ronald Moura, engenheiros da Companhia Energética de Minas Gerais (CEMIG), pelos seus comentários durante o desenvolvimento deste trabalho.

REFERÊNCIAS

- [1] G. W. Swift et. al., *Adaptive Transformer Thermal Overload Protection*, IEEE Transactions on Power Delivery, Vol. 16, No. 4, pp. 516-521, 2001.
- [2] V. Galdi, L. Ippolito, A. Piccolo and A. Vaccaro, *Neural Diagnostic System for Transformer Thermal Overload Protection*, IEE Proceedings of Electric Power Applications, Vol. 147, No. 5, pp. 415-421, 2000.
- [3] K.S. Narendra, K. Parthasarathy, *Identification and Control of Dynamic Systems using Neural Networks*, IEEE Transactions on Neural Networks, Vol. 1, pp. 4-27, 1990.
- [4] G. Goodwin and R. Payne, *Dynamic System Identification: Experiment Design and Data Analysis*, Academic Press, Inc., New York-USA, 1977.
- [5] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice Hall, NJ-USA, ed. 2, 1998.
- [6] J. Elman, *Finding Structure in Time*, Cognitive Science, Vol. 14, pp. 179-211, 1990.
- [7] M. Hell, L. Secco, P. Costa Jr. F. Gomide, *Elman Recurrent Neural Network in Thermal Modeling of Power Transformers*, Proceedings of 5th WSEAS Int.Conf. on POWER ENGINEERING SYSTEMS (ICOPES 05), Rio de Janeiro, Brazil, April, 2005
- [8] M. Figueiredo, R. Ballini, S. Soares, M. Andrade and F. Gomide, *Learning algorithms for a class of neurofuzzy network and application*, IEEE Transactions on Systems, Man and Cybernetics, vol. 34, no. 6, pp. 293-301, 2004.
- [9] L. H. Tsoukalas, R. E. Uhrig *Fuzzy and Neural Approaches in Engineering (Adaptive and Learning System for Signal Processing, Communication and Control Series)*, Jhon Wiley and Sons Inc., NY-USA, 1997
- [10] Teuvo Kohonen, *The Self Organizing Map*, Proceedings of the IEEE, Vol. 78, No. 9, 1358-1384, 1990.
- [11] P.S. Sastry, G. Santharam, K.P. Unnikrishnan, *Memory Neuron Networks for Identification and Control of Dynamic Systems*, IEEE Transactions on Neural Networks, Vol. 5, pp. 306-319, 1994.
- [12] J.-S. R. Jang, *ANFIS: Adaptive-Network-Based Fuzzy Inference System*, IEEE Transactions on System, Man, and Cybernetics, Vol. 23, No. 3, 665-685, 1993.
- [13] W. Pedrycz and F. Gomide, *An Introduction to Fuzzy Sets: Analysis and Design*, MIT Press Complex Adaptive Systems, 1998.