

Monitoramento de Temperatura e Modelos Térmicos de Transformadores

O. M. Almeida, M. F. Carvalho, S. E. U. Lima, E. M. S. Junior, O. C. S. Nottingham, C. M. T. Cruz, G. C. Leite

Resumo- O monitoramento e diagnóstico de falhas em transformadores estão diretamente relacionados à avaliação das condições do sistema de isolamento. Neste artigo, estabelece-se inicialmente o conceito de monitoramento e diagnóstico, e em seguida técnicas de análises são utilizadas para desenvolver estruturas de identificação não linear para modelar a carga térmica de um transformador imerso em óleo. O transformador é tratado do ponto de vista de carregamento térmico para o qual métodos convencionais, não-lineares e neural são aplicados para a modelagem. A primeira estrutura corresponde a um modelo NARX caixa cinza que melhora acentuadamente o modelo proposto na recomendação C57.115 IEEE/ANSI. A segunda estrutura implementada utiliza um modelo NARX caixa preta com a utilização da taxa do erro para reduzir o número de parâmetros possíveis na matriz de regressores. Uma rede neural MLP foi implementada como o terceiro modelo não linear. Comparações e limitações das estruturas estudadas são investigadas no artigo.

Palavras-chave— Transformadores de Potência, Modelos Térmicos, Identificação Não Linear, Redes Neurais Artificiais.

I. INTRODUÇÃO

Os sistemas de monitoramento e diagnóstico de transformadores possuem, geralmente duas funções que, embora distintas por definição, evoluem e são utilizadas em conjunto. O monitoramento tem por fim a aquisição de um conjunto de dados relativos ao funcionamento do transformador e cuja coleta envolve modernas tecnologias em sensores, técnicas de aquisição de dados e dispositivos digitais ou analógicos utilizados. O diagnóstico, por sua vez, está mais relacionado à interpretação dos dados e pode ser realizado por um especialista ou por um software especialmente desenvolvido para este fim. Atualmente, observa-se a tendência da substituição do diagnóstico feito por um especialista por sistemas automático de diagnóstico que incorporam uma forte parcela de técnicas inteligentes para representar entre outros conhecimentos, aquele acumulado com a experiência de um especialista [1-4].

Com a crescente disponibilidade de computadores de maior poder de processamento tem havido um crescente interesse por representações não lineares para caracterizar sistemas reais. À medida que as representações lineares são substituídas em alguma aplicação pelos seus corresponden-

tes modelos não lineares, torna-se possível analisar e reproduzir certos fenômenos e comportamentos dinâmicos mais complexos [5, 6] por outro lado a obtenção de modelos não lineares é significativamente mais trabalhosa do que para modelos lineares e, além disso, há algumas etapas na modelagem de sistema não lineares que ainda não estão bem estabelecidas. Os métodos de modelagens não lineares apresentam como principal vantagem, frente aos lineares convencionais, a capacidade de representar um maior número de regimes dinâmicos. São exemplos de representação não lineares as séries de Volterra, os modelos de Hammerstein e de Wiener, os modelos polinomiais NARX e os modelos Racionais NARX.

Por outro lado, na literatura, têm sido apresentados extensivos estudos relativos ao uso de técnicas inteligentes para identificação de sistemas não linear. Neste contexto, os modelos matemáticos concebidos a partir de abordagens que utilizam redes neurais com maior ênfase nas estruturas de redes RBF e MLP, com variados algoritmos de treinamento, têm recebido grande atenção, tanto da comunidade científica quanto no campo de aplicações práticas reais. As redes neurais são ferramentas de projeto que oferecem soluções promissoras para problemas de identificação não linear. Entre as características relevantes das redes neurais têm-se: processamento paralelo, aprendizado, memória associativa e distribuída. Estas características são inspiradas nas redes neurais biológicas, mesmo que rudimentarmente.

Desde que todos os fenômenos relacionados com os diversos estados de operação dos transformadores imersos em óleo são caracterizados por imprecisões, certo grau de incertezas nas medidas e não-linearidades não modeladas, métodos convencionais, combinados com métodos baseados em inteligência computacional como, por exemplo, sistemas nebuloso-neurais, e métodos que utilizam estruturas polinomiais NARX não lineares de modelagem podem ser empregados com sucesso para melhorar a eficiência dos sistemas de controle dos regimes de funcionamento destes equipamentos.

Alguns autores têm demonstrado o pobre desempenho dos métodos convencionais normalizados em modelar adequadamente o desempenho de equipamento do sistema elétrico em específico os fenômenos inerentes aos transformadores de potência quando submetidos a regimes adversos de carregamento.

Este artigo apresenta uma visão geral da área de monitoramento e diagnóstico e tem como objetivo desenvolver modelos não lineares para modelagem do carregamento térmico de transformadores imersos em óleo isolante. Por definição o carregamento térmico de um transformador pode

Este trabalho foi apoiado integralmente pela Coelce.

O. M. Almeida, M. F. Carvalho, S. E. U. Lima, E. M. S. Junior, O. C. S. Nottingham e C. M. T. Cruz trabalham no laboratório de Automação e Robótica da Universidade Federal do Ceará (e-mails: otacilio, marcelofc, sanderson, edilson, oliver, cicero@dee.ufc.br).

G.C. Leite trabalha na Companhia Energética do Ceará - Coelce (e-mail: gleite@coelce.com.br).

ser obtido a partir de um modelo para a temperatura do topo do óleo. A modelagem da temperatura do topo do óleo é obtida em função do carregamento do transformador, medido através de sensores de tensão e corrente e da temperatura ambiente. Quanto ao desenvolvimento dos algoritmos, a idéia básica é superar dificuldades quanto aos modelos convencionais, minimizar a quantidade de informação necessária para a modelagem do sistema, pela redução no número de variáveis monitorada com reduzido número de sensores, e comparar o desempenho dos algoritmos propostos. Desta forma, na seção II estabelece-se o conceito de monitoramento. Na seção III descreve-se o sistema a ser identificado. Na seção IV apresenta o desenvolvimento de modelos matemáticos para o comportamento térmico de transformadores. Os resultados experimentais são apresentados na seção V. Conclusões e trabalhos futuros são apresentados na seção VI.

II. MONITORAMENTO DE FALHAS EM TRANSFORMADORES

Equipamentos para monitoramento de transformadores devem ser eficientes, de custo justificável, fácil de instalar em campo e de baixa taxa de manutenção [1, 2]. A necessidade da instalação em campo de sistemas de monitoramento tem sua importância considerando que uma grande quantidade de unidades de transformação instalada nos parques elétricos atuais data de 30 anos [2]. A idade do parque elétrico tem provocado mudanças nos planos de manutenção das empresas de distribuição e transmissão. Instalações de equipamentos de monitoramento e diagnóstico em transformadores resguardam-no de possíveis falhas, em geral, causadas por elevados valores de parâmetros intrínsecos ao seu funcionamento, tais como: temperatura, nível de descargas parciais, carregamento e nível de umidade no isolamento. Também auxiliam, ou mesmo definem, o programa de manutenção preventiva existente nas empresas.

A. Distribuição de Falhas em transformadores

Considerando os últimos avanços no desenvolvimento da tecnologia de sensores, praticamente todos os parâmetros de um transformador podem ser monitorados. Atualmente a definição de quais parâmetros monitorar envolve mais uma questão de custo do que de técnica. Portanto, para o sucesso do projeto de um sistema de monitoramento e diagnóstico é importante aliar eficiência e custos. A redução do número de parâmetros monitorados e a utilização de *softwares* baseados em técnicas inteligentes (*soft computing*) correspondem a uma das medidas que tem impacto direto na viabilidade do sistema. Para isto, devem-se ter indicativos de quais são os parâmetros mais relevantes no sistema. Considerando um transformador de potência imerso em óleo com *taps* para mudança de cargas (OLTC), a figura 1 apresenta a distribuição estatística das falhas típicas nos componentes do transformador [1]. Da figura 1 pode-se observar que as principais fontes de falhas corresponde ao OLTC e enrolamentos (incluindo o sistema de isolamento). Para o OLTC os principais parâmetros a serem monitorados são a vibração e a temperatura, enquanto para o enrolamento e sistema de isolamento os principais parâmetros a serem monitorados são as concentrações de gases dissolvidos no óleo, a temperatura e o nível de descargas parciais (PD). Deve ser observado

que, independente da fonte de falha a ser considerada, a temperatura constitui um importante parâmetro a ser monitorado.

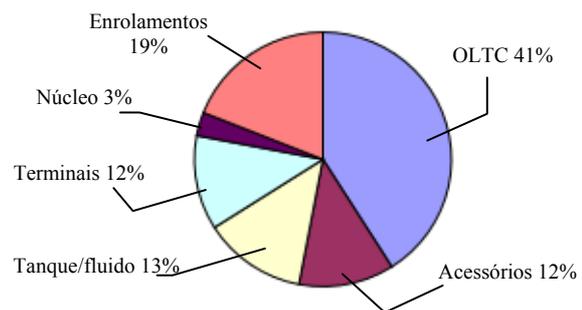


Figura 1. Distribuição das fontes de falhas em transformadores de potência.

B. Descargas Parciais (PD)

A caracterização de padrões de PD é outra importante fonte de investigação do estado do isolamento do transformador [1, 2, 4]. O monitoramento de PD é efetivo para detecção de falhas. PDs ocorrem dentro do tanque e produzem uma onda sonora e de pressão que é transmitida através do óleo. A detecção de PDs tem sido empregada a anos no diagnóstico de transformadores. Uma das técnicas não intrusiva que utiliza sensores piezolétricos (sensores ultra-som) tem sido aplicada com sucesso na prática. No entanto, em alguns casos estes sistemas, não intrusivos, podem ser ineficientes por estar sujeito a interferências de ruído proveniente do meio externo ao transformador. Este problema, entretanto, vem sendo superado através da implementação de técnicas de processamento digital de sinais para identificar o espectro de frequência das descargas parciais isolando-o do ruído ambiente. Seguindo a tendência de desenvolvimento de sensores optoeletrônicos, novas técnicas de medida de descargas parciais através de sensores ultra-som de fibra óptica vêm sendo desenvolvidas, principalmente, pelo *Virginia Polytechnic Institute e State University* [2, 4]. O sistema proposto é composto de uma sonda acústica optoeletrônica e um processador digital de sinais (DSP). Para a transmissão do sinal da sonda até o DSP utiliza-se uma fibra óptica, conforme a figura 2.

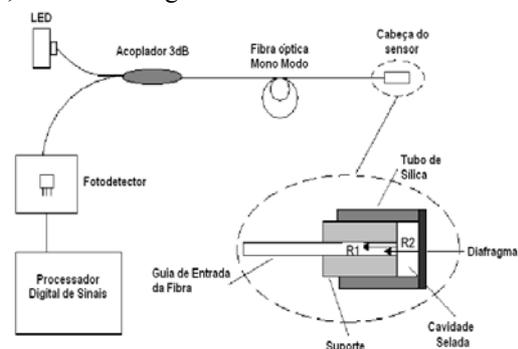


Figura 2. Sensor óptico de ultra-som para medida de descargas parciais.

No sensor, o feixe luminoso proveniente de um diodo laser incide no acoplador e é transmitido pela fibra até a cabeça do sensor. O guia da fibra e o diafragma são colados juntos ao suporte cilíndrico. O feixe de luz incidente é parcialmente refletido (4%) na face do sensor enquanto a outra porção do feixe propaga-se para o espaço interior da cavi-

dade atingindo até a superfície interna do diafragma. A superfície do diafragma é revestida por uma fina camada de ouro de forma que toda a porção de luz incidente seja refletida (96%). Com esta montagem o sinal óptico é uma função do comprimento da cavidade selada e é imune à contaminações externas. O CPT - *Center for Photonics Technology of Virginia University*, pode ser considerado hoje o mais avançado pólo em desenvolvimento de produtos optoeletrônicos para monitoramentos de grandezas tais como temperatura, pressão, fluxo, variáveis acústicas e descargas parciais.

C. Temperatura

A medida convencional e indireta da temperatura do enrolamento, ainda é largamente utilizada na indústria de transformadores. Estas medidas são úteis para a modelagem do comportamento térmico do transformador e do ponto quente do enrolamento. A medida indireta é realizada através da passagem de uma corrente de valor conhecido através de uma carga, que tem um elemento resistivo como indicador, e localizada em um ponto distante da região de alta tensão do transformador [1, 2, 7, 8]. Entretanto tem sido demonstrado que a modelagem da capacidade térmica através de medidas de temperatura utilizando este método apresenta discrepâncias muitas vezes inaceitáveis em relação ao comportamento real do transformador. Para superar as deficiências dos métodos baseados em medidas indireta, está sendo proposto em nível acadêmico e industrial medidas diretas da temperatura interna. Estas medidas, geralmente, são realizadas empregando sensores de fibra óptica.

O ponto quente do enrolamento de um transformador é um fator limitante na capacidade de carga. Atualmente sensores de temperatura baseado em dispositivos optoeletrônicos podem ser instalados nos enrolamentos dos transformadores em fase de manufatura são geralmente configurados para a medida em um único ponto ou em configurações distribuída no interior. Técnicas de medidas de temperatura utilizando fibras ópticas começaram na década de 80 e tem sido cada vez mais aplicada para medida de cargas térmicas em transformadores. Pesquisas realizadas pelo instituto INESC da Universidade do Porto na *Optoelectronics and Electronics Unit* demonstraram que sistemas ópticos são eficientes para medidas de temperatura interna de transformadores de potência. Sensores da Luxtron baseados em fibra óptica tais como, o conjunto OFT com sonda Photrix e o conjunto FO - Nortech da FISO são exemplos de produtos comerciais para medida de temperatura interna de transformadores.

O sensor de temperatura FISO para medidas direta de temperatura de enrolamento de transformadores de potência baseia-se na absorção/transmissão da luz através de um cristal semiconductor denominado de GaAs (gallium arsenide). Os efeitos de variações de temperatura neste semiconductor são bem conhecidos. Quando a temperatura do cristal aumenta, o *spectrum* da luz transmitida pelo cristal desloca-se para regiões de maiores comprimentos de onda (esta luz não é absorvida). O elemento sensor que compõe o sistema Nortech da FISO baseia-se no princípio do contato direto, ou seja, enquanto maior o contato do elemento sensor com o material (sólido, líquido ou gasoso) cuja temperatura deve ser medida, maior a velocidade de

resposta do cristal semiconductor. O elemento sensor e o sistema Nortech instalado no Departamento de Engenharia Elétrica da UFC são apresentados na figura 3.



Figura 3. Sistema de aquisição de dados de temperatura com sensor de fibra óptica – sistema FISO – transformador do DEE/UFC.

III. DESCRIÇÃO DO TRANSFORMADOR PROTÓTIPO – SISTEMA IDENTIFICADO

O valor de temperaturas suportado, em pontos específico, pelo isolante dos enrolamentos de um transformador é um parâmetro essencial para a determinação da carga máxima que este pode suportar de forma confiável. Temperaturas acima dos limites aceitáveis dos materiais podem levar a uma degradação acelerada dos materiais isolantes. [7-11].

A possibilidade de medidas diretas de temperaturas nos pontos quentes do enrolamento pode permitir que se aumente o carregamento do transformador e atender uma maior demanda sem a necessidade de investimentos imediatos, o que reflete diretamente na conta do consumidor.

Um sistema piloto para medida e interpretação da temperatura de operação de transformadores imersos em óleo foi desenvolvido e encontra-se instalado em uma subestação do Departamento de Engenharia Elétrica da UFC. A utilização de um transformador de distribuição como protótipo justifica-se tendo em vista a impossibilidade da utilização de transformadores de força, dada a seu elevado custo e dificuldades de operacionalizá-lo em diferentes regimes de trabalho dado a sua elevada potência. O transformador protótipo permite o estudo e desenvolvimento do sistema de monitoramento em nível de laboratório, inclusive com testes destrutivos, da degradação dos materiais isolantes, para futuras adaptações dos sistemas em transformadores de força.

A determinação da temperatura do topo do óleo do transformador em função do carregamento e da temperatura ambiente permite a implementação de procedimentos de acompanhamento do estado do transformador além de nortear regimes de carregamentos especiais para o mesmo. Através do desenvolvimento de um modelo não linear e inteligente é possível estimar a temperatura do topo do óleo sem utilização de sensores de temperatura para uma medida direta. No entanto para a validação dos sistemas em desenvolvimento o protótipo é equipado com 5 sensores de temperatura PT-100

sendo um instalado no topo do óleo, três nos enrolamentos de baixa, um na base do transformador e o último para medida da temperatura ambiente. Além da medida direta da temperatura a subestação deste transformador foi especialmente montada com sensores de corrente e tensão por efeito hall. Estes sensores permitem, além da medida do carregamento, a captura de componentes harmônicos em alta frequência (≤ 100 kHz), que são freqüentemente encontrados em cargas não lineares. A figura 4 apresenta uma fotografia do transformador protótipo.



Figura 4. Transformador com sistema de aquisição de dados (UFC/DEE). Os dados do transformador são apresentados na tabela 1.

TABELA 1. DADOS DO TRANSFORMADOR

Fabricante	CEMEC
Tipo	trifásico
Potência	30KVA
Tensão no primário	13,8KV
Tensão no secundário	380/220V

IV. MODELOS MATEMÁTICOS PARA TEMPERATURA DO ÓLEO

Três modelos não-lineares, para o propósito de comparações de desempenhos, foram utilizados para a estimação da temperatura do topo do óleo do transformador. Inicialmente implementa-se uma melhoria no modelo sugerido na recomendação IEEE/ANSI C57.115 [7] através de um modelo polinomial não linear caixa cinza, em seguida um modelo polinômio NARX caixa preta é utilizado e finalmente uma rede neural artificial MLP (*Muti-Layer-Perceptron*).

A. Modelo Polinomial Não Linear (NARX) Caixa Cinza - Aprimoramento da Recomendação C57115 IEEE/ANSI

Este modelo pode ser considerado caixa cinza por incorporar informações da física do sistema nos parâmetros do modelo. Segundo a recomendação IEEE/ANSI a elevação da temperatura do topo do óleo acima da temperatura ambiente é função do aumento da carga (corrente) do transformador e apresenta como consequência um aumento nas perdas internas da unidade e consequentemente um aumento global da temperatura. Esta variação de temperatura depende da constante térmica do transformador, que é relacionada à sua capacidade térmica (i.e. a massa do núcleo, bobinas e óleo), e do valor da taxa de transferência de calor do transformador. A variação de temperatura é modelada com uma

resposta exponencial de 1ª ordem do estado inicial para o estado final da temperatura em função do tempo:

$$\theta_o = (\theta_u - \theta_i)(1 - e^{-t/T_0}) + \theta_i \quad (1)$$

Na equação (1) a temperatura inicial e final são, respectivamente, θ_i e θ_u , T_0 é a constante térmica do transformador, t é o tempo referente a variação do carregamento e θ_o é a elevação da temperatura do topo do óleo acima da temperatura ambiente. A equação (1) é a solução da seguinte equação diferencial de 1ª ordem

$$T_0 \frac{d\theta_o}{dt} = -\theta_o + \theta_u, \quad \theta_o(0) = \theta_i \quad (2)$$

No modelo da recomendação IEEE/ANSI, a elevação da temperatura final depende do carregamento

$$\theta_u = \theta_{fl} \left(\frac{K^2 R + 1}{R + 1} \right)^n \quad (3)$$

onde, θ_{fl} é a temperatura máxima do topo do óleo acima da temperatura ambiente com carga nominal e R é a razão da perda com carga nominal com a perda a vazio. A variável K é a razão da carga especificada sobre a carga nominal:

$$K = \frac{I}{I_{rated}} \quad (4)$$

O expoente n depende do tipo de resfriamento. A norma de carregamento especifica $n = 0,8$ para convecção natural e $n = 0,9 - 1,0$ para arrefecimento forçado. Pode-se verificar que quando $I = I_{rated}$ então $\theta_u = \theta_{fl}$. As equações do modelo térmico IEEE/ANSI de elevação da temperatura do topo do óleo sobre a temperatura ambiente são as formas (1) e (4).

Para fins de predição e estimação de parâmetros utilizam-se dados pontuais discretos, as formas discretas no tempo (2) e (3) são necessárias. Usando a aproximação de Euler para a derivada no tempo, $d\theta_o[k]/dt \approx (\theta_o[k] - \theta_o[k-1])/\Delta t$, onde Δt é o período de amostragem, uma equação diferencial correspondente é derivada

$$\theta_o[k] = \frac{T_0}{T_0 + \Delta t} \theta_o[k-1] + \frac{\Delta t \theta_{fl}}{T_0 + \Delta t} \left(\frac{\left(\frac{I[k]}{I_{rated}} \right)^2 R + 1}{R + 1} \right)^n \quad (5)$$

Uma melhoria proposta para o modelo da recomendação C57115 IEEE/ANSI, acima descrito, é obtida quando a variação da temperatura ambiente, que tem forte influência no modelo, é levada em consideração [30]. A equação diferencial de primeira ordem (2) é modificada para:

$$T_0 \frac{d\theta_{top}}{dt} = -\theta_{top} + \theta_{amb} + \theta_u \quad (6)$$

Incorporando-se a temperatura ambiente ao modelo e utilizando $n=1$, obtém-se a seguinte modelo polinomial não linear NARX caixa cinza:

$$\begin{aligned} \theta_{top}[k] = & \frac{T_0}{T_0 + \Delta t} \theta_{top}[k-1] + \frac{\Delta t}{T_0 + \Delta t} \theta_{amb}[k] + \\ & + \frac{\Delta t \theta_{fl} R}{(T_0 + \Delta t)(R + 1)} \left(\frac{I[k]}{I_{rated}} \right)^2 + \frac{\Delta t \theta_{fl}}{(T_0 + \Delta t)(R + 1)} \end{aligned} \quad (7)$$

com

$$\begin{aligned} \theta_{top}[k] = & K_1 \theta_{top}[k-1] + (1 - k_1) \theta_{amb}[k] + \\ & + K_2 I[k]^2 + K_3 \end{aligned} \quad (8)$$

A partir do conjunto de dados medidos os parâmetros K_1 ,

K_2 e K_3 podem ser estimados a partir do algoritmo de estimação de mínimos quadrados na versão modificada do método de Gram-Schmidt modificado [3]. Uma vez estimados os parâmetros K_1 , K_2 e K_3 os parâmetros físicos T_0 , θ_{fl} e R podem ser determinados.

B. Modelo Polinomial Não Linear NARX – Caixa Preta

Um modelo polinomial multivariável com a temperatura do topo do óleo como saída, e a temperatura ambiente e carregamento (corrente) como entradas é utilizado como estrutura de um modelo não linear NARX (*nonlinear autoregressive model with exogenous variables*). Definindo $\ell=2$ como grau de não-linearidade o modelo não linear pode ser expresso através da função

$$y(k) = F^\ell [y(k-1), \dots, y(k-n_y), u(k-1), \dots, u(k-n_u)] \quad (9)$$

Expandindo-se $y(k)$ na forma NARX polinomial para garantir uma estrutura não linear com linearidade nos parâmetros obtém-se [29]:

$$\begin{aligned} y(k) = & c_{0,0} + \sum_{n_1=1}^{n_y} c_{1,0}(n_1)y(k-n_1) + \sum_{n_1=1}^{n_u} c_{0,1}(n_1)u(k-n_1) + \\ & + \sum_{n_1=1}^{n_y} \sum_{n_2=1}^{n_u} c_{2,0}(n_1, n_2)y(k-n_1)y(k-n_2) + \\ & + \sum_{n_1=1}^{n_y} \sum_{n_2=1}^{n_u} c_{1,1}(n_1, n_2)y(k-n_1)u(k-n_2) + \\ & + \sum_{n_1=1}^{n_u} \sum_{n_2=1}^{n_u} c_{0,2}(n_1, n_2)u(k-n_1)u(k-n_2) \end{aligned} \quad (10)$$

A escolha dos máximos atrasos $n_y=1$ e $n_u=1$ gera um conjunto completo de regressores

$$\psi(k-1) = [1, y(k-1), u(k-1), y(k-1)^2, y(k-1)u(k-1), u(k-1)^2] \quad (11)$$

Ao conjunto de termos obtidos, denominados de candidatos, aplica-se o método da taxa de redução do erro *ERR* (*error reduction ration*) para determinar os termos que apresentam contribuição significativa para o modelo final. A taxa de redução do erro é dada por [5]:

$$ERR_i = \frac{\hat{g}_i^2 \langle \mathbf{w}_i, \mathbf{w}_i \rangle}{\langle \mathbf{y}, \mathbf{y} \rangle} \quad (12)$$

onde \hat{g}_i é o conjunto de parâmetro do modelo definido na base de regressores \mathbf{w}_i ortogonais. As medidas da saída do sistema formam o vetor \mathbf{y} .

Os parâmetros do modelo não linear NARX podem ser determinados através do algoritmo dos mínimos quadrados e dados por:

$$\hat{\theta} = [\psi^T \psi]^{-1} \psi^T y \quad (13)$$

onde θ é o vetor de parâmetros e ψ é a matriz de regressores formada pelos vetores de entrada $u(k)$ e saídas $y(k)$.

Para resolver problemas de sensibilidades e mau condicionamento numérico do método dos mínimos quadrados quando empregado em sua forma convencional, utilizou-se o método de Gram-Schmidt modificado. O objetivo deste método é fatorar a matriz de regressores ψ da seguinte for-

ma $\psi = QA$ onde A é dada por:

$$A = \begin{bmatrix} 1 & \alpha_{1,2} & \alpha_{1,3} & \cdots & \alpha_{1,n_\theta} \\ 0 & 1 & \alpha_{2,3} & \cdots & \alpha_{2,n_\theta} \\ \vdots & \ddots & \ddots & \cdots & \vdots \\ 0 & 0 & 0 & 1 & \alpha_{n_\theta-1} \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (14)$$

correspondendo a uma matriz triangular superior de dimensão $(n_\theta \times n_\theta)$, Q é uma matriz de dimensão $(N \times n_\theta)$ com colunas ortogonais tal que $Q^T Q = D$, sendo D uma matriz diagonal definida positiva. Desta forma os parâmetros do modelo que relaciona-se com a base ortogonal segundo,

$$\hat{\theta} = A^{-1} \hat{g} \quad (15)$$

O método de Gram-Smidt determina a matriz A uma linha por vez e ortogonaliza ψ de tal forma que na i -ésima iteração as colunas $i+1, \dots, n_\theta-1$, são ortogonais à i -ésima coluna. Esta operação é repetida para $i=1, 2, \dots, n_\theta-1$.

Indicando entre parênteses a interação, tem-se $\psi_j^{(0)} = \psi_j$, $j=1, \dots, n_\theta$ e

$$\begin{aligned} q_i &= \psi_i^{(i-1)} \\ \alpha_{i,j} &= \frac{\langle q_i, \psi_j^{(i-j)} \rangle}{\langle q_i, q_i \rangle}, \quad j = i+1, \dots, n_\theta \end{aligned} \quad (16)$$

$$\psi_j^{(i)} = \psi_j^{(i-1)} - \alpha_{i,j} q_i, \quad j = i+1, \dots, n_\theta$$

Uma vez que as equações 44 são resolvidas para $i=1, 2, \dots, n_\theta-1$, os parâmetros do modelo ortogonalizado, \hat{g} , são determinados fazendo-se $\mathbf{y}^{(0)} = \mathbf{y}$ e

$$g_i = \frac{\langle q_i, y_j^{(i-1)} \rangle}{\langle q_i, q_i \rangle} \quad (17)$$

$$y^{(i)} = y^{(i-1)} - \hat{g}_i q_i, \quad i = 1, \dots, n_\theta$$

A determinação dos parâmetros correspondentes aos regressores do modelo é feita através de (15).

C. A Rede Neural Perceptron Multi-Camadas - MLP

A MLP é talvez a rede neural mais popular em aplicações de reconhecimento padrão e aproximação de funções [12, 13]. As memórias são os pesos (w_{ij} e w_{jk}) entre as camadas, ilustrados na figura 5,

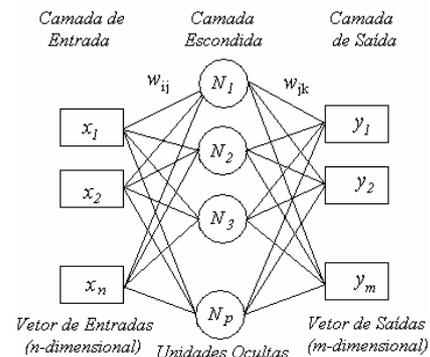


Figura 5 - RNA com propagação adiante (feedforward)

onde w_{ij} representa o peso que conecta o neurônio i ao j , a relação de entrada-saída do neurônio j está descrita em (18),

$$y_j^{(l)} = \Phi(v_j^{(l)}) = \Phi\left(\sum_{i=0}^p w_{ij}^{(l)} x_{ij}^{(l)}\right) \quad (18)$$

onde l indica a camada ($l > 0$, a camada de saída é a terceira camada), y_j é a saída do j -ésimo neurônio, v_j é a soma de pesos dos neurônios de entrada, x_{ij} é a i -ésima entrada do neurônio (p entradas da camada anterior e a polarização), w_{ij} é o peso da i -ésima entrada para o j -ésimo neurônio, e $\Phi(\cdot)$ denota a função de ativação do neurônio.

A função de ativação $\Phi(v)$ é uma função não-linear suave e pode ter várias formas, tais como a função logística e a função tangente hiperbólica.

O treinamento de uma MLP geralmente é realizado através do algoritmo “Back-Propagation”, que apresenta dois passos – o passo direto e o passo anterior (“backward”). No passo direto os pesos da rede são fixos e (18) é repetidamente utilizada para obter as saídas dos neurônios. Durante o passo anterior todos os pesos são ajustados de acordo com as equações de correção de erro colocadas a seguir:

$$e_j(n) = d_j(n) - y_j(n) \quad (19)$$

$$\delta_j^{(l)} = \begin{cases} e_j^{(l)} \Phi'(v_j^{(l)}(n)) \rightarrow \text{camada de saída} \\ \Phi' \left(v_j^{(l)}(n) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \right) \rightarrow \text{camada escondida} \end{cases} \quad (20)$$

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha w_{ji}^{(l)}(n-1) + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (21)$$

onde n é o número da iteração de treinamento, e representa o sinal de erro, d é a saída desejada, $\Phi'(\cdot)$ denota a derivada da função de ativação, η é o parâmetro da taxa de aprendizagem e α constante momento.

V. RESULTADOS - AVALIAÇÃO DOS MODELOS TÉRMICOS DESENVOLVIDOS PARA O TRANSFORMADOR PROTÓTIPO

Para avaliar o desempenho dos métodos propostos na solução do problema de modelagem da carga térmica do transformador a partir da estimação da temperatura do topo do óleo em função da carga e da temperatura ambiente, foi utilizado o protótipo descrito na seção III deste artigo. Nas implementações utilizou-se amostras da temperatura ambiente, do carregamento (corrente) e da temperatura do topo do óleo do transformador. As amostras foram obtidas durante dois dias em intervalos de tempo de $\Delta t = 5$ minutos, conforme figura 6. O transformador alimenta cargas não lineares formada de aparelhos de ar condicionado.

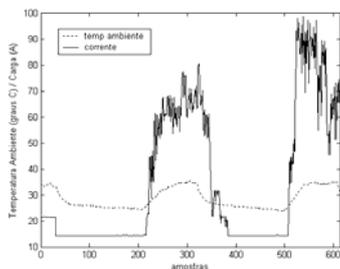


Figura 6. Temperatura Ambiente e Carregamento(Corrente)

Os resultados da aplicação dos diferentes modelos podem ser visualizados nos gráficos da figura 7.

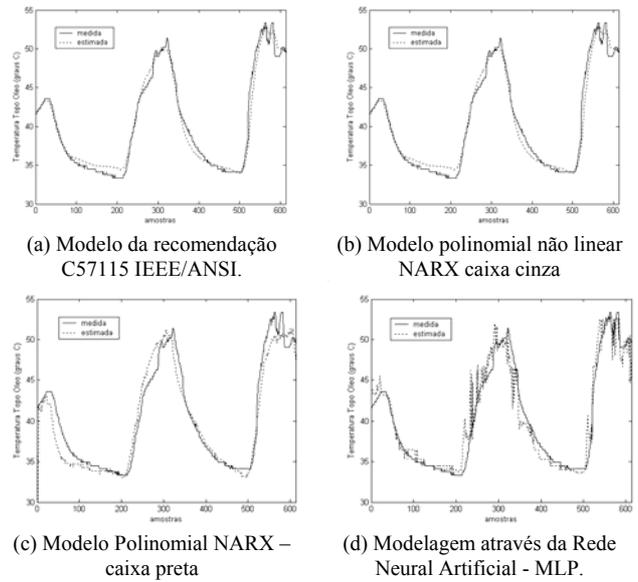


Figura 7. Modelos térmicos do Transformador

Das experimentações realizadas, observa-se que ambos os modelos apresentam melhor desempenho do que o modelo da recomendação C57115 IEEE/ANSI

A tabela 2 apresenta o erro quadrático médio obtido para cada um dos métodos descritos.

TABELA 2 - RESULTADOS OBTIDOS COM OS MODELOS.

Modelo	Erro Quadrático Médio (EQM)
C57115 IEEE/ANSI	6,8097
NARX – caixa cinza	1,2129
NARX – caixa preta	2,7083
Rede neural –MLP	2,4389

Observa-se que o melhor resultado foi obtido ao ser utilizado o modelo polinomial não linear caixa cinza que aprimora a recomendação C57115 IEEE/ANSI. O modelo polinomial NARX e redes neurais MLP com uma camada escondida apresentaram erros quadráticos médios de valores semelhantes. Desde que o modelo polinomial não linear NARX caixa cinza apresentou um melhor resultado do que o modelo caixa preta e conseqüentemente pode-se concluir dos resultados experimentais que ao se incorporar algum conhecimento do sistema real ao modelo obtém-se ganho no desempenho final. O desempenho mediano das redes neurais pode ser justificado se for considerado que se utilizou somente uma camada escondida, o que torna a estrutura da rede linear nos parâmetros, semelhante ao modelo polinomial não-linear NARX caixa preta. Espera-se em desenvolvimento futuro melhorar o desempenho da rede neural através da utilização de um maior número de camadas escondidas.

VI. CONCLUSÃO

A Neste trabalho implementou-se três estruturas de identificação não linear para resolver o problema de estimação da temperatura interna do topo do óleo de um transformador considerando somente dados do carregamento e temperatura ambiente. A primeira estrutura implementa a um modelo

NARX que incorpora informações sobre a dinâmica de transferência de calor interna e externa ao transformador e por isto considerado um modelo caixa cinza. Este modelo é uma evolução proposta para a recomendação C57115 IEEE/ANSI. Para o segundo modelo utilizou-se uma estrutura não linear NARX desconsiderando-se informações a priori do sistema e por isto classificado como caixa preta. Para estimar os parâmetros de ambos os modelos NARX caixas preta e cinza utilizou-se um estimador dos mínimos quadrado na versão Gram-Schmidt para resolver problemas de mal condicionamento numérico dos regressores. Para a escolha dos regressores do modelo NARX caixa preta, utilizou-se o método da taxa de redução do erro. Finalmente o terceiro método correspondeu a uma modelagem através de redes neurais artificiais com estrutura MLP e treinamento por back-propagation. A rede neural foi implementada com somente uma camada de neurônio escondida o que a tornou semelhante aos métodos de identificação polinomial implementados desde que, embora não linear na estrutura geral, são lineares nos parâmetros.

Das implementações realizadas obteve-se um melhor desempenho para a identificação através do modelo polinomial não linear NARX caixa cinza. Espera-se, entretanto, que em trabalhos futuros a estrutura de identificação baseada nas redes neurais apresente um melhor desempenho com a inclusão de outras camadas escondidas de neurônio desde que da forma implementada a rede neural funciona semelhante ao modelo NARX caixa preta. Um outro trabalho futuro relaciona-se à implementação de outros regimes de carga de forma que seja possível o estudo do comportamento das estruturas de identificação quando o transformador estiver submetido a cargas leve, nominal e sobrecarga.

Um transformador protótipo equipado com sensores eletrônicos e de fibra óptica para medidas de temperatura e sensores de corrente e tensão baseados em efeito Hall foi utilizado para validação dos métodos de diagnóstico de estresses térmicos.

VII. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] C. Bengtsson, "Status and Trends in Transformer Monitoring," *IEEE Transactions on Power Delivery*, vol. 11, no. 3, pp. 1379-1384, 1996.
- [2] S. Kovacevic and N. Dominelli, "Transformer Life Extension by Continuous On-Line Oil Conditioning," *Proceedings of Electrical Insulation Conference and Electrical Manufacturing & Coil Winding Technology Conference*, pp. 23-25, 2003.
- [3] S. Tenbohlen and F. Figel, "On-line condition monitoring of power transformers," *IEEE Power Engineering Society Winter Meeting*, vol.3, pp. 2211-2216, 2000.
- [4] A. K. Lazarevich, "Partial Discharge Detection and Localization in High Voltage Transformers Using an Optical Acoustic Sensor," Thesis submitted to the faculty of the Virginia Polytechnic Institute and State University, 2003.
- [5] L. A. Aguirre, *Introdução à Identificação de Sistemas*, Editora UFMG, 2004.
- [6] Chen, *Linear System Theory and Design*, Oxford University Press, 1999.
- [7] *IEEE Guide for Loading Mineral-Oil-Immersed Power Transform in Excess of 100 MVA (65oC)*, IEEE C.57.115.1991, 1991.
- [8] B. C. Lesieutre, W. H. Hagman and J. L. Kirtley Jr., "An Improved Top Oil Temperature Model for Use in An On-Line Monitoring and Diagnostic System", *IEEE Transactions on Power Delivery*, vol. 12, no. 1, pp. 249-256, January 1997.
- [9] *ABNT - Aplicação de Carga em Transformadores de Potência - Procedimento*, ABNT NBR 5416, Julho 1997.

- [10] *ABNT - Transformador de Potência – Método de Ensaio*, ABNT NBR 5380, 1993.
- [11] M. Milasch, *Manutenção de Transformadores em Líquido Isolante*, São Paulo: Editora Edgard Blucher Ltda, 1984, p. 353.
- [12] S. Haykin, *Neural Networks – A Comprehensive Foundation*, New Jersey: Prentice Hall, 2nd ed., 1999.
- [13] C. Freitas, A. N. Souza e I. N. Silva, "Aplicação de Redes Neurais na Estimação da temperatura Interna de Transformadores de Distribuição Imersos em Óleo," *Revista Controle & Automação*, vol. 13 no 3, Set-Dez, 2002.