

Avaliação do Desempenho de um Modelo Térmico Simplificado de um Motor de Indução Trifásico Submetido a Desequilíbrios de Tensão

Marcos Diego de Castro e Silva
Anésio de Leles Ferreira Filho
Universidade de Brasília - UnB
leles@unb.br

Guilherme Zanetti Rosa
Christian Chukwuemeka Abada
Universidade de Brasília - UnB
guilherme.zr@gmail.com

Resumo — Motores de indução trifásicos (MIT) têm grande peso na carga dos sistemas elétricos em todo o mundo. A modelagem destes equipamentos mostra-se fundamental para o planejamento das suas aplicações. A temperatura de operação desta máquina é uma grandeza cuja análise torna-se importante nos estudos de qualidade da energia, uma vez que ela possui influência direta na vida útil desses equipamentos. Este trabalho compara os resultados das temperaturas medidas em um MIT submetido em laboratório a diversas condições de desequilíbrio de tensão, àqueles oriundos da utilização i) de um modelo térmico simplificado e ii) de uma Rede Neural Artificial. Com isso, é possível identificar qual a estratégia mais eficaz para simulações envolvendo desequilíbrio de tensão.

Palavras-chaves — Motor de Indução Trifásico, Modelo Térmico, RNA, Desequilíbrio de Tensão, Qualidade da Energia.

I. INTRODUÇÃO

A modelagem de motores de indução trifásico (MIT) é uma questão importante no estudo desse tipo de máquina. Além dos requisitos elétricos e mecânicos a serem satisfeitos, é necessário verificar se o motor suportará a elevação de temperatura a que ele estará sujeito. Cabe ressaltar que, devido ao seu regime de funcionamento e à sua alimentação, frequentemente no sistema elétrico, este tipo de equipamento está sujeito a distúrbios de qualidade da energia (QEE) [1].

Dos problemas associados a uma rede cuja alimentação possui QEE comprometida, pode-se citar o desequilíbrio de tensão. Trata-se de um fenômeno caracterizado pela alteração no padrão trifásico do sistema de distribuição e transmissão, que é dado por um sistema equilibrado, constituído por tensões iguais em módulo e defasadas entre si de 120° elétricos. Esse distúrbio pode ser causado por diversos fatores, entre eles: distribuição irregular das cargas entre as fases; impedâncias distintas entre os enrolamentos do transformador; transposição incompleta de linhas de transmissão; falhas em bancos de capacitores; desigualdade nas impedâncias das linhas de transmissão; níveis divergentes de distorção harmônica nas fases do sistema elétrico; e fenômenos como interrupções, subtensões, sobretensões e afundamentos [2].

O desequilíbrio de tensão pode provocar problemas indesejáveis na operação dos motores de indução trifásicos, com significativas consequências devido à importância desses equipamentos em ambientes industriais. Por esta razão, fazem-

se necessárias simulações computacionais capazes de permitir a avaliação do desempenho dos motores antes mesmo deles serem instalados [3].

Este trabalho apresenta uma análise comparativa entre os resultados da aplicação de um modelo térmico simplificado e de uma Rede Neural Artificial (RNA) para a representação do comportamento da temperatura de um MIT submetido a inúmeras condições de desequilíbrios de tensão. Para tanto, realiza-se ensaios laboratoriais executados para a identificação de qual estratégia se mostra mais eficiente.

Inicialmente é descrita uma fundamentação teórica acerca dos modelos computacionais empregados neste trabalho. Nas seções subsequentes, são realizadas as descrições dos métodos e procedimentos utilizados para a obtenção dos resultados e a apresentação da metodologia desenvolvida. Em seguida, esses resultados são apresentados e analisados. Ao final, as conclusões resultantes deste estudo se fazem presente.

II. FUNDAMENTAÇÃO TEÓRICA

A. Modelo térmico

Quando em funcionamento, o MIT e o ambiente em sua volta podem ser interpretados como um sistema térmico constituído por diversos elementos que, devido às diferenças de temperaturas, trocam calor entre si. Em razão do inevitável processo de perdas na conversão de energia, algumas de suas partes atuam como fonte de calor, tais como os enrolamentos do estator, as barras do rotor e o núcleo magnético. Entretanto, outros elementos atuam como dissipador de calor, como o ar de refrigeração que circula pelo entreferro e externamente à carcaça do MIT.

Para simplificar as análises, é conveniente admitir que o sistema térmico possa ser representado por um modelo a parâmetros concentrados, ou seja, o motor pode ser dividido em regiões de interesse onde a temperatura resultante de cada uma delas corresponde a um valor médio da parte em questão [4]-[7].

A condição de carregamento e a presença de desequilíbrio nas tensões do motor interferem sobremaneira em seu comportamento térmico, pois as temperaturas estão diretamente atreladas às correntes que circulam pela máquina,

fazendo com que o calor seja distribuído de maneira desuniforme entre as fases [5].

Do ponto de vista físico, o MIT comporta-se obedecendo a primeira e segunda lei da termodinâmica. Desta forma, tem-se que: i) pelo balanço energético, o acúmulo de energia no motor é igual ao calor gerado internamente, menos o calor transferido ao meio ambiente; e ii) um gradiente de temperatura acarreta na transferência de calor, por convenção, o sentido do fluxo de energia se dá da região mais quente para a região mais fria.

Em máquinas elétricas e na natureza, o calor gerado pode ser transferido entre regiões adjacentes por condução, convecção e radiação. Por conveniência, neste estudo considera-se apenas troca de calor por condução, que é regido pela lei de Fourier [4]. Se a transferência de calor se dá em superfície condutora uniforme de comprimento L , e a distribuição espacial das temperaturas no objeto condutor não se altera, o fluxo é dado por:

$$q = -\lambda S \frac{dT}{dx} = -\lambda S (T_{quente} - T_{frio}) = \frac{\Delta T}{L/\lambda S} \quad (1)$$

Onde: q é taxa de transferência de calor por condução (W); λ é condutividade térmica do material (W/m°C); S é a seção de área perpendicular à direção de q (m²); e T corresponde à temperatura em Kelvin ou graus Celsius.

O termo $L/\lambda S$ representa a resistência térmica que a superfície condutora oferece ao fluxo de calor, sendo que a condutividade térmica é dada pelo seu inverso.

B. Rede Neural Artificial

A rede neural artificial pode, assim como o modelo térmico, ser aplicada com o intuito de se identificar as temperaturas do MIT por meio das correntes elétricas. Uma Rede Neural Artificial (RNA) pode ser definida como sendo uma estrutura de processamento (rede) passível de implementação em dispositivos eletrônicos, composta por um número de unidades interconectadas (neurônios artificiais), sendo que cada unidade apresenta um comportamento específico de entrada ou saída (computação local), determinado pela sua função de transferência, pelas interconexões com outras unidades, dentro de um raio de vizinhança, e possivelmente pelas entradas externas [8].

Neste trabalho, adotou-se uma RNA do tipo *Feed-Foward Backpropagation* cuja topologia não tem caminhos fechados. Seus nós de entrada são aqueles sem arcos para eles, e seus nós de saída não têm arcos afastados deles. Todos os outros nós são nós ocultos. Quando os estados de todos os nós de entrada são configurados, todos os outros nós na rede também podem definir seus estados à medida que os valores se propagam através da rede [9].

C. Métodos de Otimização – Mínimos Quadrados

A solução de problemas de minimização tem um enorme gama de aplicações diretas, incluindo o ajuste de curvas pelo método dos mínimos quadrados, problemas de interpolação e solução de sistemas de equações lineares. Este trabalho usará o método dos mínimos quadrados para minimizar o erro na obtenção dos parâmetros da função do modelo térmico simplificado do MIT.

O método de Mínimos Quadrados é utilizado para resolver sistemas superdeterminados (ou impossíveis), isto é, aqueles em que existem mais restrições que variáveis desconhecidas. Apesar de não ser possível encontrar uma solução que respeite todas as restrições simultaneamente, é possível calcular uma aproximação. O método de Mínimos Quadrados busca uma solução que minimize a soma dos quadrados das diferenças entre o valor predito pelo modelo e o valor desejado.

Idealmente, o modelo $g(x_j; \theta)$ seria flexível o suficiente para representar a transformação desejada. Na prática, porém, o modelo $g(x_j; \theta)$ pode somente aproximar o valor correto y_j a partir de x_j . Desta forma, podemos definir o erro de aproximação do par (x_j, y_j) como:

$$r_j(\theta) = g(x_j; \theta) - y_j \quad (2)$$

E minimizar a função objetivo:

$$f(\theta) = \frac{1}{2} \sum_j [r_j(\theta)]^2 = \frac{1}{2} \sum_j [g(x_j; \theta) - y_j]^2 \quad (3)$$

Ao minimizar $f(\theta)$ encontramos o vetor de parâmetros θ que melhor ajusta o modelo $g(x_j; \theta)$ aos dados (x_j, y_j) . Neste caso, o termo “melhor” é definido como o vetor θ que minimiza a soma do quadrado dos erros. Por isto o nome de método de Mínimos Quadrados.

III. MÉTODOS E PROCEDIMENTOS

A. Infraestrutura Laboratorial

Para a etapa experimental deste trabalho, emprega-se um MIT de 1,5 kW acoplado a um gerador DC de 4 kW, utilizado como carga. O MIT possui sensores de temperatura do tipo PT-100 em cada enrolamento do estator e sua corrente nominal é de 3,56 A para conexão em estrela. A temperatura medida experimentalmente nos enrolamentos do estator para a condição equilibrada, carga nominal e temperatura ambiente de 25 °C é igual a 81,6 °C.

Com o objetivo de aplicar numerosas condições de desequilíbrio no MIT, foi desenvolvido em laboratório um sistema onde as amplitudes e ângulos das tensões são gerados e lidos automaticamente. O esquema de ligações e os equipamentos dessa infraestrutura se encontra ilustrado na Fig. 1.




Fig. 1. Sistema de controle e registro das grandezas do motor.

O sistema da Fig. 1 permite que o controle das tensões de entrada e o registro dos valores de todas as grandezas envolvidas no processo sejam realizados de forma automatizada. O gerador C.C. opera como uma carga linear. Sua bobina de campo é alimentada por um regulador de tensão C.C., em série com um resistor variável, enquanto sua armadura é ligada a uma carga resistiva variável. Os valores escolhidos para cada um dos dois resistores, que são mantidos inalterados, correspondem aqueles em que o motor apresenta os valores nominais de corrente e de potência quando a máquina é submetida às condições nominais de tensão.

Na infraestrutura laboratorial, além dos já mencionados, se fazem presentes: um medidor de grandezas elétricas de classe A, uma fonte de tensão programável, que consiste em três módulos 5001iX California Instruments, uma placa de aquisição de dados NIPCI-6251 da National Instruments, um encoder incremental para medir a velocidade de rotação do motor, um sensor de torque, um sensor de temperatura ambiente e um computador com um software desenvolvido para controlar todo o processo.

B. Bancos de Dados

Buscando-se abarcar a maior quantidade e diversidade de combinações de tensões desequilibradas possíveis, gerou-se nesse trabalho, um banco de dados (BD) com condições de desequilíbrio de tensão que foram aplicadas ao MIT para identificar e validar os parâmetros do modelo térmico e os pesos sinápticos da RNA.

O BD é constituído pela seleção randômica de 1379 condições de desequilíbrio de tensão com as tensões limitadas entre 201 e 231 V, faixa de valores estabelecida como aceitável pelo PRODIST (2017) [10].

C. Metodologia Empregada para a Obtenção dos Coeficientes do Modelo Térmico e dos Pesos Sinápticos da RNA

Apresentam-se neste tópico as metodologias e os procedimentos empregados para a elaboração do modelo térmico e da rede neural artificial, os quais são utilizados para representar as temperaturas do MIT submetido a desequilíbrios de tensão.

Para a estimação dos coeficientes do modelo térmico, inicialmente, atribuem-se valores aleatórios para cada um deles, ou seja, para $k_A, k_B, k_C, k_{AB}, k_{BC}, k_{CA}, R_A, R_B$ e R_C . Em seguida, aplica-se a função de otimização para se determinar um conjunto de coeficientes, através de aproximações matemáticas que utilizam como entradas valores de correntes e temperaturas ambientes, e como saídas, suas respectivas temperaturas medidas em laboratório. A Tabela I mostra as grandezas empregadas nas regressões não lineares para a estimação dos coeficientes do modelo térmico.

TABELA I. GRANDEZAS EMPREGADAS NAS REGRESSÕES NÃO LINEARES PARA A OBTENÇÃO DOS COEFICIENTES DO MODELO TÉRMICO DO MIT.

Grandezas	Variáveis
Coefficientes	$k_A; k_B; k_C; k_{AB}; k_{BC}; k_{CA}; R_A; R_B; R_C$
Entradas	$I_A; I_B; I_C; T_{Amb}$
Saída	$T_A; T_B; T_C$

Por fim, para se confirmar que os valores dos coeficientes definidos pela função de otimização tornam o modelo capaz de representar com boa precisão os valores reais, efetua-se a comparação de uma nova série de valores de entrada aplicados ao MIT em laboratório e não utilizados para a obtenção desses parâmetros, de forma que se possa verificar se os resultados apresentados pelo modelo são condizentes com aqueles medidos experimentalmente.

As mesmas condições de entrada são aplicadas a um processo de Rede Neural Artificial, com o objetivo de se verificar a modelagem que esta metodologia é capaz de produzir para a temperatura do motor. Utilizando-se a RNA, aplicam-se as condições de entrada de corrente e temperatura ambiente previamente utilizadas no modelo térmico com o objetivo de se obter valores para a temperatura nos enrolamentos como dados de saída da função. Para tanto, a Tabela II mostra a configuração computacional utilizada.

TABELA II. CARACTERÍSTICAS DA REDE NEURAL ARTIFICIAL EMPREGADA NESTE TRABALHO.

Item	Descrição
Tipo da RNA:	Feed-Foward Backpropagation
Número de épocas:	5000
Gradiente mínimo:	10-10
Número máximo de falhas:	30
Camadas:	Verificar qual o melhor
Neurônios por camada:	Verificar qual o melhor
Variáveis de entrada:	$I_A; I_B; I_C; T_{Amb}$
Variáveis de saída:	$T_A; T_B; T_C$

Da Tabela II, nota-se que as quantidades de camadas e de neurônios não foram especificadas, pois estes valores são selecionados com base na verificação de resultados que são obtidos, conforme o seguinte procedimento: selecionam-se aleatoriamente diversas combinações de camadas e de neurônios por camadas. Em seguida, para cada uma das escolhas, verifica-se o erro médio entre as temperaturas medidas e estimadas. A seleção da quantidade de camadas e neurônios por camadas que serão empregados pela RNA é efetuada respeitando-se a existência de um erro que, além de estar entre os menores, corresponda a uma combinação que não exija um grande esforço computacional.

Na realização da análise comparativa entre os resultados do modelo térmico e da RNA, as etapas do processo seguem critérios similares em ambas as metodologias computacionais. Para tanto, as seguintes ações se fazem necessárias: i) estimação dos coeficientes e dos pesos sinápticos; ii) avaliação da capacidade de generalização de ambas as ferramentas; e iii) verificar se o número de amostras do BD são adequados para a correta estimação das temperaturas nos enrolamentos do MIT.

D. Estimação dos coeficientes do modelo térmico e dos pesos sinápticos da RNA

Para a estimação dos coeficientes do modelo térmico, inicialmente, atribuem-se valores aleatórios a cada um deles. Em seguida, aplica-se a função de otimização para se estimar um conjunto de coeficientes empregando-se a totalidade das leituras do BD. Este procedimento (de seleção aleatória dos coeficientes iniciais e de sua otimização) é repetido outras 49 vezes. Ao final, obtém-se um conjunto de 50 coeficientes oriundos de todas as otimizações.

De forma análoga, para a estimação dos pesos sinápticos da RNA, são realizados 50 treinamentos com escolhas aleatórias dos pesos iniciais dos neurônios. Para cada escolha, empregando-se a totalidade do BD, aplica-se o algoritmo *Feed-Forward Backpropagation*.

Após estes passos, utilizando-se as correntes elétricas das 1379 condições do BD como entrada nos métodos computacionais, é possível identificar os respectivos 1379 valores de temperaturas para cada uma das fases do MIT.

Com as temperaturas adquiridas em laboratório, quando da aplicação sobre o MIT das mesmas 1379 condições do BD, é possível calcular o erro médio de cada uma das 50 combinações de parâmetros do modelo térmico e de pesos sinápticos. Considerando-se os 50 valores de erros médios obtidos com o procedimento ora descrito, seleciona-se aquele que apresenta o menor valor para o uso no modelo final.

E. Avaliação da capacidade de generalização do modelo térmico e da RNA

Nesta etapa, para a avaliação da capacidade de generalização do modelo térmico e da RNA, inicialmente, selecionam-se aleatoriamente 80% das condições de desequilíbrio (1103 conjuntos de tensões desequilibradas) que constituem o BD. Em seguida, utiliza-se a função de otimização para se estimar um conjunto de coeficientes do modelo térmico e pesos sinápticos da RNA, empregando-se os 80% das amostras selecionadas do BD. De posse dos coeficientes do modelo térmico e pesos sinápticos da RNA, os 20% remanescentes (276 conjuntos de tensões desequilibradas) dessa escolha aleatória são empregados para se identificar as discrepâncias entre os valores de temperaturas encontrados nos ensaios em laboratório e aqueles oriundos do modelo térmico e da RNA. Com isso, ao final dessa etapa, tem-se para cada fase, em cada metodologia, 276 valores de erros.

Em seguida, as ações relacionadas à seleção aleatória de 80% das grandezas de entrada e à utilização dos 20% remanescentes, são repetidas mais 2999 vezes. Após as mencionadas etapas, para cada fase do MIT, têm-se $276 \times 3000 = 828000$ valores de erros. De posse desses 828000 resultados para a temperatura de cada fase, calcula-se o erro médio, o erro máximo, e o desvio padrão.

F. Avaliação da adequação do número de amostras do banco de dados

Inicialmente, para a avaliação da adequação do número de amostras do banco de dados do modelo térmico e da RNA, realizam-se as seguintes etapas:

- 1) Para cada etapa desta análise, selecionam-se aleatoriamente $X\%$ das condições do BD. Ao todo, são escolhidos 26 porcentagens de X , que variam de 0,5% até 100% do BD;
- 2) Para a identificação dos coeficientes do modelo térmico e dos pesos sinápticos da RNA, emprega-se $X\%$ de amostras. Este procedimento é repetido 26 vezes, ou seja, ao final desta etapa, têm-se 26 conjuntos de coeficientes em cada metodologia, uma para cada valor de X ;
- 3) Com os coeficientes e pesos sinápticos estimados em cada etapa dos 26 casos descritos no item 2, realizam-se 1379 estimações das temperaturas aplicando-se como entradas no modelo térmico e na RNA, as correntes elétricas e as temperaturas ambientes de todo o BD;

4) De posse dos 1379 resultados de temperaturas, calculam-se 1379 valores de erros para cada um dos 26 casos em cada metodologia.

5) Os procedimentos de 2 a 4 são então repetidos por mais 499 vezes. Em cada uma dessas situações, as amostras do BD para cada um dos 26 valores de X , são escolhidas aleatoriamente. Portanto, ao final desta etapa, têm-se $1379 \times 500 = 689500$ valores de erros.

Finalmente, de posse dos 689500 valores de erros para cada fase dos 26 casos, calculam-se o erro médio, o erro máximo, e o desvio padrão. Portanto, fazendo-se uso desses três resultados, é possível verificar, quão pior seriam as estimações caso fossem empregadas quantidades menores de amostras do banco de dados. Pelas tendências encontradas, é possível prever se o acréscimo de novas amostras traria ou não melhorias significativas na estimação das temperaturas nas metodologias computacionais empregadas.

IV. DESENVOLVIMENTO

A. Modelo Térmico do MIT

Neste estudo, o MIT é representado pelo modelo térmico ilustrado da Fig. 2, onde assume-se que: i) o MIT encontra-se em regime permanente; ii) todas as trocas de calor ocorrem através do processo de condução; e iii) existem três fontes de calor, uma para cada fase do enrolamento do estator.




Fig. 2. Circuito térmico equivalente do MIT

Onde: Q é o calor transferido entre os elementos do circuito em watts; T é a temperatura em graus Celsius; k é a condutividade térmica em $W/^\circ C$; e R é a resistência elétrica do estator em Ohms. Os índices A , B e C que acompanham os elementos do circuito indicam as fases dos enrolamentos do estator, e Amb refere-se às grandezas relacionadas ao ar do ambiente.

Nota-se que pelo circuito da Fig. 2, que o motor é representado por um número reduzido de elementos se comparado a outros disponíveis na literatura [4]-[7]. No entanto, o uso de uma função de otimização garante um alto nível de precisão na estimação dos parâmetros que melhor aproximam as temperaturas de operação do motor quando o mesmo é submetido a desequilíbrios de tensões.

Aplicando a técnica de análise nodal no circuito térmico, obtém-se o sistema de equações descrito em “(4)”. A resolução deste sistema resulta nas temperaturas T_A , T_B e T_C representadas em “(5)” a “(7)”, que têm os termos presentes calculados de acordo com “(8)” a “(19)”.

$$\begin{cases} -(k_{AB} + k_{CA} + k_A) \cdot T_A + k_{AB} \cdot T_B + k_{CA} \cdot T_C + k_A \cdot T_{Amb} + Q_A = 0 \\ k_{AB} \cdot T_A - (k_{AB} + k_{BC} + k_B) \cdot T_B + k_{BC} \cdot T_C + k_B \cdot T_{Amb} + Q_B = 0 \\ k_{CA} \cdot T_A + k_{BC} \cdot T_B - (k_{BC} + k_{CA} + k_C) \cdot T_C + k_C \cdot T_{Amb} + Q_C = 0 \end{cases} \quad (4)$$

$$T_A = T_{Amb} + \frac{X_4 + X_6 + X_8}{X_1 + X_2 + X_3} \quad (5)$$

$$T_B = T_{Amb} + \frac{X_5 + X_6 + X_9 + X_{11}}{X_1 + X_2 + X_3} \quad (6)$$

$$T_C = T_{Amb} + \frac{X_4 + X_7 + X_{10} + X_{12}}{X_1 + X_2 + X_3} \quad (7)$$

$$X_1 = k_{CA}[k_{AB}(k_A + k_B + k_C) + k_{BC}(k_B + k_C) + k_A(k_{BC} + k_B) + k_B k_C] \quad (8)$$

$$X_2 = k_{AB}[k_{BC}(k_B + k_C) + k_A(k_{BC} + k_C) + k_B k_C] \quad (9)$$

$$X_3 = k_A[k_{BC}(k_B + k_C) + k_B k_C] \quad (10)$$

$$X_4 = k_{CA}[(k_{AB} + k_{BC})Q_B + (k_{AB} + k_{BC} + k_B)Q_C] \quad (11)$$

$$X_5 = k_{CA}[(k_{AB} + k_{BC} + k_A + k_C)Q_B + (k_{AB} + k_{BC})Q_C] \quad (12)$$

$$X_6 = k_{AB}[(k_{BC} + k_C)Q_B + k_{BC}Q_C] \quad (13)$$

$$X_7 = k_{AB}[k_{BC}Q_B + (k_{BC} + k_A + k_B)Q_C] \quad (14)$$

$$X_8 = Q_A[k_{AB}(k_{BC} + k_C) + k_{BC}(k_B + k_C) + k_{CA}(k_{AB} + k_{BC} + k_B) + k_B k_C] \quad (15)$$

$$X_9 = k_A[(k_{BC} + k_C)Q_B + k_{BC}Q_C] \quad (16)$$

$$X_{10} = k_A[k_{BC}Q_B + (k_{BC} + k_B)Q_C] \quad (17)$$

$$X_{11} = Q_A[k_{AB}(k_{BC} + k_C) + k_{CA}(k_{AB} + k_{BC})] \quad (18)$$

$$X_{12} = Q_A[k_{CA}(k_{AB} + k_{BC} + k_B) + k_{AB}k_{BC}] \quad (19)$$

Os parâmetros do modelo térmico são obtidos por meio de uma ferramenta de otimização que emprega o método dos mínimos quadrados. De fato, o modelo térmico do MIT pode ser representado por uma expressão matemática ou por uma função algorítmica contendo uma sequência de instruções. As matrizes ou vetores de entrada e saída podem possuir tantas variáveis quanto se desejar, o que é uma condição fundamental para a representação das expressões “(5)” a “(7)” previamente descritas.

B. Rede Neural Artificial

A rede neural artificial pode, assim como o modelo térmico, ser aplicada com o intuito de se identificar as temperaturas do MIT por meio das correntes elétricas. Para tanto, é preciso obter os pesos sinápticos que melhor se adequem aos valores reais medidos experimentalmente. A RNA empregada neste trabalho é configurada como mostra a Fig. 3.




Fig. 3. Configuração da rede neural artificial.

Onde: *Pesos1* é a matriz 20x4 contendo os pesos sinápticos da camada de entrada; *b1* é o vetor de 20 elementos contendo as polarizações (*bias*) da camada de entrada; *Pesos2* é a matriz 20x3 contendo os pesos sinápticos da última camada; e *b2* é o vetor de 3 elementos contendo as polarizações (*bias*) da última camada.

As funções empregadas na camada de entrada (de 1 a 20) correspondem à tangente hiperbólica. Na camada de saída são empregadas três funções lineares. As variáveis de entrada da RNA correspondem às correntes elétricas nos três enrolamentos e à temperatura ambiente, tendo como saída as suas respectivas temperaturas de operação em regime permanente.

V. RESULTADOS

Com base nos procedimentos descritos na seção anterior, apresenta-se a seguir uma análise individual com relação à capacidade do modelo térmico e da RNA em representar as temperaturas do MIT.

Os resultados obtidos, relativos à capacidade de generalização e de aproximação, quando do emprego de ambas as técnicas, são resumidos nas Tabelas III e IV, respectivamente. Nestas tabelas, tanto os resultados do modelo térmico, quanto da RNA, são comparados com os respectivos valores resultantes dos ensaios laboratoriais envolvendo um MIT submetido a tensões desequilibradas.

TABELA III. RESULTADOS ESTATÍSTICOS PARA SE VERIFICAR A CAPACIDADE DE GENERALIZAÇÃO - CAPACIDADE DE 80% DAS AMOSTRAS DO BD EM REPRESENTAR OS 20% REMANESCENTES.

Análise	Modelo Térmico (°C)	RNA (°C)
Erro médio	0,806	0,698
Máximo erro	3,637	33,764
Desvio padrão	0,564	0,550

TABELA IV - DIFERENÇAS ENTRE OS VALORES DAS TEMPERATURAS LIDAS E APROXIMADAS EMPREGANDO-SE 100% DO BD.

Análise	Modelo Térmico (°C)	RNA (°C)
Erro médio de T_A	0,784	0,580
Erro médio de T_B	0,788	0,590
Erro médio de T_C	0,793	0,604
Erro médio conjunto de T_A, T_B e T_C	0,788	0,591
Erro médio de T_{MAX}	0,835	0,604
Desvio padrão de T_A	0,564	0,484
Desvio padrão de T_B	0,578	0,489
Desvio padrão de T_C	0,578	0,490
Desvio padrão conjunto de T_A, T_B e T_C	0,573	0,489
Desvio padrão conjunto de T_{MAX}	0,603	0,498

Considerando os valores apresentados nas Tabelas III e IV, é possível verificar que o modelo térmico e a RNA apresentaram desempenhos semelhantes em relação à capacidade de aproximar as temperaturas aos valores lidos, sendo os resultados da RNA ligeiramente melhores.

Na segunda linha da Tabela III, observa-se que o máximo erro proporcionado pela RNA foi elevado (33,764 °C). Este comportamento se deve à alta sensibilidade da RNA à escolha dos pesos sinápticos iniciais, que são aleatoriamente inseridos em ambas as metodologias computacionais aqui comparadas. Como os valores apresentados são inerentes a resultados estatísticos, uma única aproximação malsucedida fará com que o erro máximo seja elevado na RNA.

A fim de se comparar o desempenho entre o modelo térmico e a RNA em um caso prático, tem-se na Fig.4 a apresentação

de uma simulação de correntes elétricas geradas pelo MIT. Na Fig. 5, encontram-se as respectivas temperaturas estimadas por ambas as técnicas. Em ambos os gráficos, o eixo das abscissas representa de forma unitária a sequência de condições de entrada, chamadas leituras, enquanto o eixo das ordenadas representa a temperatura do enrolamento da respectiva fase para aquela condição de entrada individual. Neste caso, considera-se a temperatura ambiente constante em 25 °C.




Fig. 4 - Exemplo simulado de correntes nos enrolamentos do estator do MIT.




Fig. 5 - Estimação das temperaturas pelo modelo térmico e pela RNA em função das correntes simuladas.

É possível notar pela Fig. 5 que o modelo térmico apresenta aproximações mais condizentes com as curvas dos valores das correntes elétricas, uma vez que as temperaturas indicadas pela RNA mostram oscilações. Essas oscilações são decorrentes da capacidade da RNA de capturar a essência dos valores do treinamento, inclusive suas perturbações. Como o modelo térmico é regido por expressões matemáticas, as perturbações nas correntes utilizadas para a estimação dos coeficientes têm impacto pouco significativo nos valores de temperatura calculados.

Portanto, para a avaliação da influência da presença de desequilíbrio de tensão sobre as temperaturas de operação do MIT, o emprego tanto do modelo térmico quanto das RNAs se mostra bastante eficaz, afinal, ambas as metodologias apresentam erros médios relativamente baixos (abaixo de 0,9%). Porém, verifica-se que o modelo térmico simplificado do motor é mais eficiente como técnica de estimação das temperaturas, já que ele é menos sensível aos seus parâmetros iniciais, o que resulta em menores oscilações das saídas em relação aos valores de entrada.

VI. CONCLUSÕES

Os procedimentos de identificação e validação dos parâmetros do modelo térmico e da RNA conduziram a resultados que caracterizam esses dois métodos como excelentes formas de se obter, com base em simulações computacionais, os valores das temperaturas de um MIT submetido a desequilíbrios de tensão. Os erros médios entre as temperaturas estimadas e as medidas em laboratório, tanto na

utilização do modelo térmico como da RNA, não ultrapassaram 0,9% do valor nominal da temperatura do MIT.

Da avaliação comparativa entre estes dois métodos, o modelo térmico se mostrou mais eficiente para a estimação das temperaturas nos enrolamentos do estator do MIT operando em condições de desequilíbrio de tensão.

Embora o modelo térmico tenha se mostrado menos preciso do que a RNA, ele demonstrou ser menos sensível à escolha dos coeficientes iniciais (quando da aplicação das regressões não lineares), resultando em melhores aproximações dos valores simulados em relação àqueles obtidos experimentalmente e tornando-o o modelo mais apropriado à representação do motor sob essas condições.

VII. REFERÊNCIAS

- [1] E. R. Filho, E. Avólio, "Um Modelo Matemático Dinâmico para Determinação de Temperaturas de um Motor de Indução Trifásico de Rotor em Gaiola." *SBA Controle & Automação* Vol.6 n° 21 maio-junho 1995.
- [2] A. L. F. Filho, "Análise do Comportamento do Fator de Desequilíbrio frente a Variação da Amplitude e do Ângulo da Tensão." *Tese de Doutorado, Universidade de Brasília*, 2008.
- [3] J. E. A. de Oliveira, "Modelagem de um Motor De Indução Trifásico Operando com Tensões Desequilibradas por meio de Redes Neurais Artificiais" *Dissestação de Mestrado, Universidade Estadual Paulista*, 2011.
- [4] Souto, O. C. N., "Modelagem e Análise do Desempenho Térmico de Motores de Indução sob Condições não Ideais de Alimentação." *Tese de Doutorado, Universidade Federal de Uberlândia*, 2001.
- [5] P. Gnancinski, "Effect of unbalanced voltage on windings temperature, operational life and load carrying capacity of induction machine." In: *ScienceDirect Energy Conversion and Management*, vol. 49, no. 4, 761 - 770, 2008.
- [6] Mellor, P.H., Roberts D., Turner D.R. "Lumped parameter thermal model for electrical machines of TEFC design." In: *Electric Power Applications, IEE Proceedings B*, vol. 138, no. 5, 205 – 218, 1991.
- [7] Chowdhury, S.K., Baski, P.K. "A Simple Lumped Parameter Thermal Model for Electrical machine of TEFC Design." In: *2010 Joint International Conference on Power Electronics, Drives and Energy Systems (PEDES) & 2010 Power India*, 2010.
- [8] Leandro N. de Castro, Fernando J. Von Zuben. "Redes Neurais Artificiais." DCA/FEEC/Unicamp. FTP://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia006_03/topico5_03.pdf. Acessado em 28/06/2017.
- [9] David J. Montana, Lawrence Davis, "Training Feedforward Neural Networks Using Genetic Algorithms." *International Joint Conferences on Artificial Intelligence*, [US], 1989.
- [10] PRODIST, ANEEL, "Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional, Módulo 8 - Qualidade da Energia Elétrica." Revisão 8, data de vigência: janeiro de 2017 a dezembro de 2017.