

**UNIVERSIDADE DE TAUBATÉ**

**André Luiz Zamponi Ribeiro**

**Redes Neurais Artificiais Aplicadas à Estimação da  
Temperatura de Motores de Indução Trifásicos**

**Taubaté – SP**

**2008**

**UNIVERSIDADE DE TAUBATÉ**

**André Luiz Zamponi Ribeiro**

**Redes Neurais Artificiais Aplicadas à Estimação da  
Temperatura de Motores de Indução Trifásicos**

Dissertação apresentada para obtenção do Título de Mestre pelo Curso de Automação em Engenharia do Departamento de Engenharia Mecânica da Universidade de Taubaté.

Área de Concentração: Automação Industrial e Robótica

Orientador: Prof. Dr. Luiz Octávio Mattos dos Reis

**Taubaté – SP**

**2008**

Ribeiro, André Luiz Zamponi.  
R484r Redes Neurais Artificiais Aplicadas à Estimação da  
Temperatura de Motores de Indução Trifásicos./ André Luiz  
Zamponi Ribeiro. – Taubaté: Unitau, 2008.

80 f. :il;30 cm.

Dissertação (Mestrado) – Universidade de Taubaté.  
Faculdade de Engenharia Mecânica. Curso de Mestrado em  
Automação em Engenharia.

Orientador: Luiz Octávio Mattos dos Reis

1. Motor de Indução. 2. Estimação da Temperatura. 3.  
Redes Neurais Artificiais. I. Universidade de Taubaté.  
Departamento de Engenharia Mecânica. II. Título.

CDD(21) 621.3104

**ANDRÉ LUIZ ZAMPONI RIBEIRO**

**REDES NEURAS ARTIFICIAIS APLICADAS À ESTIMAÇÃO DA  
TEMPERATURA DE MOTORES DE INDUÇÃO TRIFÁSICOS**

Dissertação apresentada para obtenção  
do Título de Mestre pelo Curso de  
Automação em Engenharia do  
Departamento de Engenharia Mecânica  
da Universidade de Taubaté.

Área de Concentração: Automação  
Industrial e Robótica

Data: 27/09/2008

Resultado: \_\_\_\_\_

**BANCA EXAMINADORA**

Prof. Dr. Luiz Octávio Mattos dos Reis      Universidade de Taubaté

Assinatura\_\_\_\_\_

Prof. Dr. João Sinohara da Silva Sousa      Universidade de Taubaté

Assinatura\_\_\_\_\_

Prof. Dr. Leonardo Mesquita      Universidade Estadual de São Paulo

Assinatura\_\_\_\_\_

## DEDICATÓRIA

Dedico este trabalho acima de tudo aos meus queridos pais e a minha família.

## **AGRADECIMENTOS**

A Deus, pois sem Ele eu não conquistaria nada em minha vida.

Ao Prof. Dr. Luiz Octávio Mattos dos Reis, pela habilidade com que orientou este trabalho.

Ao Prof. Dr. Ronaldo Rossi, pela sua ajuda.

À Prof. Dra. Graziela Zamponi, pela sua ajuda em diversos momentos.

Aos meus pais, que sempre me apoiaram em todos os momentos da minha vida.

Faça o que pode, com o que tem, onde estiver.

Roosevelt

## Resumo

Os motores de indução são largamente usados em vários setores da sociedade. Entre os setores que mais os utilizam está o setor industrial. Existem vários aspectos a serem considerados na sua operação, entre eles a monitoração da sua temperatura de trabalho. Através desse monitoramento pode-se estimar quando e com que frequência sua manutenção se faz necessária, condições anormais de funcionamento e também o ajuste de proteções. Em alguns casos a instalação de sensores térmicos não é possível devido a limitações físicas ou econômicas e uma opção é a utilização da instrumentação virtual. O trabalho apresentado faz um estudo de uma dada condição de operação de um motor de indução trifásico cuja temperatura será estimada através de Redes Neurais Artificiais. O objetivo desse estudo é avaliar a aplicabilidade dessa ferramenta para esse caso específico como ponto de partida para estudos futuros, onde a viabilidade da aplicação para sistemas mais generalizados possa ser testada. Após a simulação da Rede Neural Artificial proposta utilizando o algoritmo *backpropagation*, concluiu-se que é possível aplicar essa metodologia para esse caso e isso indica a possibilidade de aplicá-la em sistemas mais complexos.

**Palavras Chave:** Motor de Indução, Redes Neurais Artificiais, Estimação da Temperatura.

## **Abstract**

Induction motors are largely used in the industry in our days and the temperature monitoring in these motors is extremely important for their operation. Through this monitoring one can estimate when and how often the maintenance will be performed, adjust the proper protection and identify abnormal operation conditions. In some cases the installation of thermal sensors is not possible due to physical or economical restrictions and the utilization of virtual instrumentation is an option. The following work presents a study for a specific condition where the stator temperature for a generic induction motor in a steady state operation is estimated by using an Artificial Neural Network. The purpose of this study is the evaluation of the applicability of this tool for this specific case and it is the starting point for further studies where the feasibility of a general system can be tested. After simulating the proposed Artificial Neural Network using the backpropagation algorithm it was concluded that this is an applicable method to solve this problem and can be extended to more complex systems.

**Keywords:** Induction Motor, Artificial Neural Networks, Temperature estimation.

## LISTA DE TABELAS

Tabela 1.1 - Categoria de motores de indução de acordo com a relação torque x velocidade.....	30
Tabela 1.2 – Classes de isolamento dos motores de indução.....	33
Tabela 1.3 – Elevação de temperatura máxima permitida.....	34
Tabela 3.1 – Valores de entrada para a RNA.....	67
Tabela 3.2 – Comparação dos resultados obtidos.....	73
Tabela 3.3 – Comparação dos resultados obtidos.....	75

## LISTA DE FIGURAS

Figura 1.1 – Condições de operação nos quatro quadrantes.....	27
Figura 1.2 – Circuito equivalente de um motor de indução.....	28
Figura 1.3 – Conjugado em relação à velocidade.....	31
Figura 1.4 – Comportamento da corrente em relação à velocidade.....	31
Figura 1.5 – Vida útil de um motor de indução x Temperatura.....	33
Figura 1.6 – Comportamento térmico durante a aceleração de um motor de indução.....	35
Figura 1.7 – Comportamento térmico durante a frenagem de um motor de indução.....	36
Figura 1.8 – Comportamento térmico de um motor durante um ciclo de operação.....	37
Figura 2.1 – O neurônio humano.....	45
Figura 2.2 – Estrutura do neurônio artificial.....	46
Figura 2.3 – Configuração de uma RNA.....	47
Figura 2.4 – Função reta.....	53
Figura 2.5 – Função degrau.....	54
Figura 2.6 – Função sigmóide.....	54
Figura 2.7 – Função sigmóide bipolar.....	55
Figura 2.8 – <i>Perceptron</i> .....	56
Figura 2.9 – Rede MADALINE.....	57
Figura 2.10 – Rede <i>ART</i> .....	59
Figura 2.11 – Modelo de Hopfield.....	60
Figura 3.1 – Curva da elevação de temperatura para o motor analisado.....	66
Figura 3.2 – RNA utilizada.....	69
Figura 3.3 – Passos do treinamento da RNA até a convergência.....	70
Figura 3.4 – Tempo decorrido para a convergência.....	71
Figura 3.5 – Valores obtidos (círculos vermelhos) em relação aos esperados (linha azul).....	72
Figura 3.6 – Valores obtidos (linha vermelha) em relação aos esperados (linha azul).....	74

## **LISTA DE ANEXOS**

ANEXO A – Catalogo de motores WEG.....	81
ANEXO B – Constantes térmicas de motores em relação ao tipo de carcaça.....	82
ANEXO C – Desenvolvimento matemático da equação do conjugado de um MIT .....	83
ANEXO D – Artigo publicado no congresso internacional LAPTEC no Brasil em 2007.....	84
ANEXO E – Artigo publicado no congresso internacional CLAGTEE no Chile em 2007 .....	92

# SUMÁRIO

<b>INTRODUÇÃO.....</b>	<b>14</b>
------------------------	-----------

<b>CAPÍTULO 1 – TÓPICOS AVANÇADOS EM MOTORES DE INDUÇÃO TRIFÁSICOS.....</b>	<b>16</b>
---	-----------

1.1 – CONSIDERAÇÕES INICIAIS.....	16
-----------------------------------	----

1.2 - MOTORES DC.....	17
-----------------------	----

1.3 – MOTORES AC.....	19
-----------------------	----

1.3.1 Motores Síncronos AC.....	19
---------------------------------	----

1.3.2 Motores Assíncronos AC.....	20
-----------------------------------	----

1.3.2.1 – Motor de Indução monofásico.....	21
--	----

1.3.2.2 - Motor de indução trifásico com rotor em gaiola de esquilo.....	22
--	----

1.3.2.3 - Motor de indução trifásico com rotor bobinado.....	23
--	----

1.4 – CARACTERÍSTICAS OPERACIONAIS DE UM MOTOR DE INDUÇÃO.....	23
--	----

1.5 – CLASSIFICAÇÃO DOS MIT EM RELAÇÃO AO ISOLAMENTO.....	32
---	----

1.6 – COMPORTAMENTO TÉRMICO DE UM MIT.....	35
--	----

1.7 – PERDAS EM MOTORES DE INDUÇÃO.....	38
---	----

1.8 – DETERMINAÇÃO DA ELEVAÇÃO DA TEMPERATURA.....	40
--	----

1.9 – CORRENTE X TEMPERATURA.....	41
-----------------------------------	----

<b>CAPÍTULO 2 – REDES NEURAIS ARTIFICIAIS.....</b>	<b>43</b>
--	-----------

2.1 – CONSIDERAÇÕES INICIAIS.....	43
-----------------------------------	----

2.2 - O NEURÔNIO HUMANO.....	44
------------------------------	----

2.3 – O NEURÔNIO ARTIFICIAL.....	46
----------------------------------	----

2.4 – EVOLUÇÃO E ARQUITETURAS DAS RNA.....	47
2.5 – TIPOS DE TREINAMENTO E APRENDIZADO.....	49
2.5.1- Aprendizado não supervisionado.....	50
2.5.2 – Aprendizado supervisionado.....	50
2.5.3 – Aprendizado reforçado.....	51
2.5.4 – Aprendizado competitivo.....	51
2.5.5 – Regra Delta.....	52
2.5.6 – Regra do gradiente descendente.....	52
2.5.7 – Aprendizado Hebbian.....	52
2.6 – FUNÇÕES DE ATIVAÇÃO.....	53
2.7 – OS ALGORITMOS DAS RNA.....	55
2.7.1 – <i>Perceptron</i> .....	55
2.7.2 – ADALINE e MADALINE.....	56
2.7.3 – <i>Winner-Takes-All</i> .....	57
2.7.4 – <i>Backpropagation</i> .....	58
2.7.5 – <i>Adaptive Resonance Theory (ART)</i> .....	58
2.7.6 – Modelo de Hopfield.....	59
2.8 – O ALGORITMO <i>BACKPROPAGATION</i> .....	60

**CAPÍTULO 3 – APLICAÇÃO DAS REDES NEURAIS ARTIFICIAIS EM MOTORES DE INDUÇÃO TRIFÁSICOS.....63**

3.1 - CONSIDERAÇÕES INICIAIS.....	63
3.2 – CÁLCULO DOS VALORES DE ENTRADA.....	63
3.3 – TREINAMENTO.....	70
3.4 – VALIDAÇÃO.....	74

**CAPÍTULO 4 – CONCLUSÕES.....76**

**REFERÊNCIAS.....78**

**ANEXOS.....81**

# INTRODUÇÃO

Este trabalho tem como objetivo o estudo da viabilidade de se aplicar as técnicas de Redes Neurais Artificiais na estimação da temperatura do estator de um dado motor de indução. A idéia desta aplicação vem dos princípios da instrumentação virtual, os quais se baseiam na medição indireta de grandezas com o auxílio de ferramentas matemáticas e computacionais. A aplicação deste tipo de instrumentação é bastante interessante quando se leva em consideração determinadas aplicações onde o custo de se utilizar um sensor físico ou a impossibilidade de sua instalação se faz presente.

No caso específico deste estudo, o comportamento térmico do estator de um motor de indução em regime permanente de operação ao longo do tempo é identificado, e serve como dado de entrada para o sistema computacional baseado em Redes Neurais Artificiais (RNA). Uma vez treinada, esta RNA poderá “prever” a temperatura do motor para qualquer momento de sua operação em regime permanente com base nos valores de entrada usados durante o treinamento. Imagina-se que esta aplicação pode ser utilizada para mais de uma finalidade como, por exemplo, em sistemas de proteção ou em situações onde se deseja verificar se um motor está corretamente dimensionado, nesta última, como uma ferramenta para auxiliar estudos na área de conservação de energia.

Quanto à metodologia e estrutura do trabalho, primeiramente definiu-se o motor a ser estudado e suas características de operação foram determinadas. Feito isso, identificou-se sua curva de aquecimento desde a partida até a

condição de regime permanente. Em um segundo momento foram avaliadas as possíveis arquiteturas de RNA e algoritmos a serem aplicados. Uma arquitetura e um algoritmo em particular foram escolhidos baseados em critérios como simplicidade, confiabilidade e características compatíveis ao problema em questão.

Definida a curva de aquecimento do motor e RNA a serem utilizadas, as informações foram inseridas no Matlab® e o treinamento da rede foi feito. Determinou-se então um conjunto de valores de validação e os resultados foram analisados.

# CAPÍTULO 1 – TÓPICOS AVANÇADOS EM MOTORES DE INDUÇÃO TRIFÁSICOS

## 1.1 – CONSIDERAÇÕES INICIAIS

Quando se fala em energia, sem entrar em uma discussão mais filosófica sobre seu conceito, pois não é o objetivo deste trabalho, pode-se citar as mais diversas fontes, como por exemplo, energia térmica, eólica, magnética, geotérmica, etc., que são tipos utilizados nas mais diversas aplicações. Independentemente da sua fonte, pode-se afirmar que a energia elétrica é de extrema importância no desenvolvimento humano e tecnológico, pois praticamente em qualquer atividade realizada o seu uso direto ou indireto é necessário (Santos, A. H. M., et al.; 2001). Outro aspecto importante é a necessidade de se converter a energia para que se possa utilizá-la da maneira mais eficiente dependendo do que se pretende. Um exemplo é a conversão da energia potencial de uma queda d'água em energia elétrica que vai alimentar uma cidade. Dentro do universo de técnicas e equipamentos existentes na conversão de energia, encontram-se os motores elétricos que são especificamente os objetos de interesse do presente estudo.

Os motores elétricos são largamente utilizados e extremamente importantes em diversos setores da economia e podem ser encontrados desde em usinas geradoras de energia, em indústrias, até em setores comerciais e

residenciais. Tendo como base dados referentes a 2005, pode-se dizer que os motores elétricos representavam neste ano cerca de 30% da energia total consumida no Brasil (MINISTÉRIO DAS MINAS E ENERGIA, 2008), daí a importância de se utilizar os motores elétricos com a maior eficiência possível a fim de reduzir os custos do consumo de energia e de manutenção, principalmente em usinas geradoras e indústrias.

Existem vários tipos de motores elétricos que podem ser divididos basicamente em:

- Motores DC;
- Motores AC.

## 1.2 - MOTORES DC

Os motores DC ou de corrente contínua, como o próprio nome diz, são motores responsáveis pela conversão da energia elétrica através de fenômenos eletromagnéticos gerados por uma fonte de corrente contínua em energia mecânica no seu eixo. Existem também os geradores de corrente contínua que possuem características construtivas semelhantes às dos motores, porém atuando de maneira inversa, ou seja, gerando energia elétrica contínua a partir de um sistema primário que vai determinar a velocidade do seu eixo (Almeida, A. T. L.; 2000).

Em relação ao aspecto construtivo desses motores tem-se a parte do estator, que é composta basicamente da carcaça e dos pólos de excitação, que podem ser os chamados enrolamentos de campo, ou também podem ser compostos por ímãs permanentes; e o rotor, onde encontram-se o eixo da armadura, o núcleo da armadura, os enrolamentos de armadura e o comutador, peça cilíndrica composta de barras paralelas entre si conectadas aos terminais de um enrolamento. Esses motores também são classificados de acordo com o tipo de excitação utilizada que pode ser excitação série, paralela, independente ou composta (Almeida, A. T. L.; 2000).

Uma das aplicações mais comuns de motores DC é usada quando se necessita de controle de velocidade com uma melhor precisão e com uma grande faixa de variação, ou também quando se tem um sistema que necessita de reversões, acelerações e frenagens rápidas. Porém com o aparecimento dos inversores de frequência essa vantagem deixa de ser atrativa em muitos casos pois, além dos inversores permitirem que o motor AC também tenha uma boa eficiência em relação a controle de velocidade, os motores DC possuem uma manutenção mais cara que os motores AC de indução o que faz com que o seu uso seja mais restrito nos dias de hoje (Almeida, A. T. L.; 2000).

## 1.3 - MOTORES AC

### 1.3.1 - Máquinas Síncronas AC

Os geradores síncronos ou alternadores são máquinas usadas principalmente na geração de energia elétrica. Construtivamente os geradores síncronos e os motores síncronos são similares, basicamente a máquina atua como gerador quando entrega energia elétrica a partir do acionamento do seu eixo por uma máquina primária, e atua como motor quando ele absorve energia que faz o seu eixo girar (Almeida, A. T. L.; 2000).

Essas máquinas são compostas pelo estator, onde se encontram enrolamentos que vão criar o campo magnético de velocidade síncrona, o rotor, que pode ser de pólos lisos ou salientes, e um enrolamento de campo ou excitatriz, localizada no próprio eixo do rotor e que é alimentada por corrente contínua ou corrente alternada retificada.

O gerador síncrono com rotor de pólos salientes necessita de um estator de grande circunferência e possui geralmente um maior número de pares de pólos. Ele é usado quando se tem máquinas primárias de baixa velocidade, como as turbinas hidráulicas por exemplo. Já no caso dos rotores de pólos lisos, o diâmetro do estator é menor e são usados quando se tem máquinas primárias de alta velocidade como os turbogeradores (Kosow, I. L.; 2005).

Em relação à excitação, pode-se utilizar dois tipos diferentes:

- Através de uma excitatriz rotativa, que é alimentada por um gerador de corrente contínua acionado pelo próprio eixo do rotor, neste caso existem anéis e escovas;
- Através de uma excitatriz *brushless*, onde uma excitatriz de corrente alternada é conectada a uma ponte retificadora que está localizada no eixo do rotor. Neste caso não há escovas;

Os motores síncronos possuem vantagens como a de poderem ser utilizados na correção de fator de potência apenas controlando sua excitação, e também de apresentar um bom rendimento mesmo com variação de carga. Uma desvantagem no seu uso é a manutenção mais cara e demorada em relação a motores de indução (Moreira, H. J. F., et al.; 2000).

### 1.3.2 - Motores Assíncronos AC

Os motores de indução estão entre os mais usados em aplicações comerciais, industriais e até residenciais. Isto se dá devido as inúmeras características que eles podem ter como: vários níveis de conjugado, diferentes números de fases, e diferentes características construtivas como à prova de explosão, de alto rendimento, entre outras. Pode-se dividi-los em alguns tipos principais:

- Motor de indução monofásico.
- Motor de indução trifásico com rotor em gaiola de esquilo;
- Motor de indução trifásico com rotor bobinado;

#### 1.3.2.1 – Motor de Indução Monofásico

Embora motor monofásico possua uma faixa de potência mais restrita, este é largamente utilizado nas mais diversas aplicações. Um exemplo de uso residencial muito comum é a geladeira. Em relação às características construtivas ele é constituído pelo estator, que possui dois enrolamentos em paralelo deslocados entre si, o chamado enrolamento principal e o enrolamento auxiliar, que é deslocado 90° elétricos do principal e que tem a função de auxiliar o motor na partida, pois sem o circuito auxiliar este tipo de motor não parte; e o rotor, que é do tipo gaiola de esquilo (Moreira, H. J. F., et al.; 2000).

Esses motores também são classificados de acordo com os diferentes tipos de circuitos auxiliares de partida, eles são:

- Com capacitor de partida, que aumenta o conjugado de partida. Ele é ligado em série com o enrolamento auxiliar e é desligado do circuito através de uma chave uma vez que o motor está em operação;

- Com capacitor permanente, que possui a mesma função do capacitor de partida, porém não é desligado do circuito mesmo quando o motor atinge o ponto de operação;
- Com o enrolamento auxiliar, que tem como característica o elevado valor de resistência em relação ao enrolamento principal. Esse enrolamento auxiliar também é chaveado e desligado uma vez que o motor atinge sua condição de operação.

#### *1.3.2.2 - Motor de indução trifásico com rotor em gaiola de esquilo*

Esse tipo de motor é o mais utilizado entre todos, isto se dá devido ao seu baixo custo, pouca manutenção e o fato de atenderem a uma grande quantidade de diferentes tipos de carga. Sob o aspecto construtivo, tem-se o estator, onde se encontram enrolamentos defasados entre si, podendo ser dispostos de maneiras distintas tanto em relação à defasagem angular (dependendo do número de pólos) quanto em relação à conexão entre bobinas, e vão criar o campo girante de velocidade síncrona; e tem-se o rotor, que é formado basicamente por alumínio fundido em ranhuras e curto-circuitados entre si. Seu funcionamento será melhor descrito posteriormente neste capítulo (Almeida, A. T. L.; 2000).

### 1.3.2.3 - Motor de indução trifásico com rotor bobinado

Basicamente este tipo de motor se assemelha construtivamente com o motor de indução trifásico com rotor em gaiola, porém o seu rotor ao invés de ser composto por alumínio fundido, como descrito na seção 1.3.2.2, possui enrolamentos de cobre que são conectados a anéis e escovas que vão fazer a conexão elétrica entre eles. Operacionalmente esses motores tem características de conjugado um pouco distintos dos motores com rotor em gaiola, seu conjugado de partida é mais baixo, o que altera sua curva de conjugado pela velocidade (Almeida, A. T. L.; 2000).

## 1.4 – CARACTERÍSTICAS OPERACIONAIS DE UM MOTOR DE INDUÇÃO

O presente estudo se utiliza de um motor de indução trifásico (MIT) e um dado ciclo de operação que será analisado em termos das temperaturas durante o mesmo. Este capítulo, portanto, trata do funcionamento de um motor de indução, das suas principais características e do estudo do seu comportamento térmico durante o período de aceleração, regime permanente, frenagem, etc., bem como o equacionamento matemático para tais condições.

Existem preocupações básicas que se deve ter quando se especifica um MIT para qualquer tipo de aplicação, entre elas, se o motor consegue entregar o conjugado que se deseja em todo o ciclo operativo demandado pela carga em

condições normais, e a certeza de que sua temperatura durante esse ciclo não ultrapassará os limites estabelecidos por norma para cada classe de isolamento de máquinas elétrica (Kosow, I. L.; 2005).

O princípio de funcionamento de um motor de indução se baseia em fenômenos eletromagnéticos. Alguns desses fenômenos são descritos a seguir:

- A Lei de Faraday, que afirma que:

*“O valor da tensão induzida em uma simples espira de fio é proporcional à razão de variação das linhas de força que passam através daquela espira (ou se concatenam com ela).”* (Kosow, I. L.; 2005).

Em outras palavras ela diz que quando um condutor é “mergulhado” em um campo magnético variável, tensões serão induzidas em seus terminais. Essa lei foi quantificada por Newmann da seguinte forma (Almeida, A. T. L.; 2000):

$$e = v.B.l.\text{sen}\theta \quad (1.1)$$

Onde:  $e$  é a força eletromotriz induzida [V];

$v$  é a velocidade relativa entre o campo e o condutor [m/s];

$B$  é a indução magnética [Wb/m<sup>2</sup>];

$l$  é o comprimento do condutor [m];

$\theta$  é o ângulo formado entre o vetor campo magnético e o vetor velocidade instantânea do condutor [rad].

- A regra de Fleming, também conhecida por regra da mão direita de Fleming, afirma que os sentidos de  $e$ ,  $B$  e  $V$  podem ser determinados posicionando-se os dedos polegar, que representa  $e$ , indicador, que representa  $V$ , e médio, que representa  $B$ , defasados de  $90^\circ$  entre si;
- A lei de Biot-Savart determina a intensidade do campo magnético formado ao redor de um condutor quando uma corrente elétrica circula por ele;
- A força de Lorentz determina que um conjugado é criado quando se “mergulha” uma espira percorrida por uma corrente elétrica em um campo magnético. Esse conjugado surge devido à ação de forças que aparecem nos lados da espira.

O que ocorre no motor, é que quando os enrolamentos do estator, que estão defasados de  $120^\circ$  mecânicos entre si, são alimentados por uma tensão alternada, um campo magnético girante é criado baseado nas leis descritas anteriormente. Uma vez que o rotor é “inserido” nesse campo, correntes serão induzidas em seus enrolamentos o que por sua vez fará com que um campo magnético se forme ao seu redor. Os campos magnéticos, tanto o criado pelo

estator, quanto o criado no rotor, possuem pólos positivos e negativos que vão se atrair e repelir fazendo com que o motor comece a girar. Neste caso foi ilustrada uma ação motora, pois o motor absorve energia da rede que alimenta o estator e a transforma em energia mecânica na ponta do eixo. Numa situação inversa, uma potência mecânica aplicada ao eixo do motor vai induzir tensões em seus terminais. Portanto pode-se dizer o motor vai operar em quatro quadrantes dependendo do valor do seu conjugado e velocidade. Considerando que numa ação motora a potência é positiva conforme dado por:

$$P = \frac{2\pi n}{60} M \quad (1.2)$$

Onde: P é a potência mecânica [W];

M é o conjugado na ponta do eixo [N.m];

n é a velocidade [rpm].

Tem-se que:

- Conjugado positivo e velocidade positiva corresponde a uma ação motora;
- Conjugado positivo e velocidade negativa corresponde a uma ação geradora;

- Conjugado negativo e velocidade positiva corresponde a uma ação geradora;
- Conjugado negativo e velocidade negativa corresponde a uma ação motora;

A figura 1.1 ilustra essas condições de operação.

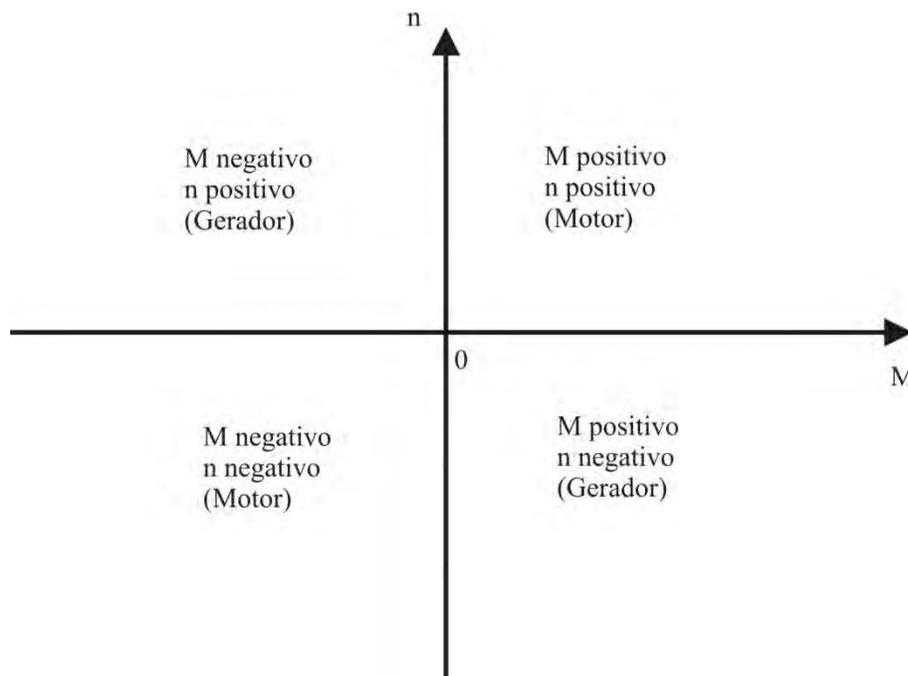


Figura 1.1 – Condições de operação nos quatro quadrantes

(Almeida, A. T. L.; 2000)

Ao se especificar um motor elétrico para uma dada aplicação, um parâmetro importante a ser verificado é o conjugado que o motor consegue desenvolver. Analisando o circuito equivalente de um motor de indução

mostrado na figura 1.2, pode-se extrair a equação (1.3), (1.4) e (1.5) que determinam o conjugado (Almeida, A. T. L.; 2000)

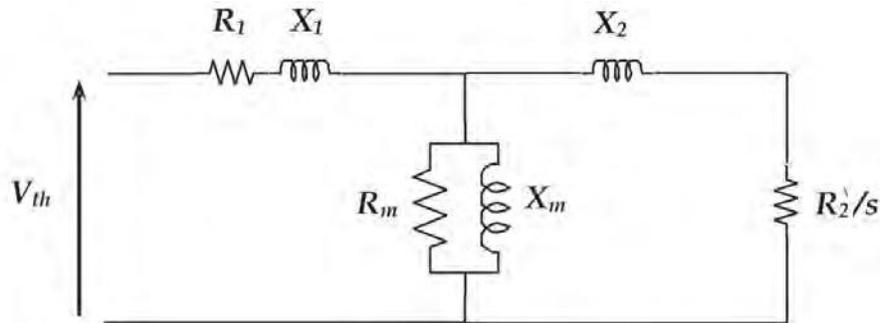


Figura 1.2 – Circuito equivalente de um motor de indução

Portanto, utilizando-se do circuito equivalente, chega-se às equações aproximadas a seguir:

$$M = 3 \frac{60}{2\pi n_s} \frac{V_{th}^2}{(R_1 + \frac{R_2'}{s})^2 + (X_1 + X_2')^2} \frac{R_2'}{s} \quad (1.3)$$

Onde: M é o conjugado;

$V_{th}$  é a tensão equivalente de thevenin [V];

$R_1$  é a resistência do estator [Ohm];

$R_2'$  é a resistência do rotor [Ohm];

$X_1$  é a reatância do estator [Ohm];

$X_2$  é a reatância do rotor [Ohm];

s é o escorregamento;

$n_s$  é a velocidade síncrona do motor [rpm].

Para a situação de partida onde o escorregamento é um e a reatância é muito maior que a resistência, pode-se desprezar a resistência e chegar à seguinte equação aproximada:

$$M \cong 3 \frac{V_{th}^2}{(X_1 + X_2')^2} \frac{R_2'}{s} \frac{60}{2\pi n_s} \quad (1.4)$$

Quando o motor está em regime permanente o escorregamento é próximo de zero e as resistências passam a ser muito maiores que as reatâncias, o que permite desprezar as reatâncias e chegar à seguinte equação aproximada:

$$M \cong 3 \frac{V_{th}^2}{(R_1 + \frac{R_2'}{s})^2} \frac{60}{2\pi n_s} \frac{R_2'}{s} \quad (1.5)$$

O escorregamento é um parâmetro importante em um motor de indução. Ele consiste na diferença entre a velocidade síncrona do campo magnético gerado pelo estator e a velocidade do rotor que chega próximo, mas jamais atinge a síncrona devido a atritos no rotor. Pode-se portanto dizer que o escorregamento é dado por:

$$s = \frac{n_s - n}{n_s} \quad (1.6)$$

Onde:  $s$  é o escorregamento;

$n_s$  é a velocidade síncrona [rpm];

$n$  é a velocidade do rotor [rpm].

Portanto o escorregamento começa em um, para o motor parado, e chega a quase zero na condição de operação nominal.

De acordo com a NBR 7094 os motores de indução trifásicos são classificados em três categorias de acordo com a relação entre o conjugado e a velocidade desenvolvida. Essas características são descritas na tabela 1.1.

Tabela 1.1 - Categoria de motores de indução de acordo com a relação torque x velocidade

<b>Categoria</b>	<b>Características</b>
N	Conjugado e corrente de partida normais e baixo escorregamento
H	Alto conjugado de partida, corrente de partida normal e baixo escorregamento
<i>D</i>	Alto conjugado de partida, corrente de partida normal e alto escorregamento

A figura 1.3 mostra a curva típica de um motor de indução referente ao comportamento do conjugado em relação ao à velocidade.

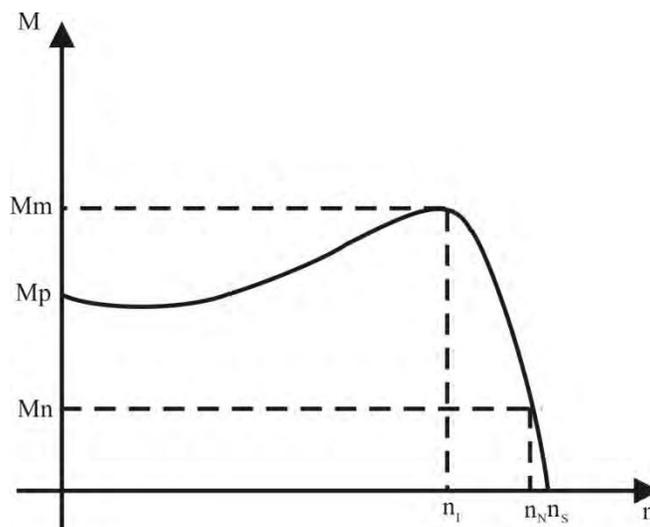


Figura 1.3 – Conjugado em relação à velocidade

Em relação à corrente de um motor durante sua aceleração até chegar a faixa de operação, nota-se que seu comportamento não é linear como mostra a figura 1.4.

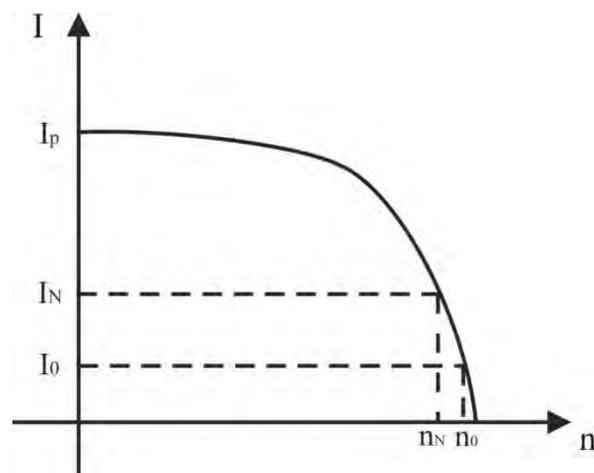


Figura 1.4 – Comportamento da corrente em relação à velocidade

## 1.5 – CLASSIFICAÇÃO DOS MIT EM RELAÇÃO AO ISOLAMENTO

É de extrema importância que o motor elétrico trabalhe com temperaturas compatíveis com os limites térmicos dos isolamentos, pois um aumento de temperatura da ordem de 10 °C acima do que o isolamento permite, pode causar uma redução de até metade da vida útil de um motor elétrico (Contatori, C.; 2005). De acordo com a lei de Montsinger, o aumento da temperatura diminui a vida útil do motor de acordo com a equação 1.7 representada também pela figura 1.5.

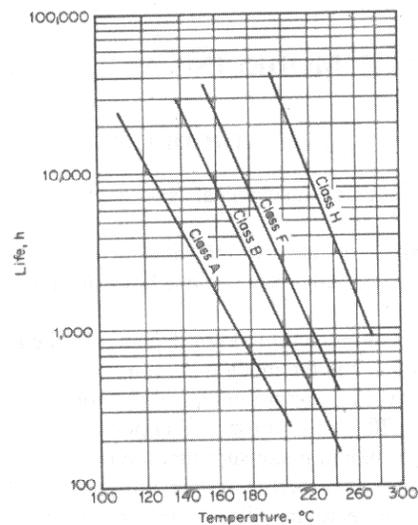
$$v = v_0 \cdot e^{-a\theta} \quad (1.7)$$

Onde:  $v$  é a vida útil do motor;

$\theta$  é a temperatura do motor;

$\theta_0$  é o incremento de temperatura em relação à máxima admissível pela classe de isolamento do motor [°C];

$$a = \frac{-1}{\theta_0} \ln \left( \frac{\theta}{\theta_0} \right).$$



Figua 1.5 – Vida útil de um MI x Temperatura (Boldea, I., Nasar, S. A.; 2002).

A norma NBR 7034 identifica as classes de isolamento das máquinas elétricas que são mostradas na Tabela 1.2.

Tabela 1.2 – Classes de Isolamento dos motores de indução

Classe de Isolamento	Temperatura (°C)
A	105
E	120
B	130
F	155
H	180

A máxima elevação de temperatura nas máquinas elétricas também é

especificada como mostra a Tabela 1.3. Nesta tem-se que, por norma, a máxima temperatura ambiente em que um motor padrão pode operar é de 40 °C, portanto a temperatura ambiente foi estabelecida neste valor. É definido também que a temperatura do ponto mais quente do motor não pode ultrapassar a máxima temperatura permitida pelo isolamento e sua diferença em relação à temperatura média do motor varia entre 5 °C e 15 °C dependendo da classe de isolamento. A temperatura do ponto mais quente é então, a soma da temperatura ambiente, que no caso é a máxima de 40 °C, com a elevação de temperatura admissível calculada pelo método das resistências, mais a diferença entre a temperatura média do enrolamento e a do ponto mais quente.

Tabela 1.3 – Elevação de temperatura máxima permitida

<b>Parâmetros</b>	<b>Classe A</b>	<b>Classe E</b>	<b>Classe B</b>	<b>Classe F</b>	<b>Classe H</b>
<b>Elevação de temperatura admissível calculada pelo método das resistências (°C)</b>	60	75	80	100	125
<b>Diferença entre a temperatura média e no ponto mais quente (°C)</b>	5	5	10	15	15
<b>Temperatura Ambiente (°C)</b>	40	40	40	40	40
<b>Temperatura admissível no ponto mais quente (°C)</b>	105	120	130	155	180

## 1.6 – COMPORTAMENTO TÉRMICO DE UM MIT

O comportamento térmico de um motor pode ser definido pela curva de aquecimento da figura 1.6, e a curva de resfriamento da figura 1.7 (Costa, P. F., Borel, J. E. V.; 1999), onde  $Q$  é a quantidade de calor produzido pelo motor por unidade de tempo,  $A$  é o coeficiente de transmissão de calor para o ambiente,  $T_H$  é a constante térmica de aquecimento e  $\Delta\theta_f$  é a variação até a temperatura final.

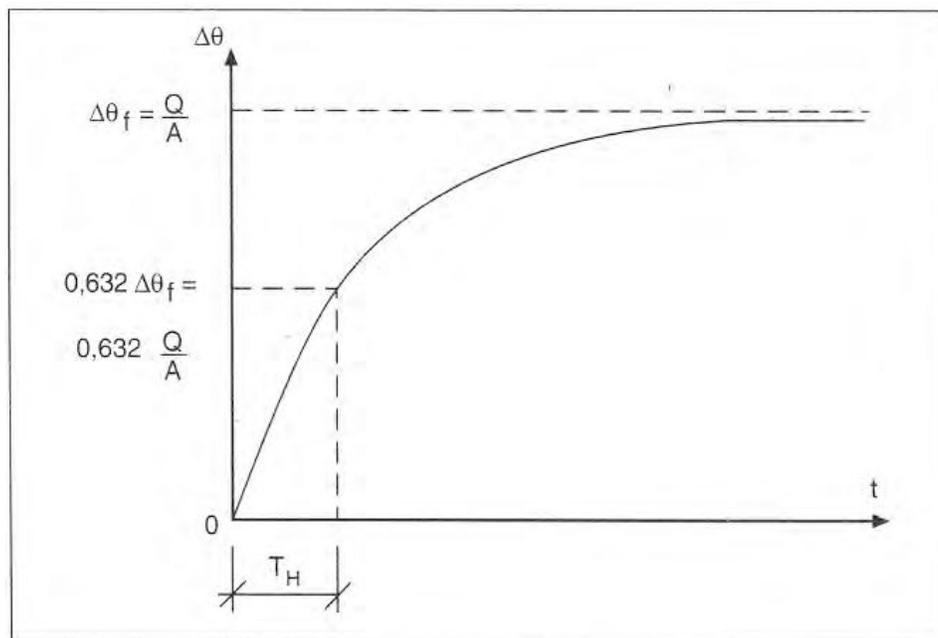


Figura 1.6 – Comportamento térmico durante a aceleração de um motor de indução (Costa, P. F., Borel, J. E. V.; 1999).

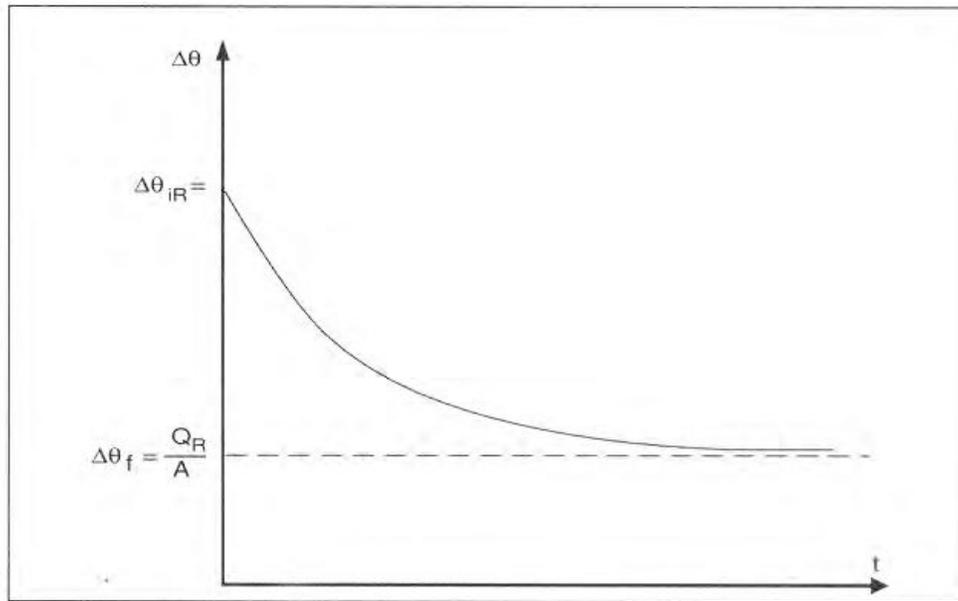


Figura 1.7 – Comportamento térmico durante a frenagem de um motor de indução (Costa, P. F., Borel, J. E. V.; 1999).

Por meio da curva de aquecimento durante a aceleração pode-se calcular a constante térmica do motor que vai determinar o seu comportamento térmico, ver equação 1.8. Porém, durante um ciclo de operação de um motor, dependendo da aplicação, pode-se ter vários períodos de aceleração e frenagem o que causa um aquecimento gradativo do motor, esse aquecimento está representado na figura 1.8. As abscissas indicadas por  $P_i$  referem-se as partidas durante o ciclo e os indicados por  $F_i$  as frenagens. Nota-se, portanto que é muito importante dimensionar o motor de maneira adequada à aplicação, pois a temperatura máxima permitida não deve ser ultrapassada, ou pelo menos se isso ocorrer, que seja pelo menor tempo possível.

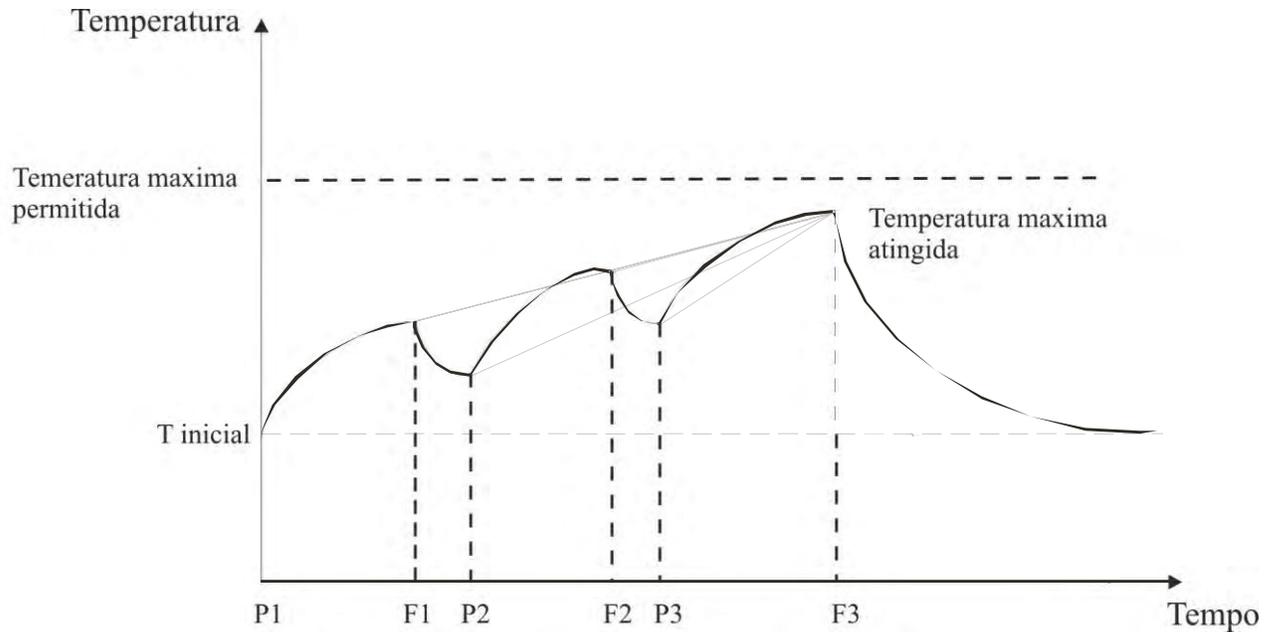


Figura 1.8 – Comportamento térmico de um motor durante um ciclo de operação.

Outra condição operativa que provoca aquecimento do motor é quando ocorre partidas mais longas, nesse caso a sua análise térmica deve levar em consideração os esforços causados no rotor, os quais terão uma maior relevância chegando até a ser o fator principal limitante da operação (Sá, J. S., Cogo, J. R., Arango, H.)

As equações (1.8) e (1.9) podem ser usadas para o cálculo da temperatura do estator nos diversos estágios do ciclo de operação de um motor (Sá, J. S., Cogo, J. R., Arango, H.).

$$T_H = \frac{C}{A} \quad (1.8)$$

Onde:  $T_H$  é a constante de tempo de aquecimento [s];

$C$  é a capacidade térmica do enrolamento do estator [W.s/°C];

$A$  é o fator de transmissão de calor [W/°C].

$$\theta = \theta_0 e^{-\frac{t}{T_H}} + \frac{P_j}{A} (1 - e^{-\frac{t}{T_H}}) \quad (1.9)$$

Onde:  $\theta$  é a temperatura calculada [°C];

$\theta_0$  é a temperatura inicial do período em estudo [°C];;

$P_j$  são as perdas no estator [W];

$A$  é o fator de transmissão de calor [W/°C];

$T_H$  é a constante de tempo de aquecimento [s].

## 1.7 – PERDAS EM MOTORES DE INDUÇÃO

As perdas em motores de indução podem ser divididas em perdas elétricas, perdas mecânicas e perdas no núcleo (estator e rotor). As perdas elétricas são basicamente referentes à perdas pelo efeito Joule nos enrolamentos do motor, as mecânicas decorrem de perdas por atrito e ventilação e as perdas no núcleo do motor estão relacionadas aos fenômenos de histerese e correntes de *Foucault*. Existem ensaios que podem ser realizados nos motores onde se pode medir essas perdas, como o ensaio de rotor livre (ou a vazio), e ensaio de rotor bloqueado (Almeida, A. T. L.; 2000).

No ensaio de rotor livre podem-se medir as perdas no núcleo do motor e as perdas por atrito e ventilação entre outros parâmetros. Neste ensaio o motor é alimentado com tensão e frequência nominais e o seu eixo é deixado desacoplado, ou seja sem nenhuma carga presente. A potência absorvida pela máquina pode ser medida através do método dos dois wattímetros e, diminuindo gradativamente a tensão aplicada até zero e construindo uma curva da potência em relação a tensão, obtêm-se as perdas por atrito e ventilação. De posse destes dados utiliza-se a equação (1.10) para a obtenção das perdas por histerese e Foucault (Almeida, A. T. L.; 2000):

$$P_{hf} = P_0 - P_{AV} - 3R_1 I_0^2 \quad (1.10)$$

Onde:  $P_{hf}$  são as perdas por histerese e Foucault;

$P_0$  é a potencia absorvida pelo motor operando a vazio;

$P_{AV}$  são as perdas por atrito e ventilação;

$R_1$  é a resistência de enrolamento do estator [Ohm];

$I_0$  é a corrente em vazio do motor [A];

No ensaio de rotor bloqueado pode-se, entre outros parâmetros, medir as perdas Joule do motor (estator e rotor juntos). Para tanto, basicamente o eixo do motor é travado e uma tensão é aplicada de forma que a corrente nominal não seja ultrapassada. Feito isso calcula-se a potência absorvida pelo motor, que

corrigida devidamente de acordo com a equação (1.11) indica as perdas Joule do motor ensaiado (Almeida, A. T. L.; 2000).

$$P_J = P_{Jensaio} \left( \frac{U_N}{U_{ensaio}} \right) \quad (1.11)$$

Onde:  $P_J$  são as perdas Joule no motor [W];

$P_{Jensaio}$  são as perdas Joule no motor obtidas durante o ensaio [W];

$U_N$  é a tensão nominal [V];

$U_{ensaio}$  é a tensão de ensaio [V].

## 1.8 – DETERMINAÇÃO DA ELEVAÇÃO DA TEMPERATURA

Uma maneira eficaz de se determinar a elevação da temperatura dos enrolamentos de um motor elétrico é através do método das resistências. Este método consiste em medir a temperatura de um motor usando um método indireto, ou seja, como o próprio nome diz, através da medição dos valores de resistência dos enrolamentos. Essa medição deve ser feita por um período suficientemente longo onde serão medidas a temperatura dos enrolamentos antes do ensaio, a resistência do enrolamento antes do ensaio, a temperatura dos enrolamentos ao final do ensaio, a resistência do enrolamento ao final do ensaio e a temperatura do meio refrigerante ao fim do ensaio. A equação (1.12) é usada para o cálculo da temperatura nesse método.

$$\Delta\theta = \theta_2 - \theta_a = \frac{R_2 - R_1}{R_1}(235 + \theta_1) + \theta_1 - \theta_a \quad (1.12)$$

Onde:  $\Delta\theta$  = elevação de temperatura [ $^{\circ}\text{C}$ ];

$\theta_1$  = temperatura dos enrolamentos antes do ensaio [ $^{\circ}\text{C}$ ];

$\theta_2$  = temperatura dos enrolamentos ao final do ensaio [ $^{\circ}\text{C}$ ];

$\theta_a$  = temperatura do meio refrigerante ao fim do ensaio [ $^{\circ}\text{C}$ ];

$R_1$  = resistência do enrolamento antes do ensaio [Ohm];

$R_2$  = resistência do enrolamento ao final do ensaio [Ohm].

## 1.9 – CORRENTE X TEMPERATURA

Como se sabe, as perdas Joule em um motor de indução é o produto da resistência pelo quadrado da corrente ( $RI^2$ ), portanto, quanto maior a corrente, maior serão as perdas por efeito Joule e maior será a temperatura do motor. Portanto, como a corrente está diretamente ligada ao comportamento térmico da máquina, ela deve ser monitorada de forma a atingir valores dentro dos limites seguros de operação.

Para se calcular a temperatura do motor em relação à corrente, considera-se o mesmo como um corpo homogêneo e efetuando simplificações, chega-se a equação (1.13) para a partida, equação (1.14) quando o motor se encontra em carga, equação (1.15) para operação em vazio e equação (1.16) para frenagem, como mostrado em (Santos, A. H. M., et al.; 2001).

$$\Delta\theta_F = \left(\frac{I_P}{I_N}\right)^2 \frac{n_N}{n_p} \Delta\theta_{LIM} \quad (1.13)$$

$$\Delta\theta_F = \left(\frac{I}{I_N}\right)^2 \Delta\theta_{LIM} \quad (1.14)$$

$$\Delta\theta_F = \left(\frac{I_0}{I_N}\right)^2 \Delta\theta_{LIM} \quad (1.15)$$

$$\Delta\theta_F = \left(\frac{I_F}{I_N}\right)^2 \frac{n_N}{n_F} \Delta\theta_{LIM} \quad (1.16)$$

Onde:  $\Delta\theta_F$  é a elevação da temperatura final [°C];

$I$  é a corrente em carga [A];

$I_P$  é a corrente de partida [A];

$I_0$  é a corrente em vazio [A];

$I_N$  é a corrente nominal [A];

$I_F$  é a corrente de partida [A];

$n_N$  é a velocidade nominal [rpm];

$n_P$  é a velocidade média de partida [rpm];

$n_F$  é a velocidade média de frenagem [rpm];

$\Delta\theta_{LIM}$  é o limite máximo de temperatura permitido pela norma [°C];

## CAPÍTULO 2 – REDES NEURAIS ARTIFICIAIS

### 2.1 – CONSIDERAÇÕES INICIAIS

O objetivo de se obter um sistema que pudesse “reproduzir” o comportamento do cérebro humano levou à criação de vários sistemas chamados de sistemas de inteligência artificial. Entre esses sistemas aparecem as Redes Neurais Artificiais (RNA), que são compostas por elementos baseados no funcionamento de um neurônio humano e que tentam reproduzir suas funções.

Habilidades como aprendizado, reconhecimento de padrões, associações, distinções, são características do funcionamento do cérebro humano e são bastante interessantes quando se deseja resolver alguns problemas onde as ferramentas matemáticas e computacionais “convencionais” não são eficazes. Com o avanço da tecnologia de processadores que permitiu o desenvolvimento de máquinas mais rápidas e robustas, o uso dos algoritmos das RNA se tornou mais viável e devido ao fato dessas redes conseguirem reproduzir algumas dessas habilidades, seu campo de aplicação é bastante vasto, por exemplo, na área financeira onde ela pode ser aplicada na previsão de comportamentos do mercado, na área médica para a determinação de um melhor diagnóstico baseado em sintomas apresentados, na engenharia em sistemas de controle e automação, no reconhecimento de caracteres, voz, imagens, etc. Seu funcionamento é essencialmente matemático e, para tanto,

existem vários tipos de arquiteturas, algoritmos de treinamento, e funções aplicadas à essas redes (Kartalopoulos, S.; 1996).

## 2.2 – O NEURÔNIO HUMANO

O cérebro humano é composto de bilhões de neurônios (da ordem de 100 bilhões) conectados entre si formando uma rede. Essa rede funciona através da transmissão de sinais elétricos em forma de pulsos que são enviados e recebidos pelos neurônios e tem uma característica que é o fato de se processar os sinais de maneira paralela. Os sinais são transmitidos de um neurônio para o outro de acordo com o funcionamento de um mecanismo químico baseado em sódio, potássio, proteínas, entre outros elementos. Para entender melhor como funciona esse processo, um neurônio humano será definido a seguir (Kartalopoulos, S.; 1996). Um neurônio é composto de alguns elementos básicos. Eles são:

- Axônio;
- Dendritos;
- Soma;
- Membranas.

A figura 2.1 mostra a fisiologia de um neurônio humano.

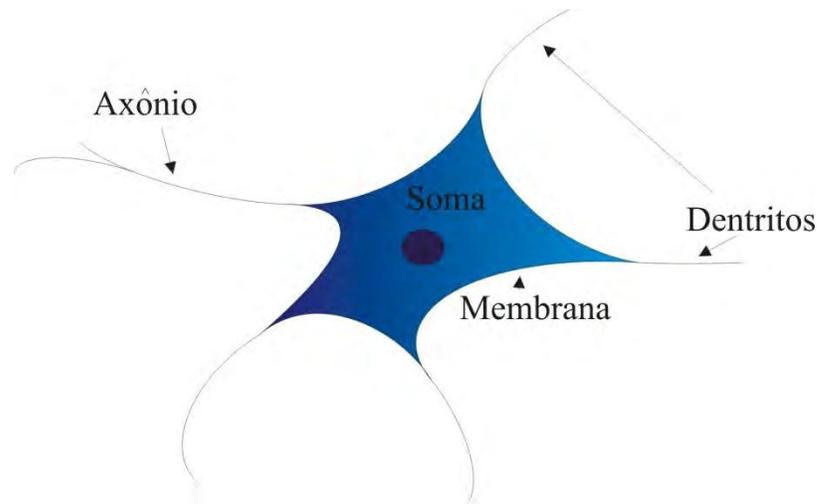


Figura 2.1 – O neurônio humano

O soma e a membrana estão relacionados com as reações químicas que acontecem no neurônio, reações essas que geram pequenos sinais elétricos. Já os axônios e os dendritos se conectam (o dendrito de um neurônio se conecta com o axônio de outro) e são responsáveis pela transmissão desse sinal, essas ligações se chamam sinapses. Dependendo de quão forte é a sinapse mais fácil será transmitir um sinal de um neurônio para outro. Para um sinal elétrico ser transmitido depende de alguns fatores, entre eles, é que a soma dos sinais que chegam a um neurônio tem que ter uma intensidade tal que ultrapassa um limite mínimo de intensidade (*threshold*). Uma vez que o sinal ultrapassa esse limite o neurônio dispara o sinal para os outros conectados a ele e de forma contrária, se a soma dos sinais não ultrapassar esse limite o neurônio permanece “inativo”. A medida que os sinais fluem as sinapses vão ficando mais fortes ou fracas, isso acontece em todos os neurônios conectados em forma de rede e é basicamente

esse mecanismo que permite ao cérebro ser treinado, aprender, etc. (Kartalopoulos, S.; 1996).

### 2.3 – O NEURÔNIO ARTIFICIAL

A estrutura no neurônio artificial é tomada de forma que o mesmo possa se comportar de maneira similar ao neurônio humano embora seu funcionamento não seja idêntico. A figura 2.2 mostra essa estrutura (Kartalopoulos, S.; 1996).

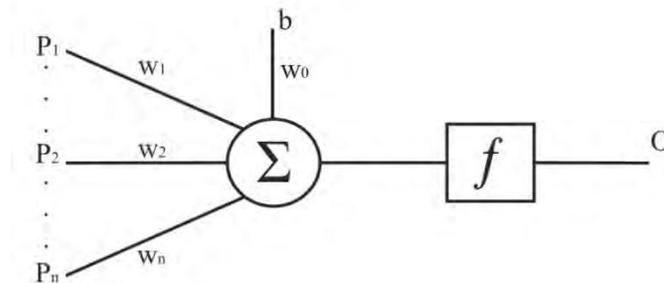


Figura 2.2 – Estrutura do neurônio artificial

No neurônio artificial, as entradas ( $P_1, P_2, \dots, P_n$ ) são multiplicadas pelos respectivos pesos ( $w_1, w_2, \dots, w_n$ ) e somadas. Também pode ou não se ter uma referência ( $b$ ) definido com um peso  $w_0$ , que vai se comportar como uma entrada. O resultado dessa somatória passa pela função de ativação e se o valor atingir o *threshold* do neurônio uma saída  $O$  aparece. Tanto as entradas  $P$  como

as saídas O são conectadas a outros neurônios formando uma rede, com exceção das camadas de entrada, onde as entradas P não se conectam a outro neurônios nem a da camada de saída, onde a saída O também não se conecta a outros neurônios. Cada elemento desses representa um nó numa RNA e cada nó está conectado a outros como mostra a figura 2.3 (Kartalopoulos, S.; 1996).

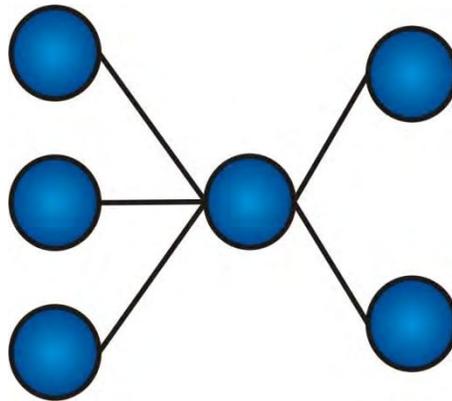


Figura 2.3 – Configuração de uma RNA

## 2.4 – EVOLUÇÃO E ARQUITETURAS DAS RNA

Na década de 40 foi desenvolvida por McCulloch e Pitt o que é considerada a primeira RNA criada. Através de combinações de neurônios eles perceberam que se podia criar várias funções lógicas simples. Foi aí também que apareceu o conceito de *threshold* para um neurônio artificial e determinou-se o comportamento do fluxo dos sinais que é utilizado em muitas redes até hoje. Foi nessa década também que Hebb introduziu o primeiro algoritmo de

treinamento para uma rede neural baseado nos pesos das ligações entre os neurônios (Fausett, L.; 1994).

A seguir, nas décadas de 50 e 60 foram introduzidos conceitos de RNA como as redes *perceptrons* por Frank Rosenblatt. Esse tipo de rede consiste em basicamente um neurônio e utiliza-se de técnicas de aprendizado relacionadas ao ajuste iterativo dos pesos de cada ligação, ajustes esses mais eficientes que os propostos anteriormente por Hebb. Ainda nessas décadas Bernard Widrow e Marcian Hoff criaram as redes ADALINE (*Adaptive Linear Neuron*) que possuíam regras de treinamento relacionadas as usadas nas redes *perceptron*, porém os pesos das ligações agora são ajustados de acordo com a regra do mínimo erro quadrático, que é determinado ao se comparar um par de (Fausett, L.; 1994).

Apesar dessas arquiteturas de rede e algoritmos de treinamento se mostrarem eficientes em alguns casos, para um grande numero de outros se mostraram limitadas. Na década de 70 estudos sobre as RNA e aplicações continuaram sendo feitos. Teuvo Kohonen aplicou as redes em sistemas de reconhecimento de voz e na resolução do problema do “Caixeiro Viajante” . James Anderson aplicou alguns tipos de redes desenvolvidas na elaboração de diagnósticos médicos a partir de conceitos de memória associativa e aprendizado de tabuadas. Também no fim dessa década e já entrando na década de 80, Stephen Grossberg e Gail Carpenter criaram um conceito de RNA chamado de *Adaptive Resonance Theory* (Fausett, L.; 1994).

Na década de 80 apareceram os algoritmos de *backpropagation* criado por David Parker e LeCun. Esse algoritmo é um dos mais utilizados e foi capaz

de solucionar problemas como a lógica “ou exclusivo” que até então não tinha sido solucionada pelos algoritmos existentes. John Hopfield cria as redes de Hopfield que são utilizadas como memória associativa e consegue resolver de maneira eficaz o problema do “Caixeiro Viajante”. Outra rede criada nessa década foi a rede criada por Kunihiko Fukushima chamada de *neocognitron*, utilizada no reconhecimento de caracteres (Fausett, L.; 1994).

## 2.5 – TIPOS DE TREINAMENTO E APRENDIZADO

Quando se aplica uma RNA à qualquer problema se deseja acima de tudo que a rede possa “aprender” para que quando estimulada por sinais semelhantes ela possa retornar uma resposta satisfatória. Em RNA o aprendizado é feito através de algoritmos matemáticos. Esses algoritmos, ao serem aplicados, vão constantemente ajustar os pesos de cada ligação entre neurônios até que a resposta obtida mediante a aplicação de um sinal seja a esperada, o que significa que a rede “aprendeu”. Como no processo de aprendizado humano onde existem as mais diversas maneiras de se aprender e cada indivíduo usa a maneira que melhor se adapte à sua realidade e limitações, existem várias maneiras de se treinar uma RNA dependendo do problema proposto ou da estrutura da própria rede. Também como os processos humanos, dependendo do tipo de treinamento que se tenta para um determinado problema, o tempo de aprendizado pode ser maior, menor ou até nem ser bem sucedido. Dentro do universo de tipos de aprendizados existentes,

pode-se citar os: supervisionado, não supervisionado, reforçado, competitivo, a regra delta, regra do gradiente descendente e o aprendizado Hebbian (Kartalopoulos, S.; 1996).

### 2.5.1- Aprendizado não supervisionado

Esse tipo de rede se auto-organiza, ou seja, são fornecidos os valores de entrada e nenhum valor desejado para ser comparado na saída. Neste caso a rede vai identificar as entradas mais semelhantes e vai agrupá-las, criando classes. Uma vez treinada, quando um sinal é enviado para a rede, ela identifica a qual classe esse sinal pertence e aciona a saída. Se esse sinal não pertencer a nenhuma classe anteriormente definida por ela uma nova classe é criada (Kartalopoulos, S.; 1996).

### 2.5.2 – Aprendizado supervisionado

Neste tipo de aprendizado, a RNA é alimentada com um conjunto de entradas e também é definido um conjunto de saídas desejadas para cada entrada. A rede vai processar o sinal de entrada e comparar a saída obtida com o valor desejado. Se o valor obtido não é igual ao desejado, a rede vai alterar o valor dos pesos das ligações entre neurônios e aí recalcular a saída. Esse processo se repete até a saída obtida ficar igual a desejada (Kartalopoulos, S.; 1996).

### 2.5.3 – Aprendizado reforçado

Neste caso a rede é alimentada por sinais, porém não são fornecidos valores desejados na saída, apesar disso, esse aprendizado não é do tipo não supervisionado. O que ocorre neste caso é que vão existir dois neurônios na camada de saída, e o que é informado para a rede é se a resposta obtida é “verdadeira” ou “falsa”. Se a resposta for falsa a rede vai alterar os valores dos pesos até chegar a resposta verdadeira. Ao contrario do aprendizado supervisionado não se tem como saber se a rede está se aproximando ou afastando do valor desejado (Kartalopoulos, S.; 1996).

### 2.5.4 – Aprendizado competitivo

Para este caso a RNA deve ter mais de um neurônio na camada de saída. O que ocorre é um processo similar ao do aprendizado supervisionado, uma vez que valores de entrada são fornecidos e valores desejados também. Porém, quando isso ocorre todos os neurônios da camada de saída tentam se aproximar o mais rápido possível da resposta e quando um deles a atinge, os outros param de processar. Para diferentes sinais, diferentes neurônios chegarão ao valor desejado, o que leva a rede a ter neurônios especializados dependendo do valor de entrada (Kartalopoulos, S.; 1996).

### 2.5.5 – Regra Delta

Neste caso a RNA compara os resultados obtidos mediante a uma entrada com os desejados e calcula um erro. Esse processo se dá continuamente até que o erro seja diminuído a um valor desejado. Essa regra também é conhecida como a dos mínimos erros quadráticos (Kartalopoulos, S.; 1996).

### 2.5.6 – Regra do gradiente descendente

Essa regra calcula o erro entre a saída obtida e a desejada, aplica a primeira derivada nesse erro e com isso recalcula os valores dos pesos. Esse processo ocorre até os erros serem suficientemente pequenos (Kartalopoulos, S.; 1996).

### 2.5.7 – Aprendizado Hebbian

Neste caso os pesos são alterados quando se tem dois neurônios próximos e que trocam sinais com maior frequência. O algoritmo então vai aumentar a força de ligação entre esses dois neurônios. Este método foi proposto por Donald Hebb, daí o nome (Kartalopoulos, S.; 1996).

## 2.6 – FUNÇÕES DE ATIVAÇÃO

Como mostrado anteriormente os sinais de entrada são multiplicados por pesos, somados e então se aplica uma função de ativação. Essas funções são usadas de acordo com a arquitetura da RNA (Fausett, L.; 1994). As funções de ativação utilizadas nas RNA são:

- Função reta:  $f(x) = ax$

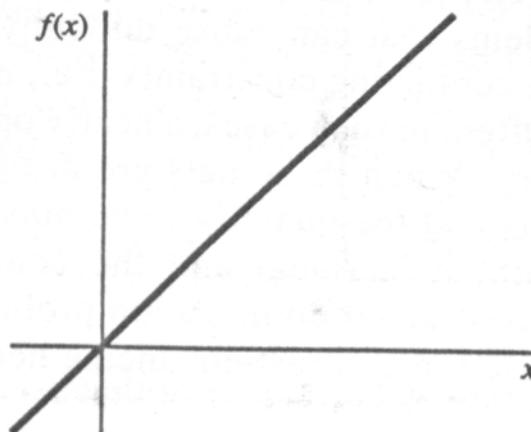


Figura 2.4 – Função reta (Fausett, L.; 1994).

- Função degrau:  $f(x) = \begin{cases} 1 & \text{se } x \geq \theta \\ 0 & \text{se } x < \theta \end{cases}$

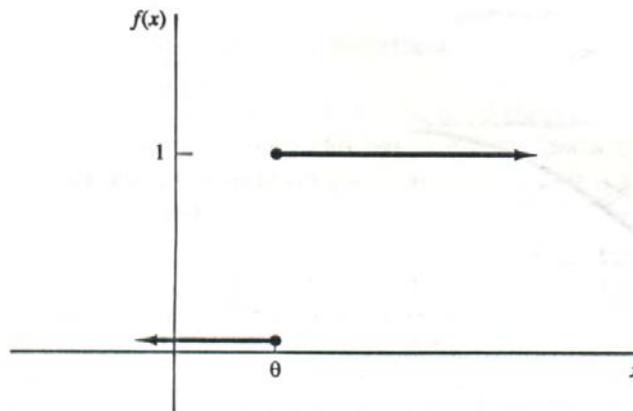


Figura 2.5 – Função degrau (Fausett, L.; 1994).

- Função sigmóide:  $f(x) = \frac{1}{1 + e^{-\alpha x}}$  com  $f'(x) = \alpha f(x)[1 - f(x)]$

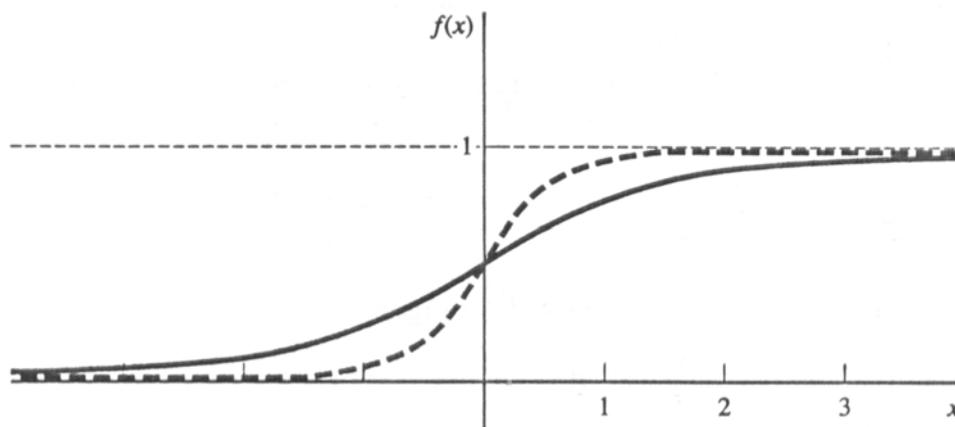


Figura 2.6 – Função sigmóide (Fausett, L.; 1994).

- Função sigmóide bipolar:  $f(x) = \frac{1 - \exp(-\sigma x)}{1 + \exp(-\sigma x)}$

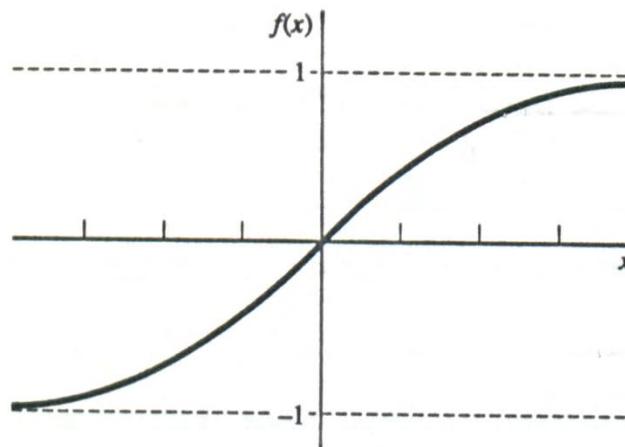


Figura 2.7 – Função sigmóide bipolar (Fausett, L.; 1994).

## 2.7 – OS ALGORITMOS E TOPOLOGIAS DAS RNA

Existem diversos algoritmos usados para de criar um RNA. Cada algoritmo leva a um tipo de aprendizado diferente, bem como tipos diferentes de arquiteturas de redes. A seguir serão basicamente descritos alguns algoritmos baseados em classificação ou associação de padrões.

### 2.7.1 – *Perceptron*

O *perceptron* é o mais simples algoritmo de todos, baseado no neurônio de McCulloch-Pitts, ele é constituído de um único neurônio sem realimentação (*single layer perceptron*). Pela sua característica esse tipo de algoritmo é bastante limitado, daí o surgimento do *multilayer perceptron*, composto de vários

neurônios e camadas, o que permitiu a rede ser aplicada a problemas mais complexos (Kartalopoulos, S.; 1996).

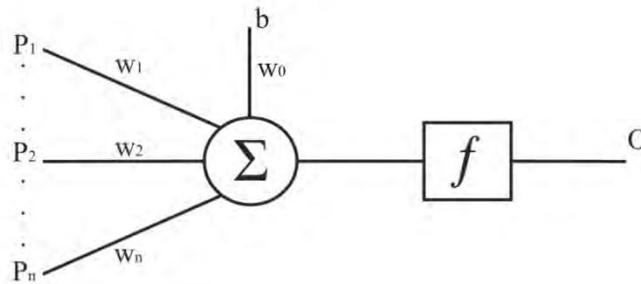


Figura 2.8 – *Perceptron*

### 2.7.2 – ADALINE e MADALINE

A ADALINE (*Adaptive Linear Neuron*) é um tipo de rede que possui um único neurônio semelhante ao *perceptron*, porém realimentada com um sistema de treinamento que pode ser regra delta por exemplo, e com entradas que normalmente variam entre (1,-1). Já MADALINE (*Many Adaptive Linear Neurons*) é composta de várias ADALINES em paralelo formando redes multicamadas com apenas uma única ADALINE na camada de saída (Kartalopoulos, S.; 1996).

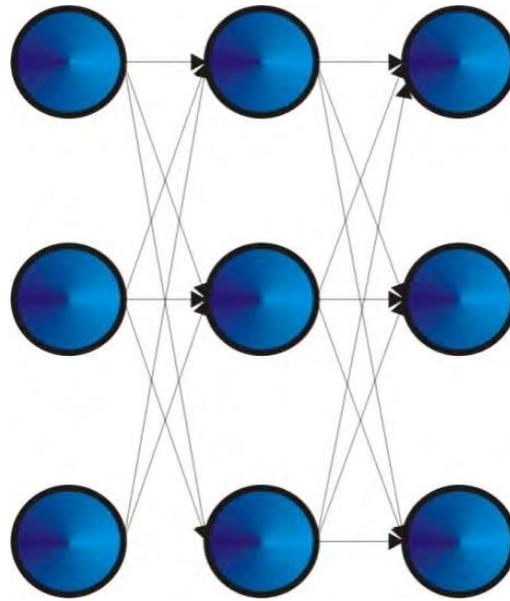


Figura 2.9 – Rede MADALINE

### 2.7.3 – *Winner-Takes-All*

Essa rede é composta de uma camada de neurônios e cada neurônio possui pesos independentes. O seu treinamento é do tipo competitivo, ou seja, os dados de entrada são fornecidos e a saída que obtiver a melhor resposta prevalece (Kartalopoulos, S.; 1996).

#### 2.7.4 – *Backpropagation*

É bastante utilizado e é aplicado a redes multi-camadas com uma ou mais camadas intermédias e do tipo *feedforward*. Como esse foi o algoritmo escolhido para esse trabalho, ele será melhor detalhado posteriormente.

#### 2.7.5 – *Adaptive Resonance Theory (ART)*

Este sistema foi criado para resolver problemas de instabilidade em sistemas *feedforward*. Basicamente esse tipo de rede é composto por duas camadas conectadas entre si por um filtro adaptivo. Os dados que chegam a camada de entrada e são multiplicados pelos respectivos pesos, somados e enviados para a camada de saída passando pelo filtro. Na camada de saída a melhor resposta é selecionada através de um algoritmo competitivo, ou seja, o neurônio com a resposta mais próxima da desejada prevalece. Essa resposta é enviada à camada de entrada passando novamente pelo filtro. Esse sinal é comparado com a entrada original e determinado se está próximo o suficiente. Se não estiver o algoritmo testa o segundo valor mais próximo selecionado na camada de saída e assim sucessivamente (Kartalopoulos, S.; 1996).

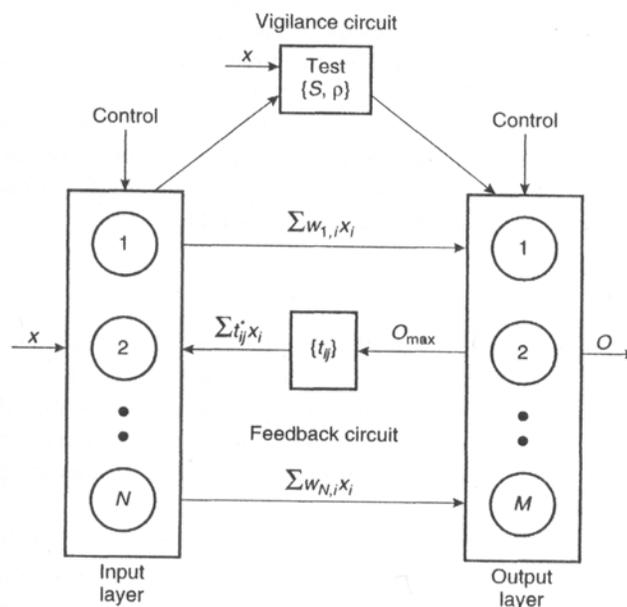


Figura 2.10 – Rede ART (Kartalopoulos, S.; 1996).

### 2.7.6 – Modelo de Hopfield

Esse modelo foi criado por John Hopfield em 1982. O modelo básico é composto de dois neurônios cujas saídas estão conectadas ao outro neurônio, porém a saída de um neurônio não se conecta a ele mesmo. Cada saída pode ser inversora ou não-inversora e as conexões são resistivas, portanto não podendo ser negativas. Quando a saída tem o mesmo valor da entrada ela é excitatória e portanto não inversora, do contrário ela será inibitória e inversora. Essa rede é aleatória e sincronizada, portanto precisa de um *clock*, como um computador. Este tipo de rede pode ser alimentada com dois tipos de entradas, binárias ou bipolares (Kartalopoulos, S.; 1996).

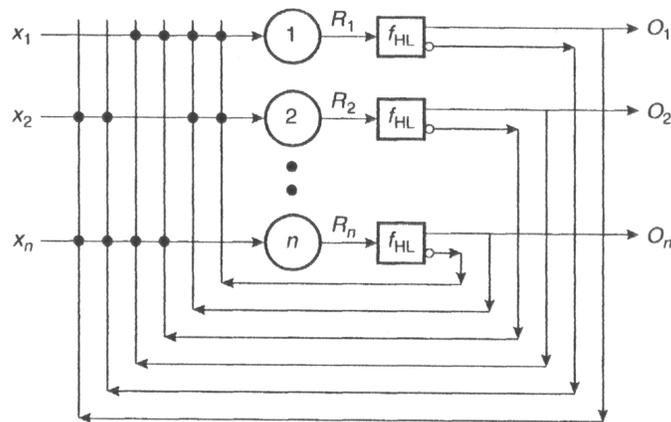


Figura 2.11 – Modelo de Hopfield (Kartalopoulos, S.; 1996).

## 2.8 – O ALGORITMO *BACKPROPAGATION*

No algoritmo *backpropagation*, sinais são aplicados na camada de entrada e cada um desses sinais é multiplicado pelos respectivos pesos de cada neurônio. Assim que o *threshold* de cada neurônio for ultrapassado o sinal é transmitido para a camada subsequente e assim por diante até a camada de saída for atingida. Quando o sinal atinge essa camada é comparado com o sinal desejado e os erros entre eles são calculados. Feito isso, os valores são aplicados à camada anterior e recalculam-se os pesos de cada neurônio com a finalidade de minimizar os erros. Esse processo continua até que o erro seja o esperado ou a camada de entrada seja atingida caracterizando o processo de *feedback* (Kartalopoulos, S.; 1996).

Dependendo dos pesos atribuídos a cada entrada, o processo se torna mais ou menos eficiente podendo convergir mais rapidamente ou não convergir. Os resultados obtidos também variam dependendo do número de neurônios em

cada camada e do número de camadas que vão formar a rede a ser treinada. As equações que modelam o algoritmo *backpropagation* e que são usadas pelo mesmo são apresentadas a seguir (Kartalopoulos, S.; 1996).

- Equação da rede *feed- forward*:

$$O_i^{l+1}(k) = f(\sum_{j=1}^{n_{l+1}} w_{ij}^l O_j^l(k)) \quad (2.1)$$

Onde:  $O_i^{l+1}(k)$  = sinal de saída do *i-ésimo* nó na camada  $l+1$ ;

$O_j^l(k)$  = sinal de saída do *j-ésimo* nó da camada  $l$ ;

$w_{ij}^l$  = *i-ésimo* peso do *j-ésimo* nó da camada  $l$ ;

$f(x) = \frac{1}{1 + e^{-\beta x}}$  = função sigmoide.

- O erro é calculado pelo método dos mínimos quadrados (mse):

$$E = \sum_{k=1}^K \left( \frac{1}{2} \sum_{i=1}^{n_l} [T_i(k) - O_i^l(k)]^2 \right) \quad (2.2)$$

Onde:  $T_i(k)$  = valores desejados;

$O_i^l(k)$  = *i-ésimo* valor de saída da camada de saída.

- O gradiente utilizado para recalculer os pesos é:

$$\delta_i^L = (T_i - O_i^L)O_i^L(1 - O_i^L) \quad (2.3)$$

$$\delta_i^l = \left( \sum_{r=1}^{n_l} \delta_r^{l+1} w_{ri}^{l+1} \right) O_i^l (1 - O_i^l) \quad (2.4)$$

Onde:  $\delta_i^L$  = gradiente da *i-ésima* saída da camada de saída;

$\delta_i^l$  = gradiente da *i-ésima* saída da camada oculta;

$O_i^L$  = *i-ésima* saída da camada de saída;

$O_i^l$  = *i-ésima* saída da camada oculta;

$T_i$  = *i-ésimo* valor desejado;

$w_{ri}^{l+1}$  = *r-ésimo* peso do *i-ésimo* nó da camada l+1.

- A diferença calculada para o peso é:

$$\Delta w_{ij}^l = \eta \delta_i^l O_j^{l-1} \quad (2.5)$$

Onde:  $\Delta w_{ij}^l$  = diferença calculada para o *j-ésimo* peso do *i-ésimo* nó da camada l;

$\delta_i^l$  = gradiente do *i-ésimo* nó na camada l;

$O_j^{l-1}$  = *j-ésima* saída na camada l-1;

# CAPÍTULO 3 – APLICAÇÃO DAS REDES NEURAIIS ARTIFICIAIS EM MOTORES DE INDUÇÃO TRIFÁSICOS

## 3.1 – CONSIDERAÇÕES INICIAIS

O objetivo deste trabalho, como já foi mencionado anteriormente, é de aplicar os conceitos de RNA na estimação da temperatura de um motor de indução tendo como parâmetros de entrada o comportamento característico da variação da temperatura no tempo. Este capítulo trata do equacionamento do problema e das técnicas aplicadas para a sua solução. Será utilizado um dado motor selecionado e proposto um ciclo de operação a ser estudado.

## 3.2 – CÁLCULO DOS VALORES DE ENTRADA

De maneira a formar um conjunto de dados de entrada da RNA, considerou-se um pequeno ciclo de operação onde o motor acelera e se mantém em operação com carga de modo a se atingir os valores nominais. O objetivo aqui é construir a curva de aquecimento do motor no tempo para que se defina o seu comportamento.

O próximo passo foi a escolha do motor utilizado na simulação. O motor escolhido foi um motor da WEG cujo catálogo parcial se encontra no Anexo A. A seguir tem-se alguns dos dados de placa do motor escolhido:

- Motor: Motor de indução trifásico IP55 com 4 pólos e 60 Hz;
- Potência nominal: 5 cv ou 3,7 kW;
- Tensão nominal: 220 V;
- Rotação nominal: 1715 rpm;
- Corrente nominal: 14 A;
- Corrente de partida: 106,4 A;
- Conjugado Nominal: 2,09 kgf;
- Conjugado com rotor bloqueado: 6,06 kgf;
- Conjugado máximo: 6,48 kgf;

Dependendo da carcaça do motor utilizado sua constante térmica de aquecimento  $T_H$  varia. Também sabe-se que:

$$\frac{1}{T_H} = \frac{A}{C} \quad (3.1)$$

Onde:  $T_H$  é a constante térmica de aquecimento [min];

$C$  é a capacidade calorífica do motor [W.s/°C];

$A$  é o coeficiente de transmissão de calor para o meio ambiente [W/°C].

$$A = \frac{P_{jN}}{\Delta\theta_{lim}} \quad (3.2)$$

Onde: A é o coeficiente de transmissão de calor para o meio ambiente [W/°C];

$\Delta\theta_{lim}$  é a máxima elevação de temperatura permitida por norma [°C];

$P_{jN}$  é a perda Joule nominal do motor [W];

Aplicando-se a equação (3.2) em (1.7) para condição de operação nominal, tem-se:

$$\Delta\theta = \Delta\theta_{lim} (1 - e^{-\frac{A}{C}t}) \quad (3.3)$$

Onde:  $\Delta\theta$  é a elevação de temperatura [°C];

$\Delta\theta_{lim}$  é a máxima elevação de temperatura permitida por norma [°C];

C é a capacidade calorífica do motor [W.s/°C];;

A é o coeficiente de transmissão de calor para o meio ambiente [W.s/°C].

Aplicando-se agora (3.1) em (3.3), tem-se:

$$\Delta\theta = \Delta\theta_{lim} (1 - e^{-\frac{1}{T_H}t}) \quad (3.4)$$

Onde:  $T_H$  é a constante térmica de aquecimento [min];

$\Delta\theta$  é a elevação de temperatura [ $^{\circ}\text{C}$ ];

$\Delta\theta_{\text{lim}}$  é a máxima elevação de temperatura permitida por norma [ $^{\circ}\text{C}$ ].

O motor em questão é da classe H, portanto a máxima elevação de temperatura permitida por norma é 125 [ $^{\circ}\text{C}$ ], como definido anteriormente. Também é dado pelo fabricante que esse motor utiliza uma carcaça do tipo 100L que possui um valor típico de constante térmica de aquecimento de 18 [min] (Anexo B). Portanto de posse desses valores e através da equação 3.4, pode-se construir a curva de aquecimento do motor ao longo do tempo semelhante a curva mostrada na figura 1.1 do capítulo 1 e traçada para o motor utilizado (figura 3.1).

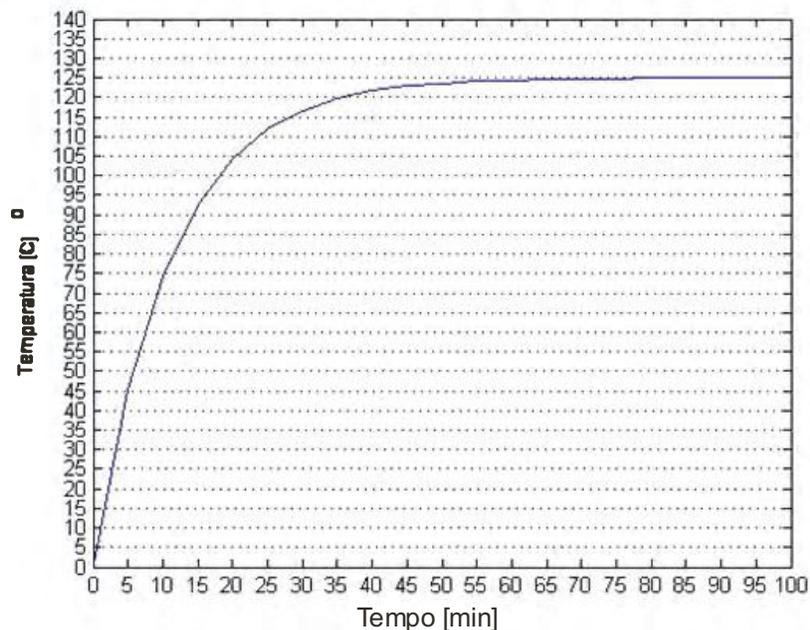


Figura 3.1 – Curva da elevação de temperatura para o motor analisado.

A tabela 3.1 contém o conjunto de valores utilizados:

Tabela 3.1 – Valores de entrada para a RNA

<b>Tempo (min)</b>	<b>Temperatura (°C)</b>
5	45,30
10	74,18
15	92,60
20	104,33
25	111,83
30	116,60
35	119,64
40	121,60
45	122,82
50	123,61
55	124,11
60	124,43
65	124,64
70	124,77
75	124,85
80	124,90
85	14,94
90	124,96
95	124,97
100	124,98

A arquitetura MADALINE foi utilizada seguindo o critério de que esse tipo de rede é um dos tipos mais eficientes com base em outros trabalhos pesquisados. Primeiramente definiu-se uma camada oculta devido ao aumento da complexidade de se manipular a rede ao se aumentar o número de camadas intermediárias. Essa arquitetura se mostrou eficaz portanto ela foi mantida. Em relação ao algoritmo escolhido, aplicou-se o algoritmo *resilient backpropagation* que em teoria converge mais rápido que o *backpropagation* porém ao simular o sistema proposto, ele demorou mais em relação ao *backpropagation* ou não convergiu, essa variação se deu pois os pesos não foram definidos, ou seja, foram determinados aleatoriamente pelo sistema, o que leva a rede a convergir em diferentes tempos, ou como dito anteriormente, não convergir, a cada nova tentativa de treinamento. Ao se utilizar a arquitetura escolhida e o algoritmo *backpropagation*, a rede convergiu em todas as tentativas de treinamento embora com tempos de convergência diferentes. Como não existe nenhum critério que determine com precisão como se encontrar o número de neurônios que deve ser utilizado na camada intermediária, essa determinação foi feita adotando-se o critério de Nielsen que diz que uma maneira de se determinar o número de elementos na camada intermediária pode ser determinada ao se multiplicar o número de entradas por dois e somar um (Contatori, C.; 2005). Portanto utilizou-se 41 neurônios na camada oculta, porém a rede não convergiu, o que levou a adoção, em seguida, de 30 neurônios e a rede convergiu.

Após a determinação da arquitetura da RNA e o algoritmo e, utilizando-se o Matlab®, uma rede neural (figura 3.2) com 20 neurônios na camada de entrada, 30 neurônios na camada oculta e 1 neurônio na camada de saída foi utilizada e fez-se o treinamento para os valores encontrados. A função de transferência entre a camada de entrada e oculta foi a sigmóide e entre a camada oculta e de saída foi uma função linear. A simulação foi feita utilizando-se o algoritmo *backpropagation* com erros calculados pelo método dos mínimos quadrados com limite da ordem de  $1.e^{-5}$  (Demuth, H., Beale, M., Hagan, M.; 2007).

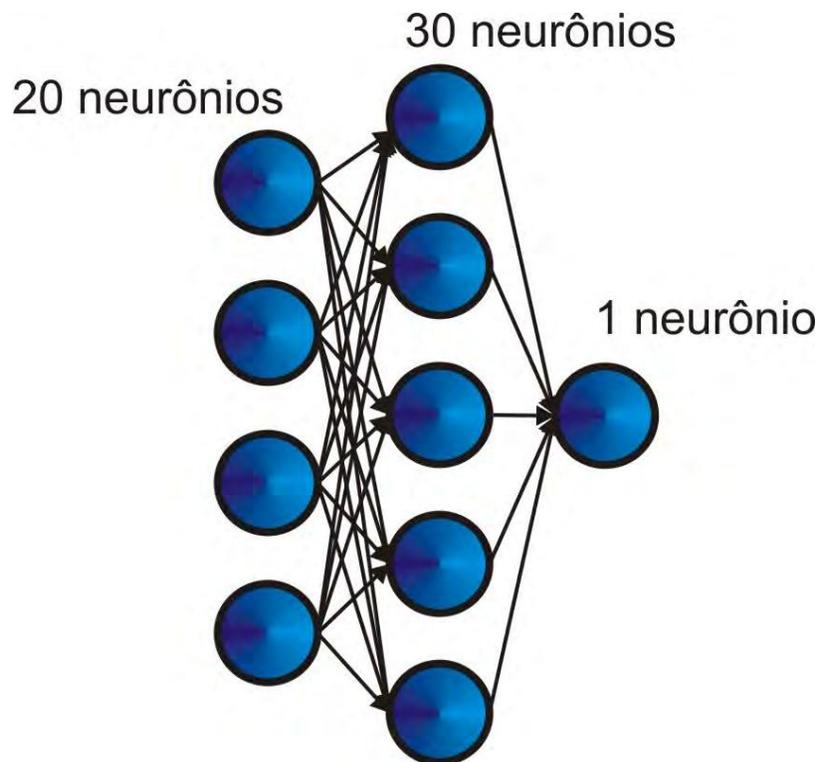


Figura 3.2 – RNA utilizada

### 3.3 – TREINAMENTO

Os resultados obtidos após a simulação estão representados nas figuras 3.3, 3.4 e 3.5. A tabela 3.2 traz uma comparação entre os valores fornecidos à rede e os obtidos após o treinamento.

```

TRAINLM, Epoch 0/10000, MSE 14068.3/1e-005, Gradient 15357.2/1e-010
TRAINLM, Epoch 25/10000, MSE 0.000741089/1e-005, Gradient 10.3884/1e-010
TRAINLM, Epoch 50/10000, MSE 0.000174012/1e-005, Gradient 0.370328/1e-010
TRAINLM, Epoch 75/10000, MSE 0.000121735/1e-005, Gradient 0.121855/1e-010
TRAINLM, Epoch 100/10000, MSE 9.83589e-005/1e-005, Gradient 0.0619698/1e-010
TRAINLM, Epoch 125/10000, MSE 8.0196e-005/1e-005, Gradient 3.07624/1e-010
TRAINLM, Epoch 150/10000, MSE 4.23357e-005/1e-005, Gradient 0.397385/1e-010
TRAINLM, Epoch 175/10000, MSE 3.22268e-005/1e-005, Gradient 0.15569/1e-010
TRAINLM, Epoch 200/10000, MSE 2.69962e-005/1e-005, Gradient 0.0836178/1e-010
TRAINLM, Epoch 225/10000, MSE 2.36812e-005/1e-005, Gradient 0.0531999/1e-010
TRAINLM, Epoch 250/10000, MSE 2.13467e-005/1e-005, Gradient 0.0385203/1e-010
TRAINLM, Epoch 275/10000, MSE 1.95916e-005/1e-005, Gradient 0.0298639/1e-010
TRAINLM, Epoch 300/10000, MSE 1.82118e-005/1e-005, Gradient 0.0237312/1e-010
TRAINLM, Epoch 325/10000, MSE 1.70912e-005/1e-005, Gradient 0.0192313/1e-010
TRAINLM, Epoch 350/10000, MSE 1.36671e-005/1e-005, Gradient 0.887117/1e-010
TRAINLM, Epoch 375/10000, MSE 1.03851e-005/1e-005, Gradient 0.329063/1e-010
TRAINLM, Epoch 380/10000, MSE 9.9897e-006/1e-005, Gradient 0.28466/1e-010
TRAINLM, Performance goal met.

```

Figura 3.3 – Passos do treinamento da RNA até a convergência

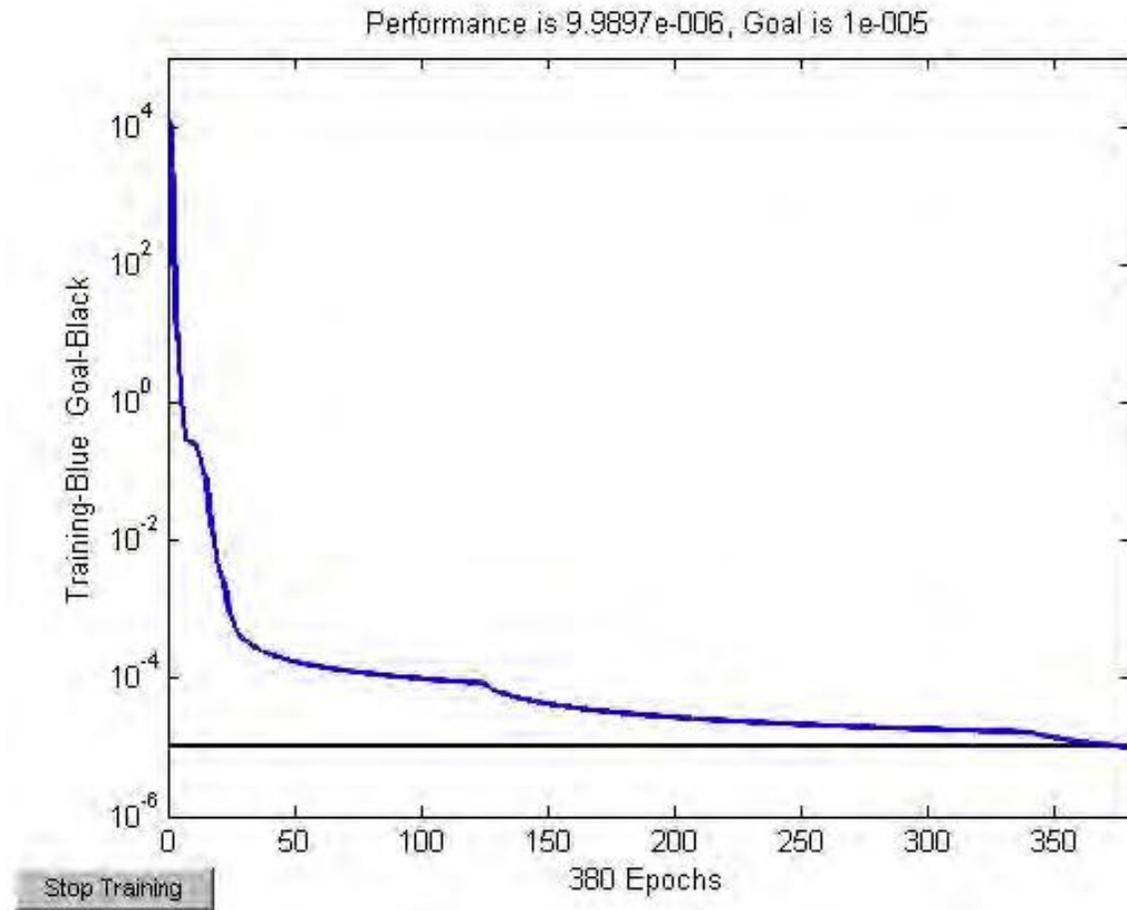


Figura 3.4 – Tempo decorrido para a convergência

As figuras 3.3 e 3.4 indicam que a rede convergiu para os valores desejados com o erro desejado em 380 *epochs* do MatLab®, ou seja, unidades de tempo. Já a figura 3.5 mostra uma curva que relaciona os valores desejados (em azul) e os valores obtidos (círculos vermelhos). Os valores iniciais dos pesos não foram fixados, ou seja, foram deixados aleatórios para cada início de treinamento. Isso não implica em nenhum erro, a rede converge, o que ocorre apenas é que ela apresenta uma variação de tempo de convergência se a rede for treinada em outra oportunidade após a memória do Matlab® ser apagada. Se

os pesos iniciais forem fixados ela sempre se comportará da mesma maneira mesmo apagando-se da memória do Matlab®.

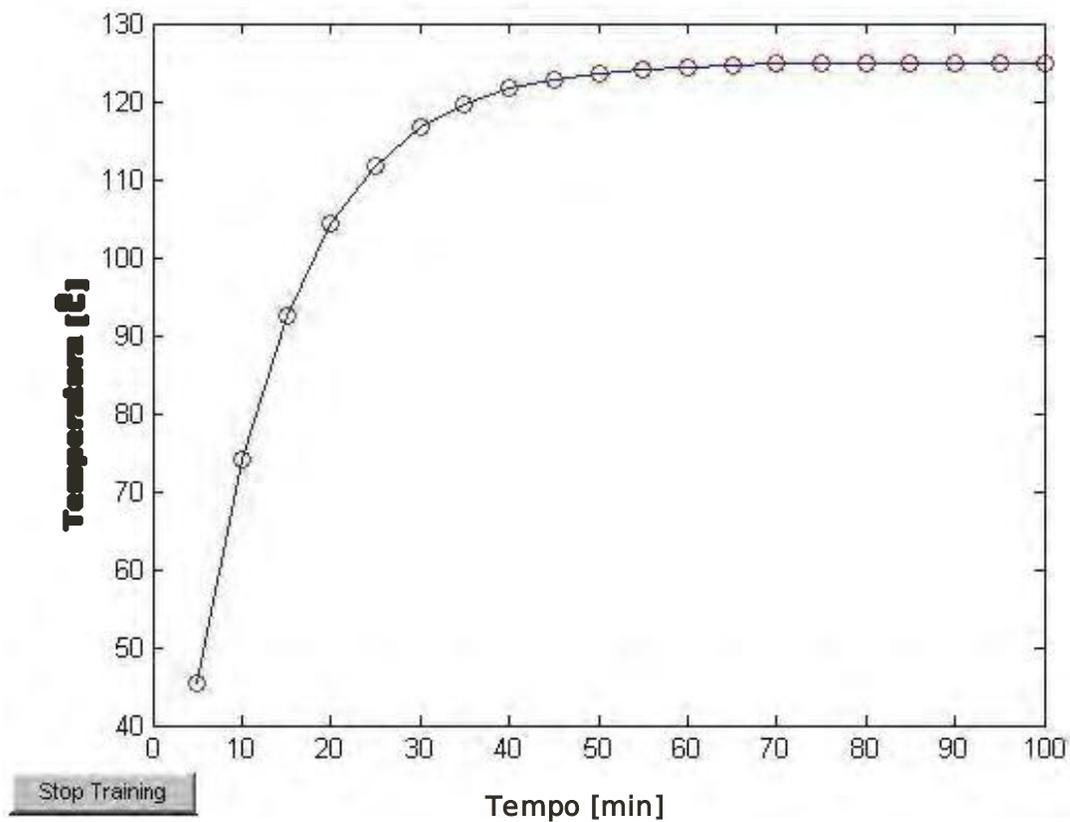


Figura 3.5 – Valores obtidos (círculos vermelhos) em relação aos esperados (linha azul)

Nota-se portanto que baseado nos valores obtidos pela simulação que a rede chegou a valores de saída quase iguais aos de entrada, o que demonstra um bom desempenho.

Tabela 3.2 – Comparação dos resultados obtidos.

<b>Temperatura desejada (°C)</b>	<b>Temperatura obtida (°C)</b>
45,30	45,3002
74,18	74,1802
92,60	92,6002
104,33	104,3301
111,83	111,8301
116,60	116,6001
119,64	119,6400
121,60	121,6031
122,82	122,8153
123,61	123,6059
124,11	124,1131
124,43	124,4349
124,64	124,6377
124,77	124,7700
124,85	124,8561
124,90	124,9059
14,94	124,9370
124,96	124,9564
124,97	124,9685
124,98	124,9760

### 3.4 – VALIDAÇÃO

Para a validação dos resultados obtidos foram utilizados um conjunto de entradas diferentes dos usados no treinamento. Esses valores e a respectiva resposta estão relacionados na tabela 3.3. A figura 3.6 mostra graficamente esses resultados.

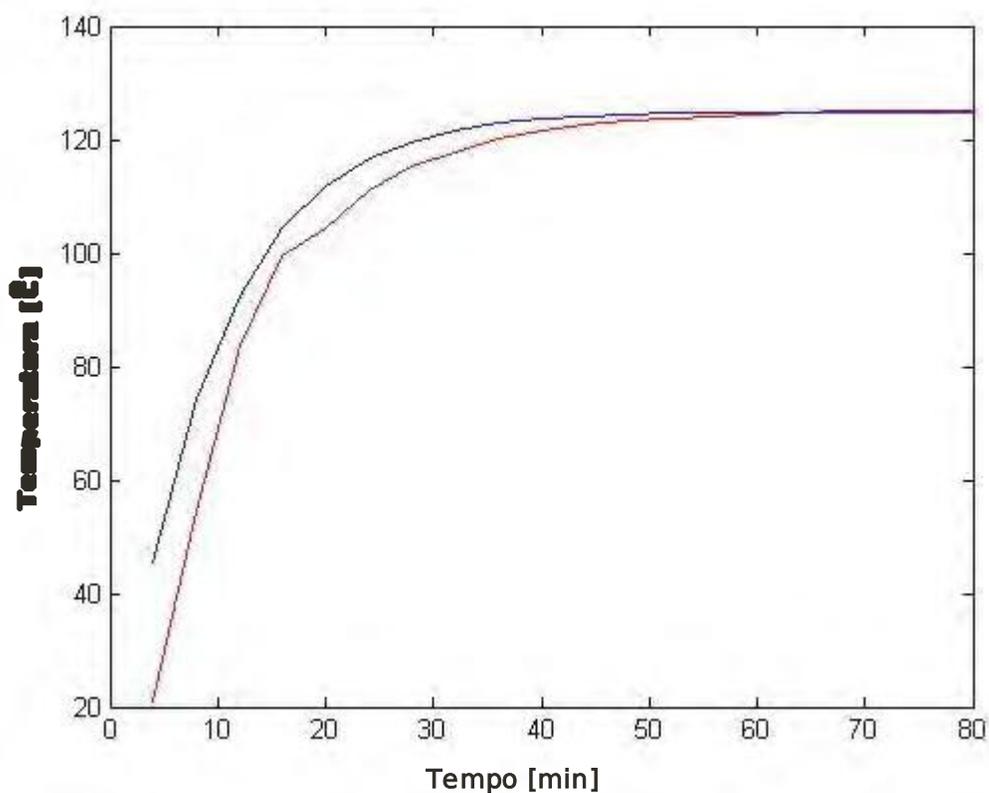


Figura 3.6 – Valores obtidos (linha vermelha) em relação aos esperados (linha azul)

Observando-se a figura 3.6 nota-se que a rede respondeu com razoável aproximação.

Tabela 3.3 – Comparação dos resultados obtidos.

<b>Tempo (min)</b>	<b>Temperatura obtida (°C)</b>
4	20,9052
8	54,5072
12	83,6164
16	99,5439
20	104,3301
24	111,0005
28	115,2961
32	117,7506
36	120,2071
40	121,6031
44	122,6118
48	123,3305
52	123,8365
56	124,1897
60	124,4349
64	124,6043
68	124,7216
72	124,8120
76	124,8681
80	124,9059

## CAPÍTULO 4 – CONCLUSÕES

Analisando-se o objetivo do presente trabalho e as respostas da rede após a simulação realizada, pode-se concluir que os resultados foram bastante satisfatórios.

Diante do fato que para se determinar a quantidade de camadas, a quantidade de neurônios em cada camada e o algoritmo de treinamento, não existe nenhum método preciso na literatura, os critérios utilizados para a determinação da Rede Neural Artificial usada neste estudo partiu, portanto, da análise de outros trabalhos que apresentaram uma boa resposta para a arquitetura proposta neste trabalho. No caso foi escolhida uma MADALINE levando em consideração o fato de este tipo de rede ser uma das mais usadas e testadas com resultados positivos. O fato de se utilizar uma camada intermediária torna a rede mais eficiente, porém ao se aumentar o número de camadas intermediárias, a manipulação dessa rede pode se tornar mais complexa. O mesmo critério se aplicou à escolha do algoritmo *backpropagation*, que é um dos mais aplicados para a resolução de problemas semelhantes ao proposto também com sucesso, apesar de ser um método que, dependendo da aplicação, pode se tornar mais lento que outros existentes. No caso do número de neurônios usados o critério de Nielsen que diz que uma maneira de se determinar o número de elementos na camada intermediária pode ser determinada ao se multiplicar o número de entradas por dois e somar um

(Contatori, C.; 2005), porém a rede não convergiu, o que levou a adoção, em seguida, de 30 neurônios e a rede convergiu.

Os valores obtidos pela RNA tiveram uma boa aproximação em relação aos fornecidos para o treinamento, com erros menores que os determinados como suficientes e reproduzindo de maneira semelhante o comportamento térmico do motor estudado. Isso confirma a aplicabilidade desta metodologia na resolução do problema para esse caso específico e também indica a possibilidade de se estendê-la para casos mais gerais. Esses resultados indicam também uma possibilidade de se usar os mesmos conceitos para se criar um sistema de instrumentação virtual destinado à diferentes aplicações.

Uma hipótese de aplicação é de se ter uma rede semelhante à que foi aqui utilizada, combinada com outras redes que poderão ser treinadas para identificar comportamentos padrão em relação à correntes ou mesmo ao conjugado do motor. Correlacionando, então, todos esses comportamentos o sensor virtual poderá, por exemplo, fazer parte de um sistema de proteção, ou servir de ferramenta para se especificar um motor com uma maior segurança e eficiência para uma determinada aplicação.

## REFERÊNCIAS

- [1] **SANTOS, A.H.M, SIMÕES, A.A., MARTINS, A.R.S., VIANA, A.N.C., BORRONI, E.C., LORA, E.E.S., TEIXEIRA, F.N., HADDAD, J., CORTEZ, J.A., NOGUEIRA, L.A.H., ALMEIDA, M.S.V., PIRANI, M.J., VENTRINI, O., GAMA, P.H.R.P., YAMACHITA, R.A., SILVA, V.F.;** - *Conservação de Energia – Eficiência Energética de Instalações e Equipamentos*, Editora EFEI, Itajubá, Minas Gerais, 2001;
- [2] **CONTATORI, C.;** - *Um Sistema Inteligente Baseado em Redes Neurais Artificiais, aplicado a Monitoração Térmica de Máquinas Elétricas*, Universidade de Taubaté, Taubaté, São Paulo, 2005.
- [3] **KOSOW, I. L.;** - *Máquinas Elétricas e Transformadores*, 15<sup>a</sup> edição, Editora Globo, São Paulo, 2005;
- [4] **ALMEIDA, A. T. L.;** - *Motores de Corrente Contínua*, FUPAI, Itajubá, Minas Gerais, 2000;
- [5] **ALMEIDA, A. T. L.;** - *Máquinas Síncronas*, FUPAI, Itajubá, Minas Gerais, 2000;
- [6] **ALMEIDA, A. T. L.;** - *Motores de Indução Trifásicos*, FUPAI, Itajubá, Minas Gerais, 2000;
- [7] **MOREIRA, H. J. F. ET AL.;** - *Guia Operacional de Motores Elétricos*, Eletrobrás, Rio de Janeiro, 2000;
- [8] **KARTALOPOULS, S.;** - *Understanding Neural Networks and Fuzzy Logic*, IEEE Press, Piscataway, NJ, USA, 1996;

- [9] **FAUSETT, L.;** - *Fundamentals of Neural Networks – Architectures, Algorithms and Applications*, Prentice Hall, Englewood Cliffs, 1994;
- [10] **GURNEY, K.;** - *An Introduction to Neural Networks*, CRC Press, London, 2003;
- [11] **DEMUTH, H., BEALE, M. AND HAGAN, M.;** - *Neural Networks Toolbox 5 User's Guide*, Mathworks Inc., Natick, MA, USA, 2007;
- [12] **CATÁLOGO WEG MOTORES;** - *Motores Elétricos - Linhas de Produtos, Características, Especificações, Instalações, Manutenções*, Jaraguá do Sul, 2007;
- [13] **BOLDEA, I., NASAR S. A.;** - *The Induction Machine Handbook*, CRC Press, London, 2002;
- [14] **NORMA TÉCNICA NBR 7034;** - *Materiais isolantes elétricos - Classificação térmica*, ABNT, São Paulo, 1981;
- [15] **SÁ, J. S., COGO J. R., ARANGO, H.;** - *Um Método Rápido Para a Análise do Comportamento Térmico do Enrolamento do Estator de Motores de Indução Trifásicos Tipo Gaiola*; EFEI, Minas Gerais;
- [16] **COSTA, P. F., BOREL, J. E. V.;** - *Comportamento Térmico dos Motores Elétricos de indução Trifásicos*, Revista EM, São Paulo, abril de 1999.
- [17] **MINISTÉRIO DAS MINAS E ENERGIA** - *Dados Consolidados - Consumo Setorial de Eletricidade*, [http://www.mme.gov.br/site/menu/select\\_main\\_menu\\_item.do?channelId=1432&pageId=10780](http://www.mme.gov.br/site/menu/select_main_menu_item.do?channelId=1432&pageId=10780), setembro de 2008;
- [18] **RIBEIRO, A. L. Z. ET AL.;** - *Estimação do Torque de um Motor de Indução Através de Redes Neurais Artificiais*, Congresso Internacional LAPTEC, Santos, 2007;

[19] **RIBEIRO, A. L. Z. ET AL.**; - *An Induction Motor Stator Temperature Estimation Using Artificial Neural Networks*, Congresso Internacional CLAGTEE, Viña del Mar, 2007.

## ANEXO A – Catálogo de motores WEG.

- Parte do catálogo de motores de indução WEG IP55 (CATÁLOGO WEG MOTORES, 2007).

Potência		Carcaça	RPM	Corrente nominal em 220V (A)	Corrente com rotor bloqueado $I_b / I_n$	Conjugado nominal $C_n$ (kgfm)	Conjugado com rotor bloqueado $C_b / C_n$	Conjugado máximo $C_{máx} / C_n$	Rendimento $\eta$ %			Fator de potência $\cos \phi$			Fator de serviço F S	Momento de inércia J (kgm <sup>2</sup> )	Tempo máx com rotor bloqueado (s) a quente	Nível médio de pressão sonora dB (A)	Peso aprox. (kg)
cv	kW								% da potência nominal										
									50	75	100	50	75	100					
<b>4 Pólos - 60 Hz</b>																			
0,16	0,12	63	1720	0,89	4,5	0,07	3,2	3,4	45,0	52,0	57,0	0,46	0,55	0,62	1,15	0,00045	31	48	7
0,25	0,18	63	1710	1,14	4,5	0,10	2,8	3,0	53,0	60,0	64,0	0,47	0,57	0,65	1,15	0,00096	18	48	8
0,33	0,25	63	1710	1,44	4,5	0,14	2,9	2,9	59,0	64,0	67,0	0,48	0,59	0,68	1,15	0,00067	20	48	8
0,50	0,37	71	1720	2,07	5,0	0,21	2,7	3,0	56,0	64,0	68,0	0,48	0,59	0,69	1,15	0,00079	10	47	10
0,75	0,55	71	1705	2,90	5,5	0,31	3,0	3,2	62,0	69,0	71,0	0,49	0,60	0,70	1,15	0,00096	10	47	11
1,0	0,75	80	1720	3,02	7,2	0,42	2,5	2,9	72,0	77,5	79,5	0,62	0,74	0,82	1,15	0,00294	8	48	15
1,5	1,1	80	1720	4,43	7,8	0,62	2,9	3,2	72,0	77,0	79,5	0,60	0,73	0,82	1,15	0,00328	5	48	16
2,0	1,5	90S	1740	6,12	6,4	0,82	2,5	3,0	77,0	81,0	82,5	0,60	0,72	0,78	1,15	0,00560	7	51	21
3,0	2,2	90L	1725	8,70	6,8	1,25	2,6	2,8	79,0	82,0	83,0	0,64	0,75	0,80	1,15	0,00672	6	51	23
4,0	3,0	100L	1725	11,8	7,5	1,66	2,6	2,8	82,0	83,0	83,5	0,61	0,73	0,80	1,15	0,00918	7	54	31
5,0	3,7	100L	1715	14,0	7,6	2,09	2,9	3,1	82,5	84,3	85,5	0,63	0,75	0,81	1,15	0,00995	7	54	33
6,0	4,5	112M	1745	16,7	7,4	2,46	2,2	2,8	85,0	85,0	85,2	0,66	0,77	0,82	1,15	0,01741	11	58	44
7,5	5,5	112M	1740	20,0	7,0	3,09	2,2	2,8	86,6	87,5	88,0	0,63	0,74	0,82	1,15	0,01741	11	58	44
10	7,5	132S	1760	26,6	8,0	4,07	2,2	3,0	86,0	88,0	89,0	0,66	0,77	0,83	1,15	0,04652	5	61	62
12,5	9,2	132M	1755	33,3	8,7	5,10	2,5	2,9	86,3	87,8	88,5	0,62	0,73	0,82	1,15	0,05427	5	61	69
15	11	132M	1755	39,3	8,3	6,12	2,3	2,8	86,8	88,2	88,5	0,68	0,80	0,83	1,15	0,05815	5	61	72
20	15	160M	1760	52,6	6,3	8,14	2,3	2,2	88,0	89,3	90,2	0,69	0,79	0,83	1,15	0,09535	13	69	114
25	18,5	160L	1755	64,3	6,3	10,2	2,3	2,4	89,0	90,0	91,0	0,70	0,79	0,83	1,15	0,11542	15	69	128
30	22	180M	1765	75,5	7,5	12,2	2,8	2,8	89,3	90,0	91,0	0,70	0,80	0,84	1,15	0,16145	12	68	158
40	30	200M	1770	101	6,6	16,2	2,3	2,5	89,5	90,5	91,7	0,72	0,82	0,85	1,15	0,27579	19	71	216
50	37	200L	1770	122	6,6	20,2	2,3	2,3	90,2	91,5	92,4	0,75	0,83	0,86	1,15	0,33095	16	71	252
60	45	225S/M	1775	146	7,2	24,2	2,3	2,7	91,0	92,2	93,0	0,75	0,84	0,87	1,00	0,69987	20	75	363
75	55	225S/M	1775	176	7,4	30,3	2,2	2,7	90,3	92,0	93,0	0,76	0,84	0,88	1,00	0,80485	15	75	386
100	75	250S/M	1780	242	8,8	40,2	3,2	3,2	92,0	93,0	93,5	0,74	0,83	0,87	1,15	1,15478	12	75	486
12,5	9,0	280S/M	1780	293	7,3	50,3	2,2	2,5	91,5	92,9	93,8	0,75	0,83	0,86	1,00	1,92710	25	80	658
150	110	280S/M	1785	353	8,0	60,2	2,6	2,7	91,5	93,5	94,1	0,78	0,84	0,87	1,00	2,59947	20	80	753
175	132	315S/M	1785	433	7,5	70,2	2,5	2,5	91,0	93,0	94,1	0,79	0,83	0,85	1,00	2,81036	14	82	899
200	150	315S/M	1785	494	7,5	80,2	2,4	2,6	90,5	93,0	94,5	0,75	0,83	0,86	1,00	3,21184	19	82	924
250	185	315S/M	1785	597	8,3	100	2,8	2,8	91,0	93,0	94,5	0,76	0,84	0,86	1,00	3,77391	22	82	1010
300	220	350M/L	1790	691	7,0	120	2,2	2,3	93,0	94,5	95,0	0,79	0,85	0,88	1,00	6,33813	48	83	1428
350	260	350M/L	1790	815	7,3	140	2,3	2,4	92,9	94,6	95,1	0,77	0,85	0,88	1,00	7,45663	32	83	1544
400	300	350M/L	1790	939	6,6	160	2,1	2,1	93,3	94,7	95,3	0,81	0,86	0,88	1,00	9,32079	37	83	1723
450	330	350M/L	1790	1030	7,1	180	2,1	2,1	93,8	94,8	95,4	0,77	0,85	0,88	1,00	10,25287	39	83	1837
500	370	350M/L	1790	1160	6,6	200	2,1	2,2	93,9	95,0	95,4	0,79	0,85	0,88	1,00	11,18495	31	83	1923

**ANEXO B – Constantes térmicas de motores em relação ao tipo de carcaça.**

- Constantes térmicas típicas (Santos, A. H. M., et al.; 2001).

Carcaça	Rotação (rpm)			
	900	1200	1800	3600
63		10,0	11,0	6,5
71				8,0
80	19,0			9,0
90S		16,5	13,0	9,0
90L			16,0	11,0
100L		17,5	18,0	11,5
112M	25,0	20,5		8,0
132M	32,0	37,0		
132S			24,0	12,0
160L	35,0	40,0	35,0	
160M		32,0		21,5
180L	37,0	33,0		
180M	30,0		33,0	
200L	46,0	35,0	27,0	
200M		43,0	28,0	23,0

### ANEXO C – Desenvolvimento matemático da equação do conjugado de um MIT.

Tomando-se as equações básicas (1), (2) e (3) a seguir e manipulando-as com base no circuito equivalente tem-se, portanto, a equação do torque total de um MIT:

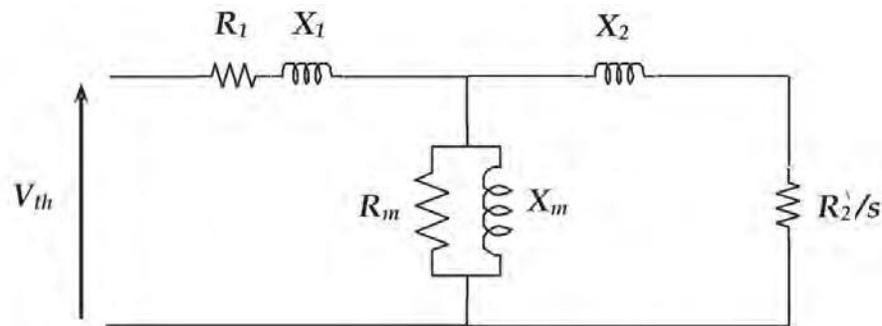


Figura 1 – Circuito equivalente de um MIT

$$P = \frac{R_2'}{s} \cdot (I_2')^2 \quad (1)$$

$$I_2' = \frac{V_{th}}{\sqrt{\left(R_1 + \frac{R_2'}{s}\right)^2 + (X_1 + X_2')^2}} \quad (2)$$

$$M = \frac{60}{2\pi n_s} \cdot P \quad (3)$$

De (1), (2) e (3) tem-se:

$$M = 3 \cdot \frac{60}{2\pi n_s} \cdot \frac{R_2'}{s} \cdot \frac{V_{th}^2}{\left(R_1 + \frac{R_2'}{s}\right)^2 + (X_1 + X_2')^2}$$

**ANEXO D** - Artigo publicado no congresso internacional LAPTEC no Brasil em 2007.

## Estimação do Torque de um Motor de Indução Através de Redes Neurais Artificiais

André Luiz Zamponi RIBEIRO<sup>a,1</sup>, Luiz Octavio Mattos dos REIS<sup>b</sup>, João Sinohara da Silva SOUSA<sup>b</sup>, Ronaldo ROSSI<sup>b</sup>,

<sup>a</sup>*Departamento de Engenharia Mecânica, UNITAU, Brasil*

<sup>b</sup>*UNITAU, Brasil*

**Resumo.** As Redes Neurais Artificiais (RNA's) são extremamente úteis quando se quer estimar e prever os possíveis comportamentos que um dado sistema pode apresentar. Elas podem ser aplicadas a várias áreas de estudos e em muitos casos, os resultados obtidos baseados nos dados estudados, mostram com boa aproximação o que se espera do sistema analisado. O presente artigo apresenta um estudo onde o torque de um motor de indução trifásico poderá ser estimado através das RNA's. O algoritmo de treinamento utilizado foi o *backpropagation* e o sistema foi simulado com o auxílio das ferramentas de redes neurais do MatLab®. A proposta do trabalho é avaliar os resultados obtidos para um caso específico de maneira a verificar a aplicabilidade dessa ferramenta, e posteriormente, aplicá-la a casos mais gerais.

**Palavras Chave.** Redes neurais, motor de indução, torque eletromagnético.

### Introdução

A eficiência energética é uma área de estudo bastante importante principalmente na atualidade, onde o uso racional da energia elétrica se torna essencial para o desenvolvimento por ser uma das fontes de energia mais utilizadas no mundo. Os motores elétricos de indução por sua vez, têm um papel fundamental nesse cenário já que são amplamente utilizados nos diversos setores industriais, comerciais, etc. e nas mais diversas aplicações chegando a representar por volta de 35% do consumo total de energia elétrica do Brasil, por exemplo [1]. Daí a importância de serem bem dimensionados de maneira a utilizar, da melhor maneira possível, a energia elétrica demandada por esses consumidores. O trabalho proposto tem como finalidade determinar o torque desenvolvido por um motor de indução trifásico qualquer, tendo

como referência a velocidade apresentada por ele num dado momento de sua operação. De posse dessa informação, pode-se avaliar as condições de operação do motor e avaliar se essa operação está adequada a melhor performance do mesmo; para tanto foram utilizados os conceitos de Redes Neurais Artificiais (RNA's). As RNA's são utilizadas em diversas aplicações, no setor financeiro quando se quer prever uma determinada situação, no controle de máquinas elétricas [4] e no reconhecimento de imagens, entre outras, e se mostra bastante eficiente em muitos casos. Sua utilização se torna interessante, onde sistemas extremamente complexos, são modelados e outras ferramentas convencionais, não podem ser aplicadas, se tornam ineficientes ou são extremamente caras. No trabalho proposto, uma RNA foi criada e aplicou-se o algoritmo de treinamento chamado de *backpropagation* através da ferramenta MatLab® para a simulação do sistema em questão. Os resultados obtidos foram satisfatórios e serão apresentados mais tarde nesse artigo, mostrando assim que o uso dessa ferramenta é viável para esse caso e pode ser testada em aplicações mais complexas.

## 1. Determinação do torque do motor de indução

### 1.1 Comportamento do torque em motores de indução trifásicos

A Figura 1 mostra o comportamento típico do torque em motores de indução trifásicos em relação à velocidade do motor, este torque pode variar de acordo com o projeto do motor e tipo de partida utilizada.

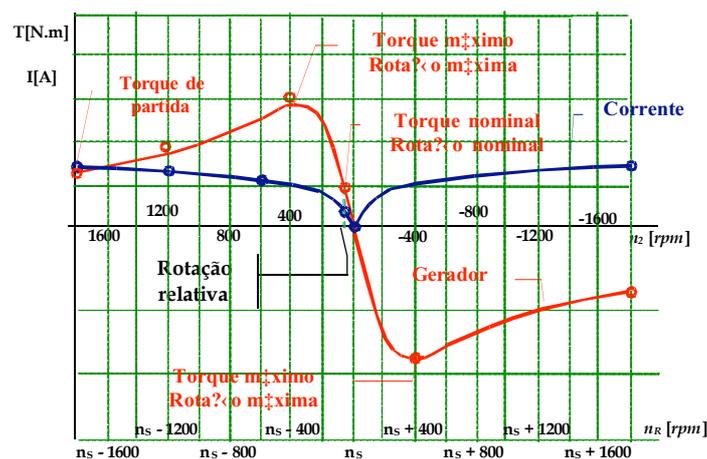


Figura 1. Comportamento do torque e da corrente para um motor de indução em relação à velocidade

De acordo com a NBR 7094 os motores de indução trifásicos são classificados em três categorias de acordo com a relação entre o conjugado e a velocidade desenvolvida. Essas

características são descritas na Tabela 1.

**Tabela 1.** Categoria de motores de indução de acordo com a relação torque x velocidade

Categoria	Características
N	Conjugado e corrente de partida normais e baixo escorregamento
H	Alto conjugado de partida, corrente de partida normal e baixo escorregamento
<i>D</i>	Alto conjugado de partida, corrente de partida normal e alto escorregamento

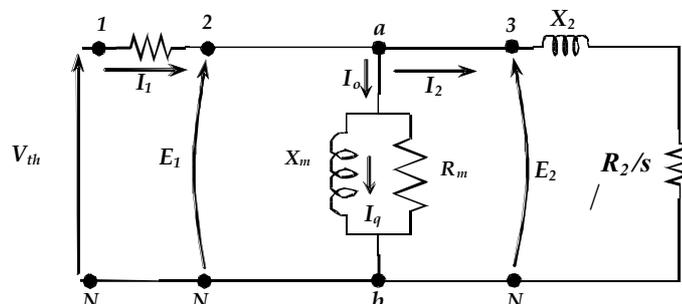
O comportamento do conjugado de um motor de indução depende também do tipo de carga aplicada que pode ser de quatro tipos como mostrado na Tabela 2. Dependendo do tipo de carga, parâmetros como tempo de aceleração, frenagem, torque de partida e etc., vão mudar.

**Tabela 2.** Tipos de cargas

Tipo de Carga	Característica
Constante	O conjugado da carga se mantém constante independente da velocidade
Linear	O conjugado da carga aumenta linearmente com o aumento da velocidade
Quadrática	Conjugado varia de acordo com uma parábola em relação a velocidade
<i>Inversa</i>	Conjugado varia de acordo com uma hip em relação a velocidade

### 1.2 Equações

Partindo-se do circuito elétrico monofásico equivalente de um motor de indução trifásico representado na Figura 2, pode-se chegar as equações utilizadas para o cálculo do torque desenvolvido pelas 3 fases.



**Figura 2.** Circuito equivalente do motor de indução

Portanto, utilizando-se do circuito equivalente de Thevenin, chega-se as equações aproximadas a seguir:

$$T \cong 3 \frac{V_{th}^2}{(X_{th} + X_2)^2} \frac{R_2}{s} \frac{1}{n_s} \quad (1)$$

Onde: T é o conjugado;  
 $V_{th}$  é a tensão equivalente de thevenin;  
 $X_{th}$  é a reatância equivalente de thevenin;  
s é o escorregamento;  
 $n_s$  é a velocidade síncrona do motor.

$$T \cong 3 \frac{V_{th}^2}{R_2} \frac{s}{n_s} \quad (2)$$

Onde: T é o conjugado;  
 $V_{th}$  é a tensão equivalente de thevenin;  
s é o escorregamento;  
 $n_s$  é a velocidade síncrona do motor.

No caso do torque temos duas situações distintas, na partida onde o escorregamento é um representado pela Eq. (1) e na faixa de operação aonde o escorregamento chega perto de zero representado pela Eq. (2).

### 1.3 Valores utilizados nas simulações

O motor escolhido para a simulação é um motor WEG de 4 polos, 60 Hz, 5 cv, 220 V, 1735 rpm e com os conjugados nominais de 2,06 kgf.m, de partida de 4,94 kgf.m e máximo de 6,18 kgf.m. Levando-se em consideração a curva de torque característica desse motor será considerada a chamada faixa de operação que, com uma aproximação razoável, pode ser considerada linear e obedece a Eq. (3).

$$T = \frac{n - n_s}{n_N - n_s} T_N \quad (3)$$

Onde: T é o torque;  
n é a velocidade do motor;  
 $n_s$  é a velocidade síncrona do motor;  
 $n_N$  é a velocidade nominal do motor;  
 $T_N$  é o torque nominal do motor.

Partindo-se de 90% da velocidade síncrona e adotando-se um passo de 1% montou-se o

conjunto de dados descritos na Tabela 3.

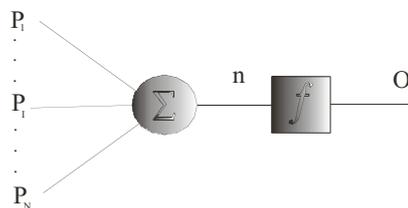
**Tabela 3.** Valores calculados

Torque (N.m)	Velocidade (rpm)
55,94	1620
50,34	1638
44,75	1656
39,16	1674
33,56	1692
27,96	1710
22,38	1728
16,78	1746
11,19	1764
5,59	1782
0,00	1800

## 2. Metodologia aplicada e resultados obtidos

### 2.1 Redes Neurais Artificiais e o algoritmo backpropagation

Basicamente as partes que compõem o neurônio humano podem ser descritas como os axônios, soma, membrana e dendritos. Cada neurônio se conecta com vários outros formando uma enorme rede e essas conexões se dão entre os axônios e dendritos formando-se sinapses. A informação flui através dos neurônios em forma de pulsos elétricos que são transmitidos de um neurônio para o outro, dependendo de um mecanismo específico que desencadeia esses pulsos. Cada neurônio possui um *threshold* que quando ultrapassado pelo pulso elétrico que é gerado por reações químicas, permite que esse pulso passe para o neurônio seguinte e assim por diante. A transmissão desses pulsos acontece de acordo com o que é chamado de peso do neurônio, o que define quanto eficiente será a transmissão desse pulso. O neurônio artificial tem como modelo o humano portanto ele é composto por partes com funções semelhantes como as entradas, o peso de cada entrada, a função de transferência, as entradas e saídas da função de transferência como mostrado na Figura 3.



**Figura 3.** Neurônio artificial

As RNA's podem ser do tipo *feed-forward* onde os sinais elétricos fluem somente em um sentido, da entrada para a saída, e a saída de cada camada da rede não tem efeito em nenhuma das camadas anteriores. Outro tipo de RNA é a chamada rede feedback onde os sinais fluem em dois sentidos diferentes, um fluindo da entrada para a saída e outro no

sentido inverso alterando o estado de neurônios em camadas anteriores a do sinal. Isso significa que dependendo dos sinais de uma dada camada os pesos atribuídos a camadas anteriores são modificados. Esses tipos de RNA's podem se tornar bastantes complexas e são úteis na resolução de problemas complexos.

No algoritmo *backpropagation* sinais são aplicados na camada de entrada e cada um desses sinais é multiplicado pelos respectivos pesos de cada neurônio. Assim que o *threshold* de cada neurônio for ultrapassado o sinal é transmitido para a camada subsequente e assim por diante até a camada de saída for atingida. Quanto o sinal atinge essa camada é comparado com o sinal desejado e os erros entre eles são calculados. Feito isso, os valores são aplicados à camada anterior e recalculam-se os pesos de cada neurônio com a finalidade de minimizar os erros. Esse processo continua até que o erro seja o esperado ou a camada de entrada seja atingida caracterizando o processo de *feedback*.

Dependendo dos pesos atribuídos a cada entrada, o processo se torna mais ou menos eficiente podendo convergir mais rapidamente o não convergir. Os resultados obtidos também variam dependendo do número de neurônios em cada camada e do número de camadas que vão formar a rede a ser treinada. As equações que modelam o algoritmo *backpropagation* e que são usadas pelo mesmo são apresentadas a seguir [2].

1. Equação da rede *feed-forward*:

$$O_i^{l+1}(k) = f\left(\sum_{j=1}^{n_{l+1}} w_{ij}^l O_j^l(k)\right) \quad (4)$$

Onde:  $O_i^{l+1}(k)$  = sinal de saída do *i-ésimo* nó na camada  $l+1$ ;

$O_j^l(k)$  = sinal de saída do *j-ésimo* nó da camada  $l$ ;

$w_{ij}^l$  = *i-ésimo* peso do *j-ésimo* nó da camada  $l$ ;

$$f(x) = \frac{1}{1 + e^{-\beta x}} = \text{função sigmoide.}$$

2. O erro é calculado pelo método dos mínimos quadrados (mse):

$$E = \sum_{k=1}^K \left( \frac{1}{2} \sum_{i=1}^{n_l} [T_i(k) - O_i^l(k)]^2 \right) \quad (5)$$

Onde:  $T_i(k)$  = valores desejados;

$O_i^l(k)$  = *i-ésimo* valor de saída da camada de saída.

3. O gradiente utilizado para recalculer os pesos é:

$$\delta_i^L = (T_i - O_i^L) O_i^L (1 - O_i^L) \quad (6)$$

e

$$\delta_i^l = \left( \sum_{r=1}^{n_l} \delta_r^{l+1} w_{ri}^{l+1} \right) O_i^l (1 - O_i^l) \quad (7)$$

Onde:  $\delta_i^l$  = gradiente da *i*-ésima saída da camada de saída;

$\delta_i^l$  = gradiente da *i*-ésima saída da camada oculta;

$O_i^l$  = *i*-ésima saída da camada de saída;

$O_i^l$  = *i*-ésima saída da camada oculta;

$T_i$  = *i*-ésimo valor desejado;

$w_{ri}^{l+1}$  = *r*-ésimo peso do *i*-ésimo nó da camada l+1.

4. A diferença calculada para o peso é:

$$\Delta w_{ij}^l = \eta \delta_i^l O_j^{l-1} \quad (8)$$

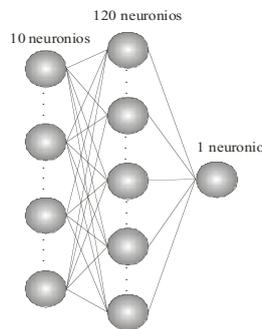
Onde:  $\Delta w_{ij}^l$  = diferença calculada para o *j*-ésimo peso do *i*-ésimo nó da camada l;

$\delta_i^l$  = gradiente do *i*-ésimo nó na camada l;

$O_j^{l-1}$  = *j*-ésima saída na camada l-1;

## 2.2 Rede Utilizada e Resultados

Utilizando-se o Matlab®, uma rede neural com 10 neurônios na camada de entrada, 120 neurônios na camada oculta e 1 neurônio na camada de saída (Figura 4), o sistema foi treinado e os resultados podem ser vistos nas Figuras 5 e 6. A função de transferência entre a camada de entrada e oculta foi a tan-sigmoide e entre a camada oculta e de saída foi uma função linear. A simulação foi feita utilizando-se o algoritmo backpropagation com erros calculados pelo método dos mínimos quadrados [3].



**Figura 4.** Ilustração da rede neural utilizada

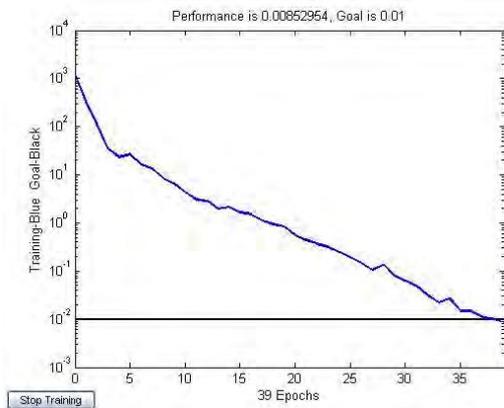


Figura 5. Desempenho da rede

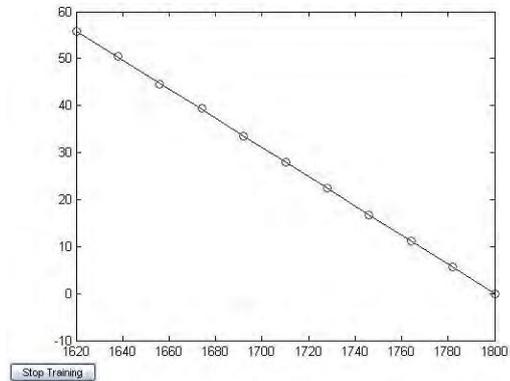


Figura 6. Resultados obtidos

### 3. Conclusões

Os resultados obtidos nesse estudo se mostraram satisfatórios. A simulação realizada foi focada na chamada faixa de operação do motor e para efeito de cálculos a mesma foi considerada linear, com boa aproximação. Contudo estudos mais complexos abordando sistemas não lineares, mais completos, se mostram possíveis de serem simulados baseados nas respostas obtidas. Estudos futuros serão realizados considerando-se não somente o torque, mas também outras grandezas relevantes para um motor de indução sendo combinadas em uma só RNA, traçando um quadro mais completo da condição de operação do motor.

### Referências

- [1] Moreira, H. J. F. et al., “Guia Operacional de Motores Elétricos”, Eletrobrás, Rio de Janeiro, 2000, pp. 61-64
- [2] Kartalopoulos, S., “Understanding Neural Networks and Fuzzy Logic”, IEEE Press, Piscataway, NJ, USA, 1996, pp. 76-81.
- [3] Demuth, H., Beale, M. and Hagan, M., 2007, “Neural Networks Toolbox 5 User’s Guide”, Mathworks Inc., Natick, MA, USA, pp. 5.2-5.72.
- [4] Contatori, C., “Um Sistema Inteligente Baseado em Redes Neurais Artificiais, aplicado a Monitoração Térmica de Máquinas Elétricas”, Universidade de Taubaté, Taubaté, São Paulo, 2005, .43.

# An Induction Motor Stator Temperature Estimation Using Artificial Neural Networks

A. L. Z. Ribeiro, L. O. M. Reis, R. Rossi, J. Sinohara

**Abstract**— Induction motors are largely used in the industry in our days and the temperature monitoring in these motors is extremely important for their operation. Through this monitoring one can estimate when and how often the maintenance will be performed, adjust the proper protection and identify abnormal operation conditions. In some cases the installation of thermal sensors is not possible due to physical or economical restrictions and the utilization of virtual instrumentation is an option. The following work presents a study for a specific condition where the stator temperature for a generic induction motor in a steady state operation is estimated by using an Artificial Neural Network. The purpose of this study is the evaluation of the applicability of this tool for this specific case and it is the starting point for further studies where the feasibility of a general system can be tested. After simulating the proposed Artificial Neural Network using the backpropagation algorithm it was concluded that this is an applicable method to solve this problem and can be extended to more complex systems.

**Index Terms**— Induction Motor, Artificial Neural Networks, Temperature Estimation.

## I. INTRODUCTION

A big part of the failures identified on induction motors in industrial environments are related to high temperatures during the operation, it can happen during the start up or on the steady state operating cycle. Unbalanced voltages, hostile environments, overloads can cause overheats that damages the stator or rotor coils among other problems. Many methods to calculate and estimate both stator and rotor temperature were developed and can be used by engineers and designers, [5] and [1] are examples of some of the techniques developed that can be applied. This paper will focus on the stator temperature analysis using the winding resistance variation experiment, simplifications extracted from [4], and a 10 (CV), 1800 (rpm) IPW55 Siemens three phase motor [6].

After completing the stator temperature analysis and defining the safe temperature operation level, the Artificial Neural Networks (ANN) techniques are applied in order to estimate the current temperature depending on the measured

stator currents. ANNs are used in many fields and it is a very useful tool to estimate, control and predict a future condition. The chosen training algorithm was the backpropagation, and the simulations were performed using MatLab®.

## II. THREE PHASE INDUCTION MOTOR TEMPERATURE ANALYSIS

One of the most important factors that determines the life cycle of an induction motor is its operation temperature. Depending on the heat acting on the insulation, motor's life can be extended or shortened. According to studies an increase of 8 to 10 degrees Celcius above the maximum operation temperature allowed can reduce a motor's life to half of the original [4]. The temperature estimation method used here is the winding resistance method; this method consists in measuring the motor winding resistance in ohms during a determined operation time length. Based on the different values obtained during the experiment one can calculate the motor's temperature at a chosen time using the following equation:

$$\Delta T = T_2 - T_a = \frac{R_2 - R_1}{R_1} (235 + T_1) + T_1 - T_a \quad (1)$$

Where:  $\Delta T$  = temperature elevation

$T_1$  = winding temperature before the experiment;

$T_2$  = winding temperature in the end of the experiment;

$T_a$  = cooling mean temperature in the end of the experiment;

$R_1$  = winding resistance before the experiment;

$R_2$  = winding resistance in the end of the experiment.

According to the Brazilian standard NBR 7034 the induction motor insulation classes are:

---

The authors are with the Mechanical Engineering department of the Taubaté University at Taubaté, Rua Daniel Danelli, s/n, Taubaté, São Paulo, Brazil.

Insulation Class	Temperature (°C)
A	105
E	120
B	130
F	155
H	180

Observing the standard values for temperature limits in induction machines and admitting the ambient temperature to be the maximum of 40 (°C), as per Brazilian standards, Table II shows typical values for temperature limits on the hottest point:

TABLE II  
TYPICAL TEMPERATURE LIMITS ON INDUCTION MOTORS DEPENDING ON INSULATION CLASS

Parameters	Class A	Class E	Class B	Class F	Class H
Maximum temperature elevation allowed ( $\Delta T_{\max}$ ) – Winding resistance method (°C)	60	75	80	100	125
Ambient temperature (°C)	40	40	40	40	40
Difference between the hottest spot and the average temperature (°C)	5	5	10	15	15
Hottest spot temperature (°C)	105	120	130	155	180

In order to determine the motor heating in a simplified way it is known that the insulation temperature depends on losses caused by temperature, load condition and ambient temperature as described in [4]. Analyzing the steady state operation, the maximum temperature elevation reached can be calculated according to the following simplified equation considering the insulation as a homogeneous body:

$$\Delta T_f = \left( \frac{I}{I_N} \right)^2 \cdot \Delta T_{\max} \quad (2)$$

Where:  $\Delta T_f$  = final temperature elevation reached in the steady state operation;

$I$  = operation current;

$I_N$  = nominal current;

$\Delta T_{\max}$  = maximum temperature elevation allowed.

#### A. Temperature calculation

The chosen motor to perform the analysis is the Siemens three phase induction motor IPW55 with 10 (CV) and 1800 (rpm). The nominal current ( $I_N$ ) at 380 (V) is 15.7 (A) for this motor. In order to create a set of temperature values that will be used as reference to train the ANN, the nominal current

will be adopted as the maximum current value and according to the Eq. (2) it corresponds to the maximum temperature increase limit ( $\Delta T_{\max}$ ). The current range analyzed will consider a -10% variation of the nominal current and by applying a 0.1 (A) step to this current the goal values are defined. As this motor is in the H class of insulation according to Brazilian standards, the maximum temperature limit ( $\Delta T_{\max}$ ) is 125 (°C), see Tab. 3. After applying these current values to Eq. (2), Tab. 4 was created:

TABLE III  
MAXIMUM TEMPERATURE INCREASE CALCULATED BY EQ. (2)

Motor current (A)	$\Delta T_{\max}$ (°C)
14.1	100.8
14.2	102.3
14.3	103.7
14.4	105.2
14.5	106.6
14.6	108.1
14.7	109.6
14.8	111.1
14.9	112.6
15.0	114.1
15.1	115.6
15.2	117.2
15.3	118.7
15.4	120.3
15.5	121.8
15.6	123.4
15.7	125.0

### III. THE ARTIFICIAL NEURAL NETWORK

#### A. Introduction

The idea of reproducing the human brain using electronic means had begun many decades ago. Based on the human neuron structure and its “ways of working”, scientists and researchers created an electronic model of a neuron and developed many different artificial networks layouts composed by these neurons, trying to replicate, in the most efficient and reliable way, the actual human neural networks. The ability to identify previous known conditions, relate different objects and situations and learn from new experiences are some of the human brain capabilities that the Artificial Neural Networks (ANN) tries to reproduce. If an artificial system could work in the same way as a human brain, it could be applied to many problems that are extremely difficult to be modeled and requires complex systems designs or even cannot be yet solved.

#### B. The human and artificial neuron structures

Fig. 1 shows the physiology of a human neuron. The neuron is composed basically by soma, membrane, dendrites, axon, intracellular and extracellular fluids.

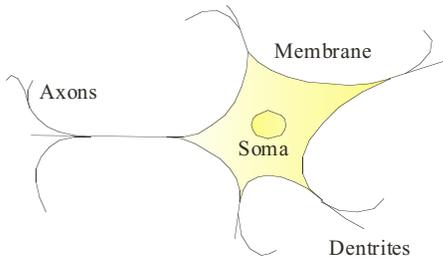


Fig. 1. Human neuron

The connections between neurons are called synapses and these are the connections between the dendrites from one neuron and the axons from other neurons in a simplified way. One neuron is connected to many others forming a network with many layers. The information flows across this network through electrical pulses which are generated by the interaction across the membrane of different substances found on the neuron as proteins, for example. When this electrical signal reaches a certain threshold on a particular neuron it is transmitted to the others connected to it, and depending on how efficient is the connection between neurons, different weights are associated to each connection.

Based on the human neuron the model of the artificial neuron will be composed by an input ( $p$ ), the input weight ( $w$ ), a transfer function ( $f$ ) and an output ( $O$ ), see Fig. 2.

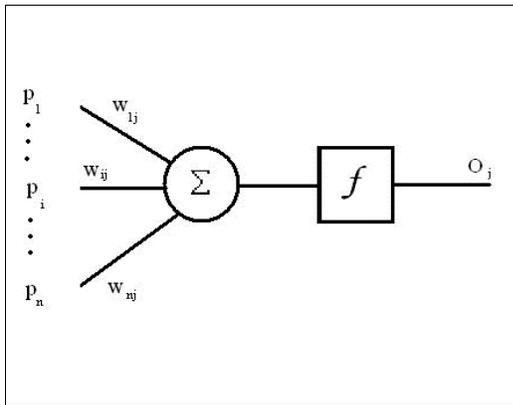


Fig. 2. Artificial Neuron

Using this artificial neuron as the basic element, a neural network can be assembled in many different layouts. Figure 3 shows some ANNs different layouts.

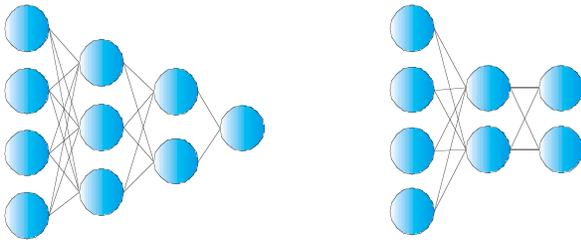


Fig. 3. Artificial Neural Networks examples

### C. The backpropagation algorithm

Among many existing training algorithms, the backpropagation one was chosen to this particular study. This algorithm is one of the most used and it will be described next.

First, input values are fed into the first layer of the network and these, combined with pre determined weight values, generates a signal that will be transferred to the next layer if the neuron threshold is reached. The same process happens on the second layer and so on until it reaches the output layer in a feed forward way. The values in the output layer are compared to the expected goal, the errors between them are calculated, and then the network steps back to the previous layer in order to recalculate the weights, trying to minimize these errors. This process will continue towards the next previous layer that and so on, until the input layer is reached and the weights remain the same.

The following equations are used on this algorithm [3]:

- Feed forward network equation:

$$O_i^{l+1}(k) = f(\sum_{j=1}^{n_{l+1}} w_{ij}^l O_j^l(k)) \quad (3)$$

Where:  $O_i^{l+1}(k)$  = output signal from the  $i$ -th node on layer  $l+1$ ;

$O_j^l(k)$  = output signal from the  $j$ -th node from layer  $l$ ;

$w_{ij}^l$  =  $i$ -th weight from the  $j$ -th node from layer  $l$ ;

$$f(x) = \frac{1}{1 + e^{-\beta x}} = \text{sigmoid function.}$$

- The error is given by the least mean square error (MSE):

$$E = \sum_{k=1}^K \left( \frac{1}{2} \sum_{i=1}^{n_l} [T_i(k) - O_i^L(k)]^2 \right) \quad (4)$$

Where:  $T_i(k)$  = target values;

$O_i^L(k)$  =  $i$ -th output value from output layer.

- The gradient used to recalculate the weights is:

$$\delta_i^L = (T_i - O_i^L) O_i^L (1 - O_i^L) \quad (5)$$

and

$$\delta_i^l = \left( \sum_{r=1}^{n_{l+1}} \delta_r^{l+1} w_{ri}^{l+1} \right) O_i^l (1 - O_i^l) \quad (6)$$

Where:  $\delta_i^L$  = gradient from the  $i$ -th output from the output layer;

$\delta_i^l$  = gradient from the  $i$ -th output from the hidden layer;

$O_i^L$  =  $i$ -th output from the output layer;

$O_i^l = i$ -th output from the hidden layer;  
 $T_i = i$ -th target value;  
 $w_{ri}^{l+1} = r$ -th weight from the  $i$ -th node from layer  $l+1$ .

- The weight difference is given by:

$$\Delta w_{ij}^l = \eta \delta_i^l O_j^{l-1} \tag{7}$$

Where:  $\Delta w_{ij}^l =$  difference for the  $j$ -th weight from the  $i$ -th node from layer  $l$ ;

$\delta_i^l =$  gradient for the  $i$ -th node on layer  $l$ ;

$O_j^{l-1} = j$ -th output on layer  $l-1$ ;

Fig. 4 illustrates the calculated values on a feed forward network:

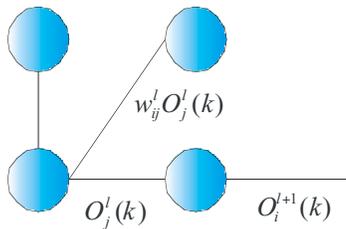


Fig. 4. Feed forward network

#### IV. SIMULATION RESULTS

Using MatLab® a feed forward ANN composed by a 17 entries input layer, a intermediate 34 neurons layer and a single neuron output layer was modeled as shown in Fig. 5. Using the backpropagation training algorithm, descent gradient learning algorithm and the mean square error function the network was simulated [2].

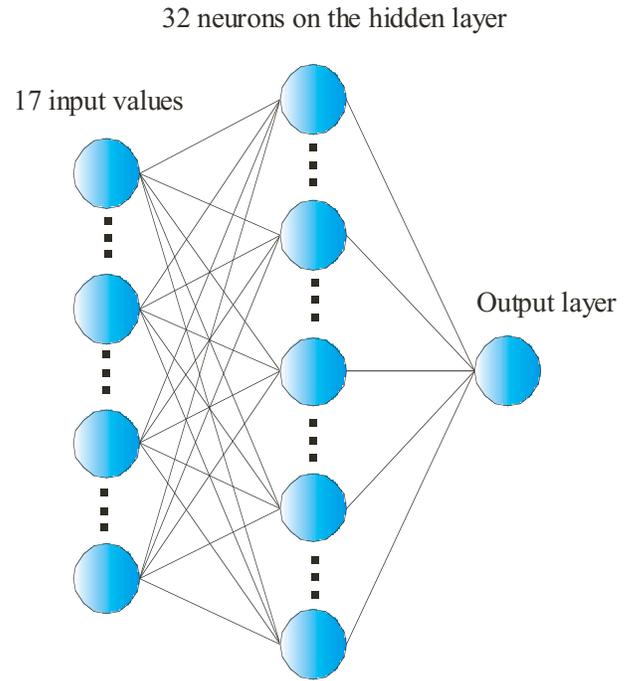


Fig. 5. ANN used on the simulation.

The transfer function used between the input and the hidden layer was the tan-sigmoid function and the one used between the hidden layer and the output was the linear transfer function. After simulating this network the goal was met after 171 epochs and the values obtained can be found in Tab.5. The performance graphic is shown in Fig. 6 and the results in Fig. 7.

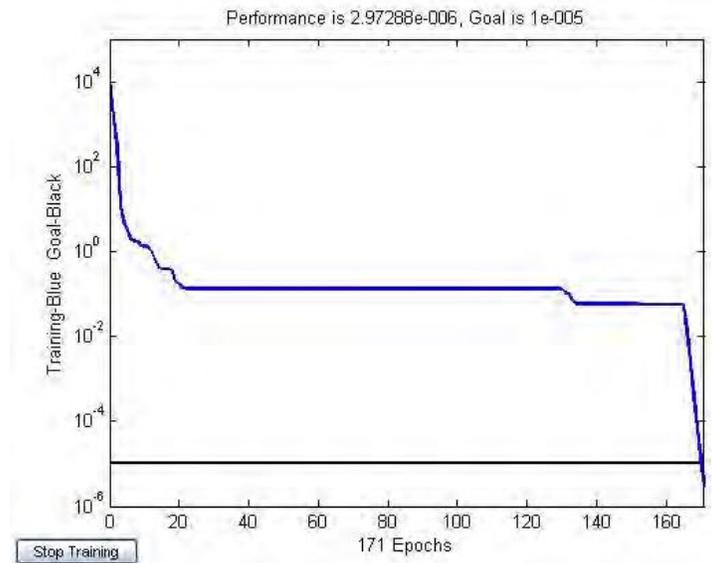


Fig. 6. Network performance

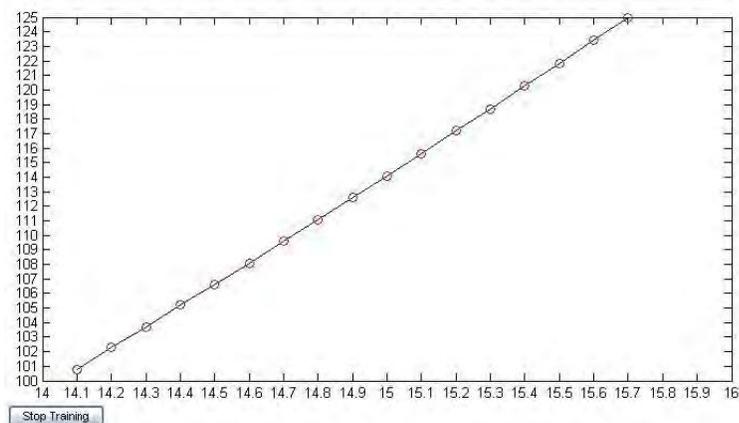


Fig. 7. Values obtained after simulation

## V. CONCLUSIONS

The results obtained in this simulation were satisfactory indicating that the application of ANN's in the estimation of the proposed target values is possible. Based on this study other more complex systems will be analyzed and different algorithms will be tested as well.

## VI. REFERENCES

- [1] Beguenane, R., Benbouzid, M.E.H., 1999, "Induction Motors Thermal Monitoring by Means of Rotor Resistance Identification", IEEE Transactions on Energy Conversion, Vol. 14, No. 3, pp. 566-567.
- [2] Demuth, H., Beale, M. and Hagan, M., 2007, "Neural Networks Toolbox 5 User's Guide", Mathworks Inc., Natick, MA, USA, pp. 5.2-5.72.
- [3] Kartalopoulos, S., 1996, "Understanding Neural Networks and Fuzzy Logic", IEEE Press, Piscataway, NJ, USA, pp. 76-81.
- [4] Santos, A.H.M, Simões, A.A., Martins, A.R.S., Viana, A.N.C., Borroni, E.C., Lora, E.E.S., Teixeira, F.N., Haddad, J., Cortez, J.A., Nogueira, L.A.H., Almeida, M.S.V., Pirani, M.J., Ventrini, O., Gama, P.H.R.P., Yamachita, R.A., Silva, V.F., "Conservação de Energia", Editora EFEI, 2001, Itajubá, Minas Gerais, Brazil, pp. 373-376
- [5] Lee, Y., Lee, H., Hahn, S., 1997, "Temperature Analysis of Induction Motor with Distributed Heat Sources by Finite Element Method", IEEE Transactions on Magnetics, Vol. 33, No. 2, pp. 1718-1719.
- [6] Siemens, 2007, "Three Phase Induction Motors Catalog". <<http://www.siemens.com.br/motores>>