

# TÉCNICAS COMPUTACIONAIS PARA A DETECÇÃO DE FALHAS POR CURTO-CIRCUITO ENTRE ESPIRAS DE UM MOTOR DE INDUÇÃO ACIONADO POR CONVERSOR DE FREQUÊNCIA

ÁTILA G. OLIVEIRA<sup>1</sup>, RENAN BESSA<sup>2</sup>, DAVID N. COELHO<sup>3</sup>, CLÁUDIO M. S. MEDEIROS<sup>2</sup>, RICARDO S.T. PONTES<sup>1</sup>

1. *Departamento de Engenharia Elétrica, Universidade Federal do Ceará, UFC*

*Endereço para Correspondência*

*E-mails: atilagirao@yahoo.com.br; ricthe@dee.ufc.br*

2. *Departamento da Indústria, Instituto Federal de Educação, Ciência e Tecnologia do Ceará, IFCE*

*Endereço para Correspondência*

*E-mails: claudiosa@ifce.edu.br; renan\_bessa@hotmail.com*

3. *Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, UFC*

*Endereço para Correspondência*

*E-mails: davidcoelho89@gmail.com*

**Abstract**— This work aims to early detect stator winding short circuit faults in converter-fed induction motors using Artificial Neural Networks. The Fourier Transformation is applied to generate the stator winding current spectrum that is used to selected fault features through two different techniques. One of them is based on the induction machine model theories and the other utilizes Principal Components Analysis, where the features are selected based on statistical information. A significant difference in results between the two feature extraction methods is noticed and a discussion about the advantages and disadvantages of each method is made. The data set used to train and validate the classifiers is acquired by a test bench where several levels of short-circuit can be applied to the induction motor.

**Keywords**— Artificial Neural Networks, Fault Detection, Induction Motor, Stator Winding Inter-turn Short-circuit

**Resumo** — Este trabalho visa à detecção prematura de curto-circuito entre espiras estáticas em motores de indução trifásico alimentados por conversor de frequência. A transformada de Fourier é aplicada para gerar o espectro harmônico das correntes estáticas, que é usado para seleção de características de falha por dois diferentes métodos. Um desses métodos é baseado em teorias referentes ao modelo da máquina de indução enquanto o outro é feito por Análise das Componentes Principais, que define as características de falha em função da representatividade estatística dos dados. Uma diferença significativa nos resultados encontrados a partir dos dois métodos, o que leva a uma discussão sobre as vantagens e desvantagens de cada método. O conjunto de dados usado para treinamento e validação dos classificadores é adquirido por uma bancada experimental de testes, onde vários níveis de curto-circuito podem ser aplicados ao motor de indução.

**Palavras-chave**— Curto-circuito Entre Espiras do Estator, Detecção de Falhas, Motor de Indução, Redes Neurais Artificiais.

## 1 Introdução

As máquinas de indução trifásicas (MITs) constituem a principal força motriz da indústria. De acordo com Thomson e Fenger (2001), em uma nação industrializada, os motores de indução podem demandar, tipicamente entre 40% e 50% de toda a capacidade elétrica gerada no país.

Porém, mesmo com a confiabilidade e robustez típicas desta máquina, ela não está isenta de falhas. Dentre elas, as de maior ocorrência são as falhas em rolamentos, de isolamento nos bobinamentos estáticos ou rotóricos, de quebra de barras, e por excentricidade (Nandi et al, 2005).

Essas falhas podem levar a paradas não programadas nas linhas de produção, o que geralmente incorrem em elevados custos. Assim, o monitoramento contínuo e em tempo real aliado à detecção prematura de falhas se apresenta como uma ferramenta poderosa na redução dos custos de manutenção quando viabiliza o agendamento de ordens de serviços para manutenção preditiva. Em falhas como quebras de barras do rotor, excentricidade, e falhas de rolamento, que demoram um tempo apreciável

para evoluir a um efeito mais danoso, o monitoramento constante dá condições para que os serviços de manutenção sejam agendados.

No entanto, nem sempre a detecção prematura pode evitar uma parada não programada. Por exemplo, a falha por curto-circuito entre espiras do estator evolui rapidamente. Thomson e Fenger (2001) fizeram um ensaio destrutivo em um motor de indução trifásico de baixa tensão aplicando um curto-circuito entre espiras estáticas e foi detectado que existe um tempo de apenas alguns minutos para a evolução da falha. Neste caso, a detecção prematura da falha permite uma rápida parada na operação, o que evita a geração de arcos elétricos e oferece uma proteção adicional em áreas onde há riscos de explosão. Outra vantagem, em caso de motores de alta potência, é a possibilidade de reparo do motor pela remoção das bobinas sob falha. Em motores de baixa potência, geralmente não é viável o reparo parcial do bobinamento, ainda assim a detecção prematura do curto-circuito pode evitar danos permanentes no núcleo estático por decorrência de arcos elétricos.

No caso de acionamentos de MITs através de conversores de frequência, notadamente em aplica-

ções com rotação variável (Bezesky e Kreitzer, 2003), a detecção prematura de falhas por curto-circuito seguida de uma interrupção no fornecimento de energia para o motor pode evitar a ocorrência de surtos de corrente e estresse térmico nas chaves eletrônicas, conferindo assim um caráter redundante à proteção contra curto-circuito.

A constante evolução de técnicas de inteligência computacional, aliada à crescente capacidade computacional de processadores de uso industrial, tem criado condições objetivas para a implementação dos detectores de falhas embarcados nos próprios conversores de frequência. Neste sentido, percebe-se algum interesse de pesquisadores através da publicação de trabalhos recentes. Por exemplo, Kowalski e Wolkiewicz (2009) analisaram o espectro da potência instantânea de Park e sinais de torque para detectar falhas incipientes por curto-circuito entre espiras do estator e quebra de barras rotóricas. Já Coelho e Medeiros (2013) tentaram classificar e mapear as falhas por Curto-Circuito Entre Espiras do Estator (CCEEE) utilizando “mapas auto-organizáveis” (*Self-Organizing Maps – SOM*).

Neste trabalho, são testados classificadores neurais Perceptron Simples (PS) e Perceptron Multi-Camadas (*Multi-layer Perceptron – MLP*) na detecção de falhas por CCEEE de um motor de indução trifásico acionado por um conversor de frequência. As redes *MLP* foram testadas com dois algoritmos de treinamento: retro-propagação do erro (*Back-propagation – BP*) e Máquina de Aprendizado Extremo (*Extreme Learning Machine – ELM*).

Como seleção de atributos para os classificadores, foram testadas duas técnicas. Ambas são baseadas no princípio de análise por assinatura de correntes, mas a primeira define atributos em função de teorias relacionadas às falhas de CCEEE em motores de indução, enquanto a segunda define os atributos da rede em função da representatividade estatística dos dados através da Análise de Componentes Principais (*Principal Components Analysis – PCA*).

A aquisição de dados foi feita através de uma bancada de testes onde vários níveis de curto-circuito e de carga podem ser aplicados ao motor de indução.

O artigo é organizado da seguinte forma: na seção 2, é mostrado o problema das falhas por curto-circuito no estator do motor de indução, já na seção 3 é descrito o método para aquisição de dados e as técnicas de seleção de atributos utilizadas. Na seção 4 são mostrados os resultados de classificação com os métodos propostos. Por fim, na seção 5 é feita a conclusão deste trabalho.

## 2 Curto-circuito entre espiras do bobinamento estatórico

Sistemas de isolamento em motores são submetidos a diversos tipos de esforços que podem causar falhas. De acordo com Nandi et al (2005), falhas de isolamento representam de 30% a 40% do total de falhas

relatadas dos motores de indução. Devido ao uso de conversores de frequência no acionamento de motores elétricos o estresse gerado chega a ser dez vezes maior que o de máquinas acionadas diretamente pela rede (Kaufhold, 2002). Tratando especificamente de falhas associadas ao bobinamento estatórico, a operação com frequências típicas de 10 kHz, sujeita o isolamento a esforços extras devido a grandes  $dv/dt$ .

O processo de falha inicia-se, normalmente, como uma falha de alta impedância (da ordem de  $k\Omega$ ) entre espiras da mesma fase, entre fases, ou entre fase e terra (Natarajan, 1989). A corrente de falha pode atingir duas vezes a corrente de rotor bloqueado, o que causa um alto aquecimento localizado e faz com que a falha se espalhe rapidamente.

Diferentes métodos para detecção de falhas por curto-circuito entre espiras foram utilizados em diversas pesquisas. Considerando o método de análise de assinatura de correntes do motor, Joksimovic e Penman (2000) mostram que não existem novas componentes no espectro de frequências devido a falhas de isolamento, e que apenas ocorre um aumento nas componentes já existentes. Stavrou et al (1999) procuram, no espectro de frequências de corrente, a variação nas frequências em função do número de polos, ranhuras e escorregamento, ou seja, em função das características operacionais e construtivas específicas.

Penman et al (1994) desenvolveram a seguinte equação

$$f_{cc} = \{k \pm n(1 - s)/p\}f_1 \quad (1)$$

para obter componentes harmônicas ( $f_{cc}$ ) no fluxo de dispersão através do eixo de motores relacionadas a falhas de curto-circuito entre espiras do estator. Nesta equação  $k = 1, 3, 5, \dots$ , é a ordem das harmônicas temporais,  $n = 1, 2, 3, \dots$ , é a ordem das harmônicas espaciais,  $s$  é o escorregamento,  $p$  é o número de pares de polos e  $f_1$  é a frequência fundamental da tensão de alimentação.

É importante salientar que algumas das frequências obtidas por decorrência da aplicação da equação 1 também podem estar relacionadas a outros tipos de falhas no motor ou na própria fonte de alimentação. Assim, Thomson e Fenger (2001) realizaram análises experimentais em motores de baixa potência para verificar que componentes de frequência sugeridas na equação 1 poderiam figurar no espectro de frequência da corrente estatórica em decorrência exclusiva de falha de curto-circuito entre espiras estatóricas. As componentes encontradas como função unicamente do curto-circuito se apresentam quando ocorrem simultaneamente  $k=1$  e  $n=3$ , e quando  $k=1$  e  $n=5$ . Para um motor a vazio ( $s=0$ ) com 2 pares de polos, essas componentes são  $2,5f_1$  e  $3,5f_1$ .

Ainda utilizando análise da assinatura de corrente do motor, Gazzana et al (2010) criou um sistema para detectar e diagnosticar, prematuramente, quebras de barras no rotor, excentricidade no eixo e falhas por CCEEE em motores de indução. Para estas últimas, a equação 1 é utilizada com  $k=1$  e  $n=7$ , e o

método Welch é utilizado para obter o espectro de frequências. A escolha de uma componente espacial de alta ordem no espectro é devido ao fato de que componentes de baixa ordem de excentricidade são coincidentes com as componentes de curto circuito.

Bouزيد et al (2008) utilizou uma rede neural para localizar a fase onde ocorre o curto-circuito. Foi escolhida como característica de falha o ângulo de fase entre as correntes e tensões das três fases. A detecção é feita através de uma rede MLP com 3 neurônios de saída, cada um representando uma fase. Se um neurônio está ativo, então a fase representada por este está em curto.

Das et al (2010) processou os sinais de corrente de linha através de uma transformação de Park, seguida por uma transformação Wavelet contínua, e utilizou Máquinas de Vetores de Suporte (*Support Vector Machine - SVM*) para classificar as características extraídas. Dos 18 casos de teste utilizados para predição, um total de 16 casos de falha foram corretamente identificados por uma SVM apropriadamente configurada.

Dentre todos os possíveis métodos de detecção de falhas, a assinatura de corrente tem um grande potencial, visto que este não é invasivo, apresenta alta capacidade para monitoramento remoto, pode ser aplicado a qualquer máquina sem restrição de potência, apresenta sensibilidade para falhas mecânicas da máquina, falhas elétricas no estator e problemas de alimentação, dentre outras (Thorsen e Dalva, 1997). Além dessas vantagens, em motores alimentados por conversores de frequência, há a possibilidade de embarcar o sistema de detecção no próprio conversor, especialmente se técnicas de inteligência computacional são utilizadas.

Neste artigo é apresentada uma proposta de utilização de redes Perceptron (simples e multicamadas) para classificar falhas por curto-circuito entre espiras estatóricas de motor de indução trifásico. Inicialmente, a equação (1), desenvolvida por Penman e explorada por Thompson, é utilizada como referência para a escolha das componentes de frequência obtidas através da aplicação da Transformada de Fourier (*TF*) como características para a detecção de falhas. Um método alternativo para seleção de atributos é a utilização da técnica de *PCA*, que por meio de uma transformação linear sobre o conjunto de dados original (espectro de frequências), projeta o mesmo em outro espaço com dimensionalidade reduzida, no qual a variância dos dados pode ser satisfatoriamente representada (Jolliffe, 2002).

### 3 Aquisição de dados e Seleção de Atributos

Nesta seção é descrita primeiramente a bancada de testes, e em seguida os detalhes da aquisição de dados e os métodos utilizados para realizar a seleção de atributos.

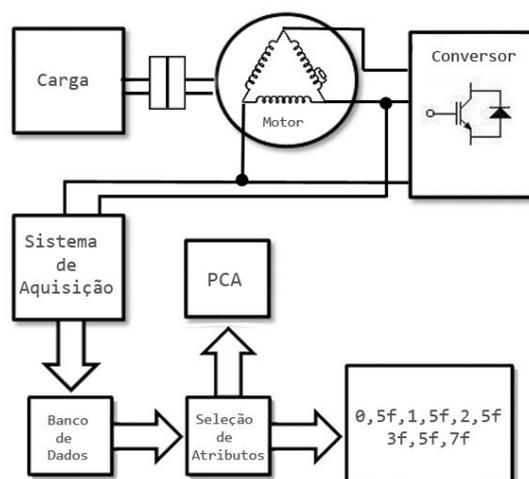
#### 3.1 Bancada de Testes

O objeto dos ensaios é um motor de indução trifásico, conectado em delta, cujo bobinamento foi

reorganizado por empresa especializada para permitir a derivação do mesmo para a emulação de falhas de curto-circuito de aproximadamente 1,41%, 4,81% e 9,26% do total de espiras do bobinamento de uma fase. O motor é da marca WEG, com os seguintes dados de placa: 0,75 kW (1,0 CV), 60 Hz, 220/380 V, 3,02/1,75 A, 1720 rpm, 79.5% de rendimento e fator de potência de 0,82 indutivo. Um conversor de frequência CFW-09, também da marca WEG, foi utilizado para acionar o motor de indução nas seguintes frequências pré-estabelecidas de 30 Hz, 35 Hz, 40 Hz, 45 Hz, 50 Hz, 55 Hz e 60 Hz.

Objetivando submeter o motor a condições de carga variáveis, os autores desenvolveram uma bancada de testes equipada com um freio de Foucault. Os níveis de carga aplicados ao motor foram de 50% e 100%. A figura 1 apresenta um esquema ilustrativo do processo de emulação, aquisição e formação do conjunto de dados.

Figura 1. Aquisição de Dados.



Como pode ser observado na figura 1, apenas duas das três correntes de linha são utilizadas para a formação do conjunto de dados. Uma das correntes está diretamente relacionada à bobina sob falha e a outra é afetada pela distorção do fluxo girante provocada pela falha. Estas correntes foram adquiridas pelo sistema de aquisição U2352 da marca Agilent, com 16 bits de resolução. Os sinais provenientes dos sensores do tipo *Hall* são primeiramente aplicados a um filtro analógico de ordem 2 e frequência de corte de 1 kHz, e em seguida, a um amplificador para adequar os níveis dos sinais para finalmente ser aplicado à entrada do sistema de aquisição de dados.

Os autores ainda tiveram a preocupação de emular, para cada percentual de espiras sob curto-circuito, dois níveis de severidade. No primeiro nível, aqui denominado curto-circuito de alta impedância (AI), a falha é emulada pela conexão de um resistor em paralelo com as espiras, de tal forma que o mesmo desvie parte da corrente desta seção de espiras. No segundo nível, aqui denominado curto-circuito de baixa impedância (BI), as espiras sob falha são destacadas do bobinamento e o resistor é conectado em série com as mesmas para a limitação

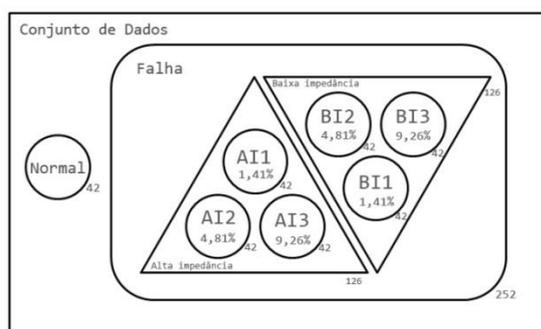
da corrente de curto-circuito ao nível da corrente nominal. No restante do texto os níveis de falha de alta impedância e baixa impedância podem ser associados aos Algarismos de 1 a 3 para representar a extensão da falha em relação aos percentuais crescentes (1,41%, 4,81% e 9,26%) do número total de espiras por bobinamento sob condição de falha. Assim, AI1 representa um curto-circuito de alta impedância em 1,41% das espiras (condição pouco severa) e AI3 representa um curto-circuito de alta impedância em 9,26% das espiras (o mais severo dentre todos emulados).

### 3.2 Aquisição de Dados

Os sinais das correntes de fase são coletados a uma taxa de amostragem de 10 kHz durante um tempo de 10 segundos, de tal forma que cada vetor de corrente amostrada contém 100.000 pontos. Para obter o espectro de frequências desses sinais, aplica-se a Transformada de Fourier, a qual retorna um espectro de frequência na faixa entre 0 Hz a 5 kHz, com a resolução de 0,1 Hz. Devido a filtragem analógica, as componentes de frequência de interesse se situam dentro da faixa de 0 Hz a 500 Hz.

O conjunto de dados base para o treinamento dos classificadores contempla, além das condições operacionais normais, diversas combinações de condições operacionais do motor sob falha. Ou seja, há dados representando operação normal a vazio, com 50% de carga e 100% de carga para os níveis de frequência de 30 Hz, 35 Hz, 40 Hz, 45 Hz, 50 Hz, 55 Hz e 60 Hz, aplicados pelo conversor de frequência. No caso do motor sob falha de curto-circuito entre espiras, todas as condições operacionais citadas são aplicadas ao motor sob os seguintes níveis AI1, AI2, AI3, BI1, BI2 e BI3 de curto-circuito. A figura 2 ilustra graficamente a composição do conjunto de dados. Nesta representação, os números associados a cada subconjunto representam a quantidade de elementos do mesmo.

Figura 2. Conjuntos de Dados.



### 3.3 Seleção de Atributos

O processo de seleção de atributos seguiu duas vertentes: uma baseada na modelagem matemática da falha e a outra baseada puramente em análise estatística.

Na primeira, foram pré-selecionadas as componentes de frequência a partir da aplicação da equação 1, com  $k=1$  e  $n=1, 2, 3, 4, 5...$  e  $s=0$ . As compo-

nentes são:  $0,5f_i, 1f_i, 1,5f_i, 2f_i, 2,5f_i, 3f_i, \dots$ . No entanto, como o escorregamento do motor em regime permanente é diferente de zero, foi elaborado um algoritmo computacional para selecionar a componente de frequência mais significativa dentro de uma faixa de frequências de  $\pm s$  nominal no espectro de frequências centrada em  $0,5f_i, 1,0f_i, 1,5f_i \dots$ . Dado que a maior frequência comandada pelo conversor de frequência para a formação do conjunto de dados é 60 Hz e que a máxima frequência útil do espectro é 500 Hz, o algoritmo é aplicado para selecionar componentes de frequência até 480 Hz, a qual corresponde a 8ª harmônica. Assim, são gerados 16 atributos preliminares para cada amostra.

Com o intuito de reduzir a dimensionalidade dos vetores de amostras, foi realizada uma análise estatística de variância na amplitude das 16 componentes de frequência sobre todo o conjunto de dados. Aqueles com variâncias consideradas significantes foram  $0,5f_i; 1f_i; 1,5f_i; 2f_i; 3f_i; 5f_i; 7f_i$ . Em seguida, baseado nos estudos de Thomson e Fenger (2001), foram incluídos os múltiplos  $2,5f_i, 3,5f_i$ . Porém, após testar exaustivamente a influência de cada um desses componentes sobre o sucesso na classificação das RNAs, os atributos mais relevantes são:  $0,5f_i; 1,5f_i; 2,5f_i; 3f_i; 5f_i; 7f_i$ .

Na seleção de atributos por PCA, o conjunto de dados selecionado para o treinamento das RNAs é utilizado para formar uma matriz de transformação, a qual projeta os vetores de atributos compostos originalmente por 5000 componentes de frequências em outro espaço no qual apenas as 280 primeiras componentes principais respondem por aproximadamente 99,9% da variância total dos dados. Esta transformação também é aplicada aos conjuntos de teste e validação.

## 4 Resultados

No projeto dos classificadores foram formados três conjuntos de dados. Neles, os dados são normalizados da seguinte forma: remoção da média, divisão pelo desvio padrão e ajuste dos valores entre -1 e +1. Cada conjunto de treinamento contém 29 amostras da classe normal, representando 70% do total de dados do conjunto normal, e 29 amostras da classe falha, o que representa 11,5% do total de dados do conjunto de falhas. É importante salientar que todas as subclasses da classe falha foram igualmente contempladas. Procedimento similar foi adotado para a formação dos conjuntos de teste, perfazendo um total de 16 amostras. O restante dos dados é usado para compor o conjunto de validação.

Os parâmetros de treinamento da rede MLP treinada com o algoritmo BP foram selecionados como resultado de busca exaustiva. A taxa de aprendizagem possui decaimento exponencial, o número de neurônios na única camada oculta é igual a 5 e a função de ativação utilizada nesta e em todas as outras topologias é a tangente hiperbólica. O critério de parada é o da validação cruzada. O número de neurô-

nios ocultos para a rede MLP treinada com o algoritmo ELM é igual a 20.

Todos os algoritmos e investigações foram implementados com o uso do *software* MATLAB®.

A Tabela I ilustra os resultados médios alcançados após 50 treinamentos de MLP/BP, de MLP/ELM e de Perceptron Simples (PS). Nesta,  $N_w$  representa o número de pesos da topologia,  $CR$  representa a taxa de classificação correta (*Classification Rate*) e  $\sigma$  representa o desvio padrão. Os subscritos  $TR$ ,  $TS$  e  $VAL$  se referem aos conjuntos de treinamento, teste e validação, respectivamente.

Tabela I. Resultados Médios das RNAs.

ANN	$N_w$	$CR_{TR}$	$\sigma_{TR}$	$CR_{TS}$	$\sigma_{TS}$	$CR_{VAL}$	$\sigma_{VAL}$
PS	7	60,1	20,6	-	-	50,5	19,2
MLP/ BP	41	78,0	8,8	74,9	11,0	64,9	11,3
MLP/ ELM	161	82,5	3,7	-	-	65,2	4,8

O perceptron simples, usado como referência, não apresentou capacidade de classificar satisfatoriamente o conjunto de dados, o que sugere que o problema não é linearmente separável. Os resultados modestos da MLP/BP e MLP/ELM na classificação do conjunto de validação reforçam a tese de que o problema em mãos é uma tarefa difícil mesmo usando classificadores não-lineares. É importante salientar que mesmo apresentando taxas de reconhecimento praticamente iguais, a rede MLP/BP leva alguma vantagem pelo número reduzido de pesos, favorecendo a implementação embarcada do classificador.

A Tabela II ilustra as taxas de acerto médias por classe ( $CM$ ). Pode-se observar consistência dos classificadores, evidenciada pelo equilíbrio das taxas de classificações em cada classe.

Tabela II. Taxas de classificação média por classe.

	MLP/BP		MLP/ELM	
	Normal	Falha	Normal	Falha
$CM_{TR}$	80,21	75,69	87,84	77,00
$CM_{TS}$	77,45	72,36	-	-
$CM_{VAL}$	69,33	64,83	75,60	64,99

Dentre os 50 classificadores projetados para gerar os resultados médios apresentados nas Tabelas I e II, foram selecionados, para cada um dos algoritmos de treinamento BP e ELM, o classificador que apresentasse simultaneamente alta taxa de acerto global nos conjuntos de treinamento e teste, equilíbrio entre as taxas de acerto por classe e que não apresentasse erro de classificação nos dados relativos à operação normal no conjunto de validação. Esses critérios foram utilizados com o intuito de aplicar os classificadores em monitoramento real, com reduzida ocorrência de falsos positivos para operação normal. As redes ainda foram submetidas ao algoritmo de poda denominado CAPE (Medeiros e Barreto, 2013) para remover

redundâncias danosas e reduzir o tempo de processamento e recursos de memória em aplicação embarcada e em tempo real. Os resultados são apresentados na Tabela III.

Tabela III. Resultados para RNAs específicas.

MLP	BP		BP/CAPE		ELM	
$N_w$	41		34		161	
$CR_{TR}$	89,7		87,1		84,1	
$CR_{TS}$	81,8		81,8		-	
$CR_{VAL}$	68,5		70,2		63,8	
	Normal	Falha	Normal	Falha	Normal	Falha
$CM_{TR}$	94,9	84,7	94,9	79,5	90,2	78,0
$CM_{TS}$	81,8	81,8	81,8	81,8	-	-
$CM_{VAL}$	100	67,9	100	69,3	100	63,9

O algoritmo de poda não conseguiu remover pesos na rede treinada pelo algoritmo ELM, mas promoveu uma redução de 17% no número de pesos do classificador treinado com o algoritmo BP, além de apresentar alguma melhora na taxa de acerto no conjunto de validação.

Para efeito de comparação, Coelho e Medeiros (2013) propuseram um classificador neural do tipo Mapa Auto-Organizável treinado com o mesmo conjunto de dados. Este apresentou taxa de acerto global de 87,5%, porém, com acerto de 52%, para dados referentes à operação normal e 94,5% para a condição de falha. Um classificador com essa característica provavelmente terá uma alta chance de apontar falsos positivos.

Em busca de taxas de classificação maiores optou-se pela aplicação de PCA sobre o conjunto de dados original com o objetivo de selecionar atributos com maior representatividade e promover uma redução de dimensionalidade. De fato, a partir da aplicação do método é possível projetar os vetores originais com 5000 atributos em um novo espaço, no qual as 282 componentes principais mais significativas representam 99,9% da variância dos dados neste espaço. Com o novo conjunto de dados realizou-se o treinamento de um perceptron simples com 7 neurônios. Um deles responde pela condição operacional normal e os outros 6 neurônios respondem pelas 6 condições de falha (AI1, AI2, AI3, BI1, BI2 e BI3).

A Tabela IV ilustra os resultados médios para 50 treinamentos. É importante salientar que nesta representação dos resultados, os erros de classificação entre subclasses de falha de curto-circuito são desconsiderados e computados apenas os erros entre subclasses de falha e classe normal.

Tabela IV. Resultados Médios Utilizando PCA.

ANN	$N_w$	$CR_{TR}$	$\sigma_{TR}$	$CR_{VAL}$	$\sigma_{VAL}$
PS	1974	99,95	0,15	97,43	3,38

Observando os resultados, percebe-se que no novo espaço de atributos o problema é linearmente

separável. Entretanto, não se pode perder de vista a necessidade de projetar cada vetor de atributos do espaço original no espaço de baixa dimensionalidade, e que o número elevado de atributos requer uma topologia de rede avantajada (1974 conexões). Estes dois fatores criam dificuldades para a implementação embarcada e em tempo real.

## 6 Conclusão

A busca por atributos através de modelos matemáticos gerou um espaço de dados não-linearmente separável e tornou difícil a tarefa de separação dos conjuntos de dados de falha e normal. Os classificadores específicos treinados pelo BP/CAPE e pela ELM foram capazes de classificar corretamente aproximadamente 70% e 64%, respectivamente, dos dados do conjunto de validação, com acerto de 100% para classe normal.

Em contrapartida, a seleção de atributos pela aplicação do PCA gera um espaço de dados linearmente separável e torna a separação muito mais precisa, com acerto médio de 97,43% no conjunto de validação. Esses resultados são promissores aos estudos de atributos alternativos para a solução deste problema, no entanto, também gera questionamentos sobre possíveis obstáculos quanto a capacidade de memória e processamento durante uma implementação prática em um sistema embarcado.

O uso de conversores de frequência no acionamento de MITs favorece a implementação embarcada do classificador no próprio equipamento, o que proporcionaria proteção adicional para o conversor além de todos os benefícios de uma detecção de falhas incipientes para a máquina e para as indústrias.

## Agradecimentos

Os autores agradecem a FUNCAP e CAPES pelo suporte financeiro.

## Referências

- Bezesky, D.M.; Kreitzer, S.; , "Selecting ASD systems," *Industry Applications Magazine*, IEEE , vol.9, no.4, pp. 39- 49, July-Aug. 2003
- Bouزيد, M.; Champenois, G.; Bellaaj, N.M.; Signac, L.; Jelassi, K.; , "An Effective Neural Approach for the Automatic Location of Stator Interturn Faults in Induction Motor," *Industrial Electronics*, IEEE Transactions on , vol.55, no.12, pp.4277-4289, Dec. 2008
- Coelho, D.; Medeiros, C., "Short Circuit Incipient Fault Detection and Supervision in a Three-Phase Induction Motor with a SOM-Based Algorithm." *Book of Advances in Self-Organizing Maps*. vol. 198, p. 315-323. Jan. 2013. ISBN 978-3-642-35229-4.
- da S Gazzana, D.; Pereira, L.A.; Fernandes, D., "A system for incipient fault detection and fault di-

- agnosis based on MCSA," *Transmission and Distribution Conference and Exposition*, 2010 IEEE PES , vol., no., pp.1,6, 19-22 April 2010
- Das, S.; Koley, C.; Purkait, P.; Chakravorti, S., "Wavelet aided SVM classifier for stator interturn fault monitoring in induction motors," *Power and Energy Society General Meeting*, 2010 IEEE , vol., no., pp.1,6, 25-29 July 2010
- Joksimovic, G.M.; Penman, J., "The detection of inter-turn short circuits in the stator windings of operating motors," *Industrial Electronics*, IEEE Transactions on , vol.47, no.5, pp.1078,1084, Oct 2000
- Jolliffe, I. T. *Principal Component Analysis*. [S.l.]: Springer, 2002.
- Kaufhold, M.; Schäfer, K.; Bauer, K.; Bethge, A. and Risse, J.: "Interface phenomena in stator winding insulation – Challenges in design, diagnosis, and service experience", *IEEE Electrical Insulation Magazine*, vol. 18, n° 2, pp. 27-36, March/April 2002.
- Kowalski, C.T.; Wolkiewicz, M., "Stator faults diagnosis of the converter-fed induction motor using symmetrical components and neural networks," *Power Electronics and Applications*, 2009. EPE '09. 13th European Conference on , vol., no., pp.1,6, 8-10 Sept. 2009
- Medeiros, Cláudio M.S.; Barreto, Guilherme. "A novel weight pruning method for MLP classifiers based on the MAXCORE principle". *Journal of Neural Computing and Applications*, vol. 22, no 1. 2013. ISSN 0941-0643
- Nandi, S.; Toliyat, H.A.; Xiaodong Li; , "Condition monitoring and fault diagnosis of electrical motors-a review," *Energy Conversion*, IEEE Transactions on , vol.20, no.4, pp. 719- 729, Dec. 2005.
- Natarajan, R., "Failure identification of induction motors by sensing unbalanced stator currents," *Energy Conversion*, IEEE Transactions on , vol.4, no.4, pp.585,590, Dec 1989
- Penman, J.; Sedding, H.G.; Lloyd, B.A.; Fink, W. T., "Detection and location of interturn short circuits in the stator windings of operating motors," *Energy Conversion*, IEEE Transactions on , vol.9, no.4, pp.652,658, Dec 1994.
- Stavrou, A.; Sedding, H.; Penman, J., "Current monitoring for detecting inter-turn short circuits in induction motors," *Electric Machines and Drives*, 1999. *International Conference IEMD '99* , vol., no., pp.345,347, May 1999
- Thomson, W.T.; Fenger, M.; , "Current signature analysis to detect induction motor faults," *Industry Applications Magazine*, IEEE , vol.7, no.4, pp.26-34, Jul/Aug 2001.
- Thorsen, O.; Dalva, M.; , "Condition monitoring methods, failure identification and analysis for high voltage motors in petrochemical industry," *Electrical Machines and Drives*, 1997 *Eighth International Conference on*, vol., no. 444, pp.109-113, 1-3 Sep 1997.