

Identificação de defeitos em motor de indução trifásico empregando SVM

Rafael Mateus Tischer, Alberto Yoshihiro Nakano, Ednei Luiz Miotto

Resumo—Os motores de indução trifásico (MIT) são parte fundamental da conversão eletromecânica de energia em diversos ramos da atividade industrial, entretanto, nem máquinas robustas como os MIT são a prova de falhas e defeitos. Logo, há necessidade de métodos de detecção prévia de defeitos para possibilitar ações de manutenção planejada com a finalidade de evitar paradas e, conseqüentemente, perdas financeiras. O objetivo deste trabalho é analisar a viabilidade da utilização de parâmetros característicos extraídos de sinais de assinatura de corrente elétrica de MIT e a ferramenta estatística máquinas de vetores de suporte (SVM) para detecção de defeitos, definidas como sendo as quebras e trincas nas barras do rotor gaiola de esquilo.

Palavras-Chave—Aprendizado de Máquina, Motor de Indução, Detecção de Falhas, Máquina de Vetores de Suporte

Abstract—Three-phase induction motors (TIM) are fundamental parts of electromechanical energy conversion in various branches of industrial activities, however, even robust machines like TIM are fail-safe. Therefore, detection methods are necessary to preventive maintenance actions in order to avoid interruption and, consequently, financial losses. The objective of this work is to analyze the feasibility of employing characteristic features extracted from electric current signature of TIM and the statistical tool, support vector machines (SVM), in the detection of faults, defined here as the breaks and cracks in the bars of the squirrel cage rotor.

Keywords—Machine Learning, Induction Motor, Fault Detection, Support Vector Machine

I. INTRODUÇÃO

Os motores elétricos são máquinas construídas com o objetivo de converter energia elétrica em energia mecânica. Devido ao baixo custo e robustez decorrente da simplicidade construtiva, cada vez mais se tem utilizado motores de indução trifásica (MIT) com rotor gaiola de esquilo, seja na simples movimentação de esteiras rolantes até equipamentos que demandam centenas de cavalos de potência. Como toda máquina, o MIT está sujeito a desgastes, intempéries e outros fatores que podem gerar danos e reduzir a vida útil do mesmo.

Um método para a detecção de defeito em MIT é a análise da distribuição espectral de potência da corrente elétrica nas fases que a alimentam, ou seja, uma análise da assinatura de corrente do equipamento. Diversos trabalhos propõem a utilização de análise espectral da corrente para a identificação de avarias. Em [1], analisa-se o espalhamento de potência elétrica nas bandas próximas a frequência fundamental de operação do motor para determinar a possibilidade da existência de

defeitos, em [2] utiliza-se sistemas inteligentes para detecção de defeitos em máquinas operando em várias condições de carga e utilização.

Neste trabalho, com o intuito de compreender o problema de detecção de defeitos em MIT, um banco de dados simples com sinais de corrente elétrica de motor sem defeito e com defeito, ambos funcionando com carga nominal, foi criado. O defeito em questão foi definido como a quebra das barras do rotor de gaiola de esquilo. Para realizar a detecção, parâmetros característicos são extraídos dos sinais que compõe o banco de dados e, posteriormente, são empregados no treinamento de um classificador estatístico, no caso, a máquina de vetores de suporte (SVM), do inglês *Support Vector Machine*.

Este trabalho é organizado da seguinte forma: na Seção II apresenta-se o referencial teórico abordando o MIT, a quebra de barras como defeito de interesse, a aquisição de dados, a extração e a definição dos parâmetros característicos estudados e o classificador SVM. Na Seção III apresenta-se os resultados obtidos com SVM com diferentes combinações dos parâmetros característicos. Na Seção IV discute-se os resultados obtidos e na Seção V têm-se as conclusões.

II. REFERENCIAL TEÓRICO

Nesta seção apresenta-se os conceitos básicos para o estudo do problema de detecção de defeitos em MIT.

A. Motor de Indução Trifásico - MIT

A Fig. 1 apresenta o MIT de 1 cavalo-vapor (CV) da fabricante Voges empregado nos ensaios. É possível identificar suas duas partes fundamentais, o rotor tipo gaiola de esquilo e a carcaça onde se encontra o estator.

Como o MIT é geralmente dimensionado para operar com sua carga nominal [2], foi acoplado ao seu eixo um gerador de corrente contínua (CC) que possibilita um bom ajuste da carga no eixo, deste modo, ajusta-se o sistema para que o motor de indução opere em sua corrente nominal de 2,9 A. A Fig. 2 apresenta a bancada de testes onde foram coletados os sinais de corrente de motor com e sem defeitos.

B. Inserção de defeito - rompimento de barras

Para inserção de defeitos, as barras do rotor gaiola de esquilo foram perfuradas com uma broca especial para metal até serem totalmente seccionadas. A Fig. 3 apresenta o rotor do motor de indução e os defeitos que foram inseridos.



Fig. 1: MIT com suas principais partes, o rotor e o estator.



Fig. 3: Cada orifício é uma barra de condução seccionada.




Fig. 2: Bancada com equipamentos empregados no ensaio.



Fig. 4: Placa de aquisição NI Elvis II e o sensor de efeito Hall.

C. Aquisição dos sinais

Para a aquisição da corrente elétrica de uma das fases de um motor trifásico foi utilizado um sensor de efeito Hall, que capta o campo magnético que envolve o condutor quando percorrido pela corrente, convertendo-o em um sinal de tensão proporcional.

O sinal de tensão oriundo do sensor é amostrado pelo conversor analógico-digital (ADC) da placa NI Elvis II, da fabricante Texas Instruments, com frequência de amostragem de 16 kHz, e resolução por amostra de 16 bits. A Fig. 4 apresenta a placa de aquisição NI Elvis II e o sensor de efeito Hall empregado.

D. Extração de parâmetros característicos

Após realizado o processo de aquisição, técnicas de processamento digital podem ser aplicadas aos sinais. Com o intuito de reduzir a quantidade de dados e as redundâncias presentes nos sinais sem comprometer a informação que os sinais descrevem, a próxima etapa consiste na determinação de parâmetros característicos que representem o sinal analisado. Neste trabalho, parâmetros característicos são estimados por quadros do sinal, ou seja, segmentos do sinal original.

O processo inicia-se com a segmentação do sinal em quadros de N amostras, com superposição de 50% entre os

quadros de modo a garantir que informações entre quadros não sejam perdidas. A cada quadro foi aplicado um janelamento que consiste em multiplicar o quadro do sinal por uma função de ponderação. O janelamento é utilizado para destacar as características espectrais de um dado sinal trazendo à tona informações anteriormente ocultas ou mascaradas [3].

A janela de Hanning representada por

$$w[n] = 0,5 \left(1 - \cos \left(\frac{2\pi n}{N} \right) \right), \quad (1)$$

foi empregada neste trabalho sendo N o tamanho da janela em amostras e $n = 0, \dots, N - 1$. Parâmetros característicos no domínio do tempo podem ser obtidos por cada quadro janelado. Para parâmetros característicos no domínio da frequência, ao sinal janelado é aplicado a transformada de Fourier discreta (TFD)

$$X_j[k] = \sum_{n=0}^{N-1} x_j[n] e^{-i \left(\frac{2\pi}{N} \right) kn}, \quad (2)$$

sendo $i = \sqrt{-1}$ o número imaginário, $x_j[n]$ o quadro j do sinal $x[n]$, $X_j[k]$ a representação do quadro j no domínio da frequência discreta e $k = 0, \dots, N - 1$ representa o índice das amostras no domínio da frequência. Para efeitos de comparação, a Fig. 5 apresenta o espectro de sinais de corrente elétrica de um MIT sem defeito e com defeito, pode-se observar claramente diferenças no comportamento do espectro devido a presença de defeito no motor.

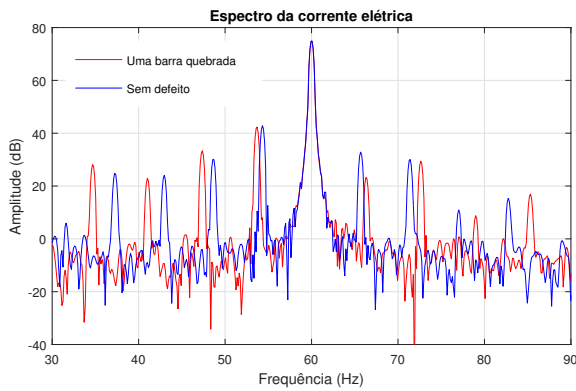


Fig. 5: Espectros de sinais de corrente de um MIT sem defeito e com uma barra quebrada.

Uma vez disponível a informação processada no domínio do tempo, sinal janelado, e em frequência, pela TFD, passa-se a determinação dos parâmetros característicos:

1) *Diferença de amplitude - Parâmetro P1*: Parâmetro calculado utilizando-se a magnitude do espectro do sinal do quadro j , $|X_j[k]|$, medindo-se a diferença relativa de amplitude entre a frequência fundamental, neste caso 60 Hz, e o pico da primeira banda lateral direita (BLD) conforme ilustrado na Fig. 6. Note que a presença de defeito no MIT acarreta a mudança na amplitude da BLD.




Fig. 6: Representação do parâmetro diferença de amplitude.

2) *Taxa de cruzamento por zero - Parâmetro P2*: Parâmetro calculado utilizando-se o sinal no domínio do tempo e tem relação intrínseca com a frequência do sinal sendo definido por

$$Z_j = \sum_{n=0}^{N-1} |\text{sgn}(x_j[n]) - \text{sgn}(x_j[n-1])| w[n], \quad (3)$$

sendo que $x_j[n]$ representa o quadro j do sinal $x[n]$ e a função $\text{sgn}(\cdot)$ é definida por

$$\text{sgn}(x) = \begin{cases} +1 & \text{se } x > 0, \\ -1 & \text{se } x < 0. \end{cases} \quad (4)$$

3) *Taxa de espalhamento - Parâmetro P3*: Parâmetro calculado pelo desvio padrão do espectro de magnitudes de cada

quadro definido por

$$Esp_j = \sqrt{\frac{1}{M-1} \sum_{m=0}^{M-1} (X_j[m] - \mu_{X_j})^2}, \quad (5)$$

sendo que μ_{X_j} é a média de amplitude do espectro do quadro j e M consiste na quantidade de amostras existentes na representação do sinal no domínio da frequência. Pelas propriedades da TFD tem-se que $M = N/2$ considerando-se N par. A Fig. 7 ilustra a taxa de espalhamento.




Fig. 7: Representação do parâmetro taxa de espalhamento.

4) *Diferença entre bandas - Parâmetro P4*: Parâmetro calculado medindo-se a distância entre a frequência fundamental de 60Hz e a frequência da BLD conforme ilustrado na Fig. 8.




Fig. 8: Representação do parâmetro diferença entre bandas.

5) *Centróide espectral - Parâmetro P5*: Parâmetro característico que representa a frequência média ponderada do espectro de um sinal [4] do quadro j calculado por

$$C_j = \frac{\sum_{m=0}^{M-1} f[m] |X_j[m]|^2}{\sum_{m=0}^{M-1} |X_j[m]|^2}, \quad (6)$$

sendo que $f[m]$ é a respectiva frequência espectral. Este parâmetro é análogo ao centro de gravidade da mecânica.

6) *Largura do espectro - Parâmetro P6*: Parâmetro característico que é diretamente relacionado ao centróide espectral e determina o quão espalhado está a distribuição de potência do sinal com relação ao centróide espectral e é calculada por

$$L_j = \sqrt{\frac{\sum_{m=0}^{M-1} (C_j - f[m])^2 |X_j[m]|^2}{\sum_{m=0}^{M-1} |X_j[m]|^2}}, \quad (7)$$

em que C_j é o centróide espectral para o quadro j . A Fig. 9 representa a largura do espectro e o centróide espectral. Note como ambos estão diretamente relacionados.




Fig. 9: Largura do espectro e centróide espectral.

7) *Ponto de roll-off - Parâmetro P7*: Parâmetro característico que mede a frequência abaixo da qual concentra-se 85% da energia do sinal [4] calculado por

$$\sum_{m=0}^R |X_j[m]| = 0,85 \sum_{m=0}^{M-1} |X_j[m]|, \quad (8)$$

ou seja, o ponto de *roll-off* é o menor valor de R que satisfaça a relação para o quadro j . A Fig. 10 representa o ponto aproximado R abaixo do qual se concentra 85% da energia presente no espectro. Altos valores de R indicam que a energia do sinal está distribuída por todo o espectro. Baixos valores de R indicam maior concentração de energia em baixas frequências.

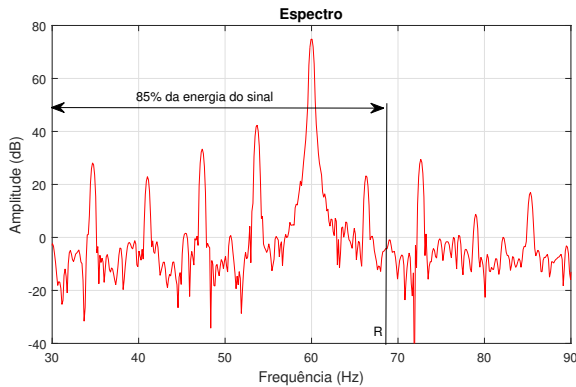


Fig. 10: Ponto de *roll-off*.

E. Classificador

Um sistema de classificação é um sistema de reconhecimento de padrões cujo objetivo é classificar padrões a partir de informações previamente conhecidas. O classificador utilizado nesta pesquisa é SVM que busca separar um conjunto de dados

em dois subconjuntos distintos, com e sem defeitos, a partir da definição de um hiperplano que divide os dados no espaço dos parâmetros característicos [4]. Na Fig. 11 tem-se um exemplo ilustrativo do espaço dos parâmetros característicos formado por um conjunto de dados bidimensionais.




Fig. 11: Representação de vetores em um espaço bidimensional de parâmetros.

Na Fig. 11, \mathbf{x}_i é um vetor de parâmetros característicos e y_i o rótulo ou classe conhecida deste parâmetro, para $i = 1, 2$. O SVM deverá encontrar o hiperplano ótimo, ou separador de margem máxima [5] que melhor divide as observações destas duas classes. Podemos representar este plano pela função

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b, \quad (9)$$

que irá separar o espaço em duas regiões, definidas por $\mathbf{w}^T \mathbf{x} + b > 0$ e $\mathbf{w}^T \mathbf{x} + b < 0$. Podemos encontrar um número infinito de hiperplanos equivalentes pela multiplicação de \mathbf{w} e b por uma constante. Logo definimos o hiperplano canônico [6], ou ótimo, como aquele em que \mathbf{w} e b satisfazem a equação

$$\begin{cases} \mathbf{w}^T \mathbf{x}_i + b \geq +1 & \text{se } y_i = +1; \\ \mathbf{w}^T \mathbf{x}_i + b \leq -1 & \text{se } y_i = -1. \end{cases}$$

Selecionado um ponto \mathbf{x}_1 tal que $\mathbf{w}^T \mathbf{x}_1 + b = 1$ e \mathbf{x}_2 tal que $\mathbf{w}^T \mathbf{x}_2 + b = -1$, ou seja, um ponto pertencente a cada classe e sendo \mathbf{w} um vetor perpendicular ao hiperplano de separação e início na origem, calcula-se a margem de separação d através da projeção do vetor $(\mathbf{x}_2 - \mathbf{x}_1)$ sobre o vetor \mathbf{w} . Esta projeção pode ser visualizada na Fig. 11 que é calculada através de

$$Proj_{\mathbf{w}}(\mathbf{x}_1 - \mathbf{x}_2) = (\mathbf{x}_1 - \mathbf{x}_2) \left(\frac{\mathbf{w}^T (\mathbf{x}_1 - \mathbf{x}_2)}{\|\mathbf{w}^T\| \|\mathbf{x}_1 - \mathbf{x}_2\|} \right). \quad (10)$$

Definido que $\mathbf{w}^T \mathbf{x}_1 + b = +1$ e $\mathbf{w}^T \mathbf{x}_2 + b = -1$, da diferença entre estas equações obtém-se

$$\mathbf{w}^T (\mathbf{x}_1 - \mathbf{x}_2) = 2, \quad (11)$$

e substituindo a Eq. (11) na Eq. (10) obtêm-se

$$Proj_{\mathbf{w}}(\mathbf{x}_1 - \mathbf{x}_2) = \frac{2(\mathbf{x}_1 - \mathbf{x}_2)}{\|\mathbf{w}^T\| \|\mathbf{x}_1 - \mathbf{x}_2\|}. \quad (12)$$

O objetivo de um SVM é maximizar a distância d , e podemos encontrar d tomando o módulo da projeção do vetor \mathbf{w} sobre o vetor $(\mathbf{x}_1 - \mathbf{x}_2)$, logo

$$d = \|Proj_{\mathbf{w}}(\mathbf{x}_1 - \mathbf{x}_2)\| = \frac{2}{\|\mathbf{w}\|}. \quad (13)$$

para $\|\mathbf{w}^T\| = \|\mathbf{w}\|$. Observe que para maximizar d devemos minimizar $\|\mathbf{w}\|$, resultando no problema de otimização

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2, \quad (14)$$

observada a restrição $y_i(\mathbf{w}^T \mathbf{x}_i + b) - 1 \geq 0$.

Este problema pode ser solucionado com a introdução de uma função lagrangiana, englobando as restrições e a função que se deseja minimizar, associados aos parâmetros multiplicadores lagrangianos α_i , sendo definida por

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i(\mathbf{w}^T \mathbf{x}_i + b) - 1). \quad (15)$$

Minimizar a Eq. (15) implica em minimizar \mathbf{w} e b e maximizar α_i . Minimizar \mathbf{w} e b se traduz em encontrar o ponto de sela da função [7], isto é

$$\frac{\partial L}{\partial b} = 0, \quad (16)$$

$$\frac{\partial L}{\partial \mathbf{w}} = 0, \quad (17)$$

o que resulta em

$$\sum_i \alpha_i \mathbf{x}_i = 0 \quad (18)$$

e

$$\mathbf{w} = \sum_i \alpha_i \mathbf{x}_i y_i. \quad (19)$$

Desta forma, substituindo as Eqs. (18) e (19) na Eq. (15) obtemos o problema de otimização

$$\max_{\alpha} \left(\sum_i \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i^T \mathbf{x}_j) \right), \quad (20)$$

sujeito às restrições $\alpha_i \geq 0$ e $\sum_i \alpha_i y_i = 0$. Este é um problema de computação quadrática cuja solução, a função que define o separador ótimo, é dada por

$$h(\mathbf{x}) = \text{sgn} \left(\sum_j \alpha_j y_j (\mathbf{x}^T \mathbf{x}_j) - b \right). \quad (21)$$

O exemplo apresentado é o mais simples possível, visto que os dados já são linearmente separáveis em seu domínio de origem. Para o caso em que os dados não são separáveis, o SVM irá utilizar uma função de mapeamento denominada *kernel* que mapeia o espaço dos parâmetros característicos em

uma dimensão superior, ou seja, se as distribuições apresentadas na Fig. 11 não estivessem separadas, o SVM utilizaria uma função *kernel* para representar estes parâmetros em um espaço de dimensão superior no qual os dados poderiam ser linearmente separáveis. A Eq. (22) apresenta matematicamente uma função *kernel* [6], [7],

$$K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j), \quad (22)$$

desta forma a Eq. (20) com uma função *kernel* é definida como

$$\max_{\alpha} \left(\sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (\Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j)) \right), \quad (23)$$

e a Eq. (21) se torna

$$h(\mathbf{x}) = \text{sgn} \left(\sum_j \alpha_j y_j (\Phi(\mathbf{x})^T \Phi(\mathbf{x}_j)) - b \right). \quad (24)$$

De forma geral, salvo algumas exceções, se tivermos um vetor de N pontos, eles serão separáveis em espaços de $N - 1$ ou mais dimensões [5]. Entre as funções *kernel* comuns estão as funções lineares, polinomiais, quadráticas, cúbicas e gaussianas [6], ficando a critério da análise do problema e da distribuição dos dados a seleção do *kernel* mais apropriado.

Neste trabalho foi empregado o *kernel* linear, definido por

$$\Phi(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T \mathbf{x}_j). \quad (25)$$

III. RESULTADOS

O conjunto de dados disponível foi dividido em conjunto de treinamento e teste realizando-se validação cruzada permutando-se os dados cinco vezes de modo que os dados de treinamento são sempre distintos de dados de teste. Os resultados apresentados correspondem a média das cinco validações. O desempenho dos classificadores foi medido através da taxa de acerto geral (TA GERAL) que consiste na relação entre a quantidade de dados corretamente classificada em relação a quantidade total de dados de teste. É interessante também analisar as taxas de acerto através da taxa de acerto de motor com defeito (TA COM), que correspondem a taxa de acerto de dados de motor com defeito classificadas corretamente como motor com defeito e, taxa de acerto de motor sem defeito (TA SEM), quando os dados de motor sem defeito são classificados corretamente como sendo de motor sem defeito. A análise destas taxas separadamente pode revelar informações sobre o desempenho do classificador quanto a falsos-positivo e falsos-negativo.

A. SVM - Modelos com um parâmetro

Inicialmente foram testados os parâmetros propostos na Seção II individualmente cujos resultados estão na Tabela I.

O parâmetro P1 apresentou a maior TA com 100%. O segundo parâmetro mais eficaz foi P2, que obteve taxa de acerto de 83,2%, classificando 91,8% das observações de motor com defeito corretamente e 74,7% para motor sem defeito.

TABELA I: Desempenho individual dos parâmetros

Parâmetro	TA COM	TA SEM	TA GERAL
P1	100,0%	100,0%	100,0%
P2	91,8%	74,7%	83,2%
P3	79,7%	65,9%	72,8%
P4	78,6%	59,3%	69,0%
P5	68,1%	63,2%	65,7%
P6	74,2%	61,0%	67,6%
P7	56,0%	67,6%	61,8%

B. SVM - Modelos com dois parâmetros

A Tabela II apresenta os resultados com modelos SVM treinados com dois parâmetros sendo que **PX** representa qualquer parâmetro individual excetuando-se o P1. Considerou-se as combinações que resultaram em mais de 83,2% de acerto, ou seja, a segunda maior TA GERAL da Tabela I. Pode-se observar que qualquer parâmetro combinado com P1 obteve 100% de taxa de acerto.

TABELA II: Desempenho de modelos com dois parâmetros

Parâmetros	TA COM	TA SEM	TA GERAL
P1 + PX	100,0%	100,0%	100,0%
P4 + P2	91,8%	85,7%	88,7%
P6 + P2	88,5%	84,6%	86,5%
P5 + P2	86,8%	85,7%	86,3%
P2 + P3	87,9%	83,5%	85,7%

O segundo melhor resultado foi obtido pela combinação P4 + P2 com taxa de acerto de 88,7%, sendo superior ao desempenho individual de cada parâmetro visto na Tabela I. Nota-se também que TA SEM melhora para 85,7% em relação aos resultados apresentados para os parâmetros P2 e P4 individualmente.

C. SVM - Modelos com três parâmetros

A Tabela III apresenta os resultados com modelos SVM treinados com três parâmetros sendo que **PXY** representa quaisquer conjunto de dois parâmetros excetuando-se o P1. Considerou-se as combinações que resultaram em taxas maiores ou iguais a 88,7% de acerto, ou seja, a segunda maior TA GERAL da Tabela II. Pode-se observar que qualquer parâmetro combinado com P1 obteve 100% de taxa de acerto.

TABELA III: Desempenho de modelos com três parâmetros

Parâmetros	TA COM	TA SEM	TA GERAL
P1 + PXY	100,0%	100,0%	100,0%
P2 + P4 + P6	92,3%	87,9%	90,1%
P2 + P3 + P5	90,7%	86,8%	88,7%

D. SVM - Modelos com quatro parâmetros

A Tabela IV apresenta os resultados com modelos SVM treinados com quatro parâmetros sendo que **PXYZ** representa quaisquer conjunto de três parâmetros excetuando-se o P1. Considerou-se as combinações que resultaram em taxas

maiores ou iguais a 90,1% de acerto, ou seja, a segunda maior TA GERAL da Tabela III. Pode-se observar que qualquer parâmetro combinado com P1 obteve 100% de taxa de acerto.

TABELA IV: Desempenho de modelos com quatro parâmetros

Parâmetros	TA COM	TA SEM	TA GERAL
P1 + PXYZ	100,0%	100,0%	100,0%
P2 + P4 + P6 + P5	95,1%	86,3%	90,7%

IV. DISCUSSÕES

O comportamento do parâmetro P1 pode ser observado na Fig. 6 e quando confrontado com outro parâmetro verifica-se uma grande separabilidade entre as classes com e sem defeito, como pode ser observado na Fig. 12 onde se tem P1 versus P4. A separação proporcionada pelo parâmetro P1 leva as taxas de acerto de 100%, mesmo quando este é combinado com parâmetros não tão bem avaliados individualmente. Na Fig. 13 tem-se a distribuição das observações dos parâmetros P2 e P4, onde claramente pode-se verificar a sobreposição das duas classes, em decorrência deste fato a TA GERAL foi menor, visto que, a separabilidade entre as classes é menor. A superposição se torna mais evidente quando se analisa outros parâmetros como o da Fig. 14 onde temos a relação entre os parâmetros P2 e P5. A Fig. 15 apresenta a sobreposição das observações dos parâmetros P2 e P3. Novamente fica claro que a superposição limita a taxa de acerto do classificador.




Fig. 12: Distribuição das observações dos parâmetros P1 e P4.

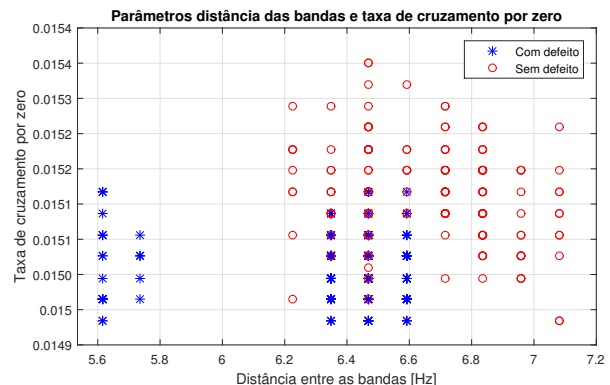


Fig. 13: Distribuição das observações dos parâmetros P2 e P4.

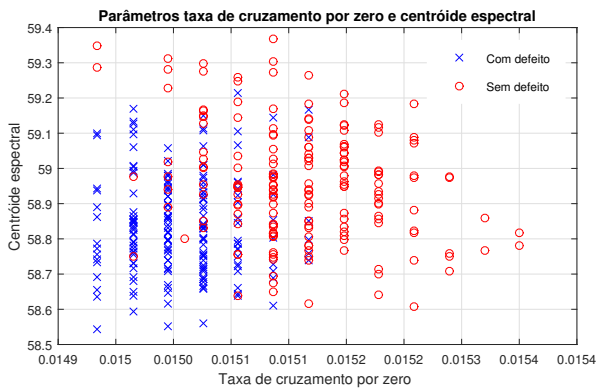


Fig. 14: Distribuição das observações dos parâmetros P2 e P5.

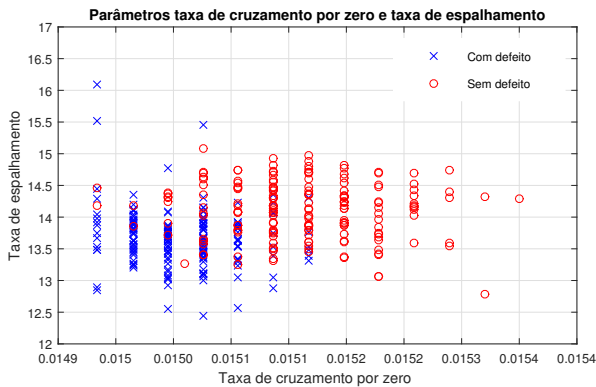


Fig. 15: Distribuição das observações dos parâmetros P2 e P3..

V. CONCLUSÕES

O parâmetro característico P1 obteve taxa de acerto de 100% em todos os ensaios realizados mostrando que é um parâmetro importante na análise de defeitos em MIT. Os parâmetros P2, P3, P4, P5 e P6 individualmente apresentaram resultados de TA GERAL acima de 50% com destaque para P2 que permite 83,2% de taxa de acerto. Ao contrário de P1, em todos os outros parâmetros nota-se a superposição das duas classes analisadas. A superposição é responsável por limitar a taxa de acerto do classificador, visto que, não é possível separar estes dados linearmente em seu domínio de origem. Podemos observar que parâmetros capazes de identificar pequenas variações na frequência do sinal e, conseqüentemente no espectro, foram capazes de atingir as maiores TA GERAL. Parâmetros relacionados a variação das características estatísticas do sinal no tempo não obtiveram bons resultados. Ao associar dois ou mais parâmetros observa-se que as informações dos parâmetros podem ser complementares ou redundantes. No caso do novo parâmetro ser complementar, observamos melhoria nas TA, já para parâmetros redundantes, a TA pode ficar inalterada ou mesmo piorar. A utilização de parâmetros característicos para a identificação de defeitos no rotor de motores de indução trifásicos utilizando um SVM é viável. Apenas a análise do parâmetro diferença de amplitude é suficiente para a tomada de decisão quanto a presença de um defeito rotórico no motor e os resultados encontrados nesta pesquisa validam esta afirmação. É possível concluir pelos resultados da pesquisa que, diante

da indisponibilidade dos valores de diferença de amplitude, é possível a utilização de alguns dos parâmetros descritos na Seção II, individualmente ou combinados, para auxiliar a detecção de defeitos no motor. Verifica-se também que a taxa de acerto para motor com defeito é maior que a taxa de acerto para motor sem defeito, ou seja, é mais provável classificar como defeituoso um motor bom, do que o contrário, que é o pior caso, devido ao risco de não detectar uma falha iminente.

REFERÊNCIAS

- [1] E. L. Bonaldi and L. E. L. de Oliveira, "Análise e identificação de falhas em motores de indução em indústrias petroquímicas através da técnica de análise da assinatura elétrica - esa," *Induscon VIII Conferência internacional de aplicações industriais*, 2008.
- [2] M. Suetake, "Sistemas inteligentes para monitoramento e diagnósticos de falhas em motores de indução trifásicos," Ph.D. dissertation, Escola de engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2012.
- [3] A. O. Andrade and A. B. Soares, "Técnicas de janelamento de sinais," *Universidade Federal de Uberlândia - Faculdade de engenharia elétrica*, 2013.
- [4] L. de Abreu Borges, "Extração de parâmetros característicos para detecção acústica de vazamento de água," Ph.D. dissertation, Escola Politécnica da Universidade de São Paulo, São Paulo, 2011.
- [5] S. Russel and P. Norvig, *Inteligência artificial*, 3rd ed. Rio de Janeiro: Elsevier, 2013.
- [6] A. C. Lorena and A. C. P. L. F. de Carvalho, "Uma introdução as support vector machines," *Universidade Federal do Rio Grande do Sul*, 2007.
- [7] A. J. Smola, P. Bartlett, B. Scholkopf, and D. Schuurmans, "Advances in large margin classifiers," *The MIT Press*, 1999.