

Detecção de Anomalias na Vibração de Motores Elétricos Baseada em OCSVM

Lucas Gabriel Cosmo Morais* Ademar Virgolino da Silva Netto**

* *Curso de graduação em Engenharia Elétrica, Universidade Federal da Paraíba - UFPB, PB (e-mail: lucas.morais@cear.ufpb.br)*

** *Departamento de Engenharia Elétrica (DEE), Universidade Federal da Paraíba - UFPB, PB (e-mail: ademar@cear.ufpb.br).*

Abstract: The importance of detecting failures and anomalies in electric motors reflects the improvement in the application of techniques used for maintenance on these machines. Thus, in the present work, a technique for detecting anomalies in the vibration of electric motors is proposed, based on the classification algorithm One-Class Support Vector Machine (OCSVM). An accelerometer device was used to capture the vibrations of an electric motor of 1.5 cv together with an electromagnetic brake system. In addition, a method for selecting the hyper-parameters of the algorithm was developed, obtaining a decision boundary that classified the operating data considered normal with a lower error rate than 5%

Resumo:

A importância da detecção de falhas e anomalias em motores elétricos reflete o aprimoramento da aplicação das técnicas utilizadas para a manutenção nessas máquinas. Dessa forma é proposto no presente trabalho uma técnica de detecção de anomalias na vibração de motores elétricos, baseando-se no algoritmo de classificação *One-Class Support Vector Machine* (OCSVM). Utilizou-se um dispositivo acelerômetro para captar as vibrações de um motor elétrico de 1,5 cv junto a um sistema de freio eletromagnético. Além disso, desenvolveu-se um método de seleção dos hiper-parâmetros do algoritmo, obtendo-se uma fronteira de decisão que classificou os dados de operação considerados normais com uma taxa de erro menor que 5%

Keywords: Vibration; Anomaly; OCSVM; Electric Motor; Maintenance.

Palavras-chaves: Vibração; Anomalia; OCSVM; Motores Elétricos; Manutenção.

1. INTRODUÇÃO

Os motores elétricos estão presentes dentro das mais diversas cadeias de produção da indústria, sendo um dos principais ativos que requerem atenção em sua manutenção. Isso traz à tona o fato de que possíveis falhas e paradas não programadas desses motores elétricos acarretam em um impacto produtivo negativo, comprometendo condições de custos de operação e de segurança. Com isso, evidencia-se a necessidade da implementação de técnicas de detecção de anomalias como uma forma de previsão de possíveis falhas de operação desses equipamentos (Teixeira et al., 2020).

No contexto da manutenção e da predição de falhas, a aplicação de métodos baseados em aprendizado de máquina têm ganhado notoriedade, uma vez que permitem a elaboração de modelos que representam as operações dos equipamentos sob determinadas condições. Dessa forma, os modelos desenvolvidos podem realizar previsões, classificações e até mesmo detectar anomalias em conjunto de dados de operação da máquina. A abordagem a ser tratada nesse trabalho é fundamentada em um método de aprendizado de máquina para detecção de funcionamento anômalo orientado por dados de vibração. Nesse tipo de procedimento, tem-se como principal objetivo obter um modelo de funcionamento normal de um equipamento, o qual é alcançado diretamente através dos dados históricos

de vibração previamente coletados. Com isso, tem-se por finalidade a classificação da operação de um motor elétrico, determinando-a como normal ou anômala (El-Thalji and Jantunen, 2015) (Amir et al., 2016).

A detecção de falhas e anomalias na operação dos motores elétricos é extensivamente abordada em literatura, tomando por base alguns algoritmos de aprendizado de máquina. Em Borges et al. (2019) é exposta a elaboração de um classificador de anomalias através do algoritmo de Análise de Curvas Principais (PCA), com uma metodologia fundamentada na extração de parâmetros estatísticos dos sinais de vibração. No estudo, construiu-se uma curva principal a partir dos dados de treinamento sem falhas do motor, com a introdução de uma tolerância, visando abranger os dados de treinamento aplicados. Nesse sentido, Borges et al. (2020) também se valeram de uma técnica semelhante para classificar a operação de um motor elétrico de 2 cv de potência. Os autores utilizaram o algoritmo *One-Class Support Vector Machine* (OCSVM), obtendo taxas de detecção de anomalias superiores a 90%.

Por outro lado, Xu et al. (2019) propuseram o uso do algoritmo *Isolation Forest* (IF) como método de detecção de anomalia em sinal de vibração, baseando-se na clusterização de componentes de frequência para distinguir diferentes condições de operação das máquinas. Já em Shin

et al. (2005) são avaliadas diferentes funções *kernel* junto ao algoritmo OCSVM, classificando-o como superior aos algoritmos de Redes Neurais Artificiais (RNA) na identificação de anomalias em motores elétricos. Por fim, em Amir et al. (2016) é exposta a superioridade de algoritmos baseados em *Support Vector Machine* (SVM) para detecção de falhas quando o conjunto de dados caracteriza-se como ruidoso e não-linear.

Com isso, demonstra-se a existência de diversos algoritmos de aprendizado de máquina na solução desse tipo de problema, com algumas técnicas apresentando melhores resultados frente à outras. No entanto, características como a não-linearidade e os ruídos introduzidos no conjunto de dados dos equipamentos, sob diferentes condições de operação, demonstram a necessidade de averiguar a robustez do algoritmo OCSVM frente à diferentes cenários de operação das máquinas rotativas.

O presente trabalho está dividido da seguinte forma: na seção 2 são apresentados os conceitos necessários à compreensão dos algoritmos de detecção de anomalias, em especial o OCSVM; em seguida, na seção 3 descreve-se o método de ensaio e aquisição dos dados de vibração, bem como as ferramentas utilizadas nesse procedimento e a implementação do algoritmo junto à seleção de hiper-parâmetros; já na seção 4 são expostos os resultados alcançados, seguidos da conclusão na seção 5.

2. DETECÇÃO DE ANOMALIAS

Os algoritmos de aprendizado de máquina para detecção de anomalias buscam identificar padrões em um determinado conjunto de dados, distinguindo amostras que apresentam não conformidades; essas amostras podem ser chamadas de anomalias ou *outliers*. Com isso, as técnicas de detecção podem ser aplicadas em situações tais como: monitoramento do estado de equipamentos, detecção de fraudes em sistemas financeiros, detecção de invasão em sistema de informação e até mesmo como algoritmo de pré-processamento para remoção de amostras espúrias (Mahdavinejad et al., 2018).

As duas abordagens principais para a implementação da detecção de anomalias são pelos métodos supervisionado e não-supervisionado. Quando empregado através de técnicas supervisionadas, têm-se à disposição um conjunto de dados composto por amostras normais e anômalas, podendo-se rotular as amostras para representar as duas classes. A partir disto, um algoritmo classificador binário é treinado para reconhecer as amostras mais dispersas de um certo conjunto. Contudo, existem certos desafios quanto a esta abordagem: uma vez que os dados anômalos são frequentemente sub-representados nos bancos de dados disponíveis para treinamento, é necessário lidar com a influência do desbalanceamento que afeta a qualidade de classificação do algoritmo. Em contrapartida, na modalidade não-supervisionada, apenas o conjunto das amostras normais é necessário para o treinamento, em uma perspectiva na qual não inclui nem a marcação e nem a disponibilidade de dados anômalos no banco de dados. Nesse contexto, os algoritmos mais comuns de detecção de anomalias encontrados na literatura são expostos a seguir (Amir et al., 2016) (Mahdavinejad et al., 2018).

- *K-nearest neighbours* (K-NN): é um algoritmo utilizado majoritariamente em situação supervisionada para problemas de classificação. O princípio básico deste algoritmo está na suposição de que observações semelhantes estão próximas, em uma vizinhança, e outliers estão mais distantes deste agrupamento.
- *Isolation Forest* (IF): O algoritmo é baseado em árvores de decisão, utilizando como métrica os comprimentos médios de caminho em várias árvores.
- *Local Outlier Factor* (LOF): é um método baseado em densidade e funciona por meio do cálculo da densidade das amostras em torno da amostra de teste, comparando-a com a densidade dos seus vizinhos.
- *Principal Component Analysis* (PCA): é uma técnica não supervisionada para extração de parâmetros e redução de dimensionalidade de um conjunto de dados com base em uma classificação de covariância.
- *One-Class SVM* (OCSVM): é um algoritmo não supervisionado amplamente utilizado em literatura para identificação de anomalias. Segundo Amir et al. (2016) a técnica pode ser empregada em aplicações de detecção de falhas por meio de vibrações, apresentando como pontos positivos a capacidade de classificar conjuntos de dados contendo ruídos e não-linearidades.

2.1 OCSVM

O algoritmo *One-Class SVM* (OCSVM) é uma adaptação do algoritmo *Support Vector Machine* para o caso de classificação de apenas uma classe, sendo considerado por Schölkopf et al. (2001) uma extensão do SVM para dados não rotulados. Em princípio, o algoritmo tem como objetivo a maximização da distância de um hiperplano a partir da origem até um conjunto de dados. Para isto, é realizado um processo de transformação dos dados do espaço de entrada \mathbf{X} para um novo espaço de dimensionalidade superior, também chamado de espaço de *features* \mathbf{F} , tal que $\{\mathbf{F} = \phi(x) : x \in \mathbf{X}\}$, onde $\phi(x)$ é a projeção dos pontos no novo espaço.

A partir disto o algoritmo ajusta uma função binária que captura regiões no espaço de entrada \mathbf{X} onde a densidade dos dados de treinamento é grande (Schölkopf et al., 2001). A seguir é apresentado a formulação do problema de otimização para o algoritmo OCSVM:

$$\min_{\omega, \xi_i, \rho} \frac{\|\omega\|^2}{2} + \frac{1}{\nu m} \sum_{i=1}^m \xi_i - \rho \quad (1)$$

sujeito a:

$$\begin{aligned} \omega^T \phi(x_i) &\geq \rho - \xi_i & \forall i = 1, \dots, m \\ \xi_i &\geq 0 & \forall i = 1, \dots, m \end{aligned} \quad (2)$$

Tal que ω representa o vetor normal do hiperplano e ρ sua distância da origem, ξ_i é uma variável de folga e $\phi(x)$ a projeção dos dados em um espaço dimensional de ordem superior. O parâmetro ν caracteriza uma fração de erros que podem ser admitidos durante o treinamento, também representando o limite inferior da fração de vetores de suporte (Schölkopf et al., 2001). Com isso, por meio de técnicas de multiplicadores de Lagrange, quando esse problema de minimização é resolvido, a função de decisão

para uma amostra x torna-se igual (3), onde α_i representa os coeficientes de Lagrange, com $\sum_{i=1}^m \alpha_i = 1$.

$$f(x) = \text{sgn}\left(\sum_{i=1}^m \alpha_i K(x, x_i) - \rho\right) \quad (3)$$

Pode-se entender $f(x)$ como sendo o resultado proveniente da avaliação entre a combinação linear dos valores obtidos por uma função *kernel* $K(x, x_i)$ para todo x_i . Quando a combinação linear resulta em um valor superior a ρ , a função sinal determina um valor de +1 para a saída, indicando que a amostra x pertence ao conjunto de dados de treino. Já quando o resultado é inferior ao valor de ρ , tem-se -1 na saída, indicando uma amostra anômala.

2.2 Funções Kernel

As funções *kernel* caracterizam-se como uma técnica empregada para reduzir a complexidade computacional na resolução do OCSVM, sendo uma operação que permite ao algoritmo resolver um problema de natureza não-linear. Existem diversos tipos de *kernel* à disposição dos problemas que envolvem o OCSVM, entre eles: Funções de Base Radial (RBF), Polinomiais, Lineares e Sigmoidais. Apesar disso, Bounsiar and Madden (2014a) e Tao et al. (2020) defendem que, em geral, a função *kernel* de base radial gaussiana é a que apresenta melhores resultados diante dos problemas de classificação.

Esse fato pode ser observado no trabalho de Bounsiar and Madden (2014b) quando do uso de diferentes tipos de *kernel* na obtenção de fronteiras de decisão para um certo conjunto de dados. Demonstrou-se que os outros tipos de *kernel* mencionados anteriormente falharam no procedimento de separação dos dados alvo e não são recomendados junto ao OCSVM. Tendo isto em mente, o foco neste trabalho será voltado à utilização do *kernel* do tipo RBF gaussiano, com formulação exposta a seguir, onde x e x_i são as entradas da função e γ é um hiper-parâmetro da própria função *kernel*.

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2), \quad \gamma > 0 \quad (4)$$

O hiper-parâmetro γ tem forte influência na decisão da fronteira de aprendizagem do modelo, de modo que valores grandes de γ aproximam a fronteira de decisão ao conjunto de amostras, ao passo que valores pequenos podem não capturar a complexidade no contorno dos dados. Em todo caso, técnicas de validação cruzada devem ser utilizadas para decidir o valor ótimo deste hiper-parâmetro (Tao et al., 2020).

2.3 Detecção de Anomalias em Motores Elétricos

O conceito de anomalias a ser tratado neste trabalho baseia-se em Xenos (1998), onde as anomalias são descritas como falhas em potencial. As falhas em potencial levam em consideração o desenvolvimento da perda de desempenho do equipamento, dividindo-se entre o período de tempo de condição normal, aparecimento de um sinal de falha e falha funcional da máquina.

Nesse sentido, a detecção de anomalias nos motores elétricos considera um conjunto de técnicas preditivas que

podem ser empregadas para indicar a necessidade de intervenção para manutenção no equipamento. As técnicas mais comuns envolvem a análise de vibração, termografia, assinatura de corrente e análise de óleo de lubrificação dessas máquinas (Xenos, 1998).

Com relação à vibração, existem duas fontes principais em motores elétricos: mecânicas e eletromagnéticas. As vibrações de fonte mecânica podem derivar de desbalanceamento do rotor, desalinhamento do eixo, fixação inadequada, rolamentos defeituosos e condições de acoplamento com as cargas. Por outro lado, as vibrações da fonte eletromagnética podem vir a ocorrer devido a forças eletromagnéticas radiais e tangenciais da máquina, em virtude de fontes de alimentação de baixa qualidade e devido a carga acionada (Tsyppkin, 2011) (Baccarini, 2005).

3. METODOLOGIA

3.1 Extração de características

Um processamento adequado dos dados de vibração permite identificar, de forma objetiva, diferentes tipos de falhas mecânicas e magnéticas. Esse processamento geralmente é realizado por meio de medidas estatísticas, em uma etapa conhecida como extração de características ou *features* (Teixeira et al., 2020). Além disso, o domínio (tempo ou frequência) no qual se trabalha permite obter diferentes informações sobre a condição de um equipamento. A transformação e obtenção de atributos no domínio da frequência, é comumente realizada através da *Fast Fourier Transform* (FFT). No entanto, uma limitação da técnica é a consideração de que o sinal a ser processado é estacionário, o que nem sempre é verdadeiro. Além disso, outras interferências podem atrapalhar na obtenção de tais características, como o escorregamento da máquina e a sobreposição de vibrações (Caesarendra and Tjahjowidodo, 2017). Dessa forma, uma simplificação ao método proposto é a utilização de características no domínio do tempo.

Segundo Caesarendra and Tjahjowidodo (2017), uma das características mais comuns na análise de vibração é o *Root Mean Square* (RMS). O RMS mostra a tendência de vibração ao longo do tempo, aumentando à medida que a falha se desenvolve. Outro atributo amplamente utilizado é o Fator de Crista (FC), que indica quão extremos são os picos de uma forma de onda. A seguir é apresentado o equacionamento para extração de tais medidas, onde N é um número de amostras de aquisição, com $i = 1, \dots, N$.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (5)$$

$$\text{Fator de Crista} = \frac{\max |x_i|}{RMS} \quad (6)$$

3.2 Aquisição de dados

Para a coleta dos dados de vibração elaborou-se um dispositivo de aquisição sem fio, com capacidade de transmissão de dados via protocolo *Bluetooth Low Energy* (BLE) por meio do módulo de comunicação BLE-CC41-A. O dispositivo contou com um microcontrolador STM32F103C8T6,

um acelerômetro MPU-6050 MEMS tri-axial, com fundo de escala programável ($\pm 2g$, $\pm 4g$, $\pm 8g$, $\pm 16g$), conversor analógico digital (ADC), taxa de amostragem máxima de 1kHz e interface de comunicação i²c de 400kHz.

Ainda nesse sentido, no ensaio de aquisição dos dados de vibração, utilizou-se um motor de indução trifásico com 1,5 cv de potência, velocidade nominal de 1715 RPM, tensão de alimentação de 220/380V, 60Hz e fator de potência de 0,80. Além disso, visando estabelecer duas diferentes condições de operação do motor elétrico, empregou-se um freio de Foucault. O freio de Foucault caracteriza-se como um dispositivo eletromagnético empregado para frenagem ou simulação de carga, que é obtida através da interação de campos magnéticos presentes em uma massa metálica acoplada ao eixo do motor e um par de bobinas. A seleção do conjunto deu-se em virtude de restrições de laboratório em introduzir qualquer tipo de defeito mecânico ao equipamento durante o ensaio. Nesse sentido, definiu-se uma condição de operação (A) a partir da aplicação da carga do disco metálico em conjunto à ativação do freio de Foucault, visando caracterizar um funcionamento anômalo. Por outro lado, determinou-se um estado de operação normal (N) com aplicação da carga do disco metálico mas sem a ativação da frenagem, mencionada anteriormente.

Durante a coleta dos dados, a velocidade da máquina foi mantida em, aproximadamente, 800 RPM nas condições de operações (A) e (N), com a fixação do sensor de vibração junto a um mancal, entre o motor elétrico e o disco metálico do freio eletromagnético. Na figura 1 é exposto o local de montagem do sensor, no qual percebe-se que os eixos de aceleração x e z são radiais e y é longitudinal ao eixo do motor.



Figura 1. Fixação do sensor no mancal

3.3 Implementação do algoritmo de detecção

A classificação dos dados foi tratada individualmente para cada eixo de aceleração, visando uma representação adequada dos diferentes modelos de vibração dos eixos durante o processo de treinamento do algoritmo. Foram utilizados como características os valores de RMS e Fator de Crista, em uma perspectiva de que esses atributos seriam suficientes para a identificação das anomalias introduzidas ao sistema. Ainda sobre as especificações do algoritmo,

utilizou-se o *kernel* do tipo RBF gaussiano, tendo em mente o que foi apresentado na seção 2.2. Com isso, foi necessário a aplicação de um método de validação cruzada, para a seleção dos hiper-parâmetros ν e γ ótimos do classificador OCSVM, uma vez que esses valores definem uma fronteira de decisão adequada à classificação de novas amostras.

O método estipulado para treinamento dos modelos e definição dos hiper-parâmetros ótimos do classificador envolveu a divisão dos dados de condição de operação (N) em uma fração de 80% para 20%, sendo estabelecido um conjunto de dados para treinamento e teste, respectivamente. Foram definidos os seguintes valores de inicialização para os hiper-parâmetros: $\nu = [0.01, 0.1, 0.3, 0.5, 0.7, 0.9]$ e $\gamma = [1, 5, 10, 50, 100]$. A partir disto, baseando-se na metodologia de seleção de hiper-parâmetros apresentada no estudo de (Shin et al., 2005), foi definida uma busca de valores ótimos em área ampla, tendo por objetivo encontrar uma região de valores de hiper-parâmetros para os quais fossem obtidos os menores erros sobre o conjunto de dados de teste. Posteriormente, uma nova convergência de valores foi estabelecida próxima à região encontrada no passo anterior, empregando uma regra de criação de valores linearmente espaçados entre si e visando um ajuste refinado dos hiper-parâmetros ótimos do classificador.

4. RESULTADOS E DISCUSSÕES

Com a conclusão das etapas de coleta e processamento, foram obtidas cerca de 400 amostras sob condição de operação (N) para caracterização do modelo da máquina e 20 amostras correspondentes a operação (A) ou condição anômala. Como já mencionado, o treinamento do algoritmo incluiu apenas as características RMS e Fator de Crista do sinal de vibração, possibilitando a observação das fronteiras de decisão em uma representação bidimensional. Nas Figuras 2, 3, 4 são apresentados os resultados obtidos na definição das fronteiras para os eixos x , y e z , respectivamente.

Pode-se observar, na Figura 2, a fronteira de decisão obtida para o eixo de aceleração x . Os pontos em azul caracterizam as amostras de operação sob condição normal (N) e em vermelho estão as amostras representativas das condições de operação anômala (A). A fronteira de decisão é representada pela linha em cor verde e foi obtida com a seleção de valores de 0.012 e 4.0 para os hiper-parâmetros ν e γ , respectivamente. É possível notar a capacidade de generalização do algoritmo classificador, apesar do conjunto de dados normais conter algumas amostras de elevada dispersão.

Já para a obtenção da fronteira de decisão exposta na Figura 3, a técnica elaborada determinou os valores ótimos de 0.010 e 2.0 para os hiper-parâmetros ν e γ , respectivamente. Assim, também foi possível notar um ajuste do classificador aos dados normais obtidos para o eixo y . Por outro lado, na Figura 4, é mostrada a fronteira de decisão para os dados de aceleração do eixo z , em uma composição diferente das anteriores. Pode-se notar que, a maior parte das amostras consideradas normais foram classificadas corretamente e a fronteira obteve um perfil com uma maior distribuição de valores de Fator de Crista

com relação às demais. Utilizou-se como valores de hiper-parâmetros 0.012 e 1.3 para ν e γ , respectivamente.

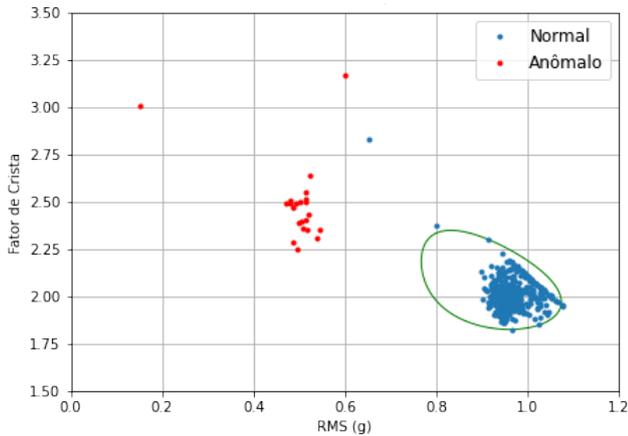


Figura 2. Fronteira de decisão - eixo x

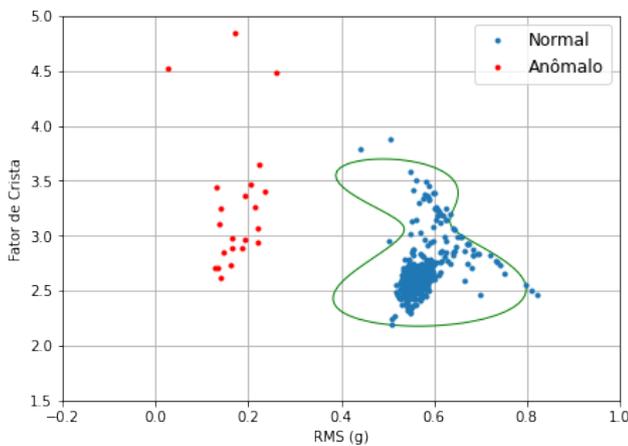


Figura 3. Fronteira de decisão - eixo y

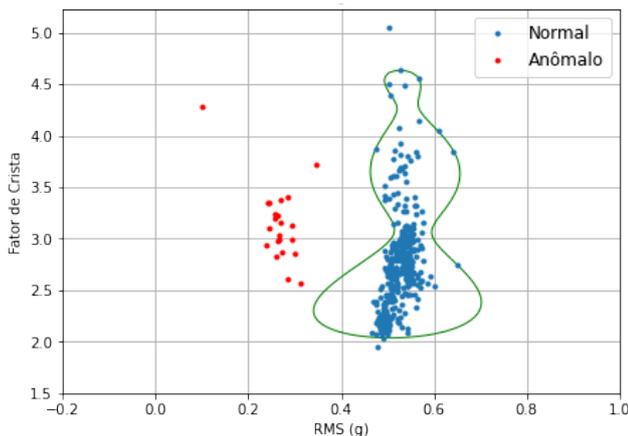


Figura 4. Fronteira de decisão - eixo z

A influência dos hiper-parâmetros nos modelos de classificação com OCSVM é demonstrada em um conjunto de testes elaborado com a técnica de seleção de hiper-parâmetros. As Tabelas 1, 2 e 3 apresentam esses resultados, com os valores percentuais de erro de treinamento, de validação cruzada e erro na detecção de anomalias.

Os erros de treinamento e validação cruzada refletem os casos para os quais os modelos identificaram as amostras como sendo anômalas, quando na verdade eram normais. Por outro lado, os erros na detecção de anomalias foram quantificados para os casos nos quais as amostras anômalas foram caracterizadas como sendo normais.

Tabela 1. Seleção de hiper-parâmetros - eixo x

ν	γ	treino (%)	val. cruzada (%)	anomalias (%)
0.007	1.2	0.946	1.266	0.000
0.006	3.8	0.946	0.000	0.000
0.012	4.0	1.262	1.266	0.000
0.009	2.9	0.946	2.532	0.000
0.009	6.7	0.946	1.266	0.000

Tabela 2. Seleção de hiper-parâmetros - eixo y

ν	γ	treino (%)	val. cruzada (%)	anomalias (%)
0.010	0.7	0.946	2.532	36.364
0.009	1.0	0.946	0.000	0.000
0.009	2.0	1.262	0.000	0.000
0.008	3.2	0.631	3.797	0.000
0.009	2.0	1.262	1.266	0.000

Tabela 3. Seleção de hiper-parâmetros - eixo z

ν	γ	treino (%)	val. cruzada (%)	anomalias (%)
0.011	0.8	1.577	1.266	0.000
0.012	1.3	1.893	2.532	0.000
0.006	1.0	1.262	3.797	4.545
0.008	1.9	1.893	1.266	0.000
0.012	1.0	1.262	5.063	4.545

Percebe-se, que em todas as tabelas ocorreu uma convergência dos valores de ν e γ para uma determinada região de valores. O hiper-parâmetro ν , inicializado com valores iguais a [0.01, 0.1, 0.3, 0.5, 0.7, 0.9] foi o que menos sofreu variação nas diferentes rodadas de execução do algoritmo, tendo valores próximos a 0.010. Já γ , que foi inicializado com valores de [1, 5, 10, 50, 100], apresentou uma maior discrepância, tendo uma maior faixa de variação para o eixo x , com valores indo de 1.2 até 6.7.

Com relação aos erros de treinamento e de validação cruzada, notam-se, em todas as tabelas, que estes não passaram de 5%, indicando que a maior parte das amostras consideradas normais foi classificada corretamente. O erro percentual de detecção de anomalias também revelou uma indicação adequada pelos modelos alcançados. A exceção, no entanto, foi para uma execução do algoritmo com relação ao eixo y : embora as amostras normais tenham sido classificadas corretamente, 36,364% das anômalas não foram.

Dito isto, o fato mencionado para o eixo y , evidencia a influência do hiper-parâmetro γ na definição dos limites da fronteira de decisão, uma vez que valores pequenos podem não capturar a complexidade no contorno dos dados. Como forma de exemplificação é exibido o contorno da fronteira de decisão para dois pares de ν e γ : (0.010, 0.7) e (0.010 e 2.0), respectivamente. Percebe-se, das Figuras 5 e 6, que quando γ é maior, a fronteira de decisão ajusta-se ao conjunto de dados de operação (N), caracterizando um menor quantitativo de amostras da condição (A) de forma incorreta.

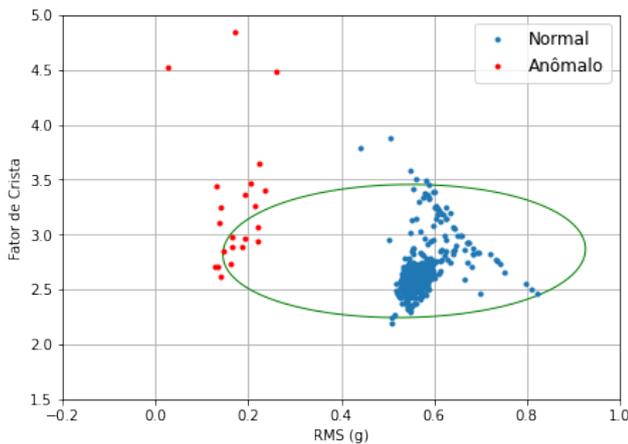


Figura 5. Influência de γ pequeno - eixo y

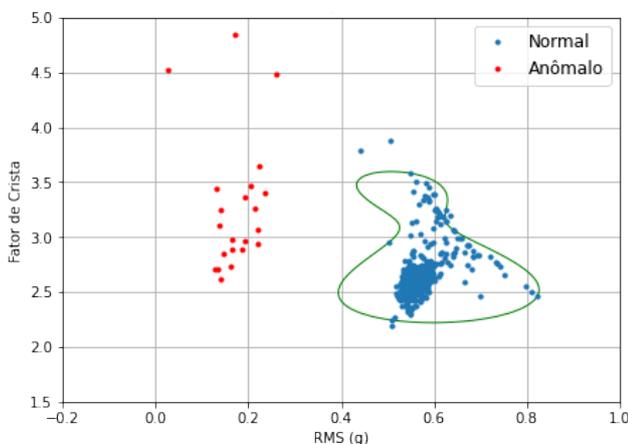


Figura 6. Influência de γ grande - eixo y

5. CONCLUSÕES

A utilização do algoritmo OCSVM, para detecção de anomalias nos dados de vibração do motor elétrico, permitiu encontrar uma fronteira de decisão que restringiu os dados de operação considerados normais, daqueles ditos irregulares, para o modelo de cada eixo de aceleração. No entanto, como observado por Bounsiar and Madden (2014b) e Tao et al. (2020) há uma grande influência da seleção da função *kernel* e dos hiper-parâmetros ótimos ao modelo de classificação. Sendo necessária uma elaboração refinada na escolha desses valores.

Em trabalhos futuros, propõem-se o aproveitamento dessa tática de detecção de anomalia visando uma integração junto a uma plataforma de monitoramento, o que pode contribuir para a adoção de práticas de manutenção mais assertivas, diminuindo as diversas perdas relacionadas a reposição de peças e paradas não programadas.

REFERÊNCIAS

Amir, R.B., Gul, S.T., and Khan, A.Q. (2016). A comparative analysis of classical and one class svm classifiers for machine fault detection using vibration signals. In *2016 International Conference on Emerging Technologies (ICET)*, 1–6. IEEE.

Baccarini, L.M.R. (2005). *Deteção e diagnóstico de falhas em motores de indução*. Ph.D. thesis, Universidade Federal de Minas Gerais.

Borges, F., Pinto, A., Ribeiro, D., Barbosa, T., Pereira, D., Magalhães, R., Barbosa, B., and Ferreira, D. (2020). An unsupervised method based on support vector machines and higher-order statistics for mechanical faults detection. *IEEE Latin America Transactions*, 18(06), 1093–1101.

Borges, F.E.d.M., Ribeiro, D.A., Mota, O.F., Ferreira, D.D., and Huallpa, B.N. (2019). Classificador não supervisionado baseado em curvas principais para detecção de falhas em motor de indução. *Anais da Sociedade Brasileira de Automática*, 1(1).

Bounsiar, A. and Madden, M.G. (2014a). Kernels for one-class support vector machines. In *2014 International Conference on Information Science & Applications (ICISA)*, 1–4. IEEE.

Bounsiar, A. and Madden, M.G. (2014b). One-class support vector machines revisited. In *2014 International Conference on Information Science & Applications (ICISA)*, 1–4. IEEE.

Caesarendra, W. and Tjahjowidodo, T. (2017). A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines*, 5(4), 21.

El-Thalji, I. and Jantunen, E. (2015). A summary of fault modelling and predictive health monitoring of rolling element bearings. *Mechanical systems and signal processing*, 60, 252–272.

Mahdavejad, M.S., Rezvan, M., Barekatain, M., Adibi, P., Barnaghi, P., and Sheth, A.P. (2018). Machine learning for internet of things data analysis: A survey. *Digital Communications and Networks*, 4(3), 161–175.

Schölkopf, B., Platt, J.C., Shawe-Taylor, J., Smola, A.J., and Williamson, R.C. (2001). Estimating the support of a high-dimensional distribution. *Neural computation*, 13(7), 1443–1471.

Shin, H.J., Eom, D.H., and Kim, S.S. (2005). One-class support vector machines—an application in machine fault detection and classification. *Computers & Industrial Engineering*, 48(2), 395–408.

Tao, C., Li, T., and Huang, J. (2020). Kernel choice in one-class support vector machines for novelty and outlier detection. In *2020 2nd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)*, 116–120. IEEE.

Teixeira, H.N., Lopes, I., and Braga, A.C. (2020). Condition-based maintenance implementation: a literature review. *Procedia Manufacturing*, 51, 228–235.

Tsytkin, M. (2011). Induction motor condition monitoring: Vibration analysis technique—a practical implementation. In *2011 IEEE International Electric Machines & Drives Conference (IEMDC)*, 406–411. IEEE.

Xenos, H.G. (1998). *Gerenciando a manutenção produtiva*, volume 171.

Xu, H., Song, P., and Liu, B. (2019). A vibration signal anomaly detection method based on frequency component clustering and isolated forest algorithm. In *2019 IEEE 2nd International Conference on Automation, Electronics and Electrical Engineering (AUTEEE)*, 49–53. IEEE.