

Detecção de anomalias em ventiladores industriais via sinais de vibração^{*}

Gercilio C. Zuqui Jr.^{*} Thomas W. Rauber^{**}
Eduardo Carneiro de Assis^{***} Patrick Marques Ciarelli^{***}
Celso J. Munaro^{***}

^{*} Vale, S.A., ES, Brasil, (e-mail: gercilio.zuqui@vale.com).

^{**} Núcleo de Inferência e Algoritmos, Departamento de Informática,
Vitória, ES, Brasil, (e-mail: thomas@inf.ufes.br)

^{***} Laboratório de Controle e Instrumentação, Departamento de
Engenharia Elétrica, Vitória, ES, Brasil, (e-mail:
eduardo.c.assis@edu.ufes.br, celso.munaro@ufes.br,
patrick.ciarelli@ufes.br)

Abstract: Pelletizing furnaces require the use of high power fans to circulate the air in the different regions of the furnace, ensuring the efficiency of the pellet burning process and the use of energy. The failure of one of these fans results in a stop of the production process and economic losses. This work presents a contribution to support predictive maintenance routinely performed on this equipment. Vibration signals in rotating machinery are sensitive to many faults and are therefore widely used in diagnostic systems. From the speed and torque information of the fans and the vibration signals in the bearings collected at low sampling rates, it is possible to generate alarms that guide investigative actions, specifically in the equipment that exhibit anomalous behavior. Graphs with sliding windows allow checking trends in vibration increase, and are used to predict alarms in advance. The monitoring of two fans for four months, compared to inspection reports carried out in the same period showed the contribution that the proposed system can bring to reduce downtime and more rationally use the work of the maintenance teams.

Resumo: Fornos de pelotização requerem o uso de ventiladores de grande potência para fazer circular o ar nas diferentes regiões do forno, garantindo a eficiência do processo de queima das pelotas e do uso de energia. A falha em um desses ventiladores implica na parada do processo de produção e perdas econômicas. Neste trabalho é apresentada uma contribuição para apoiar manutenção preditiva realizada rotineiramente nesses equipamentos. Os sinais de vibração em máquinas rotativas são sensíveis a muitas falhas, sendo por isso muito utilizados em sistemas de diagnóstico. A partir das informações de velocidade e torque dos ventiladores e dos sinais de vibração nos mancais coletados a baixas taxas de amostragem, consegue-se gerar alarmes que orientam ações de investigação especificamente nos equipamentos que apresentam comportamentos anômalos. Gráficos com janelas deslizantes permitem verificar tendências de aumento de vibração, e são usados para prever os alarmes com antecedência. O monitoramento de dois ventiladores durante quatro meses, comparado aos laudos de inspeção realizados no período, mostrou a contribuição que o sistema proposto pode trazer para reduzir paradas e usar mais racionalmente o trabalho das equipes de manutenção.

Keywords: Anomaly detection, condition monitoring, pelletizing furnace, industrial fans, Fisher discriminant analysis, vibration.

Palavras-chaves: Detecção de anomalias, monitoramento de condição, forno de pelotização, ventiladores industriais, análise via discriminante de Fisher, vibração.

1. INTRODUÇÃO

Os ventiladores industriais desempenham um papel fundamental na combustão, troca de calor e reaproveitamento de energia em fornos de pelotização. Como são máquinas de grande porte, o monitoramento das suas condições opera-

cionais é fundamental para a detecção rápida de desvios, antes que se tornem problemas que possam acarretar a paralisação do equipamento e, conseqüentemente, do forno de pelotização. Paradas corretivas dos equipamentos podem gerar interrupções longas da produção, com custos milionários. Um exemplo que gera tal parada é a queima de um casquilho.

A manutenção preventiva costumeiramente consome tempo, gerando paralisações da produção e, como consequência,

^{*} Este trabalho recebeu o apoio da Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) e da Vale, sob o termo de cooperação 29501.412.19434.18122015.

perdas financeiras. Uma forma mais eficiente são as manutenções preditivas baseadas na condição dos equipamentos, que conseguem detectar desvios de comportamento e antecipar falhas (Teixeira et al., 2020). No caso de ventiladores industriais, a manutenção preditiva é geralmente feita usando sensores de vibração com dados coletados com altas frequências de amostragem. A análise do espectro dos sinais permite identificar comportamentos anormais e diagnosticar problemas tais como desbalanceamento, folgas, quebra de placas, entre outros (Kebabsa et al., 2018). Normalmente há rotinas para realizar tais inspeções localmente no ventilador, realizadas por especialistas. Havendo indícios de comportamento anormal, inspeções são realizadas para identificar a causa.

Ventiladores de grande porte são instrumentados com sensores de vibração (acelerômetros) e suas medidas são acompanhadas nas telas de operação do processo, como amostragens em torno de 1Hz (Scheffer e Girdhar, 2004). São definidos limites para a vibração máxima permitida que deve gerar alarmes. Nesse artigo, uma metodologia para extrair informação desses sensores é desenvolvida, com o objetivo de orientar as equipes de manutenção sobre a necessidade de realizar inspeções em ventiladores com comportamentos anormais. A comparação dos alarmes gerados com relatórios de inspeção periódicos realizados nos equipamentos confirmou a utilidade das previsões geradas pelos alarmes, racionalizando o trabalho das equipes de manutenção. Por fim, os algoritmos adaptados da literatura (Aldrich e Auret, 2013) foram programados para gerar alarmes diretamente nas telas dos sistemas de supervisão, permitindo uma maior integração das ações entre operação e manutenção.

Na seção 2 são descritos os ventiladores e os sinais monitorados, com uma breve descrição das rotinas de inspeção. Na seção 3 são apresentados os algoritmos e a metodologia proposta, bem como resultados preliminares da modelagem feita. Na seção 4 são apresentados os resultados: a detecção de eventos anormais, curvas que permitem identificar tendências de falhas, e a previsão de falhas. Na última seção são apresentadas as conclusões do trabalho.

2. DESCRIÇÃO DOS VENTILADORES E DOS SINAIS MEDIDOS

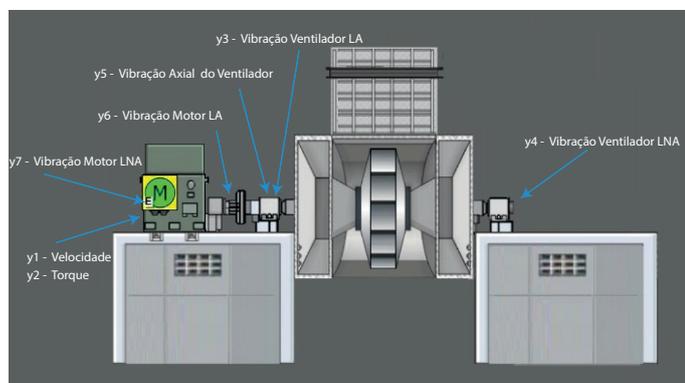


Figura 1. Esquemático do Ventilador de Processo

Os ventiladores de processo, objetos deste estudo, são do tipo radial e cada um possui quatro mancais, dois

para o ventilador e dois para o motor. Como o motor é acoplado ao ventilador, os mancais são identificados como lado acoplado (LA) e lado não acoplado (LNA).

Além das medições de velocidade (y_1) e torque (y_2), cada ventilador analisado possui cinco acelerômetros posicionados conforme a figura 1, com objetivo de paralisar a operação do equipamento em caso de violação dos seus limites de desarme. Os limites para os medidores posicionados nos mancais do ventilador y_3 a y_5 são 4,5 mm/s para alarme e 7,1 mm/s para desarme. Os limites para os medidores nos mancais do motor y_6 e y_7 são 6,4 mm/s para alarme e 10,2 mm/s para desarme. Todos os sinais são acompanhados pela tela sinótica através do acompanhamento do seu valor instantâneo em um display analógico, e nada é feito enquanto os limites não são atingidos.

Adicionalmente, uma rotina de inspeção periódica é realizada em cada ventilador, coletada através de sensores específicos dedicados que não estão ilustrados na figura 1. Um especialista em manutenção preditiva analisa o espectro dos sinais e é capaz de detectar pequenos desvios de comportamento. O desenvolvimento de um sensor virtual capaz de analisar os sinais dos medidores y_3 a y_7 e gerar alarmes para técnicos especializados, em caso de pequenas mudanças no comportamento, pode resultar em uma antecipação significativa da falha, evitando ou reduzindo os danos causados ao equipamento.

3. DETECÇÃO DE ANOMALIAS

A maioria dos métodos para detecção de anomalias em grandes máquinas rotativas envolve a análise do espectro de sensores de vibração instalados em diferentes pontos desses equipamentos (Xu et al., 2018). Essas análises requerem a coleta dos dados com altas taxas de amostragem, e são feitas periodicamente com analisadores e sensores específicos instalados nestas máquinas. O monitoramento diário é feito com sensores de vibração com baixa frequência de resposta (< 1 Hz) que são comumente instalados nesses equipamentos. As medições são monitoradas nas telas de supervisão do processo, havendo alarmes caso ultrapassem limites estabelecidos.

Como os sinais de vibração radial estão associados à velocidade de rotação, o limite deve ser definido, considerando as velocidades mais elevadas. Essa escolha tende a eclipsar anomalias nesses sinais. Como a vibração depende da velocidade, há dificuldade em se perceber tendências de aumento, pois a velocidade obedece a referências dadas pela malha de otimização do processo. Um limiar alto para alarmes impede que se conclua que a vibração está muito alta para velocidades menores.

O uso de modelos para estimar variáveis de processo e produzir resíduos, a diferença entre valores medidos e estimados, é um procedimento bastante comum para detecção de falhas. O desafio é transformar o resíduo em uma característica que detecte com boa confiança comportamentos anômalos do equipamento monitorado. Em Hamadache et al. (2019) um modelo dinâmico foi utilizado para gerar resíduos e seus erros acumulados permitiram detectar falhas nos mecanismos de troca de trilhos em ferrovias. A extração de características de sinais de vibração de máquinas rotativas usando diferentes

algoritmos de aprendizado de máquinas foi apresentado em Kuncan et al. (2020).

Nessa seção, conceitos clássicos de monitoramento de processos (Chiang et al., 2001) e o método das variáveis externas, proposto por Kano et al. (2004), são a base para gerar resíduos que permitem o monitoramento dos equipamentos rotativos, detectando comportamentos que requerem uma investigação. O objetivo é a combinação de técnicas simples, que permitam o tratamento de sinais de vibração obtidos a baixas taxas de amostragem e que possam ser prontamente aplicados na indústria.

3.1 Análise via variáveis externas

Em Kano et al. (2004) foi proposto o método denominado de variáveis externas para aplicar as metodologias de análise estatística multivariada a processos operando em múltiplos pontos de operação. Assume-se que a mudança do ponto de operação se deve a variáveis denominadas externas, que são conhecidas e mensuráveis. Usa-se então modelos para prever os valores das demais variáveis, denominadas principais, nos diversos pontos de operação. Neste artigo, as variáveis externas são a velocidade de rotação e o torque, e as variáveis principais são os cinco sinais de vibração.

Uma análise da correlação dos sete sinais mostrados na figura 1 foi realizada para escolha das variáveis externas que explicam as variações de cada um dos sinais de vibração. Embora o torque e a velocidade estejam bastante correlacionados, verificou-se uma correlação maior da velocidade com sinais de vibração do ventilador (y_3 e y_4) e do eixo do motor lado acoplado (y_6). A correlação do torque é maior com a vibração axial do ventilador (y_5) e a vibração no motor no lado não acoplado (y_7).

Uma regressão linear foi realizada tendo cada um dos cinco sinais de vibração como variável explicada (ou principal) e a velocidade e o torque como variáveis explicativas (ou externas) escolhidas conforme acima a partir da análise de correlação. O histograma dos resíduos para cada modelo usando 500 amostras selecionadas aleatoriamente é mostrado na figura 2. Na ordenada mostra-se a frequência dos resíduos pertencentes às 20 classes mostradas na abcissa.

No título de cada gráfico mostra-se também o *fit* do modelo calculado usando a equação 1, onde r é a vibração medida e \hat{r} é seu valor médio. Um valor do *fit* de 100% indica um ajuste perfeito do modelo entre r e \hat{r} , o valor estimado pelo modelo da regressão linear.

$$\text{fit} = 1 - \frac{\|r - \hat{r}\|}{\|r - \bar{r}\|} \quad (1)$$

A repetição dessa análise com diferentes valores selecionados aleatoriamente mostrou valores similares para o *fit* de cada modelo.

Os resíduos assim calculados são utilizados para construir uma carta de controle para cada um dos resíduos, conforme (Chiang et al., 2001). Uma análise multivariada permitiria monitorar apenas uma estatística, além de captar mudanças na correlação entre as variáveis. Entretanto, em caso de falha é necessário identificar em qual sensor houve vibração excessiva, e métodos para quantificar a contribuição das

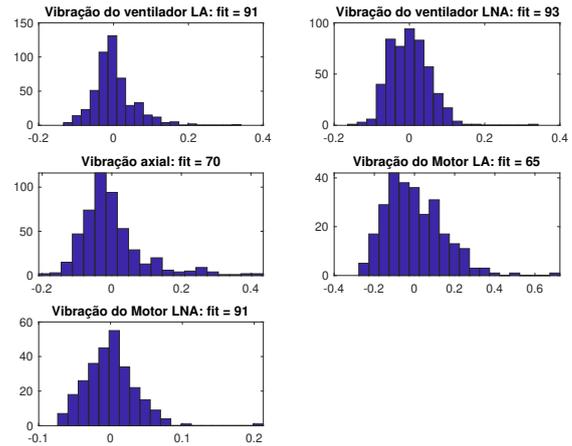


Figura 2. Histogramas dos resíduos dos sinais de vibração variáveis teriam que ser utilizados. A análise univariada por carta de controle foi escolhida para facilitar às equipes de supervisão e manutenção interpretarem os resultados de algoritmos de detecção. Saber qual ou quais sensores de vibração apresentam comportamento anômalo ajuda a diagnosticar a causa raiz.

Para reduzir a presença de falsos alarmes, uma janela de comprimento L costuma ser utilizada. Um alarme é gerado para a operação após L violações sucessivas dos limiares da carta de controle. Este valor é constante, e há bastante flexibilidade para sua escolha, sendo um parâmetro escolhido junto com as equipes de operação, para otimizar a geração de alarmes. Maiores discussões serão apresentadas na seção de Resultados. Alarmes gerados dessa forma são úteis para detectar problemas que requerem rápida intervenção, podendo impedir maiores danos aos ventiladores. Entretanto, há também os comportamentos anômalos que se manifestam lentamente, e são decorrentes de desgastes dos equipamentos. Para alertar para esses eventos, uma análise ao longo de um período maior de tempo foi implementada. O uso da soma cumulativa (Chiang et al., 2001) foi considerada, mas sem sucesso, pela dificuldade de obter os parâmetros que indicassem uma tendência no aumento dos resíduos para os cinco modelos. Foi utilizada então uma janela deslizante de dois dias para o cálculo da média de cada resíduo, que avança sobre os dados com 90% de sobreposição das amostras. Procedimento similar foi usado em Qin et al. (2021) para detectar falhas incipientes. O resultado dessa análise foi utilizado de duas formas: plotando o resultado ao longo do tempo, e treinando um algoritmo para detectar a eminência de falhas. A segunda alternativa é objeto da próxima seção.

Por fim, tanto o treinamento quanto o monitoramento é feito para velocidades dentro de uma faixa estabelecida. Neste artigo, valores entre 400 RPM e 600 RPM são considerados, por serem a faixa em que esses ventiladores devem operar.

3.2 Análise via Discriminante Linear de Fisher

O Discriminante Linear de Fisher (*Fisher Linear Discriminant Analysis* - FLDA) é uma técnica supervisionada linear que busca projetar dados multivariados de um pro-

blema binário (duas classes) em lados opostos de um hiperplano, de tal maneira que os dados estão possivelmente bem separados. Para ele obter uma boa separação dos dados projetados, ele busca maximizar a diferença entre as médias de duas classes (normal e falha) considerando a dispersão de cada classe. Assim, o FLDA visa maximizar a razão da dispersão interclasse pela dispersão intraclasse (Duda et al., 2001; Tharwat et al., 2017).

Esta abordagem é interessante para a análise e uso em ambientes industriais, pois ela une as informações advindas de diferentes variáveis, com a vantagem de permitir um operador realizar uma análise univariada com um auxílio de um limiar de decisão, sendo bem mais simples do que analisar várias variáveis individualmente. Além disso, como ela realiza a projeção linear dos dados em uma dimensão, é possível analisar, dentro de certas limitações, quais são as variáveis que mais podem contribuir para uma falha, por exemplo.

Sejam m_i , Σ_i e n_i a média, a matriz de covariância e o número de amostras da classe c_i , $i \in \{1, 2\}$, respectivamente. Então, o vetor normal do hiperplano separador entre as classes é calculado pela Equação 2.

$$w = S_w^{-1}(m_1 - m_2), \quad (2)$$

onde a matriz de dispersão intraclasse é definida como

$$S_w = (n_1 - 1)\Sigma_1 + (n_2 - 1)\Sigma_2. \quad (3)$$

O vetor w que define o hiperplano separador faz uma soma ponderada das variáveis originais, de forma que a projeção \hat{x} de cada amostra x para um ou outro lado do hiperplano é obtida pela Equação 4.

$$\hat{x} = w^T x. \quad (4)$$

Para encontrar o vetor normal do hiperplano que separa as duas classes, os dados das duas classes podem ser modelados como duas distribuições multivariadas normais de igual matriz de covariância e, conforme (Duda et al., 2001), o limiar de decisão ideal τ é determinado pela Equação 5, onde $P(c_i)$ é a probabilidade *a priori* da classe c_i e $n = n_1 + n_2$.

$$\tau = \frac{m_1^T S_w^{-1} m_1}{2} - \frac{m_2^T S_w^{-1} m_2}{2} + \frac{1}{(n-2)} \ln \left[\frac{P(c_2)}{P(c_1)} \right]. \quad (5)$$

Assim, a classificação é realizada pela Equação 6:

$$C(x) = \begin{cases} c_1, & \text{se } w^T x > \tau, \\ c_2, & \text{caso contrário.} \end{cases} \quad (6)$$

O FLDA, aplicado com outras técnicas, tem alcançado relativo sucesso em aplicações de diagnóstico de falhas (Chiang et al., 2000; He et al., 2005) e de predição de eventos (Santoso e Wibowo, 2018; Kalsoom et al., 2018). Neste trabalho, o FLDA será utilizado para fazer a predição se os ventiladores entrarão em falha ou não, sendo a decisão baseada em dados passados e presentes.

4. RESULTADOS E DISCUSSÕES

4.1 Monitoramento de dois ventiladores industriais

Os dados utilizados neste trabalho são coletados diretamente dos controladores dos ventiladores a cada um segundo, usando o padrão OPC UA (Mahnke et al., 2009)

de comunicação. Na fase de desenvolvimento, os dados são analisados *off-line* usando o software Matlab. Uma vez validados, os algoritmos são implantados em um computador que acessa dados do processo e disponibiliza os alarmes gerados aos operadores em suas telas de supervisão. Para isso, também é usada a comunicação via OPC. A cada 1 minuto, 60 medições de cada sinal são recebidas pelo algoritmo de detecção de falhas, e o resultado é persistido no mesmo computador com um resumo dos alarmes enviados para as telas de supervisão do processo.

Na figura 3 é mostrado o resultado para um dos dias de monitoramento para o ventilador #2. Os dois primeiros gráficos mostram a velocidade e o torque, facilitando a interpretação dos resultados. Os gráficos três a sete mostram o resíduo calculado usando os modelos ajustados e os limiares para detecção de falhas (linhas vermelhas na horizontal), conforme seção 3.1. Os pontos marcados em vermelho correspondem aos alarmes gerados quando $L = 20$ valores subsequentes de resíduos ultrapassaram o limiar no gráfico correspondente. Nesse dia houve uma parada, que se observa pela velocidade que foi reduzida a zero. Na retomada da operação, os sinais três sensores deram origem aos alarmes mostrados. Essa situação é típica, segundo a operação, e optou-se por inibir esse alarme.

Para avaliar a metodologia proposta, foram monitorados dois ventiladores durante quatro meses. No ventilador #1, poucos alarmes foram observados no período. Para acompanhar o comportamento ao longo do tempo, foram gerados os gráficos com as médias móveis dos resíduos descritos na seção 3.1, e mostrados na figura 4 para os 560 valores médios calculados para uma janela deslizante de dois dias com superposição de 90% dos dados. O gráfico correspondente para o ventilador #2 no mesmo período mostrou valores que crescem continuamente, como se observa na figura 5.

Por fim, foram calculados os alarmes médios usando a mesma janela de dois dias e mesma superposição de 90% usados para os resíduos, para os ventiladores #1 e #2. Como o valor do alarme é zero ou um, um valor médio igual a um indica que o alarme foi gerado de forma ininterrupta no período calculado, nesse caso, dois dias. Esse resultado pode ser observado na figura 6. A curva em azul mostra que alarmes foram gerados para o ventilador #1 e depois cessaram. Partidas e paradas do ventilador, por exemplo, geram tais alarmes. A curva em laranja mostra um aumento crescente dos alarmes no ventilador #2. A vibração no mancal no qual o ventilador e o motor estão acoplados foi detectada pelos sensores correspondentes, e produziram os alarmes.

Para validar os resultados dos algoritmos, foram solicitados os relatórios de inspeção realizados no ventilador #2 nos 4 meses durante os quais foi realizado o monitoramento. Em um desses relatórios se lê: “picos de vibração observados”. Em outro se lê “ventilador apresentando instabilidade na manutenção dos parâmetros normais de operação para os mancais de apoio do rotor”. Essas inspeções são feitas periodicamente ou quando houver suspeita de mau funcionamento. Verificou-se que os laudos de suspeita ou instabilidade coincidiram com o aumento do número de alarmes gerados pelo algoritmo desenvolvido. Isto indica

que a abordagem usada pode ser usada para detectar falhas.

A próxima etapa envolve utilizar os resíduos e os alarmes gerados para prever a ocorrência de um evento anormal, e assim poder solicitar inspeções e manutenções nos ventiladores com maior antecedência.

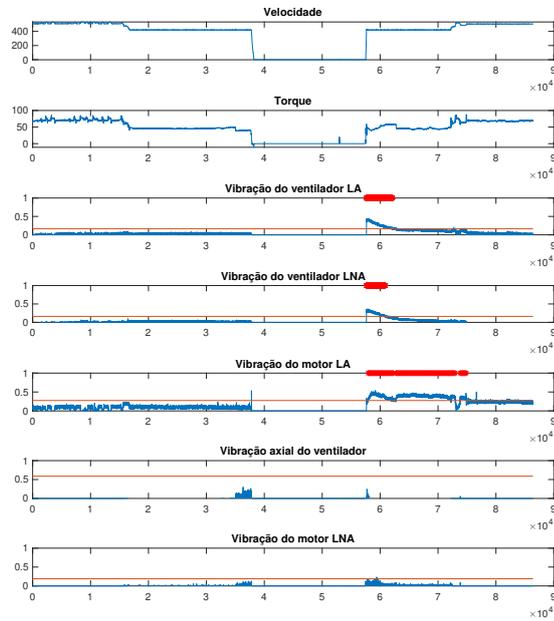


Figura 3. Ventilador #2 durante um dia de operação

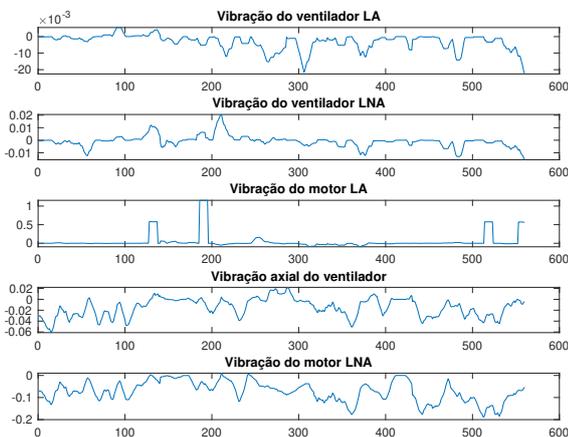


Figura 4. Resíduos médios do ventilador #1 durante 4 meses

4.2 Predição de falhas via Discriminante Linear de Fisher

Na figura 3 observa-se que há alarmes (pontos em vermelho) em cada um dos medidores de vibração que ocorrem tão logo os limiares sejam ultrapassados por ao menos $L = 20$ valores consecutivos. Esses alarmes são muito importantes quando ocorrem eventos anormais que devem

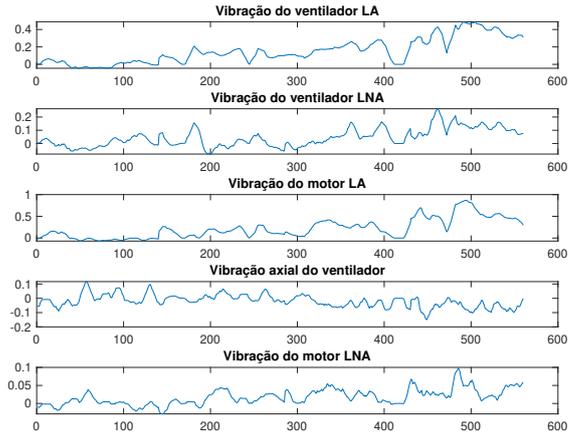


Figura 5. Resíduos médios do ventilador #2 durante 4 meses

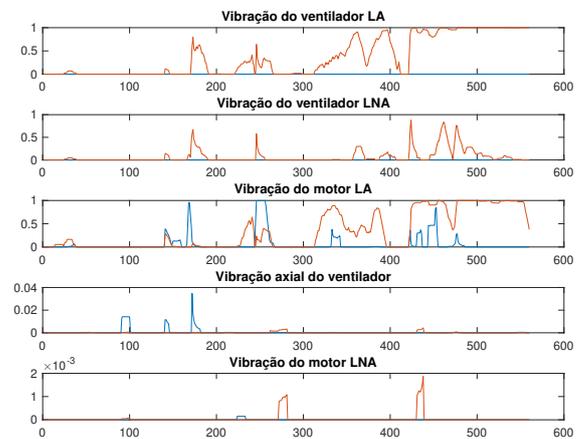


Figura 6. Alarmes médios gerados pelos ventiladores #1 e #2 durante os 4 meses (azul=vent#1 e laranja=vent#2)

ser avaliados rapidamente, para evitar maiores danos aos equipamentos. Entretanto, gráficos como os mostrados na figura 5 indicam a existência de tendência de aumento nos resíduos que poderão levar a falhas, embora ainda não tenham gerado alarmes (ver figura 6). Uma análise multivariada que pudesse antecipar a ocorrência desses alarmes seria muito desejável.

Para tentar prever a ocorrência de alarmes e, conseqüentemente, de falhas, é proposto aplicar o FDLA sobre os dados para discriminar os dados que antecipam condições normais de operação daqueles que antecedem situações de falha.

Para os experimentos de predição de falhas foram usados os dados dos ventiladores #1 e #2. Para estes ventiladores existem 560 valores de resíduos, conforme as figuras 4 e 5. O primeiro passo foi rotular os dados de cada ventilador nas classes normal e falha para aplicação do método FLDA. Para isto, foi calculada, para cada ventilador, a média das falhas em cada instante de tempo da figura 6, e aplicado um limiar igual a zero para distinguir operação

normal de falha (valores maiores que zero foram considerados falhas).

Após isso, foram extraídas características dos resíduos das variáveis de cada ventilador. Para o resíduo de cada variável foi passada uma janela móvel de tamanho 4, com sobreposição entre janelas de 3 observações. De cada janela foram extraídos os seguintes atributos estatísticos: mediana, desvio padrão e coeficiente de correlação de Kendall para verificar tendência nos dados. Estes atributos foram escolhidos na esperança de representarem bem os efeitos das falhas nos dados. Em especial, a informação de tendência foi escolhida por acreditar que um sistema em falha tem a tendência de elevar ou reduzir os valores de certas variáveis. A correlação de Kendall tem vantagens sobre a correlação de Pearson por ela ser não paramétrica e não precisar assumir linearidade nos dados, sendo necessária apenas existir uma relação monotônica nos dados (Sprent e Smeeton, 2001). No total, foi obtida uma matriz de 557 amostras de 15 atributos cada (3 atributos de cada resíduo) para cada ventilador. Porém, como o propósito do método é tentar prever se ocorrerá falha ou não em uma observação futura, uma amostra no instante t terá como rótulo a informação da classe no instante $t + 1$, de forma que a última amostra não terá rótulo, sendo descartada, restando 556 amostras para cada ventilador. Como as janelas usadas para o cálculo da média dos resíduos contêm dois dias de dados, e cada novo valor da janela avança 10%, tem-se 4,8 horas de tempo entre cada amostra das figuras 4 ou 5.

Para avaliar o método proposto, foram usadas, de cada ventilador, 400 amostras para treinamento e 156 amostras para teste. Com os dados de treinamento foi obtido o escalar $w^T x$ pela Equação 6 para cada ventilador, realizando uma mudança de espaço de \mathbb{R}^{15} para \mathbb{R} . Desta forma, cada amostra é representada como somente um único valor, podendo, assim, as amostras serem representadas como um sinal ao longo do tempo, o que facilita a sua análise. O limiar de decisão τ foi obtido conforme a equação 5, sendo as probabilidades *a priori* $P(\text{normal})$ e $P(\text{falha})$ estimadas a partir do número de amostras de treino de cada uma das duas classes.

Os resultados da previsão são apresentados nas figuras 7 e 8. Nas figuras são observadas as amostras projetadas em uma dimensão com seus respectivos rótulos (as linhas em azul são as amostras normais e em verde as falhas, lembrando que o rótulo é a condição do ventilador 4,8 horas a frente), o limiar de decisão, representada pela linha horizontal vermelha, e uma linha vertical tracejada preta, cujas amostras à esquerda dela foram usadas para treinamento e à direita para teste. Os valores dos sinais abaixo do limiar foram previstos como falha. Como resultado, foram obtidos sobre o conjunto de teste uma acurácia na predição de 72,44% para o ventilador #1 e 95,51% para o ventilador #2. Pode-se observar nas figuras que nos instantes de tempo com grandes quantidades de alarmes, conforme apresentado na figura 6, a predição foi mais assertiva, especialmente para o ventilador #2 (figura 8).

A tabela 1 apresenta os resultados para as métricas acurácia, recall, precisão e F1, que é a média harmônica entre recall e precisão. A métrica recall informa a capacidade do método de prever todos os alarmes gerados, sendo o

valor ótimo 100%, enquanto que a métrica precisão indica a capacidade do método de prever corretamente quando um alarme acontecerá, sendo que quanto maior o seu valor, menor a quantidade de previsões de falsos alarmes. Pode ser observado na tabela que para o ventilador #2 foram obtidos para todas as métricas valores acima de 95%, indicando um desempenho satisfatório. Entretanto, para o ventilador #1 os resultados não foram tão bons. Esta diferença pode ser explicada observando as figuras 7 e 8. O fato do ventilador #2 estar claramente em falha faz com que nos dados de teste, as amostras de falha sejam mais facilmente discrimináveis do que as de normalidade. Ainda assim, o método pode auxiliar na previsão de possíveis alarmes e, conseqüentemente, de falhas.

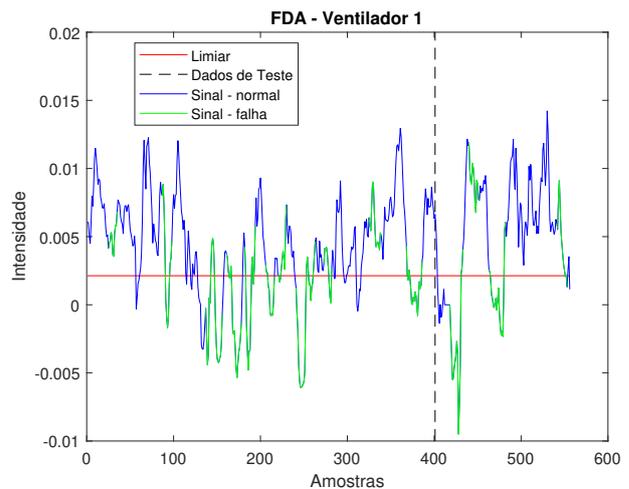


Figura 7. Resultado da previsão de falhas para o ventilador #1

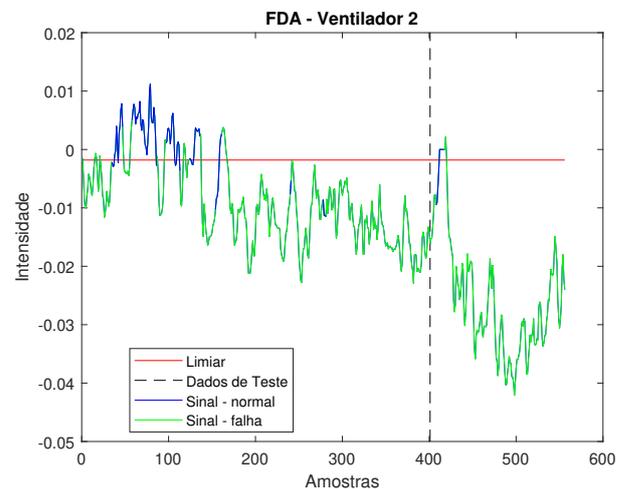


Figura 8. Resultado da previsão de falhas para o ventilador #2

5. CONCLUSÕES

Nesse trabalho, o problema de detectar comportamentos anormais em ventiladores industriais de grande porte foi abordado. Como o comportamento anormal ainda não é uma falha, há tempo para ações corretivas ou para

Tabela 1. Resultados de predição para os ventiladores #1 e #2

Métricas	Ventilador #1	Ventilador #2
Acurácia	72,44%	95,51%
Recall	52,63%	97,28%
Precisão	65,21%	97,95%
F1	58,25%	97,61%

planejar paradas com menores perdas de produção. Os resíduos gerados pelos modelos que relacionam torque e velocidade com vibração foram utilizados para detectar esses eventos, que devem desencadear ações de investigação no equipamento usando conhecidas metodologias de análise espectral. Essas inspeções periódicas poderiam ser antecipadas usando os alarmes gerados. Janelas deslizantes foram também utilizadas para monitorar o valor médio dos resíduos, permitindo identificar tendências que em algum momento gerarão alarmes. A análise via discriminante linear de Fisher aplicada a esses sinais permitiu antecipar esses alarmes. A comparação dos alarmes de eventos anômalos detectados com relatórios de inspeção no período de quatro meses para dois ventiladores comprovou a utilidade da proposta apresentada, que já foi implantada na planta industrial.

AGRADECIMENTOS

Este trabalho recebeu o apoio da Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) e da Vale, sob o termo de cooperação 29501.412.19434.18122015.

REFERÊNCIAS

- Aldrich, C. e Auret, L. (2013). *Unsupervised process monitoring and fault diagnosis with machine learning methods*. Springer.
- Chiang, L.H., Russell, E.L., e Braatz, R.D. (2000). Fault diagnosis in chemical processes using fisher discriminant analysis, discriminant partial least squares, and principal component analysis. *Chemometrics and Intelligent Laboratory Systems*, 50, 243–252.
- Chiang, L., Braatz, R., e Russell, E. (2001). *Fault Detection and Diagnosis in Industrial Systems*. Advanced Textbooks in Control and Signal Processing. Springer London. URL <http://web.mit.edu/braatzgroup/links.html>.
- Duda, R.O., Hart, P.E., e Stork, D.G. (2001). *Pattern Classification*. Wiley, New York, 2nd edition.
- Hamadache, M., Dutta, S., Ambur, R., Olaby, O., Stewart, E., e Dixon, R. (2019). Residual-based fault detection method: Application to railway switch & crossing (s&c) system. In *2019 19th International Conference on Control, Automation and Systems (ICCAS)*, 1228–1233. IEEE.
- He, Q.P., Qin, S.J., e Wang, J. (2005). A new fault diagnosis method using fault directions in fisher discriminant analysis. *American Institute of Chemical Engineers*, 51, 555–571.
- Kalsoom, A., Maqsood, M., Ghazanfar, M.A., Aadil, F., e Rho, S. (2018). A dimensionality reduction-based efficient software fault prediction using fisher linear discriminant analysis (FLDA). *The Journal of Supercomputing*, 74, 4568–4602.
- Kano, M., Hasebe, S., Hashimoto, I., e Ohno, H. (2004). Evolution of multivariate statistical process control: application of independent component analysis and external analysis. *Computers & chemical engineering*, 28(6–7), 1157–1166.
- Kebabsa, T., Ouelaa, N., e Djebala, A. (2018). Experimental vibratory analysis of a fan motor in industrial environment. *The International Journal of Advanced Manufacturing Technology*, 98(9), 2439–2447.
- Kuncan, M., Kaplan, K., Minaz, M.R., Kaya, Y., e Ertunc, H.M. (2020). A novel feature extraction method for bearing fault classification with one dimensional ternary patterns. *ISA transactions*, 100, 346–357.
- Mahnke, W., Leitner, S.H., e Damm, M. (2009). *OPC unified architecture*. Springer Science & Business Media.
- Qin, Y., Yan, Y., Ji, H., e Wang, Y. (2021). Recursive correlative statistical analysis method with sliding windows for incipient fault detection. *IEEE Transactions on Industrial Electronics*.
- Santoso, N. e Wibowo, W. (2018). Financial distress prediction using linear discriminant analysis and support vector machine. *Journal of Physics: Conf. Series*, 979, 1–7.
- Scheffer, C. e Girdhar, P. (2004). *Practical machinery vibration analysis and predictive maintenance*. Elsevier.
- Sprent, P. e Smeeton, N.C. (2001). *Applied Nonparametric Statistical Methods*. Chapman & Hall, New York, 3rd edition.
- Teixeira, H.N., Lopes, I., e Braga, A.C. (2020). Condition-based maintenance implementation: a literature review. *Procedia Manufacturing*, 51, 228–235.
- Tharwat, A., Gaber, T., Ibrahim, A., e Hassanien, A.E. (2017). Linear discriminant analysis: A detailed tutorial. *AI Commun.*, 30(2), 169–190. doi:10.3233/AIC-170729. URL <https://doi.org/10.3233/AIC-170729>.
- Xu, S., Xing, F., Wang, R., Li, W., Wang, Y., e Wang, X. (2018). Vibration sensor for the health monitoring of the large rotating machinery: review and outlook. *Sensor Review*.