

# DETECÇÃO DE FALHAS DE CURTO-CIRCUITO ENTRE ESPIRAS DE AEROGERADORES POR MEIO DE SINAIS DE VIBRAÇÃO

MARCOS AURÉLIO ARAUJO FERREIRA JUNIOR\*, ELENE FIRMEZA OHATA\*, GERALDO LUIS BEZERRA RAMALHO\*

\**Instituto Federal de Educação, Ciência e Tecnologia do Ceará  
Laboratório de Processamento de Imagens, Sinais e Computação Aplicada  
Campus Fortaleza, Ceará, Brasil*

Emails: marcos.aurelio@lapisco.ifce.edu.br, elene.ohata@lapisco.ifce.edu.br,  
gramalho@ifce.edu.br

**Abstract**— Monitoring wind turbines in order to avoid failure in early stages avoids defects that can cause accidents, especially fires. This paper presents a methodology for monitoring and detecting short circuits in wind turbines coils. The vibration signal from the generator is collected with the MEMS accelerometers. A structural signal analysis technique was used to identify vibration signals patterns and a classifier was used to characterize the different machine conditions. The result was evaluated in a wind turbine simulation system, composed of a group of motor-generator controlled by a frequency converter. Using a recommendation algorithm, the detected patterns are analyzed to provide information about the condition of the equipment. In the performed experiments, we achieved a minimum accuracy of 86% and no false-positives.

**Keywords**— Condition monitoring, Fault detection, Wind turbine.

**Resumo**— O monitoramento de aerogeradores para evitar falhas nos estágios iniciais evita quebras que podem provocar acidentes, especialmente incêndios. Este artigo apresenta uma metodologia para o monitoramento e detecção de curto-circuito entre espiras de aerogeradores. O sinal de vibração do gerador é coletado com acelerômetros MEMS. Uma técnica de análise estrutural de sinais foi utilizada para identificar padrões do sinal de vibração e um classificador foi utilizado para caracterizar as diferentes condições da máquina. O resultado foi avaliado em um sistema de simulação de aerogerador, composto por um conjunto de motor-gerador acionado por conversor de frequência. Usando um algoritmo de recomendação, os padrões detectados são analisados para fornecer uma informação sobre a condição do equipamento. Nos experimentos realizados foi obtida acurácia acima de 86% e sem falsos-positivos.

**Palavras-chave**— Monitoramento de condição, Detecção de falha, Aerogerador

## 1 Introdução

Trabalhos recentes têm investigado metodologias de aprendizagem de máquina e técnicas de inteligência artificial para classificar os sinais coletados em equipamentos monitorados. (Konar and Chattopadhyay, 2011; Ramalho et al., 2012), utilizam uma máquina de vetor de suporte juntamente com a transformada *Wavelet* contínua para analisar vibrações de quadros durante a partida de motores. No trabalho de (Zhang et al., 2014), investiga-se numericamente o desempenho de cavitação de uma bomba centrífuga e (Kiranyaz, 2016) propõem um monitoramento de condição de um motor e um sistema de detecção de falhas precoces usando redes neurais convolutivas. (Chen et al., 2011) apresentam um sistema para o monitoramento contínuo de condições e para o diagnóstico automático de falhas em um motor com rolamento desequilibrado. Os autores utilizaram o classificador kNN com operador de soma de correlação como medida de similaridade. Em Herp et al. (2018) foi proposto um método estatístico para prever o estado de operação de turbinas eólicas com base em inferência de temperatura de engrenagens e processos Gaussianos.

Neste trabalho, os dados de vibração são coletados por um sensor de vibração MEMS triaxial

(MMA7361) fixado à carcaça do motor sobre o mancal dianteiro do eixo do gerador. O sistema de aquisição empregado neste trabalho baseia-se na proposta de Ramalho et al. (2012), tendo sido projetado para ser simples e utilizar componentes de baixíssimo consumo, da ordem de microampéres, permitindo ser alimentado por baterias ou sistemas de energia solar. Devido a essas características, esse sistema de coleta possui limitações de memória e de taxa de amostragem do sinal. Por isso, o sinal de vibração coletado é bastante contaminado com ruído, possui descontinuidades que resultam em distorções nas componentes de frequência, inviabilizando o uso de técnicas que são baseadas no espectro de frequência obtido com a transformada rápida de Fourier (FFT, *Fast Fourier Transform*).

Assim, este trabalho propõe um método de detecção de falhas de curto-circuito entre espiras de aerogeradores baseado na detecção de padrões de vibração a partir da classificação de descritores do sinal, no domínio do tempo. Um dispositivo periodicamente coleta os dados de vibração e analisa os padrões vibração para identificar a condição de operação do equipamento. Um algoritmo decide qual a condição atual do sistema e fornece essa informação para que um sistema de controle execute as ações necessárias.

O restante desse trabalho está organizado como segue. A seção 2 apresenta a metodologia, descreve os experimentos, os dados utilizados e as formas de avaliação. A seção 3 apresenta os resultados experimentais e uma discussão sobre os achados. A seção 4 apresenta as conclusões e sugestões de trabalhos futuros.

## 2 Metodologia

O método de monitoramento e detecção de falhas utilizado no trabalho, baseia-se na extração de características do sinal de vibração usando sensores MEMS (Ramalho et al., 2012) e na identificação de uma possível condição de falha. O modelo experimental utilizado na coleta de dados pode ser observado na Figura 1. O sinal de vibração é coletado periodicamente na direção radial do motor e enviado ao interpretador, que realiza a extração de características do sinal de vibração, a classificação do padrão e infere a condição do aerogerador em uma de três classes a saber, Parado, Normal e Falha. O interpretador envia a recomendação (Parado, Normal ou em Falha) ao controlador do aerogerador que realiza a atuação mais adequada.

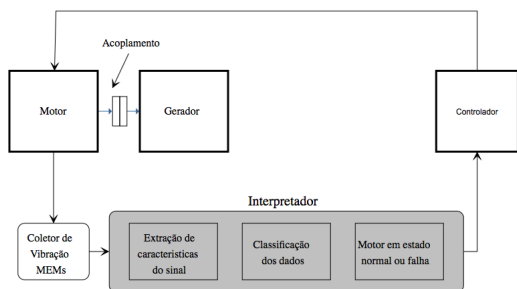


Figure 1: Metodologia para monitoramento de condição e classificação de falhas

### 2.1 Modelo experimental

Os testes foram realizados em um sistema de simulação de aerogerador. O equipamento contém um motor trifásico de 1CV eletricamente ligado em configuração de delta com alimentação de 220V, com corrente nominal de 3A, na função de gerador. As bobinas desse motor são alimentadas por um conversor de frequência trifásico com alimentação monofásica, modelo CFW-08 WEG ilustrado na Figura 2. Como máquina primária, acoplada mecanicamente ao eixo do gerador, utilizou-se um motor de indução com as mesmas características e ligações, igualmente acionado por conversor de frequência. O conversor de frequência a 60Hz é ajustado para simular

a velocidade do eixo acionados por pás e, indiretamente, o papel do vento que atua sobre o aerogerador. Para aplicar uma falha de curto-circuito entre as espiras do aerogerador o mesmo foi modificado internamente, permitindo 3 níveis diferentes de curto-circuito entre espiras. Os níveis de falha compreendem curto-circuito de baixa e de alta impedância, com percentual de 4,81% e 9,26% do total de espiras. A emulação da falha quanto a número de espiras é feita por meio de chaveamento dos terminais do simulador. Os dados de vibração são coletados por um sensor de vibração MEMS triaxial (MMA7361) fixado à carcaça do motor sobre o mancal dianteiro do eixo.




Figure 2: Simulador de aerogerador utilizado na coleta de dados e nos experimentos




Figure 3: Sistema de coleta de dados de vibração com sensor MEMS (em destaque)

### 2.2 Extração de características do sinal

Utilizou-se o algoritmo de análise estrutural de sinais SCM (*Structural Co-occurrence Matrix*), proposto por Ramalho et al. (2016), para extrair as características de vibração, gerando um conjunto de atributos com 6 dimensões, a saber  $\{CAD, DKL, MDR, IDM, CSD, COR\}$ . Os atributos  $COR$  e  $IDM$  são do grupo, que medem o nível de similaridade estrutural do sinal de entrada. Os demais atributos fazem parte do grupo que mede a divergência mútua entre as distribuições das estruturas do sinal de entrada,

Esse conjunto de atributos, conforme descrito por Ramalho et al. (2016), capta diferenças sutis na estrutura dos sinais de vibração, permitindo identificar diferentes padrões. Foram utilizados como parâmetros da SCM, 32 níveis de quantização e o filtro passa-alta para destacar as estruturas do sinal. O método foi empregado na configuração de extração de características, ou seja, as funções

de entrada  $f$  e  $g$  da SCM são ambas o sinal de vibração capturado pelo sistema de aquisição.

### 2.3 Base de dados

O banco de dados utilizado neste artigo, possui 450 amostras do sinal de vibração, distribuídas em três classes distintas e definidas pela condição de operação do aerogerador, a saber, Parado (sistema desconectado, sem vento), Normal (sistema ligado em operação normal) e Falha (falha de curto-circuito entre espiras). Os dados foram preparados conforme a Tabela 1.

Table 1: Descrição das condições de operação do aerogerador.

Classe	Quantidade de amostras	Condição	Intensidade da falha % das espiras
0	90	Parado	-
1	90	Normal	-
2	90	Falha 1	4,81% Alta imped.
	90	Falha 2	4,81% Baixa imped.
	90	Falha 3	9,26% Alta imped.

A Figura 4 apresenta exemplos dos sinais coletados. Cada amostragem do sinal é composta de 400 valores. Após a etapa de extração de características o banco de dados contém 450 vetores de 6 atributos cada.




Figure 4: Amostras normalizadas dos sinais de vibração coletados.

### 2.4 Classificação dos padrões de vibração

Nesse trabalho utiliza-se o algoritmo Random-Forest (Ho, 1998) como classificador. Este algoritmo foi escolhido por apresentar grande poder de generalização para dados que possuem atributos redundantes. Os parâmetros utilizados neste classificador são: 20 estimadores, e um estado de inicialização aleatório para cada treinamento realizado. Todos os demais parâmetros são definidos de forma automática pelo algoritmo ou foram uti-

lizados os valores padrão da biblioteca **sklearn** do Python.

### 2.5 Algoritmo de recomendação

Por causa das características anteriormente discutidas sobre as limitações do sistema de aquisição de dados e para minimizar o número de falsos-almos, neste trabalho propomos um algoritmo de recomendação da condição do aerogerador, ilustrado na Figura 5. Uma amostragem do sinal de vibração é realizada periodicamente, em intervalos de tempo ( $t$ ) pré-estabelecidos em minutos ou horas, de acordo com os requisitos da aplicação. A entrada do algoritmo é uma série temporal formada pelos códigos de falha resultantes da classificação de cada amostragem do sinal coletado. Para determinar o estado de operação recomendado, o algoritmo avalia uma janela de tempo  $w$  e calcula a mediana dos valores das classes. O resultado é, então, disponibilizado como valor de recomendação.

```

Tempo:          t0 t1 t2 t3 t4 t5 t6 t7...
Código da falha: 1  2  1  1  2  2  2  2
Janela (w):     -----
                  1 (mediana)
Janela (w):     -----
                  1 (mediana)
Janela (w):     -----
                  1 (mediana)
Janela (w):     -----
                  2 (mediana)...
Recomendação:   -  -  1  1  1  2  2  2

```

Figure 5: Algoritmo de recomendação

A Figura 5 também destaca que existe um atraso associado ao sistema de recomendação. Este atraso é proporcional ao tamanho da janela temporal. Portanto, a janela deve ser a menor possível para minimizar o tempo de resposta do controlador do sistema.

### 2.6 Avaliação de desempenho

A avaliação de desempenho baseia-se na uma matriz de confusão demonstrada na Figura 6. Nesta matriz, são contabilizados os acertos e erros de classificação dos sinais de vibração após o sistema de recomendação.

Algumas métricas de avaliação utilizadas nesse artigo são calculadas com base na matriz de confusão, a saber:

- Precisão

$$P = \frac{VP}{VP + FP}. \quad (1)$$

- Revocação ou Sensibilidade

$$S = \frac{VP}{VP + VN}. \quad (2)$$



Figure 6: Matriz de confusão para o teste de validade dos modelos

- F1 score: uma média harmônica entre precisão e a sensibilidade,

$$\frac{2PS}{P+S} \quad (3)$$

### 3 Resultados

A seguir são apresentados os resultados do método proposto. Todos os algoritmos foram implementados em **Python**.

Os experimentos foram realizados em duas etapas: i) treinamento/teste do classificador; ii) simulação e medida de desempenho do interpretador. Metade das amostras foram separadas para a fase de treinamento/teste do classificador. A metade restante foi utilizada na fase de simulação para medir o desempenho do interpretador.

Para avaliar o desempenho do sistema, algumas estratégias foram adotadas visando reproduzir o uso da metodologia em um sistema de monitoramento em tempo real. Cada estratégia resultou em um experimento diferente cujos parâmetros estão relacionados na Tabela 2. Esses parâmetros compreendem o tamanho da janela temporal  $w$  e a quantidade de  $n$  amostras de cada subconjunto de intensidade da condição de falha (Falha 1, Falha 2 e Falha 3). Ou seja, o número  $n$  representa a quantidade de amostras extraída de cada subconjunto de 90 amostras da Classe 2 da Tabela 1. A Tabela 2 também registra a acurácia do sistema de recomendação e a quantidade de falsos-negativos e falsos-positivos (falsos-almes) reportados.

Para cada experimento foi obtida uma série de amostras, simulando um sistema de monitoramento do funcionamento de 1 semana do aerogerador no qual cada amostra é coletada em intervalos de 5 minutos. Os testes de desempenho foram realizados com  $n = 5$ , simulando a ocorrência de uma breve falha após um período de normalidade.

A matriz de confusão dos classificadores Random-Forest treinados são mostrados nas Tabelas 3 e 4 para o experimentos E-H e I-L, respectivamente. Merece destaque o fato de que o classificador dos experimentos D-F não identifica corretamente os eventos da classe 2, já que

Table 2: Experimentos de classificação

Experimento	Parâmetros Treinamento e Simulação	F1-score Simulação	Falso-negativo/ Falso-positivo
A	$n=5, w=5$	0,72	13/13
B	$n=5, w=7$	0,75	13/7
C	$n=5, w=9$	0,75	13/6
D	$n=5, w=11$	0,79	12/1
E	$n=10, w=5$	<b>0,88</b>	<b>9/0</b>
F	$n=10, w=7$	<b>0,86</b>	<b>10/0</b>
G	$n=10, w=9$	<b>0,87</b>	<b>9/0</b>
H	$n=10, w=11$	<b>0,83</b>	<b>11/0</b>
I	$n=20, w=5$	0,73	6/21
J	$n=20, w=7$	0,71	6/21
K	$n=20, w=9$	0,70	6/22
L	$n=20, w=11$	0,71	5/22

a quantidade de amostras dessa classe é mínima (15) quando comparada às demais. Além disso, devido às características restritivas do sistema de coleta, o padrão de vibração da classe de falha é muito similar ao padrão da classe normal. Entretanto, como será demonstrado mais adiante, este classificador, associado ao algoritmo de recomendação, atribuirá o rótulo correto para as amostras de falha na fase de testes, pois os padrões dessa classe são diferentes daqueles para o qual o classificador se especializou durante o treinamento.

Table 3: Matriz de confusão do classificador utilizado nos experimentos E-H.

Classe/Predição	0	1	2
0	12	1	0
1	2	12	0
2	0	7	2

Por outro lado, o classificador dos experimentos E-H apresenta sobre-treinamento para a classe 2, resultando em uma maior sensibilidade para esse tipo de evento, porém com a desvantagem de produzir muitos falsos-positivos.

Table 4: Matriz de confusão do classificador dos experimentos I-L

Classe/Predição	0	1	2
0	12	1	0
1	0	7	7
2	0	2	16

A Figura 7 ilustra o experimento no qual foi utilizado uma quantidade maior de amostras da classe de falhas ( $n = 20$ ) para treinamento do classificador. A curva pontilhada refere-se à indicação de condição esperada. Percebe-se a ocorrência de falsos-almes nas condições de operação Parado e Normal, caracterizado pela presença de marcadores de falha. Este experimento demonstra que, por ser um evento raro, o treinamento do

classificador deve ser desbalanceado, priorizando as amostras das classes Parado e Normal.




Figure 7: Exemplo de sequência de comandos para os experimentos I-L. Observe a ocorrência de falsos-positivos no período de operação normal.

A série de eventos registrada na Figura 8 revela que os melhores resultados são obtidos para  $n = 10$  e  $w = 5$ . Com esses parâmetros é possível minimizar os falsos-alarmes (falsos-positivos) e, ao mesmo tempo, minimizar falsos-negativos, tornando o sistema de recomendação mais confiável.

Percebe-se que o sistema responde de forma sensível às falhas e sem falsos-alarmes. Os falsos-negativos contabilizados na Tabela 2 acontecem apenas no limiar entre as classes, em decorrência da janela temporal  $w$  utilizada na análise. Isto representa um atraso temporal de até 5 amostras, ou seja 25 minutos, o pode ser observado na Figura 8, entre as amostras 45-50 e 90-95.

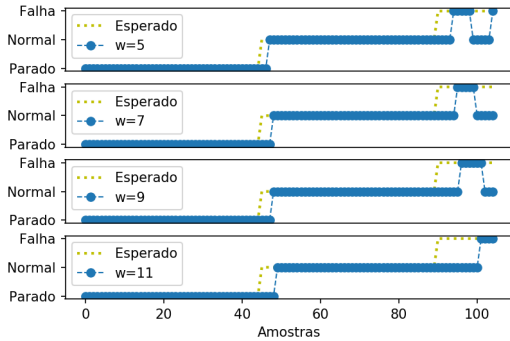


Figure 8: Resultado da sequência de comandos para os experimentos E-H. Falsos-negativos ocorrem apenas na mudança de condição. Falsos-positivos não são reportados.

Percebe-se, também, que o aumento da janela contribui para a diminuição dos falsos-positivos quando  $n = 10$ , porém tem pouca influência no conjunto de dados para  $n = 20$ . Este resultado também corrobora com estratégia de utilizar pou-

cas amostras da condição de falhas no treinamento do classificador.

Para uma melhor interpretação do resultado entre os diferentes experimentos, pode-se observar nas Tabelas 5 a 8 as matrizes de confusão construídas a partir da saída do interpretador. A diagonal principal das matrizes corresponde à quantidade de amostras identificadas corretamente para cada classe. Os falsos-negativos são proporcionais ao tamanho da janela temporal.

Table 5: Matriz de confusão do experimento E

Classe/Predição	0	1	2
0	45	0	0
1	2	43	0
2	0	9	6

Table 6: Matriz de confusão do experimento F

Classe/Predição	0	1	2
0	45	0	0
1	3	42	0
3	0	10	5

Table 7: Matriz de confusão do experimento G

Classe/Predição	0	1	2
0	45	0	0
1	3	42	0
2	0	9	6

Table 8: Matriz de confusão do experimento H

Classe/Predição	0	1	2
0	45	0	0
1	4	41	0
2	0	11	4

Na Tabela 9 pode-se conferir as medidas de desempenho do experimento E para cada classe ( $N$ =número de amostras utilizadas no teste). Vale destacar os valores de precisão (Pre) da classe 2 e a sensibilidade (Sens) na classe 0. Estes valores mostram que o sistema é capaz de detectar corretamente as 3 condições do experimento com máxima precisão para a classe de falhas. Se for desconsiderado o atraso temporal, todas as classes podem ser detectadas com precisão e sensibilidade máximas.

## 4 Conclusões

Os resultados mostram que a classificação de padrões de vibração obtidos com sensores MEMS,

Table 9: Desempenho do melhor experimento

Classe	Pre	Sens	F1-score	N
0	0,96	1,00	0,99	45
1	0,83	0,96	0,97	45
2	1,00	0,40	0,57	15
Média/Total	0,91	0,90	0,88	105

no experimento proposto, possibilita monitorar o estado do aerogerador e identificar as três condições de operação a que foi submetido.

Apesar do método proposto apresentar erros de classificação, entre a condição normal e de falha, esta última é uma condição rara quando comparada à condição normal. Isto é, ela ocorre menos e é sutil. Porém, depois que a falha se instala no equipamento, as diferenças estruturais no sinal de vibração são suficientes para que o identificador rejeite as classes 0 e 1 e atribua o rótulo 2 da classe de falha. Com auxílio do algoritmo de recomendação, que monitora e detecta mudanças no padrão de ocorrência das condições, o resultado é um sistema capaz de identificar a ocorrência de falhas, embora com algum atraso, porém sem falsos-alarmes, como demonstrado nos experimentos para  $n = 10$  e  $w = 5$ .

Em trabalhos futuros, pretende-se empregar técnicas mais apuradas de rejeição no treinamento dos classificadores para minimizar a ocorrência de falsos-positivos e falsos-negativos. Com isso, pode-se desenvolver um sistema de recomendação antecipativo ao invés de reativo, visando minimizar os atrasos na resposta do controlador do aerogerador.

### Agradecimentos

Os autores agradecem o apoio financeiro do CNPQ UNIVERSAL 13-2016, IFCE PIBIC 7-2017 e IFCE PIBITI 8-2017.

### References

- Chen, W.-Y., XU, J.-X. and Panda, S. K. (2011). A study on automatic machine condition monitoring and fault diagnosis for bearing and unbalanced rotor faults, IEEE International Symposium on Industrial Electronics.
- Herp, J., Ramezani, M. H., Bach-Andersen, M., Pedersen, N. L. and Nadimi, E. S. (2018). Bayesian state prediction of wind turbine bearing failure, Renewable Energy **116**: 164–172.
- Ho, T. (1998). The random subspace method for constructing decision forests, IEEE

Transactions on Pattern Analysis and Machine Intelligence **20**(8): 832–844.

- Kiranyaz, S. e. a. (2016). Real-time motor fault detection by 1-d convolutional neural networks, IEEE Transactions on Industrial Electronics **63**: 7067–7075.
- Konar, P. and Chattopadhyay, P. (2011). Bearing fault detection of induction motor using wavelet and support vector machines (svms)., Applied Soft Computing **11**(6): 4203–4211.
- Ramalho, G. L. B., Ferreira, D. S., Rebouças Filho, P. P. and de Medeiros, F. N. S. (2016). Rotation-invariant feature extraction using a structural co-occurrence matrix, Measurement **94**: 406–415.
- Ramalho, G. L. B., Schmidlin J., C. R., Bezerra, L. D. S. and Dias, S. V. (2012). Monitoramento de condição de máquina utilizando acelerômetro mems, Revista Tecnologia-UNIFOR **1**: 33.
- Zhang, Y. L., Yuan, S. Q., Zhang, J. F. and LU, J. X. (2014). Numerical investigation of the effects of splitter blades on the cavitation performance of a centrifugal pump, Vol. 22, 27th IAHR Symposium on Hydraulic Machinery and Systems., pp. 1–9.