

CLASSIFICAÇÃO DE PADRÕES DE VIBRAÇÃO PARA O MONITORAMENTO DE CONDIÇÃO DE BOMBAS

ELENE FIRMEZA OHATA*, MARCOS AURÉLIO ARAUJO FERREIRA JUNIOR*, 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: elene.ohata@lapisco.ifce.edu.br, marcos.aurelio@lapisco.ifce.edu.br,
gramalho@ifce.edu.br

Abstract— Machine condition monitoring is one way to determine the operational status of a machine. Evaluating the condition of the machine helps to detect failures in the initial stages, avoiding downtime and saving resources and energy. This article presents a methodology for monitoring conditions and detecting failures in a centrifugal pump through the analysis of vibration signal collected with a MEMS accelerometer. The proposed method uses artificial intelligence techniques to classify the vibration patterns that characterize the pump conditions, allowing the detection of undesired operating conditions with at least 80 % accuracy.

Keywords— Condition monitoring, Fault detection, Energy saving.

Resumo— O monitoramento de condição de máquina é uma forma de determinar a situação operacional de uma máquina. Avaliar a condição da máquina ajuda a detectar falhas nos estágios iniciais, evitando quebras e economizando recursos e energia. Este artigo apresenta uma metodologia para monitoramento de condições e detecção de falhas em uma bomba centrífuga através da análise de sinal de vibração coletada com um acelerômetro MEMS. O método proposto utiliza técnicas de inteligência artificial para classificar os padrões de vibração que caracterizam as condições da bomba, permitindo detectar condições indesejadas de operação com pelo menos 80% de acurácia.

Palavras-chave— Monitoramento de condição, Detecção de falha, Economia de energia

1 Introdução

O uso de máquinas rotativas nas indústrias vem sendo bastante analisado, devido a sua grande importância e por ser amplamente utilizada para plantas de tratamento de água, esgoto, agricultura, drenagem, produção de alimentos e utilizada em projetos.

A cavitação tem grande influência no desempenho da operação de um sistema de bombeamento e na ocorrência de muitos problemas, como a degradação do material, a vibração da unidade e o ruído hidráulico (Yang et al., 2012). Por isso, a detecção de cavitação em seus estágios iniciais é um requisito importante para a manutenção preditiva desses equipamentos. O monitoramento e análise de vibrações é a técnica mais difundida e mais adequada para máquinas rotativas (Beebe, 2004). Além disso, os sinais de vibração de um equipamento são utilizados como um meio para detectar falhas (De Moura et al., 2011; Lei et al., 2013; De Moura et al., 2009).

Trabalhos recentes têm investigado metodologias de aprendizagem de máquina e técnicas de inteligência artificial para classificar os dados coletados no equipamento. (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 o arranque. No trabalho de (Zhang et al., 2014), investiga-se nu-

mericamente 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 esquema baseado em dados simples para o monitoramento contínuo de condições e para o diagnóstico automático de falhas em um motor com rolamento desequilibrado, além disso, os autores utilizam o classificador kNN com operador de soma de correlação como medida de similaridade.

O sistema de aquisição empregado nos experimentos deste trabalho baseia-se na proposta de Ramalho et al. (2012). Esse dispositivo foi projetado para ser simples e utilizar componentes de baixíssimo consumo, o que permite ser alimentado por baterias ou sistemas de energia solar. Dessa forma, a coleta do sinal e o diagnóstico da bomba pode ser realizado em ambientes desassistidos.

Este trabalho apresenta um método de detecção de cavitação incipiente em bombas periféricas a partir de sinais de vibração coletados por um sensor acelerômetro MEMS e a extração de descritores de complexidade de sinal no domínio do tempo. Um dispositivo coleta dados de vibração continuamente e analisa os sinais de vibração automaticamente para identificar o estado de operação do equipamento monitorado.

O restante deste trabalho apresenta detalhes dos experimentos realizados, incluindo a coleta e

o processamento do sinal na seção 2. Na seção 3 são apresentados os resultados e na seção 4 são apresentadas as conclusões.

2 Metodologia

O método de detecção de condição da bomba baseia-se na extração de características do sinal de vibração usando um sensor MEMS triaxial (Freescale MMA7361), no qual a frequência de ressonância é da ordem de 6kHz e o nível de sensibilidade é $\pm 1,5g$ (800mV/g) (Ramalho et al., 2012). O sinal é coletado em uma bomba centrífuga de baixa potência presente em uma planta industrial. Após a extração de características, os dados são submetidos a algoritmos de classificação, e estes, geram uma saída informando a condição do equipamento. O modelo experimental utilizado na coleta de dados pode ser observado na Figura 1.

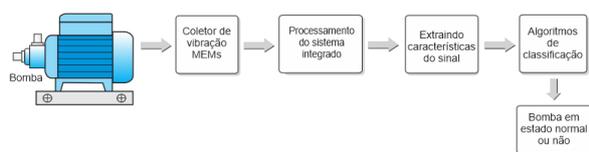


Figure 1: Monitoramento de condição e classificação de falhas.

2.1 Modelo experimental

Os testes foram realizados em um circuito hidráulico experimental contendo uma bomba centrífuga movida por um motor monofásico de 0,5 HP, ilustrado na Figura 2. As válvulas dispostas na entrada da bomba foram controladas manualmente, a fim de simular diferentes níveis de cavitação, por meio da restrição gradual da sucção da bomba. O estrangulamento da válvula cria uma diferença de pressão na entrada fazendo com que a mesma caia abaixo da pressão de vapor do líquido, formando bolhas de ar, nas quais irão implodir em uma região onde a pressão é acima da pressão de vapor do líquido. Se as sucessivas implosões ocorrerem próximas a uma superfície sólida, poderá ocasionar danos microscópicos, que podem evoluir para danos irreparáveis (Plesset, 1949).

2.2 Descritores de complexidade do sinal

Utilizou-se um algoritmo em C++, para extrair as características da bomba, gerando um con-

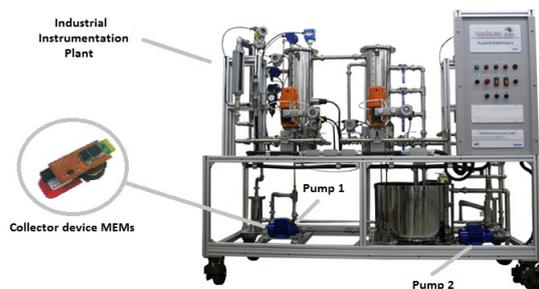


Figure 2: Modelo utilizado para realizar os experimentos.

junto com quatro dimensões de entrada $a = \{En, Et, DF, Ej\}$.

- **En - Energia:** Fornece uma estimativa indireta da intensidade de vibração, através do nível de variação dos coeficientes de detalhes do sinal. Quando somados em todos os níveis de decomposição do sinal, obtemos os valores da energia,

$$En = \frac{1}{D} \sum_{i=1}^D d_i [i]^2, \quad (1)$$

D é o comprimento do sinal, d_i são os coeficientes de detalhe e i representa o número de decomposições *wavelets* do sinal.

- **Et - Entropia:** Aproxima o grau de desorganização dos coeficientes de detalhes do sinal. É sensível a presença de harmônicas e é obtida a partir da densidade de probabilidade do conjunto de coeficientes,

$$Et = -p \log p(d_i), \quad (2)$$

p é a densidade de probabilidade e d_i são os coeficientes de detalhe do sinal.

- **DF - Dimensão Fractal:** Utilizada para medir o grau de complexidade do sinal. O cálculo é obtido através do algoritmo de contagem de caixas (*BoxCounting*),

$$DF = \lim_{l \rightarrow 0} \frac{\log(N(l))}{\log(l)}, \quad (3)$$

$N(l)$ representa o número de quadrados que coincidem com o objeto analisado e l corresponde ao tamanho da caixa usada na malha de quadrados.

- **Ej - Energia da taxa de aceleração (*Jerk*):** mede a variação súbita na aceleração, indicando um possível aumento da complexidade do sinal monitorado,

$$Ej = \frac{1}{L} \sum_{k=1}^L c^2(k), \quad (4)$$

2.3 Base de dados

O banco de dados utilizado neste artigo, possui 500 amostras distribuídas em três classes distintas e definidas pelo estado de operação da bomba, para diferentes posições da válvula de fluxo no circuito de sucção. Os dados foram separados conforme a Tabela 1. A separação dos dados nessas três classes permite identificar como a bomba está operando, se está desligada, ligada em funcionamento normal ou ligada em condição de falhas.

Table 1: Descrição das condições de operação da bomba durante os ensaios realizados.

Classe	Quantidade de amostras	Condição	Estado da bomba	abertura da válvula de entrada
Classe X	100	(referência)	desligada	-
Classe Y	200	(normal)	ligada	100 e 75
Classe Z	200	(possível falha)	ligada	50 e 25

As amostras foram apresentadas a quatro classificadores, a saber, MLP, kNN, SVM e GNB, com o objetivo de treiná-los para reconhecer a classe a que uma determinada amostra pertence. Dessa forma, pode-se identificar a condição de operação da bomba. Esses classificadores são detalhados na subseção seguinte.

2.4 Classificadores para reconhecimento de padrões

Nesse trabalho foram utilizados alguns classificadores comumente encontrados na literatura como solução para detecção de padrões (Ramalho and Medeiros, 2017).

2.4.1 Multilayer Perceptron - MLP

O Perceptron Múltiplas Camadas é constituído por um array que forma a camada de entrada, por uma ou mais camadas escondidas e uma camada de saída. Cada neurônio recebe uma soma ponderada das contribuições dos neurônios da camada precedente. Uma das funções de ativação mais utilizadas para obter uma saída da rede $\in [-1, 1]$, sendo 0 o limiar que define uma saída verdadeira (1) ou falsa (-1) para uma dada classe, é a tangente hiperbólica \tanh , definida por,

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (5)$$

Para treinar a rede, um algoritmo popular para treinamento de MLP é o método conhecido como retro-propagação (*backpropagation*), onde o erro é calculado na saída da rede é propagado através das camadas de neurônios para atualizar os pesos das somas ponderadas (Pandey and Barai, 1995). O *backpropagation* é uma generalização do algoritmo de mínimo quadrado médio (LMS, do inglês *Least Mean Square*).

Os neurônios das camadas intermediárias (escondidas) desempenham um papel fundamental em MLPs com algoritmos de retro-propagação, (Braga et al., 2000).

2.4.2 K-Nearest Neighbors - kNN

O kNN assume que todos os elementos da amostra contêm não somente dados em cada conjunto, mas também a classificação desejada de cada item. Quando uma classificação deve ser feita para um novo item, sua distância para cada item no conjunto de amostra deve ser computada. Somente as k amostras mais próximas no grupo de amostras são consideradas. O novo item é então classificado para a classe que possui mais itens para esse grupo das k amostras mais próximas.

Componentes de uma amostra denota suas características e a distância entre duas amostras representa sua similaridade. A medida da distância euclidiana é geralmente adotada no kNN tradicional. Para quais quer duas amostras com n características, por exemplo $X = (x_1, x_2, \dots, x_n)$ e $Y = (y_1, y_2, \dots, y_n)$, a distância euclidiana entre elas é medida através da equação 6 (Su, 2011):

$$\text{dist}(X, Y) = \sqrt{(x_1 - y_1)^2 + \dots + (x_n - y_n)^2}. \quad (6)$$

2.4.3 Support Vector Machine - SVM

O SVM é baseado na redução de risco estrutural (SRM, do inglês *Structural Risk Minimization*), princípio enraizado na teoria de aprendizagem estatística. Ele possui melhores habilidades de generalização do que os sistemas que utilizam a minimização empírica de risco (ERM, do inglês *Empirical Risk Minimization*), e o SRM é conseguido através da minimização do limite superior de erro de generalização. O SVM tem o potencial de lidar com espaços de características muito grandes, pois o treinamento do SVM é conduzido de forma que a dimensão dos vetores classificados não tenha um impacto distinto na performance do SVM, como é o caso dos classificadores tradicionais. O SVM pode solucionar problemas de aprendizado com um pequeno número de amostras. Devido ao fato que é difícil de conseguir amostras de falhas na prática, SVM é introduzido em diagnóstico de falhas nas máquinas devido à grande precisão e boa generalização para menores números de amostras (Widodo and Yang, 2007).

Dado o vetor de treinamento $x_i \in \mathbb{R}^p, i = 1, \dots, n$ em duas classes, e o vetor $y \in \{1, -1\}^n$, o SVM busca encontrar um hiperplano otimizado

$$w_o \cdot x - b_o = 0, \quad (7)$$

sendo w_o o vetor ponderador e b_o o limiar de classificação ótimo, para gerar o classificador binário linear $f(x) \in \{-1, 1\}$, definido como:

$$f(x) = \text{sgn}(w_o \cdot x - b_o) \quad (8)$$

em que $\text{sgn}(\cdot)$ é uma função que retorna o sinal do argumento.

Para encontrar o classificador $f(x)$ ótimo em SVM, deve-se solucionar o problema de otimização quadrática:

$$\arg \min_{w, \zeta} \frac{1}{2} w^T w + C \sum_{i=1}^n \zeta_i, \quad (9)$$

em que C é um parâmetro de regularização e ζ_i são chamadas de variáveis que medem o desvio de condição de separabilidade ideal entre as classes (Webb, 2002).

2.4.4 Gaussian Naive Bayes - GNB

O Naive Bayes é um conjunto de algoritmos de aprendizado supervisionado, que aplicam o teorema de Bayes com a suposição “naive” (ingênua) de que existe independência entre todos os pares de elementos. Este classificador calcula a probabilidade de que um dado exemplo pertence a uma determinada classe, e assume que os dados possuem uma distribuição normal. Dado um exemplo X , descrito pelo seu vetor característico (x_1, x_2, \dots, x_n) e uma classe alvo y , o teorema de Bayes nos permite expressar a probabilidade condicional $P(y|X)$ como o produto de probabilidades mais simples utilizando o pressuposto “naive” de independência,

$$P(y|X) = \frac{P(y)P(X|y)}{P(X)} = \frac{P(y) \prod_{i=1}^n P(x_i|y)}{P(X)}, \quad (10)$$

Como $P(x)$ é constante para um dado exemplo, a seguinte regra é utilizada para classificar a amostra,

$$\hat{y} = \arg \max_y P(y) \prod_{i=1}^n P(x_i|y). \quad (11)$$

A estimativa “Maximum a Posteriori” (MAP) é comumente utilizada para estimar os parâmetros no modelo Naive Bayes, incluindo $P(y)$ e $P(x_i|y)$; o primeiro é a frequência de amostras com a classe y no conjunto de treinamento. Além disso, este implementa a classificação assumindo que a distribuição de características é normal, também conhecida como distribuição gaussiana,

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad (12)$$

onde σ e μ são estimados pela probabilidade máxima (Lou et al., 2014).

2.5 Avaliação de desempenho dos classificadores

Para avaliar o desempenho dos classificadores adequadamente, alguns critérios foram adotados. Consideraram-se a separação dos dados em um

conjunto de treinamento e em um conjunto de testes. Essa divisão é importante para que o modelo realize os testes com dados desconhecidos. Neste trabalho foram utilizadas 77% das amostras para treinamento e 33% para testes.

Como o conjunto de dados contém apenas 500 amostras (conjunto relativamente pequeno dada a dimensão dos atributos), é importante utilizar uma validação cruzada para que o classificador apresente maior eficiência e através deste recurso, seja possível avaliar a capacidade de generalização dos modelos. Utilizou-se a validação k -Fold sendo que as amostras foram divididas em 10 grupos selecionados aleatoriamente.

Após o treinamento e os testes dos dados, empregaram-se alguns critérios para a avaliação do desempenho dos classificadores. A avaliação foi feita com base em uma matriz de confusão demonstrada na Figura 3).

	PREVISTO	
REAL	VERDADEIRO POSITIVO VP	FALSO POSITIVO FP
	FALSO NEGATIVO FN	VERDADEIRO NEGATIVO VN

Figure 3: Matriz de confusão para o teste de validade dos modelos

Algumas métricas de avaliação utilizadas nesse artigo calculados com base na matriz de confusão de um dado modelo:

- **Acurácia:** é a capacidade de definir o quanto o resultado encontrado está próximo do resultado real, quanto maior a acurácia, mais eficiente é o resultado da experiência, o cálculo é representado pela soma de todos os acertos positivos dividido pelo total de amostras,

$$\text{Acurácia} = \frac{VP + VN}{VP + FP + FN + VN}. \quad (13)$$

- **Precisão:** quantidade de amostras classificadas como pertencentes a uma classe, que realmente são daquela classe (verdadeiros positivos), dividido pela soma deste valor, e o número de amostras classificadas nesta classe, mas que pertencem a outras (falsos positivos),

$$\text{Precisão} = \frac{VP}{VP + FP}. \quad (14)$$

- **Sensibilidade:** é a capacidade que o teste apresenta de detectar as classes verdadeiramente positivas,

$$\text{Sensibilidade} = \frac{VP}{VP + VN}. \quad (15)$$

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

$$\text{F1 score} = \frac{2 \times P \times S}{P + S}, \quad (16)$$

onde P é a precisão (Equação 14) e S é a sensibilidade (Equação 15).

3 Resultados

Após a realização dos experimentos de classificação, foram obtidos os resultados mostrados na Tabela 2. Em todos os testes foram utilizados a validação cruzada k -Fold com 10 conjuntos, selecionados aleatoriamente. Um dos conjuntos foi utilizado para teste e os demais para o treinamento do classificador. A configuração dos classificadores, assim como a média e o desvio padrão da acurácia estão registrados na Tabela 2.

Table 2: Resultados dos experimentos de classificação.

Método de Classificação	Parâmetros	Acurácia Média	Desvio padrão da Acurácia
MLP	13 neurônios, alpha=0.1, max iter 1000	0,83	0,02
KNN	rótulos=6	0,80	0,02
SVM	núcleo=linear	0,84	0,01
GNB	X	0,88	0,01

Para uma melhor interpretação do resultado entre os diferentes classificadores, pode-se observar nas Tabelas 3, 4, 5 e 6 as matrizes de confusão com os resultados de cada classificação. A diagonal principal das matrizes corresponde a quantidade de amostras identificadas corretamente para cada classe.

Table 3: Predição com MLP.

Condição	X	Y	Z
X	97	3	0
Y	4	170	26
Z	0	52	148

Table 4: Predição com kNN.

Condição	X	Y	Z
X	97	3	0
Y	4	170	26
Z	3	64	133

Table 5: Predição com SVM.

Condição	X	Y	Z
X	98	2	0
Y	1	175	24
Z	0	53	147

Table 6: Predição com Gaussian Naive Bayes.

Condição	X	Y	Z
X	100	0	0
Y	0	178	22
Z	0	39	161

O classificador GNB apresentou, em geral, um melhor desempenho quando relacionado aos demais modelos. Analisando a Tabela 6 podemos concluir que ele apresenta menos de 5% de falsos-positivos e abaixo de 8% de falsos-negativos.

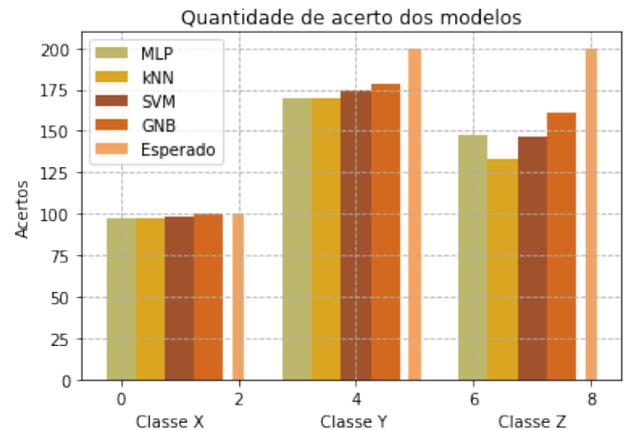


Figure 4: Quantidade de acerto de cada um dos modelos separados por classe

A Figura 4 nos permite uma melhor visualização dos resultados contidos na diagonal principal das matrizes de confusão de forma gráfica. Através do gráfico é possível visualizar que o modelo GNB consegue identificar todas as amostras da classe X (bomba desligada) com 100% de acerto, mas para as classes Y (bomba normal) e Z (bomba apresentando problema) ainda apresenta alguns falsos-positivos e falsos-negativos.

Para uma análise detalhada, podemos verificar na Tabela 7 algumas métricas de avaliação de desempenho dos classificadores, esses resultados foram gerados com base nas matrizes de confusão acima.

4 Conclusões

Os resultados permitem inferir que a classificação de padrões de vibração obtidos com sensores MEMS, no experimento proposto, possibilita

Table 7: Métricas de Avaliação dos Classificadores (%)

	Acurácia	Precisão	Sensibilidade	F1 score
MLP	83%	83%	83%	83%
SVM	84%	85%	84%	84%
kNN	80%	81%	80%	80%
GNB	88%	88%	88%	88%

monitorar o estado da bomba e identificar as três condições de operação a que foi submetida.

Os classificadores testados conseguem uma taxa de acerto maior do que 80%. O classificador GNB apresentou o melhor desempenho nos experimentos e é um algoritmo de baixo custo computacional. Portanto, o GNB seria uma possível escolha para um sistema de monitoramento e detecção do estado da bomba.

O método de coleta do sinal, pelas suas restrições de memória e taxa de amostragem, contribui para os erros de classificação entre a condição normal e de falha. Entretanto, esta última é uma condição rara quando comparada à condição normal. Assim, em um processo industrial, um sistema de supervisão e controle da bomba pode ser programado para minimizar falsos-alarmes utilizando, por exemplo, o controle estatístico de processos.

Em trabalhos futuros, pretende-se empregar técnicas de rejeição no treinamento dos classificadores, para minimizar falsos positivos e falsos negativos na matriz de confusão.

Agradecimentos

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

References

Beebe, R. S. (2004). *Predictive Maintenance of Pumps Using Condition Monitoring*, Vol. 1, Elsevier Science, Elsevier Science.

Braga, A. d. P., Carvalho, A. and Ludermir, T. B. (2000). *Redes neurais artificiais: teoria e aplicações*, "Livros Técnicos e Científicos".

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*.

De Moura, E., Souto, C., Silva, A. and Irmao, M. (2011). Evaluation of principal component analysis and neural network performance for bearing fault diagnosis from vibration signal processed by rs and df analyses, *Mechanical*

Systems and Signal Processing **25**(5): 1765–1772.

De Moura, E., Vieira, A., Irmao, M. and Silva, A. (2009). Applications of detrended-fluctuation analysis to gearbox fault diagnosis, *Mechanical Systems and Signal Processing* **23**(3): 682–689.

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.

Lei, Y., Lin, J., He, Z. and Zuo, M. J. (2013). A review on empirical mode decomposition in fault diagnosis of rotating machinery, *Mechanical Systems and Signal Processing* **35**(1-2): 108–126.

Lou, W., Wang, X., Chen, F., Chen, Y., Jiang, B. and Zhang, H. (2014). Sequence based prediction of dna-binding proteins based on hybrid feature selection using random forest and gaussian naive bayes, *PLoS One* **9**(1): e86703.

Pandey, P. and Barai, S. (1995). Multilayer perceptron in damage detection of bridge structures, *Computers & Structures* **54**(4): 597–608.

Plesset, M. S. (1949). The dynamics of cavitation bubbles, *Journal of applied mechanics* **16**: 277–282.

Ramalho, G. L. B. and Medeiros, F. N. S. d. (2017). *Análise Estrutural de Imagens Aplicada À Visão Computacional*, Recife, Fortaleza.

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.

Su, M.-Y. (2011). Using clustering to improve the knn-based classifiers for online anomaly network traffic identification, *Journal of Network and Computer Applications* **34**(2): 722–730.

Webb, A. R. (2002). *Statistical Pattern Recognition*, John Wiley & Sons Ltd, Inglaterra.

Widodo, A. and Yang, B.-S. (2007). Support vector machine in machine condition monitoring and fault diagnosis, *Mechanical systems and signal processing* **21**(6): 2560–2574.

Yang, F., Liu, C. and Tang, F. P. (2012). Cavitation performance prediction of mixed-flow pump based on cfd, *Earth and Environmental Science* **15**: 1–7.

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.