

# DETECÇÃO E DIAGNÓSTICO DE FALHAS EM UM SISTEMA DE BOMBEIO CENTRÍFUGO SUBMERSO DE PRODUÇÃO OFFSHORE OPERANDO EM MÚLTIPLAS REGIÕES

WENDERSON L. GANDA

*Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo*  
E-mail: wlganda@gmail.com

CELSON J. MUNARO

*Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo*  
E-mail: celso.munaro@ufes.br

**Abstract**—Process monitoring is necessary to ensure the reliability of the long-term operation of industrial systems. A fault is an unallowed deviation from the normal operating condition of at least one characteristic or parameter of the system. This work analyzes the implementation of a system for detecting and diagnosing failures at multiple points of operation of an electrical submersible pump system used in the offshore oil production, through external residue analysis technique with principal component analysis.

**Keywords**—Electrical Submersible Pump, Fault Detection and Diagnosis, Intelligent Systems.

**Resumo**—O monitoramento de processos é necessário para garantir a confiabilidade da operação de sistemas industriais em longo prazo. Uma falha é um desvio não permitido da condição normal de operação de ao menos uma característica ou parâmetro do sistema. Este trabalho analisa a implementação de um sistema de detecção e diagnóstico de falhas em múltiplos pontos de operação de um sistema de bombeio centrífugo submerso usado na produção de petróleo *offshore*, através de uma técnica de análise externa dos resíduos com análise das componentes principais.

**Palavras-chave**—Bombeio Centrífugo Submerso, Detecção e Diagnóstico de Falhas, Sistemas Inteligentes.

## 1 Introdução

O monitoramento de sistemas e processos tem captado cada vez mais atenção na indústria em geral, principalmente no seguimento *offshore*, devido aos altos custos de manutenção e parada de equipamentos e plantas e pelo aumento da complexidade dos processos de produção. Simples sistemas de monitoramento de alarmes individuais para determinados parâmetros tem-se mostrado ineficientes para garantir a operação contínua e confiável de equipamentos importantes para o processo, mostrando a necessidade de desenvolvimento de sistemas de detecção mais robustos e confiáveis, que operem de maneira automática e que analisem um conjunto maior de parâmetros para identificar situações anormais que mereçam interrupção do processo para que falhas catastróficas não venham a ocorrer.

Os principais métodos para detecção de falha aplicados na indústria são aqueles baseados em dados históricos. Em Venkatasubramanian (2003) é feita uma revisão sobre estes métodos, subdividindo estes em dois grupos: métodos qualitativos e métodos quantitativos. Os métodos qualitativos são classificados em sistemas especialistas e os modelos de tendências. Já os métodos quantitativos se dividem em métodos estatísticos e os métodos baseados em redes neurais. Os principais métodos estatísticos são aqueles baseados

na análise de componentes principais (PCA) e os classificadores Bayesianos.

O método PCA é basicamente uma decomposição ortonormal de matriz de covariância das variáveis do processo na direção que aponta a máxima variação dos dados, encontrando assim fatores que possuem uma dimensionalidade menor do que o conjunto de dados originais e ainda assim, descrevam adequadamente as principais tendências do conjunto original de dados.

Para detecção de anormalidades a partir da técnica PCA, é necessário definir uma métrica para identificar se ocorreram variações importantes no conjunto de variáveis ou não. Os métodos mais usados realizam o monitoramento estatístico multivariável usando a estatística de Hotelling.

Kourti et al (1994) explica que o objetivo de um controle estatístico do processo, ou monitoramento, é verificar se as variáveis de processo permanecem dentro de limites desejáveis e que as únicas variações que ocorram sejam de causa comum. A estatística de Hotelling  $T^2$  é aplicável em sistemas multivariáveis onde a matriz de covariância não é conhecida. Ela é então estimada de uma amostra de observações passadas. A partir dela, calcula-se a estatística  $T^2$  e a partir de um parâmetro conhecido como nível de significância, calculam-se os limiares de detecção. Em alguns casos, o monitoramento de variáveis baseado na estatística  $T^2$  sobre as primeiras componentes principais não é suficiente. Se um evento novo ocorrer que não está presente nos dados de referência usados para desenvolver o modelo PCA, estas novas componentes principais

irão aparecer nas novas observações. Elas podem ser detectadas pela estatística  $Q$ , que se baseia no erro quadrático de predição dos resíduos de uma nova observação. Representa o quadrado da distância perpendicular de novas observações multivariáveis do espaço de projeção e é muito utilizada em conjunto com  $T^2$ .

Métodos estatísticos de monitoramento de processo para detecção e diagnóstico de falhas foram revisados em Qin (2003), com a restrição de que processo opere em uma região de operação, ou seja, as variáveis sejam estacionárias. Assim, um dos grandes desafios para tornar prático o uso da técnica PCA para detecção de falhas em sistemas industriais reais é a detecção de falhas em várias regiões de operação. A técnica clássica usa os dados de operação normal para definição dos limiares da estatística de detecção. No entanto, como na situação real, usualmente os processos podem operar normalmente em mais de um ponto, técnicas que considerem esta condição devem ser desenvolvidas.

Para tratar problemas de detecção em vários modos de operação, Maestri et al (2010) analisou a estratégia de clusterização para delimitar as regiões que representam os diferentes modos de operação do processo. Diferentes clusters certamente possuem médias diferentes, no entanto, desde que as regras físicas que regem o processo sejam as mesmas, as estruturas de covariância, dividem características comuns. Para melhorar a performance do monitoramento considerando imutáveis as condições físicas, um modelo estatístico de múltiplas distribuições normais dividindo uma matriz de covariância comum é considerada, e então, um método de clusterização robusta é usada. O método considera que os clusters dividem uma matriz de covariância comum chamada Matriz de Covariância Agrupada. Um outro problema é definir o número ideal de clusters. É então utilizado um algoritmo heurístico baseado no volume do elipsoide associado a matriz de covariância agrupada. Uma vez definido os tamanhos dos clusters e a sua quantidade são utilizados os métodos como PCA, com Estatística de Hotelling para cada cluster considerando que os clusters possuem diferentes médias, e a matriz de covariância agrupada é usada ao invés da matriz de covariância comum. Moutinho (2016) aplicou técnicas de clusterização para identificar falhas em internos de válvulas sob várias condições de operação diferentes e Ganda et al. (2017) implanta esta técnica para detectar falhas em bombas de injeção offshore.

Em Zheng et al. (2016) foi proposto um método para detectar mudanças na região de operação através da aplicação de *Concurrent Projection to Latent Structures* (CPLS) usando variáveis externas que causam estas mudanças. O CPLS é um método similar ao PCA e é aplicado sobre dois conjuntos de variáveis, de entrada e de saída e usa as estatísticas de Hotelling  $T^2$  e  $Q$ . Este método foi originalmente proposto em Kano et al. (2004), no qual o uso de componentes independentes também foi considerado. Outro método foi desenvolvido em Zhao et al. (2004), realizando monitoramento em vários modos de operação, através

de múltiplos modelos PCA. Supondo que os dados possam ser agrupados para cada modo de operação, o método desenvolve modelos PCA para cada grupo de dados e depois calcula um parâmetro de similaridade entre os modelos através dos ângulos das componentes principais. De acordo com uma métrica é possível então, decidir se cada modelo PCA é independente ou se os grupos podem ser fundidos.

Um outro tipo de técnica de detecção de falhas em múltiplas regiões de operação foi desenvolvido por Kano et al. (2004) e foi denominada análise externa. Nesta técnica, as variáveis do processo são divididas em variáveis principais e variáveis externas. Assim, pode-se escrever um modelo que calcule as variáveis principais em função das variáveis externas e a diferença entre os resultados deste modelo e os dados reais é o resíduo, que deve ser independente do ponto de operação para poder ser usado para monitoramento.

Neste trabalho é analisada a aplicação da técnica de detecção de falha em múltiplas regiões de operação através da análise externa em um sistema de bombeio centrífugo submerso submarino usado para produção de petróleo *offshore*.

## 2 Sistema de Bombeio Centrífugo Submerso Submarino

A produção de poços de petróleo *offshore* se dá basicamente de dois modos: em elevação natural e em elevação artificial. Na elevação natural, o reservatório tem energia suficiente para fazer com que o fluido escoe desde o fundo do poço até a plataforma de produção sem outros meios auxiliares. Os poços que produzem deste modo são chamados de surgentes. No caso da elevação artificial, é necessário aumentar a energia dentro do poço para que o fluido possa escoar até a unidade de produção (Thomas, 2004). Atualmente os principais meios de elevação artificial são o *gas-lift* e o bombeio centrífugo submerso submarino (BCSS). Caso os poços sejam surgentes para o leito marinho, os equipamentos de bombeio podem ser instalados no fundo do mar para providenciar a elevação até a plataforma, como nos casos do *skid-BCS* (S-BCS) e do módulo de bombeio em poço falso (MOBO). A Figura 1 mostra um esquemático de um sistema de produção *offshore* típico com BCSS em MOBO.

O sistema de BCSS é composto de uma bomba centrífuga de múltiplos estágios, acionada por um motor elétrico. Neste trabalho, analisa um sistema BCSS instalado em um MOBO. Dessa forma, o conjunto fica submerso no óleo em um poço falso no leito marinho e o seu funcionamento cria um incremento de pressão nesse poço de modo a se obter a vazão desejada de óleo para a plataforma de produção. O sistema BCSS é dividido em dois grupos de componentes: equipamentos de subsuperfície e equipamentos de superfície. No arranjo típico, os equipamentos de subsuperfície são motor, selo, *intake*/separador, bomba centrífuga de multi-estágios, cabo elétrico e acessórios. Os equipamentos de superfície são os que compõem o sistema de acionamento elétrico, sistema de controle, sistema

de proteção e acessórios. O sistema de acionamento elétrico usual é o inversor de frequência.

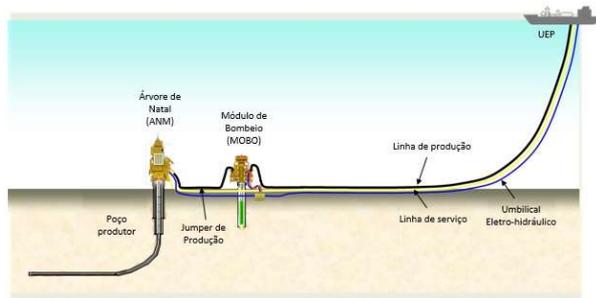


Figura 1. Sistema BCSS com MOBO

### 3 Detecção de Falhas em Múltiplas Regiões de Operação

#### 3.1 Análise de Componentes Principais

Um método comum para reduzir a dimensão do espaço de variáveis é a utilização de métodos de projeção como PCA. Estes métodos baseiam-se na redução da matriz de covariância  $S$ , para uma matriz diagonal  $L$  pré-multiplicando e pós-multiplicando por uma matriz ortogonal  $U$ , de tal modo que  $U^T S U = L$ . Os elementos diagonais de  $L$ ,  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_D$  são os autovalores de  $S$ , e as colunas de  $U$  são os autovetores de  $S$ , também chamados de vetores de carga ( $u_i$ ). A matriz de covariância  $S$  é calculada a partir de um conjunto de dados  $X_{n \times m}$  que possui  $m$  variáveis e  $n$  amostras, correspondendo às medidas em condição de operação normal da planta. Estas medições devidamente normalizadas são projetadas por  $T = X U$ , ou  $t_i = X u_i$  para  $i = 1, 2, \dots, m$ . Os vetores  $t_i$ , chamados de vetores de peso, são as colunas de  $T$  e estatísticas diferentes podem ser calculadas para decidir se as medidas permanecem sob controle, em condição normal, ou não. Para isso, a decisão é baseada nas  $a$  primeiras componentes principais (1). A estatística baseada no erro quadrático de predição é dada por (2), onde  $x_i$  e  $\hat{x}_i$  são as medidas da  $i$ -ésima variável e sua predição respectivamente.

$$T_a^2 = \sum_{i=1}^a \frac{t_i^2}{\lambda_i} \quad (1)$$

$$Q = \sum_{i=1}^m (x_i - \hat{x}_i)^2 \quad (2)$$

#### 3.2 Análise de Através de Variáveis Externas

As mudanças de região de operação ocorrem devido a uma causa externa ao processo em si, como variações de entrada e *setpoints* de controladores. Assim, as variáveis de processo podem ser divididas em dois

grupos: as variáveis externas, que provocam as alterações no processo e as variáveis principais, que são afetadas pelas mudanças (Assis et al., 2017).

Considere o conjunto de dado  $X$ , com  $m$  variáveis e  $n$  amostras. Este conjunto pode ser decomposto em duas partes, conforme (3):

$$X = [H G] \quad (3)$$

onde  $G$  é o grupo de variáveis externas e  $H$  o grupo de variáveis principais. A matriz  $H$  deve ser decomposta em duas: a parte que é explicada pelas variáveis externas e a parte que não é explicada, chamada de resíduo. Para isso, uma regressão linear será feita, utilizando  $G$  como entrada e  $H$  como saída. Os coeficientes são calculados utilizando mínimos quadrados, resultando na matriz  $C$  dada pela equação (4):

$$C = (G^T G)^{-1} G^T H \quad (4)$$

e os resíduos são calculados por (5):

$$E = H - GC \quad (5)$$

Para o monitoramento do processo são utilizados os resíduos provenientes da retirada da influência das variáveis externas sobre as principais. Os resíduos são calculados nas diversas regiões de operação normal. Um modelo PCA é obtido a partir dos resíduos para o monitoramento, calculando-se as estatísticas  $T^2$  e  $Q$  para identificar ultrapassagens do limiar calculado para operação normal (Qin, 2003).

## 4 Metodologia

#### 4.1 Simulação e geração de dados do poço de petróleo

Neste trabalho, foi utilizado um modelo de poço produtor de petróleo no simulador de escoamento transiente OLGA®, com características típicas de campos do pós-sal da Bacia de Campos, equipado com BCS em um módulo de bombeio (MOBO). Este simulador é bastante usual na indústria de petróleo e com resultados muito acurados em relação aos processos reais de produção. No entanto, por sua complexidade e acurácia, as simulações são de difícil modelagem, com grande quantidade de parâmetros para serem inseridos ou ajustados e o tempo de simulação é muito alongado.

O modelo usado neste trabalho (reservatório, poço, bomba e dutos de escoamento) possibilita a análise do comportamento dinâmico entre o processo e o sistema de controle implementado em Bacellar (2016). A Figura 2 mostra o sistema modelado.

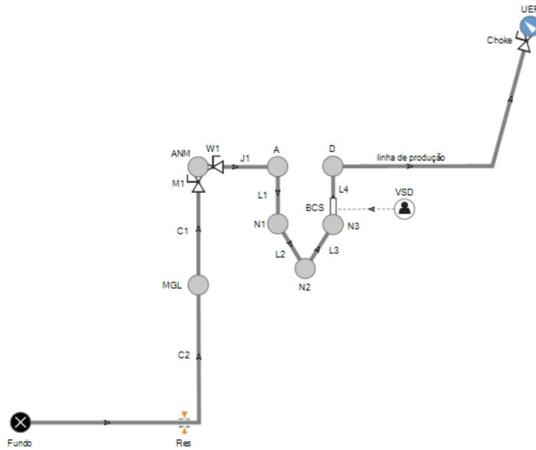


Figura 2. Modelo de simulação

No simulador OLGA®, foram realizadas as simulações em duas etapas:

- a) Simulação da operação normal em 13 velocidades de rotação da BCS
- b) Simulação das falhas para quatro diferentes velocidades de rotação da BCS.

As falhas simuladas representam mudanças nas condições dos equipamentos submarinos, das propriedades dos fluidos escoados, do reservatório ou da planta de processamento (Bacellar, 2016) e são mostradas na tabela 1, com os parâmetros em sua condição normal (ON) ou em falha (OFF).

As variáveis principais de processo usadas nesta análise foram: pressão no sensor PDG (fundo do poço), pressão de sucção da bomba, pressão de descarga da bomba, pressão no sensor TPT (árvore de natal), pressão a montante da válvula *choke* (chegada na plataforma) e abertura da válvula *choke*. A velocidade de rotação da bomba foi usada como variável externa.

Tabela 1. Descrição das falhas simuladas.

Falha	Parâmetro	ON	OFF
1	Teor de água (BSW)	20%	30%
2	Pressão do separador	15.43 bar	25 bar
3	Pressão do Reservatório	250 bar	242,5 bar
4	Razão Gás-Óleo	41 m <sup>3</sup> /m <sup>3</sup>	45 m <sup>3</sup> /m <sup>3</sup>
5	Número de estágios	52	48
6	Abertura da válvula à montante	100%	8%
7	Abertura da válvula à jusante	100%	8%
8	Aberturas das válvulas à montante e à jusante	100% e 100%	8% e 8%

#### 4.2 Detecção de falhas via análise externa

O processo de detecção de falhas possui as seguintes etapas que devem ser seguidas para efetuar o monitoramento de processos multivariáveis em múltiplas regiões de operação usando análise externa:

- 1) Definir as variáveis a serem monitoradas e encontrar a variável externa, que causa a mudança da região de operação;

- 2) Obter os dados de operação normal nas múltiplas regiões de operação;
- 3) Definir o modelo de regressão a ser utilizado para relacionar as variáveis principais com a variável externa;
- 4) Segregar os dados de operação normal em um grupo de treinamento e outro de teste para criar o modelo de regressão e obter os resíduos para operação normal;
- 5) Definir qual modelo PCA será utilizado e treinar o modelo com os resíduos obtidos anteriormente, definindo o limiar estatístico de detecção de falha;
- 6) Testar o modelo PCA de detecção com os dados de operação normal;
- 7) Etapa de monitoramento: obter os resíduos dos dados de operação que serão monitorados com o modelo de regressão obtido em (4) e aplicar o modelo PCA nos resíduos para detectar violações do limiar a cada nova medição das variáveis.

#### 4.3 Diagnóstico via classificação de padrões

Após a detecção, foi desenvolvida uma etapa de diagnóstico das falhas através de um algoritmo kNN (*k-Nearest Neighbour*) sobre os resíduos durante a falha. O kNN é um algoritmo de classificação de padrões bastante conhecido e é baseado na determinação de rótulos de classificação de uma amostra com base nas amostras vizinhas advindas de um conjunto de treinamento. Dado um conjunto de amostras já rotuladas, o algoritmo classifica uma nova amostra com base na menor distância da nova amostra aos k-vizinhos já rotulados. A etapa de treinamento do algoritmo implementada foi:

- 1) Selecionar 30 amostras dos resíduos após a detecção da falha devidamente rotulados;
- 2) Escolher o número k de vizinhos que serão usados para o cálculo de distância para nova amostra.

No monitoramento, a etapa de diagnóstico se inicia após a detecção da falha. As amostras são classificadas pelo algoritmo conforme a menor distância encontrada aos k vizinhos já rotulados.

## 5 Resultados e Discussões

Na primeira etapa da análise são usados os dados de operação normal, obtidos por simulação variando a velocidade de rotação da BCS entre 2430 rpm (frequência de 40,5 Hz no inversor de acionamento) e 3600 rpm (60 Hz), por quatro horas em cada patamar de velocidade. As variáveis principais são mostradas nas Figuras 3 e 4. A variável externa (velocidade de rotação da BCS) é mostrada na Figura 5. O tempo de amostragem é 1 amostra por minuto.

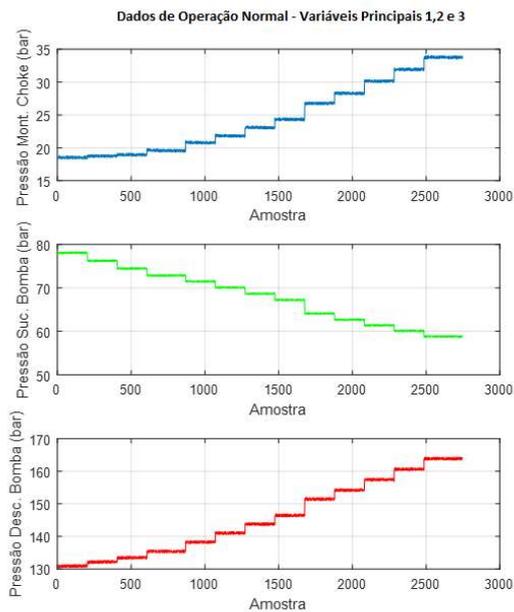


Figura 3. Dados das variáveis principais (1, 2 e 3) em operação normal para 13 regiões de operação.

Em seguida, foi usado um modelo de regressão para relacionar a velocidade de rotação da BCS com as variáveis principais. Dentre as opções mais conhecidas, estão a regressão via vetores de suporte (SVR), regressão polinomial, regressão via rede neural de regressão generalizada (GRNN) e árvore de regressão. Uma vez treinado o modelo, as variáveis principais se tornam função da variável externa. Os resíduos deste modelo são então usados para obter o modelo PCA.

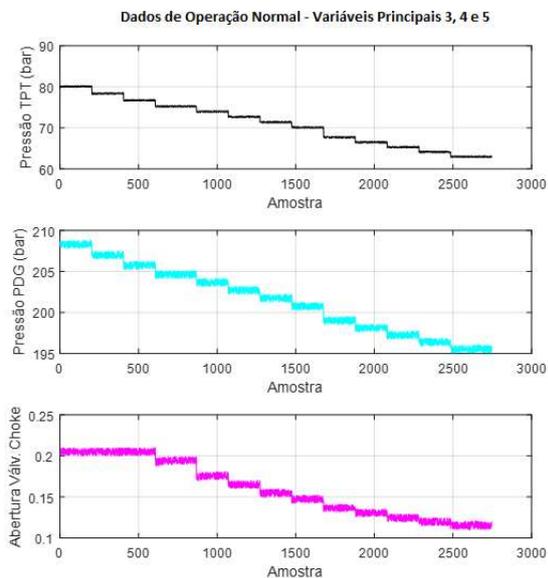


Figura 4. Dados das variáveis principais (4, 5 e 6) em operação normal para 13 regiões de operação.

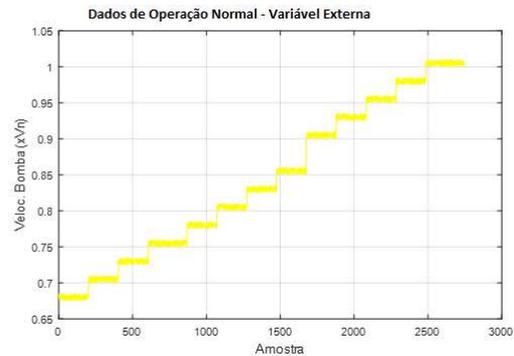


Figura 5. Dados da variável externa em operação normal para 13 regiões de operação.

Neste trabalho, optou-se pelo modelo de regressão via vetor suporte que é uma máquina de aprendizagem baseada na teoria da aprendizagem estatística com princípio da minimização do risco estrutural, minimizando um limite superior do erro de generalização ao invés de minimizar o erro de treinamento, como nas redes neurais. Este método sido bastante usado em problemas de regressão não linear e depende apenas de um subconjunto de dados de formação e uma função custo (Rodrigues et al., 2016). Usou-se 70% dos dados de operação normal de cada região para gerar o modelo. Os resíduos do modelo para operação normal podem ser vistos na Figura 6.

Com estes resíduos da operação normal para as diversas regiões de operação, criou-se um modelo PCA com estatística combinada ( $T^2, Q$ ) e nível de confiança de 99%. Usando 3 componentes principais, a variância acumulada foi de 80% e o limiar obtido para detecção da falha foi de 1,3963 (Qin, 2013).

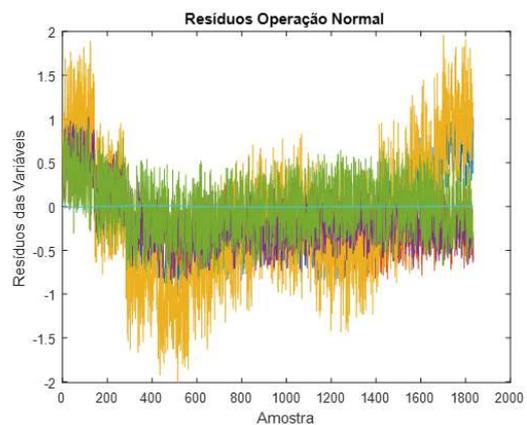


Figura 6. Resíduos para operação normal nas 13 regiões de operação.

Para verificação do modelo PCA obtido, usou-se os 30% restantes de dados de operação normal das 13 regiões de operação. O resultado é mostrado na Figura 7. Para simulação das falhas, escolheu-se quatro regiões de operação, com base na velocidade de rotação da BCS: 2520 rpm (42 Hz), 3060 rpm (51 Hz), 3420 rpm (57 Hz) e 3600 rpm (60 Hz). A restrição do número de regiões de operação para esta simulação se deu pela grande quantidade de tempo gasto em cada

simulação e assim, optou-se por estas quatro representativas frequências, devido ao fato de que em situação real, frequências acima de 50 Hz são pontos de operação mais comuns.

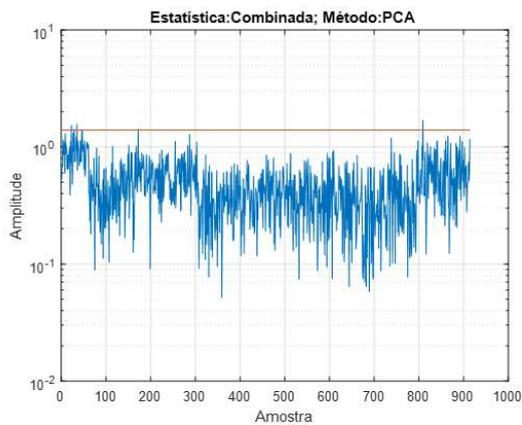


Figura 7. Estatística T²,Q para dados de operação normal.

Para ilustrar a implementação do sistema de detecção, as Figuras 8 e 9 mostram as variáveis para a velocidade de rotação de 3060 rpm (51 Hz). Em determinado momento (amostra 120) é inserida a falha 4 (aumento da razão gás-óleo do reservatório).

Os resíduos obtidos nesta situação são mostrados na Figura 10, na qual se percebe mudanças significativas nos patamares dos resíduos.

Na Figura 11 é ilustrado o modelo PCA para o monitoramento deste caso detectando a violação do limiar de operação normal.

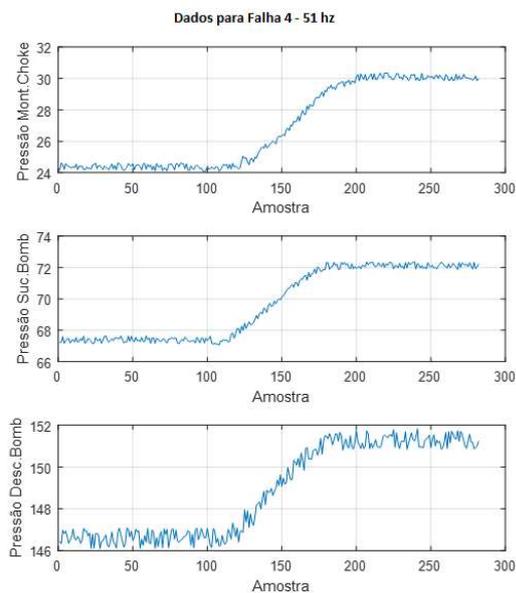


Figura 8. Dados para variáveis de 1 a 3 durante a falha 4 em 51 Hz.

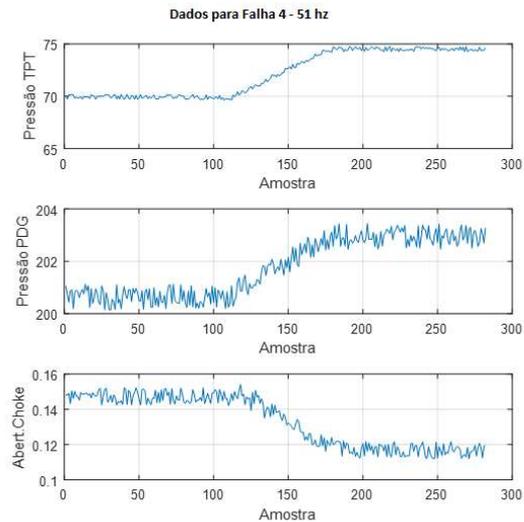


Figura 9. Dados para variáveis de 4 a 6 durante a falha 4 em 51 Hz.

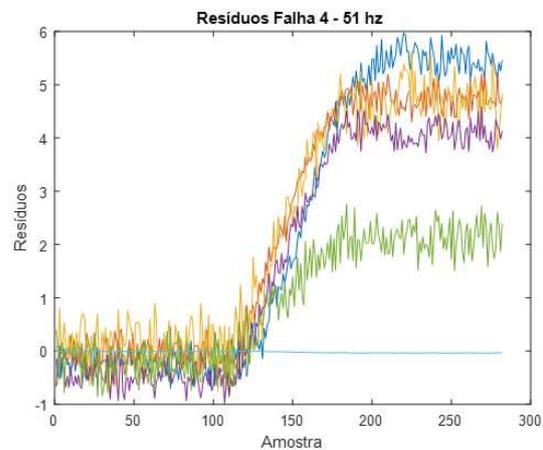


Figura 10. Resíduos durante a falha 4 em 51 Hz.

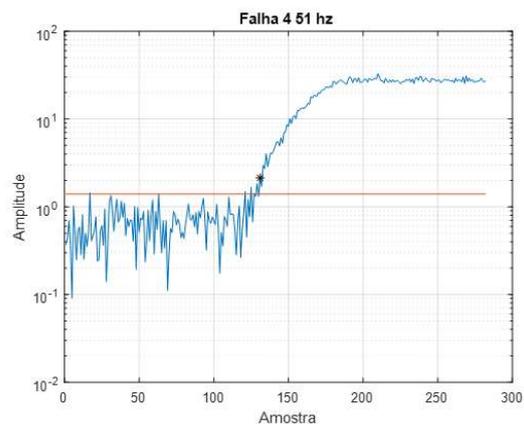


Figura 11. Estatística T²,Q durante a falha 4 em 51 Hz.

Foram simuladas as 8 falhas nas 4 regiões de operação e aplicadas as etapas descritas anteriormente e todas as falhas foram detectadas em todas as regiões de operação.

A seguir, foi treinado o classificador k-NN, com k igual a 1 para diagnóstico usando os resíduos.

Para avaliar a capacidade de generalização de diagnóstico do algoritmo k-NN, foi realizada uma validação

cruzada. Foram treinados quatro classificadores a partir dos dados das falhas. Cada classificador foi treinado com os dados de três regiões de operação e testado para a quarta região de operação que não foi usada no treinamento. Na etapa de teste, o algoritmo recebe como entrada as 30 primeiras amostras após a detecção e indica qual falha foi detectada, resultado este baseado no classificador k-NN. A tabela 2 apresenta a matriz de confusão resultante dos testes de diagnóstico.

Tabela 2. Matriz de Confusão do Classificador de Falhas.

Matriz de Confusão		Rótulos do Classificador							
		1	2	3	4	5	6	7	8
Rótulos Reais	1	4							
	2		2			1		1	
	3			4					
	4				3	1			
	5				1	3			
	6						4		
	7							4	
	8								4

A acurácia do classificador foi de 87,5%. Para visualizar a dificuldade do algoritmo para classificar as falhas de 2, 4 e 5 foi gerado o gráfico usando duas componentes principais dos resíduos das falhas. Assim, pode-se verificar qual região do espaço em duas dimensões as falhas ocupam. A Figura 12 mostra o resultado.

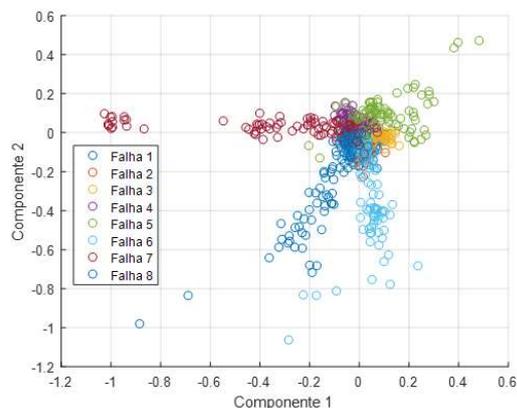


Figura 12. Gráfico para avaliar a separabilidade das falhas para três regiões de operação.

Verifica-se, pelas características das falhas 2, 4 e 5 mostradas, a dificuldade existente em identificá-las. No entanto, o classificador possui excelente desempenho para as demais falhas.

## 6 Conclusão

O monitoramento e diagnóstico de sistemas de produção *offshore* tem grande importância dado custo de parada e de intervenção é muito elevado, como é o caso

de sistemas BCSS. Neste trabalho foi aplicada uma técnica de monitoramento multivariável em múltiplas regiões de operação para detecção e diagnóstico de falhas em sistemas de produção *offshore* baseados em BCSS. O monitoramento dos resíduos através da análise externa em conjunto com modelos PCA comprovou-se altamente eficaz na detecção de falhas em diferentes regiões de operação definidas pela velocidade de rotação da bomba. Para o diagnóstico das falhas, o algoritmo de classificação de padrões k-NN apresentou excelente desempenho para identificação da maior parte das falhas após detecção. Seu desempenho para três tipos de falha ficou abaixo dos demais e pode ser melhorado alterando as características usadas ou o tipo de classificador. Como o simulador usado tem grande confiança e aceitação na indústria do petróleo, a aplicabilidade dos métodos aqui propostos é imediata.

## Referências Bibliográficas

- Assis, A. A., Munaro, C. J., Rauber, T. W., Ciarelli, P. M. and Santi, G. B. (2017). Parametrização de Diagnóstico de Falhas de Processos em Múltiplas Regiões de Operação Utilizando Análise Externa. Simpósio Brasileiro de Automação Inteligente (SBAI), 2017. Porto Alegre – RS..
- Bacellar, F. R. R. (2016). Proposta de Controle Automático e Monitoramento Operacional do Bombeio Centrífugo Submerso em Sistemas de Produção *Offshore*. Dissertação de Mestrado. Universidade Federal do Espírito Santo.
- Ganda, W. L., Moutinho, M. V. B. and Castro, G. B. (2017). Aplicação de Algoritmo para Detecção de Falhas em Bombas Centrífugas Multi-Estágio de Injeção de Água em Reservatórios de Petróleo. Simpósio Brasileiro de Automação Inteligente (SBAI), 2017. Porto Alegre – RS.
- Kano, M., Hasebe, S., Hashimoto, I. and Ohno, H., (2004). Evolution of multivariate statistical process control: application of independent component analysis and external analysis. *Computers & chemical engineering*, 28(6), pp.1157-1166.
- Rodrigues, S. B., Silva, A. C. L., Corrêa, J. M., Neto, A. C. (2016). Combinação Preditiva das Técnicas ARIMA e *Support Vector Regression (SVR)* na Previsão do Descolamento do Bloco H8 da Usina Hidrelétrica de Itaipu com Base nas Séries Temporais dos Pêndulos. PPGMNE/UFPR. Curitiba- PR.
- Thomas, J. E., (2004). Fundamentos de Engenharia de Petróleo. Interciência, 2ª Ed. Rio de Janeiro- RJ.
- Maestri, M.; Groisman, P.; Cassanello, M. and Horowitz, G., (2010). A robust clustering method

for detection of abnormal situations in a process with multiple steady-state operation modes. *Computers & Chemical Engineering*, Vol. 34, No. 2, pp. 223–231.

Moutinho, M. V. B. (2016). *Detecção de Falhas em Internos de Válvulas de Controle Atuando em Múltiplas Regiões de Operação*. Dissertação de Mestrado. Universidade Federal do Espírito Santo. 112 f.

Qin, S.J. (2003). Statistical process monitoring: basics and beyond. *J Chemom.*, 17, pp. 480–502.

Venkatasubramanian, V.; Rengaswamy, R.; Kavuri, S. N.; Yin, K., (2003). A review of process fault detection and diagnosis: Part III: Process history based methods. *Computers & chemical engineering*, Vol. 27, No. 3, pp. 327- 346.

Zheng, Y, S. Qin, J. and Chai, T. (2016). Fault Detection of Multimode Processes Using Concurrent Projection to Latent Structures. *IFAC-PapersOnLine* 49.7, pp. 705-710.

Zhao, S. J., Zhang, J. and Xu, Y. M. (2004). Monitoring of processes with multiple operating modes through multiple principle component analysis models. *Ind. Eng. Chem. Res.*, vol. 43, pp. 7025–7035.