

UNIVERSIDADE FEDERAL FLUMINENSE
INSTITUTO DE CIÊNCIA E TECNOLOGIA
MESTRADO EM ENGENHARIA DE PRODUÇÃO E SISTEMAS
COMPUTACIONAIS

VANDERSON PIMENTA CARVALHO

APRIMORAMENTO DA DETECÇÃO E IDENTIFICAÇÃO DE
FALHAS EM UM SISTEMA PREVENTOR DE EXPLOSÕES
SUBMARINO (BOP)

RIO DAS OSTRAS, RJ
2016

VANDERSON PIMENTA CARVALHO

**APRIMORAMENTO DA DETECÇÃO E IDENTIFICAÇÃO
DE FALHAS EM UM SISTEMA PREVENTOR DE
EXPLOSÕES SUBMARINO (BOP)**

Dissertação apresentada ao Instituto de Ciência e Tecnologia da Universidade Federal Fluminense, como requisito parcial à obtenção do título de Mestre em Engenharia de Produção e Sistemas Computacionais.

Campo de Confluência: Sistemas Computacionais.

Orientador:

Prof. Dr. Alessandro Copetti, D.Sc.

Coorientador:

Prof. Dr. Ana Paula Barbosa Sobral, D.Sc.

Rio das Ostras, RJ
2016

VANDERSON PIMENTA CARVALHO

**APRIMORAMENTO DA DETECÇÃO E IDENTIFICAÇÃO
DE FALHAS EM UM SISTEMA PREVENTOR DE
EXPLOSÕES SUBMARINO (BOP)**

Dissertação apresentada ao Instituto de Ciência e Tecnologia da Universidade Federal Fluminense, como requisito parcial à obtenção do título de Mestre em Engenharia de Produção e Sistemas Computacionais.

Campo de Confluência: Sistemas Computacionais.

Aprovada em 7 de março de 2016.

BANCA EXAMINADORA

Prof. Dr. Alessandro Copetti, D.Sc. - UFF
Orientador

Prof. Dr. Ana Paula Barbosa Sobral, D.Sc. - UFF
Coorientador

Prof. Dr. Luciano Bertini, D.Sc. - UFF

Dr. Bruno Astuto Arouche Nunes, Ph.D. - Centro de Pesquisas da GE/RIO

Rio das Ostras, RJ
2016

FICHA CATALOGRÁFICA
Preparada pela Biblioteca da UFF



*Aos meus amados pais Alda e José, e
a minha eterna namorada e amor da
minha vida Cíntia.*

Agradecimentos

Aos meus orientadores Alessandro Copetti e Ana Paula Barbosa Sobral, que com seu profissionalismo, paciência e amizade me transmitiram muito mais que apenas conhecimento. Me mantiveram no caminho e não desistiram de mim em nenhum momento.

À minha amada esposa Cíntia Carvalho, pelo seu apoio incondicional, mesmo nos longos períodos que estive ausente durante a elaboração deste trabalho. Completar esta etapa da minha vida não seria possível sem sua presença e incentivo.

Aos meus pais, familiares e amigos pelo incentivo, e por nunca deixarem de acreditar em mim.

Aos professores e amigos do Mestrado em Engenharia de Produção e Sistemas Computacionais da Universidade Federal Fluminense, pelo apoio na elaboração deste trabalho.

Aos amigos da GE Oil and Gas, que de forma direta ou indireta, contribuíram no desenvolvimento deste trabalho.

A todos aqueles que encontrei durante esta caminhada que certamente, de uma forma ou de outra, me influenciaram e ajudaram na conclusão deste trabalho.

Quem é sábio procura aprender, mas os tolos estão satisfeito com a sua própria ignorância.

Salomão (Pv 15:14)

Resumo

O sistema de prevenção de explosões em poços de petróleo submarinos (BOP) possui papel indispensável nas atividades exploratórias de petróleo em alto mar. Como se trata de um equipamento de segurança, a rapidez e eficiência na descoberta de falhas são de vital importância para a rentabilidade do trabalho, para a segurança de todos a bordo da plataforma de petróleo e para proteção do meio ambiente. Atualmente, para o sistema BOP analisado neste trabalho, a análise dos dados históricos não é comum dada a complexidade do sistema e o número de variáveis envolvidas. Contudo, quando esta análise é realizada, é feita de forma manual e o seu resultado é totalmente dependente da habilidade e experiência do operador encarregado de executá-la. Isso demonstra a relevância deste estudo, e como a automatização deste processo pode auxiliar os operadores na análise do histórico de dados. O presente trabalho propõe uma metodologia onde serão investigadas ferramentas estatísticas e computacionais aplicadas à um conjunto de dados históricos provenientes desse sistema com o objetivo de automatizar a análise de dados. A ideia principal da metodologia é através da preparação dos dados, aplicação da ACP e utilização de Cartas de Controle estatístico (T^2 de Hotelling e Estatística Q) detectar a variabilidade e conseqüentemente falhas em um conjunto de dados. Além da detecção e identificação de falhas, a metodologia é capaz de extrair informações relevantes, como a frequência e relação entre alarmes, apropriadas para a análise do arquivo de dados de alarmes do BOP. Posteriormente, a metodologia é validada através de sua aplicação em dados reais e dados simulados. Os resultados desta metodologia, disponibilizados aos operadores, podem colaborar significativamente para a redução do tempo necessário para o diagnóstico e a posterior resolução da falha detectada. Isso pode contribuir significativamente para a redução das perdas operacionais e aumento da confiabilidade geral do sistema BOP.

Palavras-chave: BOP, preventor de explosão, análise de falhas, estatística multivariada, análise de componentes principais, cartas de controle.

Abstract

The BlowOut Preventer or BOP has an important role in the offshore drilling operations. As a safety equipment, the failure detection speed and efficiency are very important to the profitability, rig personal safety and environmental protection. Nowadays, for the BOP system under analysis on this work, the historical data analysis is not a common task due to the system complexity and the large number of variables involved. Nevertheless, when a kind of analysis is need to be carried out, it's performed manually by the operators and its results are fully dependent to the operator abilities and experience. All that show the relevance of this work, and how the automation of this process can help the operator during the historical data analysis. This work propose a methodology which investigate and apply statistical and computational tools to a BOP historical data set in order to automatize the data analysis process. The idea behind the methodology is preparing the data, applying the Principal Components Analysis (ACP) and Statistical Control Charts (Hotelling T^2 and Q Statistic) be able to detect the variability and thus failures in the data set. In addition to it, the methodology is able to extract relevant information such as frequency and relationship between alarms, appropriate for monitoring BOP alarm data set. Subsequently, the methodology is applied against real and simulated sensor data for validation. The results of this methodology available to the operators, may contribute significantly to improve the time required for the diagnosis and the subsequent resolution of the failure detected. This can greatly contribute to reduce operational losses and increase the overall reliability of the BOP system.

Keywords: BOP, blowout preventer, failure analysis, multivariate statistic, principal component analysis, control charts.

Sumário

Lista de Ilustrações	1
Lista de Tabelas	3
1 Introdução	1
2 Sistema BOP	4
2.1 Painéis de controle de superfície	9
2.2 POD de controle	10
2.3 BOP Stack	10
2.3.1 Preventor anular	11
2.3.2 Preventor de gaveta (<i>RAM</i>)	11
3 Referencial Teórico	16
3.1 Trabalhos relacionados	16
3.2 Detecção e identificação de falhas	18
3.3 Medidas e ferramentas de análises estatísticas	21
3.3.1 Coeficiente de variação	21
3.3.2 Detecção de outliers	22
3.3.3 Análise de Componentes Principais - ACP	24
3.3.4 Cartas de controle estatístico	27
3.3.5 Estatística T^2 de Hotelling	28
3.3.6 Estatística Q	30

4 Metodologia Proposta	32
5 Aplicação da metodologia proposta	35
5.1 Preparação dos dados	35
5.2 Período operacional	39
5.3 Frequência dos alarmes	42
5.4 Matriz de frequência	45
5.5 Detecção e identificação de falhas	48
5.5.1 Dados de alarme	48
5.5.2 Simulação - Falha do tipo <i>sensor drift</i>	53
5.5.3 Simulação - Falha do tipo repetibilidade	57
6 Conclusão	62
Referências	64
Apêndice A – Artigo não publicado	68

Lista de Ilustrações

Figura 2.1	Arranjo completo do BOP Stack (GE/HYDRIL, 2013)	4
Figura 2.2	Localização dos PODs de controle (GE/HYDRIL, 2013)	5
Figura 2.3	Sistema de controle Eletro-hidráulico (GE/HYDRIL, 2013)	6
Figura 2.4	Sistema de controle Eletro-hidráulico(GE/HYDRIL, 2013)	7
Figura 2.5	Sistema de BOP (GE/HYDRIL, 2013)	8
Figura 2.6	Painéis de controle de superfície (GE/HYDRIL, 2013)	9
Figura 2.7	POD de controle submarino (GE/HYDRIL, 2013)	10
Figura 2.8	Preventor Anular (GE/HYDRIL, 2013)	11
Figura 2.9	Arranjo do preventor de gaveta (GE/HYDRIL, 2013)	12
Figura 2.10	Gaveta de tubo com diâmetro fixo (MALOUF, 2013)	13
Figura 2.11	Gaveta de tubo com diâmetro variável (MALOUF, 2013)	13
Figura 2.12	Gaveta cega (MALOUF, 2013)	14
Figura 2.13	Gaveta cega cisalhante (MALOUF, 2013)	14
Figura 2.14	Sequência de acionamento da gaveta cega cisalhante (GE/HYDRIL, 2013)	15
Figura 2.15	Gaveta cisalhante para corte de revestimento (GE/HYDRIL, 2013)	15
Figura 3.1	Ciclo de monitoramento de um processo (CHIANG et al., 2001)	19
Figura 3.2	Classificação dos algoritmos de diagnóstico - Adaptado de Venkatasubramanian (2003)	20
Figura 3.3	Gráfico <i>Boxplot</i> (O Autor)	23
Figura 3.4	Típica carta de controle (MONTGOMERY, 2009)	28
Figura 4.1	Fluxograma da metodologia proposta neste trabalho (o Autor)	34
Figura 5.1	Fluxograma da preparação dos dados (o Autor)	36
Figura 5.2	Pressão hidrostática versus Pressão de travamento do <i>wellhead connector</i> (o Autor)	40
Figura 5.3	Frequência de alarmes (o Autor)	44
Figura 5.4	Matriz de cruzamento de frequência dos alarmes (o Autor)	46

Figura 5.5	Resultado da ACP para os dados de treinamento (acima) e teste (abaixo) (o Autor)	49
Figura 5.6	Estatística T^2 e limite superior para os dados de treinamento (acima) e teste (abaixo) (o Autor)	51
Figura 5.7	Estatística Q para os dados de treinamento (acima) e teste (abaixo)(o Autor)	52
Figura 5.8	Contribuição individual por sensor para o ponto amostral 50 (o Autor)	53
Figura 5.9	Resultado da ACP para os dados de treinamento (acima) e simulados (abaixo) (o Autor)	54
Figura 5.10	Estatística T^2 e limite superior para os dados de treinamento (acima) e simulados (abaixo) (o Autor)	55
Figura 5.11	Estatística Q para os dados de treinamento (acima) e simulados (abaixo)(o Autor)	56
Figura 5.12	Contribuição individual por sensor para a simulação <i>sensor drift</i> (o Autor)	57
Figura 5.13	Resultado da ACP para os dados de treinamento (acima) e simulados (abaixo) (o Autor)	58
Figura 5.14	Estatística T^2 e limite superior para os dados de treinamento (acima) e simulados (abaixo) (o Autor)	59
Figura 5.15	Estatística Q para os dados de treinamento (acima) e simulados (abaixo)(o Autor)	60
Figura 5.16	Contribuição individual por sensor para a simulação de repetibilidade (o Autor)	61

Lista de Tabelas

Tabela 3.1	Valores do coeficiente de variação	22
Tabela 5.1	Maiores contribuintes para o <i>downtime</i> total (SILVA, 2002)	37
Tabela 5.2	ID e descrição dos alarmes utilizados (O Autor)	38
Tabela 5.3	Período de operação	41
Tabela 5.4	Frequência dos alarmes dos 20 sensores no período operacional	43
Tabela 5.5	Total de alarmes e reconhecimento de alarmes no período sob análise .	44
Tabela 5.6	Maiores frequências de ocorrência entre alarmes	47

Capítulo 1

Introdução

Durante a fase de perfuração de um poço de petróleo em águas profundas, é comum encontrar zonas de alta pressão ou qualquer outro problema no poço de petróleo que leve a diminuição da pressão hidrostática sobre a formação (SILVA, 2002). Quando isso ocorre, existe a possibilidade de haver influxo de fluídos da formação para o poço, o que é denominado como *kick*. Se este *kick* não for contido, poderá ocasionar um *blowout*, ou fluxo indesejado e inesperado de hidrocarbonetos (gás/óleo) proveniente da formação para o poço e em seguida para a superfície (SILVA, 2002), podendo acarretar paradas de produção, perda de equipamentos e da própria plataforma, ocasionar perda financeira significativa, gerar desastres ambientais e a perda de vidas humanas. Diante disto, todo o poço de petróleo durante a fase de perfuração possui um equipamento Preventor de Explosão Submarino ou *BlowOut Preventer*-BOP.

Além da operação normal e diária do sistema BOP, os operadores ainda têm como responsabilidade monitorar os alarmes do sistema e atuar de acordo. Contudo, em razão da operação do equipamento ser extremamente complexa, a enorme quantidade de dados gerada e a falta de tempo hábil, dificulta sobremaneira a análise de qualquer possível falha que esteja associada ao alarme gerado. Além disso, mesmo havendo redundância, caso ocorra falha em algum determinado sensor o sistema não seleciona automaticamente o sensor redundante, ficando esta ação a cargo do operador. Logo, faz-se necessário que o operador consiga verificar de forma direta a ocorrência de falha nos sensores do BOP.

Neste contexto, o aumento da complexidade dos processos, o elevado número de variáveis envolvidas a serem observadas nos sistemas de controle, em conjunto com as restrições de qualidade, segurança e meio-ambiente vigentes, são razões suficientes para que sistemas automatizados de detecção e diagnóstico de falhas sejam desenvolvidos ou aperfeiçoados (ALEXANDRE et al., 2012). A automação do processo de análise de falhas

é fundamental para garantir a confiabilidade do sistema e a sua maior disponibilidade, uma vez que análises realizadas manualmente consomem muito tempo e necessitam de profissionais bastante experientes para seu sucesso (CHEN et al., 2004). Esses autores definem detecção de falha como o ato de determinar se um dado sistema experimenta problemas. Já o diagnóstico de falha é definido como a tarefa de localizar a causa da falha detectada.

Uma forma de aprimorar/automatizar a detecção e a identificação de falhas é pela aplicação de métodos estatísticos multivariados. Tais métodos são amplamente utilizados em diversos processos industriais (JENG et al., 2007). Entre esses métodos, a Análise de Componentes Principais (ACP) pode ser aplicada para reduzir e preparar o conjunto de dados históricos para a posterior aplicação de testes estatísticos, utilizados na detecção de mudanças no ponto de operação, falhas de sensores, falhas no processo e distúrbios da planta (VENKATASUBRAMANIAN, 2003). Evidencia-se assim, a necessidade de investigar técnicas estatísticas apropriadas para o aprimoramento da detecção e identificação de falhas em um Sistema Preventor de Explosões Submarino. Esse processo pode ser aplicado utilizando ferramentas computacionais disponíveis, como por exemplo o ambiente estatístico R.

O presente trabalho propõe uma metodologia onde serão investigadas ferramentas estatísticas e computacionais aplicadas à um conjunto de dados históricos provenientes desse sistema. A ideia principal da metodologia é através da preparação dos dados, da aplicação da ACP e da utilização de Cartas de Controle estatístico detectar a variabilidade e conseqüentemente falhas em um conjunto de dados. Além da detecção e identificação de falhas, a metodologia é capaz de extrair informações relevantes, como a frequência e relação entre alarmes, apropriadas para o monitoramento de alarmes do BOP.

Atualmente, para o sistema BOP analisado neste trabalho, a análise dos dados históricos não é comum dada a complexidade do sistema e o número de variáveis envolvidas. Contudo, quando esta análise é realizada, é feita de forma manual e o seu resultado é totalmente dependente da habilidade e experiência do operador encarregado de executá-la. Isso demonstra a relevância deste estudo, e como as informações de detecção e identificação de uma determinada falha, e a frequência e relação entre alarmes, disponibilizadas aos operadores podem colaborar significativamente para a redução do tempo necessário para o diagnóstico e a posterior resolução desta falha. Além de contribuir significativamente para reduzir as perdas operacionais e aumentar a confiabilidade geral do sistema BOP.

Esta dissertação está organizada da seguinte forma: o capítulo 2 introduz os com-

ponentes que compõem o sistema de prevenção de explosão submarino (BOP); o capítulo 3 expõe o referencial teórico utilizado nesse trabalho; o Capítulo 4 apresenta a proposta da metodologia para a detecção e identificação de falhas e no Capítulo 5 a metodologia proposta é aplicado a dados reais e dados simulados.

Capítulo 2

Sistema BOP

Este capítulo apresenta uma visão geral dos componentes principais que constituem o Sistema Preventor de Explosão Submarino (*Blow Out Preventer* - BOP), e têm o intuito de fornecer uma noção básica de suas principais funções e modo de funcionamento.

O sistema BOP é formado basicamente por um conjunto de válvulas instaladas em forma de pilha (*stack*), responsáveis por controlar e monitorar os fluxos de hidrocarbonetos nos poços de petróleo e gás (PETROMIN, 2011). O BOP é projetado de forma a fechar completamente o poço de petróleo e permitir que o poço seja controlado através da circulação de fluídos (SILVA, 2002). Para isto, são utilizados diversos tipos de válvulas de grande porte e dispositivos mecânicos, hidráulicos, pneumáticos e elétricos, mantendo ligação direta do poço com a plataforma de perfuração. O conjunto completo de válvulas é mostrado na Figura 2.1



Figura 2.1: Arranjo completo do BOP Stack (GE/HYDRIL, 2013)

O sistema BOP basicamente possui três grandes blocos: painéis de controle de superfície, LMRP (*Low Marine Riser Packadge*) e BOP *Stack*. Cada grupo possui um grande número de componentes associados a eles, os quais serão abordados nas próximas seções.

O sistema de controle submarino do BOP opera através de dois módulos localizados na parte superior do BOP (LMRP), denominados *PODs* de controle azul e amarelo. Os *PODs* são independentes para prover redundância ao sistema e portanto, uma maior confiabilidade. A Figura 2.2 mostra a localização dos *PODs* de controle do BOP.




Figura 2.2: Localização dos PODs de controle (GE/HYDRIL, 2013)

Historicamente, existem três tipos de sistemas de controle para o BOP, são eles:

1. **Hidráulico:** os sistemas de BOP hidráulicos possuem controle e acionamento hidráulico. Neste tipo de sistema, as altas pressões necessárias para acionamento das válvulas do BOP são enviadas diretamente da plataforma de perfuração para cada válvula. Este tipo de sistema é atualmente utilizado somente em plataformas terrestres. Seu uso em plataformas submarinas possui grandes limitações técnicas que inviabilizam sua utilização.
2. **Eletro-hidráulico:** nos sistemas de BOP eletro-hidráulicos o acionamento das funções é realizado por meio de painéis elétricos e válvulas especiais denominadas solenoides, ambos localizados na superfície. Uma vez que estas válvulas solenoides estejam energizadas, uma pressão hidráulica piloto ou de comando é enviada para comandar a válvula principal de acionamento da função. A Figura 2.3 mostra este tipo de sistema.

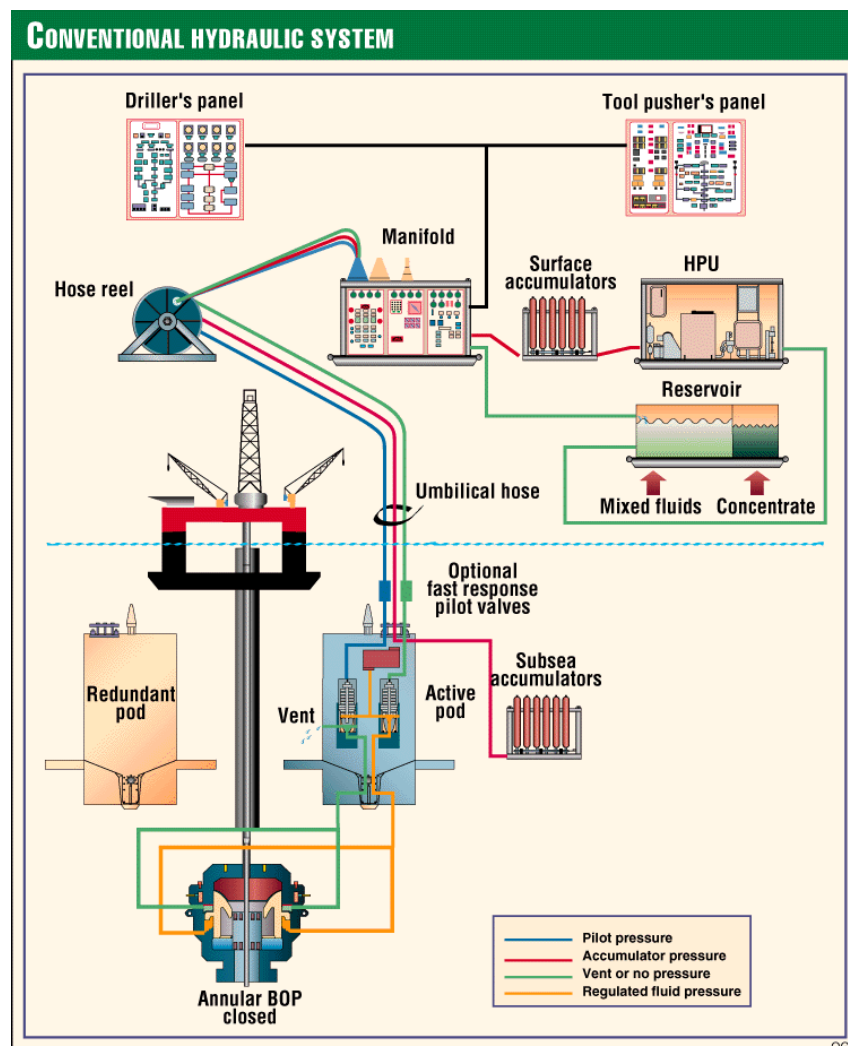


Figura 2.3: Sistema de controle Eletro-hidráulico (GE/HYDRIL, 2013)

3. **Multiplexados:** este é o tipo de controle mais moderno, onde o tempo de acionamento da função é minimizado, uma vez que todo acionamento é realizado através de sinais elétricos provenientes da superfície. Este tipo de sistema necessita apenas de dois cabos elétricos para enviar todos os sinais de função ao BOP. Os sinais elétricos são codificados e enviados ao sistema submarino do BOP que opera a função selecionada. Este tipo de sistema de controle também permite que várias variáveis sejam monitoradas através de sensores, que podem ser utilizados como ferramenta para verificar a operacionalidade do equipamento. Na Figura 2.4 é mostrado o sistema de controle multiplexado que será o objeto de estudo neste trabalho.

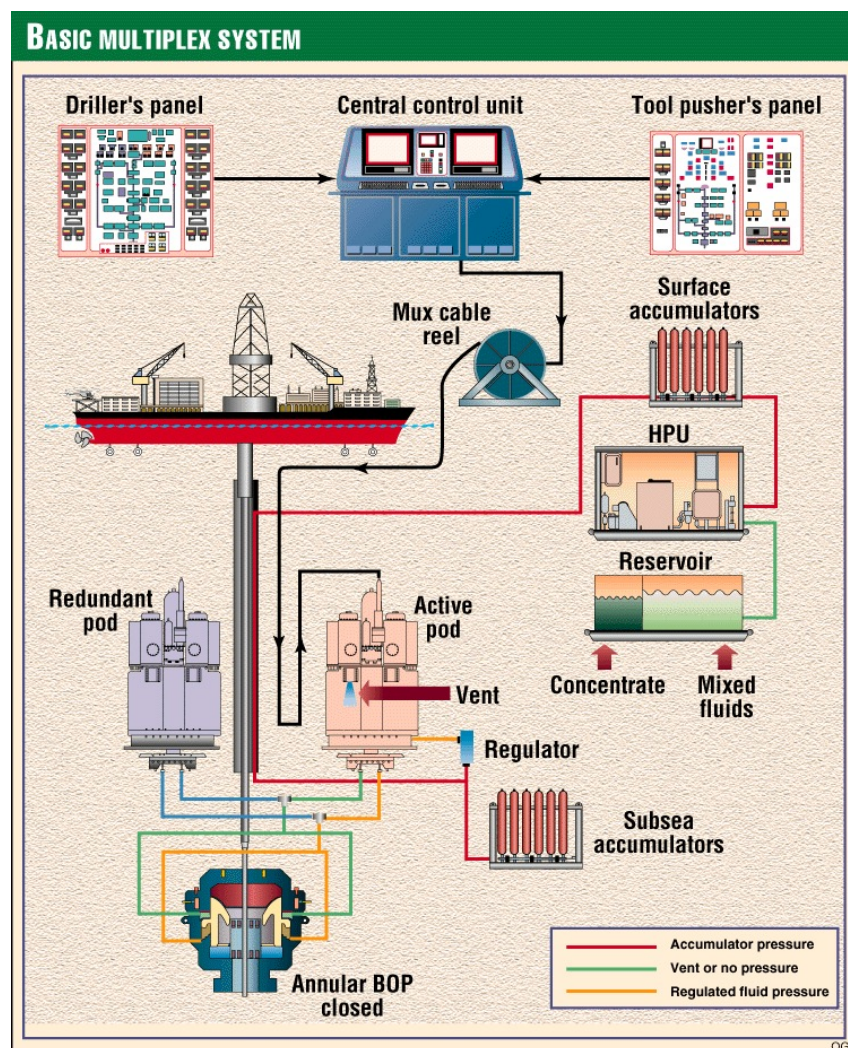


Figura 2.4: Sistema de controle Eletro-hidráulico (GE/HYDRIL, 2013)

Nos BOP modernos multiplexados, por causa de sua complexidade, diversos componentes de *hardware* e *software* podem apresentar problemas. Por esta razão tais sistemas possuem diversos sensores, que monitoram inúmeras variáveis e, por consequência, geram uma enorme massa de dados, para permitir a verificação do funcionamento correto do

sistema.

O controle operacional do BOP é realizado através de painéis de controle, também denominados MMI (*Man Machine Interface*). Nesses painéis todas as funções do equipamento são dispostas graficamente e acessadas através do toque nas telas de controle. Qualquer operação do sistema é individualmente gravada em um histórico de dados, para que, caso necessário, estas informações sejam posteriormente analisadas em busca de falhas operacionais ou de falha no sistema. A Figura 2.5 mostra um sistema de BOP completo, incluindo o sistema de controle de superfície e a parte submersa de acionamento eletro-hidráulico.

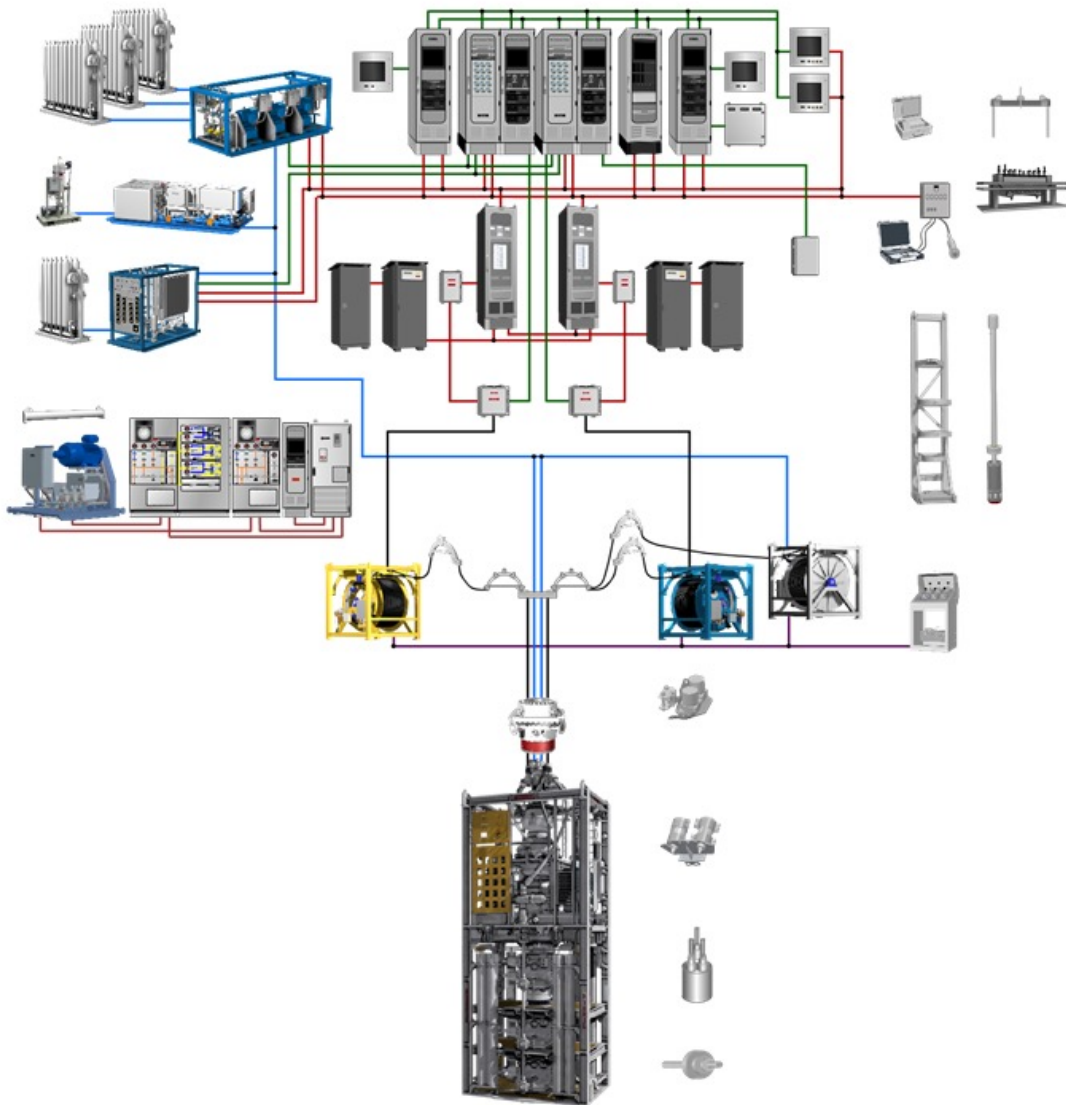


Figura 2.5: Sistema de BOP (GE/HYDRIL, 2013)

2.1 Painéis de controle de superfície

Estes painéis são utilizados para controlar remotamente as funções do BOP. Os painéis de superfícies são mostrados na Figura 2.6. De acordo com a norma API16D (A.P.I Spec, 2004), tais painéis devem estar localizados em pontos específicos da plataforma, para garantir a completa redundância e controle do BOP mesmo em situações de sinistro. A localização do painel define sua nomenclatura. Os principais painéis do sistema de BOP são:

1. Painel do sondador (*Driller's Panel*): localizado na sala de controle de perfuração. Devido a sua localização, este é o painel principal de operação do BOP.
2. Painel do supervisor de perfuração (*Toolpusher Panel*): localizado na sala do supervisor de perfuração ou em outra parte da plataforma diferente da sala de controle de perfuração.
3. Painéis principais de controle (*CCU Panels*): assim como os PODs de controle, existem os conjuntos de painéis azul e amarelo. Estes painéis são responsáveis por gerenciar todo o controle e comunicação entre os demais painéis de controle e os PODs de controle submarino. Todas as informações enviadas e provenientes do BOP trafegam através destes painéis. Com o propósito de garantir total redundância, cada conjunto de painéis de controle deve ser instalado em sala separada sem nenhuma ligação uma com a outra.



Figura 2.6: Painéis de controle de superfície (GE/HYDRIL, 2013)

2.2 POD de controle

Como citado anteriormente cada sistema de BOP possui para efeito de redundância, dois PODs de controle: um azul e outro amarelo. Os PODs de controle estão localizados na LMRP como mostrado na Figura 2.2. Eles têm como objetivo principal receber as informações do sistema de controle de superfície, processar e executar as funções definidas pelo operador. Para isso, os PODs de controle possuem uma eletrônica altamente complexa embarcada. Cada POD de controle possui também um conjunto de sensores utilizados para monitorar importantes variáveis do sistema de BOP, tais como: pressão de suprimento do sistema, pressão de atuação das funções, temperatura dos fluidos, parâmetros elétricos, etc. A Figura 2.7 mostra um POD de controle comercial.



Figura 2.7: POD de controle submarino (GE/HYDRIL, 2013)

2.3 BOP Stack

O BOP *Stack* é formado basicamente pelos preventores, que são os elementos selantes do sistema BOP projetados para fechar o poço ou *wellbore*. A quantidade, tamanho e

modelo de cada preventor dependerá exclusivamente das características de profundidade e pressão das formações geológicas do poço de petróleo. Existem basicamente dois tipos de preventores: os anulares e os de gaveta.

2.3.1 Preventor anular

O preventor anular pode ser visto na Figura 2.8, é constituído basicamente por uma válvula que permite o fechamento do poço mesmo na existência de uma coluna de perfuração com diferentes diâmetros que passam através dele. A pressão aplicada na câmara de fechamento (*closing chamber*) desloca o pistão para cima, que por sua vez força o elemento vedante de borracha (*packer*) ao redor do tubo, selando a cavidade do poço. Quando aplicada uma pressão na câmara de abertura (*opening chamber*) o pistão de acionamento é movido para baixo abrindo o elemento de vedação. Nos BOPs multiplexados, ambas pressão de fechamento e de abertura são monitoradas através de sensores de pressão instalados na linha hidráulica correspondente. A pressão de trabalho deste preventor é geralmente 1500 psi (SILVA, 2002).




Figura 2.8: Preventor Anular (GE/HYDRIL, 2013)

2.3.2 Preventor de gaveta (*RAM*)

A Figura 2.9 mostra um arranjo de preventores de gaveta (*RAM*). Este tipo de preventor pode ser encontrado em diferentes arranjos. Os mais comuns são módulos com uma, duas

ou três gavetas.




Figura 2.9: Arranjo do preventor de gaveta (GE/HYDRIL, 2013)

Existem três tipos principais de gavetas: vazada (*pipe RAM*), cega (*blind RAM*), cega cisalhante (*blind-shear RAM*) e cisalhante (*casing shear RAM*).

A gaveta vazada, também conhecida como gavetas de tubo, permite que o fechamento do poço ocorra ao redor da coluna de perfuração. A superfície de vedação destes preventores podem possuir diâmetro fixo ou variável, dependendo da utilização proposta. Este tipo de preventor de gaveta suporta pressão em torno de 15000 psi no sentido de baixo para cima. Devido ao seu projeto, também é capaz de segurar uma grande carga de peso no sentido de cima para baixo. A Figura 2.10 mostra a gaveta de tubo com diâmetro fixo. Já a Figura 2.11 mostra uma gaveta de tubo com diâmetro variável.



Figura 2.10: Gaveta de tubo com diâmetro fixo (MALOUF, 2013)



Figura 2.11: Gaveta de tubo com diâmetro variável (MALOUF, 2013)

A gaveta cega é mostrada na Figura 2.12, e tem por objetivo fechar e selar o poço apenas, uma vez que ela não é capaz de cortar a coluna de perfuração. Este tipo de preventor é capaz de suportar pressões da ordem de 15000 psi provenientes do poço de petróleo.



Figura 2.12: Gaveta cega (MALOUF, 2013)

Já a gaveta cega-cisalhante mostrada na Figura 2.13 pode fechar e selar o poço e também executar o corte na coluna de perfuração.




Figura 2.13: Gaveta cega cisalhante (MALOUF, 2013)

Na Figura 2.14 pode-se observar a sequência de acionamento da gaveta cega cisalhante, onde o tubo de perfuração é cortado e o poço por sua vez completamente fechado e selado.




Figura 2.14: Sequência de acionamento da gaveta cega cisalhante (GE/HYDRIL, 2013)

A gaveta cisalhante é utilizada quando se deseja cortar o revestimento de poço durante sua instalação. Este tipo de gaveta possui uma capacidade de corte maior que a gaveta cega de corte, mas não possui a capacidade de cortar a coluna de perfuração. Ela é utilizada especificamente, quando durante uma emergência ou eminência de um *kick*, existe um tubo de revestimento passando através do BOP. Este tipo de preventor de gaveta é mostrado na Figura 2.15.



Figura 2.15: Gaveta cisalhante para corte de revestimento (GE/HYDRIL, 2013)

Capítulo 3

Referencial Teórico

Este capítulo apresenta os trabalhos relacionados a performance e confiabilidade de sistemas BOP e uma revisão teórica acerca das medidas e ferramentas estatísticas utilizadas na preparação dos dados. Além disso, descreve alguns algoritmos e métodos de detecção e identificação de falhas encontrados na literatura.

3.1 Trabalhos relacionados

Um dos primeiros estudos sobre performance e confiabilidade dos sistemas de *blow out preventer* é apresentado por [Holand e Rausand \(1987\)](#). Os autores computaram as falhas ocorridas nos sistemas BOP e de seus componentes na Noruega em um período de 11 anos. Os dados coletados foram utilizados para o cálculo da taxa de falha, dada pelo número de falhas dividido pelo tempo total em serviço. Seus resultados demonstraram que a confiabilidade do sistema de BOP melhorou significativamente durante os últimos anos. Mas, que políticas de manutenção e treinamento precisam ser desenvolvidas e implementadas de maneira eficaz para a melhoria da confiabilidade e eficiência operacional.

As manutenções e políticas de inspeções regulares são fundamentais para o aumento da confiabilidade do sistema ([JORGE et al., 2001](#)). Estes autores avaliaram a confiabilidade dos sistemas de BOP, por meio da análise de um grande conjunto de dados relativos ao seu desempenho e confiabilidade. Para tal, calcularam o tempo médio para falha (MTTF), estimou o tempo T em que a falha ocorre e o número de total de falhas (Nf), para os componentes do BOP.

[He et al. \(2014\)](#) discorrem sobre o desenvolvimento de uma metodologia de análise de riscos para o BOP, baseado no modelo de Análise dos Modos e Efeitos de Falha (FMEA) e árvore de falhas, com o objetivo de gerar uma metodologia de decisão para as compa-

nhas petrolíferas, operadores e agências reguladoras governamentais. Esta metodologia é utilizada para garantir que a melhor decisão seja tomada durante uma falha ou evento atípico, ou mesmo se as operações devam ser temporariamente suspensas ou não de acordo com a criticidade do evento. Estes autores afirmam que os padrões utilizados pelos modelos FMEA e árvore falhas são definidos antes do início das operações, pois caso durante as operações, algum evento viole estes padrões, o modelo é capaz de identificar esta violação e indicar a melhor tratativa para o caso.

Cai et al. (2013) analisam a confiabilidade dos programas de controle do BOP através de redes Bayesianas. A probabilidade de falha no software é realizada via análise progressiva (*forward analysis*), e a análise da probabilidade do que tais falhas podem acarretar é realizada através de análise de erro regressivo (*Backward analysis*).

Uma análise de arquivos de dados proveniente de um sistema de informação utilizando métodos de mineração de dados e organização das informações é demonstrado por Mihut (2008), que identifica como a utilização das técnicas de mineração de dados auxiliam de maneira eficiente na extração de informações relevantes de um grande volume de dados e que se tais técnicas não fossem utilizadas, uma grande parte das informações relevantes seriam descartadas.

Yairi et al. (2006) apresentam o uso da mineração de dados aplicada a dados de telemetria de uma nave espacial com o intuito de detectar falhas e anomalias no sistema. Neste artigo é realizada uma comparação entre os métodos tradicionais e aqueles utilizando o aprendizado de máquina e mineração de dados. O ponto chave de sua proposta é maximizar a utilização de dados passados, objetivando a geração de modelos de comportamento para o sistema. Modelos estes, que podem ser utilizados para a detecção de falhas e anomalias do sistema.

Silva (2002) descreve os componentes do sistema BOP que contribuem significativamente nas falhas e conseqüentemente *downtime* no sistema BOP. Este trabalho contempla a análise de confiabilidade obtida a partir de boletins de operação, expressando assim as condições reais de operação. Também subdivide o sistema em 10 componentes principais e avalia a confiabilidade de cada um deles separadamente utilizando a Análise dos Modos e Efeitos de falha (FMEA - *Failure Mode Effects and Analysis*). Investiga o efeito da profundidade de operação na confiabilidade do sistema BOP e correlaciona estas informações com outros trabalhos e publicações da área.

Processos e métodos para o controle de qualidade estatístico da análise de dados multivariados, dentre elas a Análise de Componentes Principais, são descritos por Mac-

Gregor e Kourti (1995). Esses autores apresentam as Cartas de Controle estatístico, tais como: a estatística Q ou *Square Prediction Error* (SPE) e a estatística T^2 de Hotelling, como metodologias eficazes na verificação da qualidade e detecção de problemas nos dados.

A aplicação da Análise de Componentes Principais (ACP) para a detecção e identificação de falhas em sensores é descrita por Dunia et al. (1996). Nesse artigo é proposto um modelo para a obtenção do Índice de Validação do Sensor (SVI), baseado no valor do *Square Prediction Error*, com o objetivo de detectar a falha e identificar o sensor responsável pela mesma.

Segundo Liu et al. (2005) vários métodos estatísticos multivariados são amplamente utilizados em processos industriais. Dentre eles, a Análise de Componentes Principais (ACP) é um dos métodos mais populares. A ACP é particularmente eficiente na detecção de mudanças no ponto de operação, quebra de sensores e falhas e distúrbios em um determinado processo.

Fu (2004) utiliza o método ACP, a estatística Q e a estatística T^2 de Hotelling na detecção de falhas e na identificação de sensores defeituosos em sistemas de ar condicionado industriais (HVAC). O objetivo deste autor foi demonstrar a utilização das Cartas de Controle para a detecção e identificação de falhas, com o objetivo de reduzir os custos de operação e aumentar a confiabilidade geral do sistema.

Através da aplicação do método ACP, Silva (2008) desenvolve uma metodologia de diagnóstico de falhas em rolamentos de motores elétricos de indução, através da análise dos sinais elétricos e de sensoriamento. Demonstra na prática a utilização do modelo desenvolvido na detecção da variância relacionada diretamente à falha apresentada.

3.2 Detecção e identificação de falhas

Existem diversos trabalhos na área de detecção, isolamento e diagnóstico de falha no setor industrial. Isermann e Ballé (1997) e Chiang et al. (2001) resumem a terminologia utilizada nesta área, sendo esta a terminologia utilizada neste trabalho:

- Detecção de falhas: determinação das falhas presentes em um sistema e o instante de tempo da ocorrência;
- Identificação de falhas: determinação dos agentes que contribuem para a ocorrência da falha.

- Diagnóstico de falhas: através da análise das informações da detecção e identificação de falhas determinar a extensão da falha no sistema e como realizar a intervenção.
- Intervenção: este é um passo fundamental para que o ciclo do monitoramento de um determinado processo após a detecção de uma falha seja finalizado. Nesta etapa o efeito da falha é removido por meio da ação sobre a variável em falha, por exemplo, troca de sensor, reparo, etc.

Na Figura 3.1 é mostrado o ciclo de monitoramento de um determinado processo. Destaca-se que sempre que uma falha é detectada, as etapas de identificação, diagnóstico e intervenção são aplicadas em sequência; caso contrário, somente a etapa de detecção da falha é repetida. [Chiang et al. \(2001\)](#) defendem que não há necessidade de automatizar todas as etapas do processo, pois é fundamental incorporar os operadores no processo de monitoramento, em vez de automatizar todas etapas de monitoramento completamente. Isso é necessário para que os operadores tomem as devidas ações de contingência de acordo com a severidade da falha. Por exemplo, a automatização da detecção e identificação de uma falha auxilia os operadores no processo do diagnóstico desta falha, dando-lhes subsídios para realizar a intervenção necessária para que o sistema retorne a seu pleno funcionamento.




Figura 3.1: Ciclo de monitoramento de um processo ([CHIANG et al., 2001](#))

Nenhum dos métodos de diagnóstico pode ser considerado infalível, cada um apresenta vantagens e desvantagens uns em relação aos outros. Logo, nenhum método isoladamente é ideal para todas as aplicações. Como exposto por [Chiang et al. \(2001\)](#), um bom sistema de diagnóstico é formado por múltiplos métodos, sendo denominados de sistemas híbridos. Ou seja, os sistemas se complementam, resultando em um sistema de diagnóstico mais eficiente ([VENKATASUBRAMANIAN, 2003](#)).

O conhecimento prévio do processo é necessário para que o modelo obtenha o resultado esperado. Este conhecimento pode ser profundo, casual ou baseado em modelo ([MILNE, 1987](#)), adquirido a partir de experiências passadas com o processo.

Existem diferentes formas pelas quais os dados provenientes do processo podem ser transformados e apresentados como conhecimento prévio para o sistema de diagnóstico, com o objetivo de facilitar o diagnóstico de falhas. A Figura 3.2 mostra as diferentes técnicas e métodos de diagnóstico utilizadas.

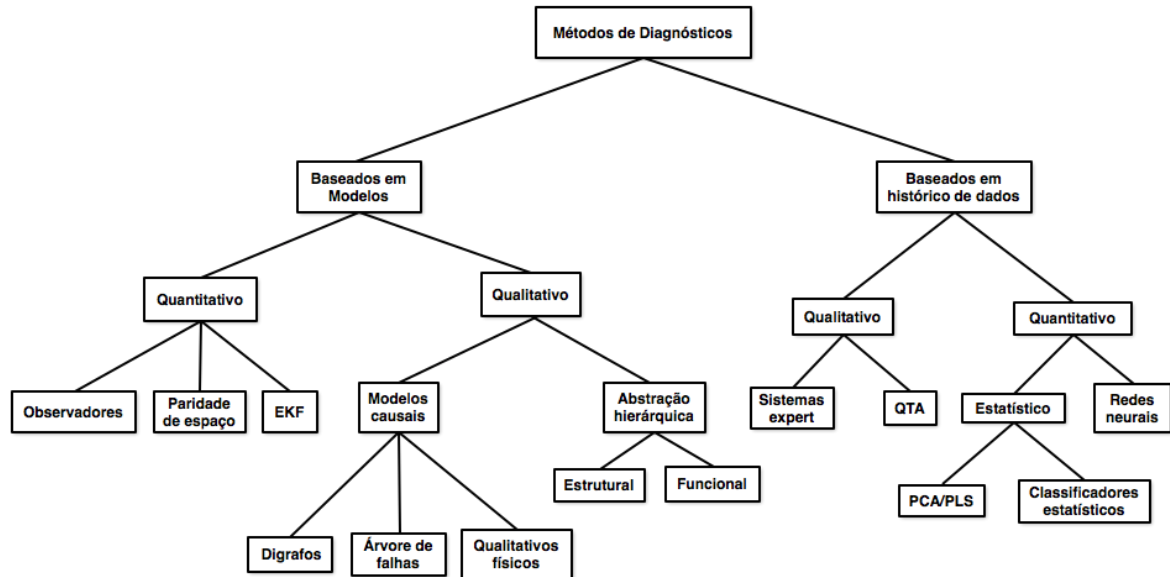


Figura 3.2: Classificação dos algoritmos de diagnóstico - Adaptado de Venkatasubramanian (2003)

Os métodos de diagnóstico baseados em modelos, podem ser subdivididos em duas categorias: modelos qualitativos e modelos quantitativos. Nos modelos qualitativos, o processo é descrito em termos de funções matemáticas relacionadas entre as entradas e saídas do processo. Por sua vez, os modelos qualitativos são relacionados em termos de funções qualitativas centradas em diferentes fases do processo.

Em contraste aos métodos baseados em modelos, onde o conhecimento anterior e modelagem do processo são necessários, os métodos de diagnóstico baseado em histórico de dados do processo, necessitam apenas de uma grande quantidade de dados histórico do processo, neste caso, utilizando-se várias técnicas distintas, é possível extrair e apresentar informações sobre o comportamento do processo.

De forma análoga aos métodos baseados em modelos, os métodos baseados em histórico de dados do processo podem também ser divididos em duas categorias: qualitativos e quantitativos. Os métodos qualitativos são baseados em sistemas especialistas e envolvem um mapeamento explícito dos sintomas conhecidos para as raízes causais. Já os métodos quantitativos podem empregar técnicas computacionais como as redes neurais

ou técnicas estatísticas, como por exemplo a Análise de Componentes Principais (VENKATASUBRAMANIAN, 2003).

No presente trabalho será utilizado o método de diagnóstico baseado em histórico de dados quantitativo; utilizando ferramentas estatísticas na definição de uma metodologia de detecção e identificação de falhas.

Venkatasubramanian (2003) realiza um estudo profundo sobre os métodos de detecção e identificação de falhas baseados em histórico de dados. Neste estudo é apresentado que métodos como a Análise de Componentes Principais e Rede Neurais são extensivamente descritos na literatura como métodos eficazes de diagnósticos. Também demonstra que ambos, a Análise de Componentes Principais e Redes Neurais possuem exatamente a mesma eficiência como métodos de diagnóstico de falhas.

Convém ressaltar que, nesta dissertação foi selecionado a Análise de Componentes Principais (ACP) como método primário em virtude de sua facilidade de implementação e eficiência comprovada.

Nas Seção 3.3 são apresentadas as ferramentas estatísticas empregadas na metodologia proposta neste trabalho.

3.3 Medidas e ferramentas de análises estatísticas

Esta seção descreve algumas medidas e ferramentas de análise estatística que serão consideradas e aplicadas neste trabalho, na preparação e limpeza dos dados, e também na detecção e identificação de falhas.

3.3.1 Coeficiente de variação

O coeficiente de variação (CV) é uma medida de dispersão empregada para estimar a precisão de experimentos. A principal vantagem do CV é a capacidade de comparar diferentes resultados que envolvem a mesma variável-resposta, permitindo quantificar a precisão das pesquisas (GARCIA, 1989).

O coeficiente de variação é igual ao desvio-padrão dividido pela média, como demonstra a Equação 3.1. O coeficiente de variação pode ainda ser expressado como per-

centagem.

$$CV = \left(\frac{S}{\bar{X}} \right) \times 100 \quad (3.1)$$

Onde,

S : desvio padrão do conjunto de dados

\bar{X} : média do conjunto de dados

O CV é útil para a compreensão em termos relativos do grau de dispersão dos dados em torno da média (REIS, 1991). É importante notar que o Coeficiente de Variação pode ser expresso em porcentagem porque é adimensional, isto é, não tem unidade de medida.

Segundo Garcia (1989), o CV é amplamente utilizado por pesquisadores que trabalham com o mesmo fenômeno, para avaliar a precisão de cada um dos seus experimentos. Através de experimentos Gomes (1990) inferiu a faixa de valores para o coeficiente de variação, como mostrado na Tabela 3.1.

$CV \leq 0,1$	Dados ótimos (baixa dispersão)
$0,1 < CV \leq 0,2$	Dados bons (média dispersão)
$0,2 < CV \leq 0,3$	Dados ruins (alta dispersão)
$CV > 0,3$	Dados péssimos (descartar)

Tabela 3.1: Valores do coeficiente de variação

Neste trabalho o CV será utilizado durante a fase de preparação dos dados para aferir a qualidade do histórico de dados que será utilizado.

3.3.2 Detecção de outliers

Pyle (1999), Tabachnick e Fidell (2007) definem *outlier* (extremo), distante da maior parte dos valores da variável estudada. Cabe ressaltar que, dependendo dos seus valores, os *outliers* podem distorcer o restante do conjunto de dados ao ponto de torna-lo sem utilidade.

De acordo com Kabacoff (2011) o fato de se identificar e remover os *outliers*, pode melhorar significativamente a qualidade do conjunto de dados sob análise. Existem basicamente dois métodos de identificação de *outliers*: gráfica e testes de hipótese.

O método gráfico será utilizado neste trabalho para detecção de *outliers*. Mas, existem diferentes testes de hipótese para detecção de *outliers*, tais como: Teste de Grubbs; Teste de Dixon(Q); Teste de Chauvenet e Teste de Cochran.

O método gráfico utilizado aqui será o *Boxplot*. O gráfico *Boxplot* representa a distribuição dos valores de uma variável. Uma caixa representa a maior parte da distribuição, e as extensões denominadas bigodes, atingem os pontos extremos da distribuição (HAIR et al., 2005). Destaca-se que o *Boxplot* é utilizado para avaliar a distribuição dos conjunto de dados de forma empírica, ou seja, não é utilizado teste de hipótese para avaliar a distribuição. O gráfico *Boxplot* é mostrado na Figura 3.3.




Figura 3.3: Gráfico *Boxplot* (O Autor)

O *Boxplot* exibe o valor mínimo a (que não seja um *outlier*), o primeiro quartil (Q1), a mediana ou segundo quartil (Q2), o terceiro quartil (Q3), o valor máximo b (que não seja um *outlier*) e os valores extremos (*outliers*). As hastes inferiores e superiores se estendem, respectivamente, do primeiro quartil até o menor valor que não seja um *outlier* e do terceiro quartil até o valor máximo que não seja um *outlier*. Os limites inferiores e superiores são calculados pelas Equações 3.2 e 3.3 respectivamente:

$$LI = \text{Limite inferior: } \max\{\min(\text{dados}); Q_1 - 1,5(Q_3 - Q_1)\} \quad (3.2)$$

$$LS = \text{Limite superior: } \min\{\max(\text{dados}); Q_3 + 1,5(Q_3 - Q_1)\} \quad (3.3)$$

Como os *outliers* podem afetar os resultados finais da análise estatística (MINGOTI, 2005), o *Boxplot* é utilizado durante a fase de preparação dos dados, com o objetivo de identificar e eliminar os *outliers* do conjunto de dados sob análise.

3.3.3 Análise de Componentes Principais - ACP

A análise multivariada é um arranjo de técnicas que utilizam, simultaneamente, todas as variáveis na interpretação do conjunto de dados obtidos (VICINI, 2005). Hair et al. (2005) definem a Análise de Componentes Principais como uma abordagem estatística que pode ser utilizada para analisar inter-relações entre um grande número de variáveis em termos de suas dimensões inerentes comuns (fatores), além de fornecerem uma estimativa empírica da estrutura das variáveis consideradas. Isso significa que a ACP identifica um número menor de novas variáveis alternativas, não correlacionadas e que, de algum modo, resumem as informações principais das variáveis originais encontrando os fatores ou variáveis latentes (MINGOTI, 2005).

A Análise de Componentes Principais tem sido aplicada largamente em indústrias, governos e em centros de pesquisas acadêmicas de diversas áreas como psicologia, educação, medicina, geologia, ciências sociais, engenharias e ergonomia. Lira et al. (2015) conclui que a Análise de Componentes Principais, possui grande aplicação na engenharia, pois fornece uma maior clareza na interpretação dos fenômenos complexos com que a mesma lida.

De acordo com Vicini (2005), o objetivo da ACP é descrever os dados contidos em grande conjunto de dados através das variáveis mais significativas (componentes principais). A ACP é considerada um método fatorial, pois a redução do número de variáveis não se faz por uma simples seleção de algumas variáveis, mas pela construção de novas variáveis sintéticas, obtidas pela combinação linear das variáveis iniciais, por meio dos fatores.

A ACP é uma técnica que consiste em se reduzir o espaço amostral, transformando os sinais (variáveis) correlacionados em um novo conjunto de dados onde se mantém a maior parte da variância original (VILLEGAS et al., 2010). A técnica desacopla o espaço amostral do vetor X em um novo conjunto de variáveis não correlacionadas que correspondem aos elementos do vetor Y . O j -ésimo componente principal pode ser obtido pela Equação 3.4 (JOHNSON; WICHERN, 2007):

$$Y_j = e_j'X = e_{j1}X_1 + e_{j2}X_2 + \dots + e_{jp}X_p \quad (3.4)$$

Onde,

Y_j é denominado *score*.

e_j é a j -ésima componente principal da matriz de amostras X normalizada pela média e desvio padrão.

Os elementos do autovetor e_j funcionam como pesos de importância de X_1, \dots, X_p na composição do j -ésimo componente principal Y_j , e são denominados cargas (*loadings*), e são obtidos através da decomposição em valores singulares da matriz de covariância amostral S dos dados de treinamento, calculada através da Equação 3.5 (BEZERGIANNI; KALOGIANNI, 2008)).

$$S = \frac{1}{n-1} X'X = V\Lambda V^{-1} \quad (3.5)$$

onde, X é uma matriz de amostras com várias ocorrências de x , e de acordo com Chiang et al. (2001), a matriz diagonal $\Lambda \in R^{m \times n}$ contém os autovalores da matriz S , reais e positivos em ordem decrescente da magnitude ao longo de sua diagonal ($\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_m$). A variância explicada pelo autovetor correspondente a i -ésima coluna da matriz V é igual a λ_i , por sua vez $\lambda_i = \sigma_i^2$ (VILLEGAS et al., 2010), onde σ_i é o desvio padrão descrito pelo vetor correspondente a i -ésima coluna de V .

Um exemplo na aplicação da ACP na detecção de falhas e o trabalho de Bezergianni e Kalogianni (2008), que afirmam que a correta escolha dos dados de treinamento é fundamental para o processo, uma vez que devem reproduzir a variabilidade natural dos dados. O conjunto de dados de treinamento é constituído por um espaço amostral, onde se considera que as variáveis possuem valores normais, dentro de sua faixa de operação, ou seja, sem apresentar falha. Outro passo fundamental é o tratamento adequado dos dados antes da aplicação da ACP, como a normalização pelo desvio padrão e média (Equação 3.6), é importante para garantir que tendências e diferentes escalas de medição, não interfiram no cálculo dos componentes principais (CHIANG et al., 2001).

$$Z = \frac{X - \mu}{\sigma} \quad (3.6)$$

Onde,

μ : média do conjunto de dados

σ : desvio padrão do conjunto de dados

A matriz de carga (*loading matrix*) $P \in R^{m \times a}$ é formada pelos a autovetores associados ao maiores autovalores da matriz de covariância amostral S , que explicam a

variabilidade dos dados de treinamento. As projeções do espaço amostral X em um espaço de menor dimensão estão contidas na matriz de *scores* T e a projeção reversa de T no espaço de observação, está contida na matriz \hat{X} .

$$T = XP \quad (3.7)$$

$$\hat{X} = TP^T \quad (3.8)$$

Um passo primordial do método ACP está na escolha do número de componentes principais contidos na matriz P , que serão utilizados para expressar a maior variância dos dados. [Chiang et al. \(2001\)](#) apresentam quatro critérios para a escolha do número de componentes principais:

- Percentual total da variância: determina o menor número de componentes principais necessários para explicar uma variância total da ordem de 90% a 95%;
- *Scree test*: assume que a variância, σ_i^2 , correspondente a um ruído branco com perfil linear. O número de autovetores selecionados a , é determinado pela localização do vetor de σ_i^2 que não é mais linear;
- Análise paralela: determina o número de dimensões do espaço de *scores*, comparando o perfil da variância com o de variáveis independentes. A redução da ordem é determinada pelo ponto, onde o perfil das duas variâncias, matriz Λ e variáveis independentes se cruzam.
- Validação cruzada: utiliza o valor residual previsto para a soma dos quadrados

$$PRESS(i) = \frac{1}{mn} \|X - \hat{X}\|_F^2 \quad (3.9)$$

onde, i é o número de autovetores mantidos para calcular \hat{X} e $\|\cdot\|_F^2$ é a norma Frobenius. Para a implantação deste tipo de critério, os dados de treinamento devem ser divididos em grupos, pois a estatística *PRESS* é calculada para várias dimensões do espaço de *scores* (i) para cada grupo separadamente.

Pode-se resumir o procedimento para aplicação da ferramenta ACP, e obtenção dos componentes principais nos seguintes passos:

- (a) Organizar os dados em uma matriz de amostras X , onde cada coluna (p) representa uma variável a ser monitorada e cada linha (k) uma ocorrência de medição das variáveis. Isto é;

$$X = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1p} \\ X_{21} & X_{22} & \dots & X_{2p} \\ \vdots & \vdots & \vdots & \vdots \\ X_{k1} & X_{k2} & \dots & X_{kp} \end{pmatrix}$$

- (b) Normalizar cada variável, subtraindo a média e dividindo pelo desvio padrão amostral de cada variável (Equação 3.6);
- (c) Calcular a matriz de covariância amostral S (Equação 3.5);
- (d) Reduzir as dimensões dos dados através da escolha dos autovalores que representam a variabilidade requerida, através da utilização de um dos critérios descritos anteriormente. No caso deste trabalho, será utilizado o percentual total da variância como critério para a escolha do número de componentes principais, em virtude de sua efetividade e fácil implementação computacional.

No presente trabalho, a ACP será utilizada para reduzir o conjunto de dados (número de variáveis estudadas) e fornecer as informações para aplicação das Cartas de Controle estatístico, descritas nas Subseções 3.3.4 à 3.3.6

3.3.4 Cartas de controle estatístico

O Controle Estatístico de Processos (CEP) é um conjunto de técnicas estatísticas utilizadas para avaliação de um processo, com o objetivo de controle e melhoria de sua qualidade (MONTGOMERY, 2009). Nesse contexto, esse autor afirma que as Cartas de Controle são uma das principais técnicas de CEP existentes e tem como objetivo detectar desvios de parâmetros do processo e mostrar a variabilidade do processo em função do tempo ou do número de amostras.

As Cartas de Controle basicamente consistem em um gráfico formado por: uma linha central (CL), um limite inferior de controle (LCL) e um limite de controle superior (UCL). Caso todos os valores estejam localizados dentro dos limites de controle (superior e inferior) ou apresentam comportamento aleatório, indica que o processo está sobre controle, e não existem fontes de variabilidade anormal nos dados (MONTGOMERY, 2009). Contudo, caso existam valores que extrapolem os limites de controle ou compor-

tamento padrão, o processo é considerado fora de controle para tais valores e a fonte de variabilidade deve ser analisada. Uma típica Carta de Controle é mostrada na Figura 3.4.

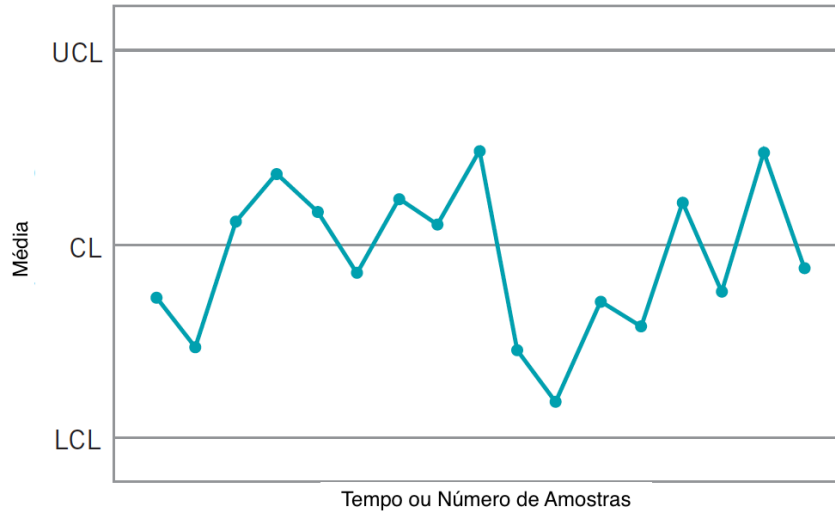


Figura 3.4: Típica carta de controle (MONTGOMERY, 2009)

Existem dois tipos de Carta de Controle em função do número de variáveis. As cartas de controle univariadas monitoram apenas uma variável do processo. Por sua vez, as Cartas de Controle multivariada, monitoram um conjunto de duas ou mais variáveis do processo.

Neste trabalho serão utilizadas Cartas de Controle multivariada baseadas em componentes principais (CCMCP), conforme descrito por Nomikos e MacGregor (1995), Kourti et al. (1995) e Martin et al. (2002). Essas CCMCP utilizam a técnica de ACP descrita na Subseção 3.3.3 para a redução de dimensionalidade dos dados e posteriormente aplicação das Cartas de Controle multivariada T^2 de Hotelling e da estatística Q , descritas respectivamente nas Subseções 3.3.5 e 3.3.6.

3.3.5 Estatística T^2 de Hotelling

A estatística T^2 de Hotelling (HOTELLING, 1933) foi um dos primeiros métodos de controle multivariado. A detecção de falha com o uso da ACP e da estatística T^2 de Hotelling, consiste no cálculo de T^2 de menor dimensão calculado para cada nova amostra x através da Equação 3.10 (CHIANG et al., 2001):

$$T^2 = x' P \Lambda_p^{-1} P' x \quad (3.10)$$

Onde,

p é o número de componentes principais selecionados

x é o vetor com uma amostra

P é a matriz de componentes principais

Λ_p é a matriz de autovalores da decomposição em valores singulares da matriz de covariância S reduzida a dimensão p

A carta de controle de Hotelling tem como métrica a distância estatística entre uma amostra multivariada e a parte central do modelo estatístico dos dados. A estatística T^2 é definida pela distância de Mahalanobis. Em outras palavras, a estatística T^2 é a medida da variação no modelo ACP (HARROU et al., 2015).

A fim de se obter limite superior de controle (UCL) para um determinado intervalo de confiança, cujo o valor é geralmente 95% (JACKSON; MUDHOLKAR, 1979), utiliza-se a distribuição F de Snedecor, conforme mostra a Equação 3.11:

$$T_{\alpha,p,n}^2 = \frac{p(n-1)(n+1)}{n(n-p)} F_{\alpha,p-n,p} \quad (3.11)$$

onde, p é o número de componentes principais, n o número de amostras de dados de treinamento, e α é o nível de significância.

Com isso, temos as seguintes condições para T^2 :

Se $T^2 \geq T_{\alpha,p,n}^2 \implies$ Falha

Se $T^2 < T_{\alpha,p,n}^2 \implies$ Não-falha / condição normal

No escopo deste trabalho, a estatística T^2 de Hotelling é importante, pois ela será utilizada para obtenção de uma medida estatística da distância de cada amostra ao seu valor provável. A partir do intervalo de confiança, esta é uma forma analítica de se verificar pontos extremos nos dados, que eventualmente fujam do padrão estatístico do modelo obtido com a aplicação da ACP. Uma amostra considerada como um ponto extremo pode indicar a ocorrência de uma mudança de operação ou o surgimento de um fator antes não presente no sistema, como uma falha.

3.3.6 Estatística Q

A estatística T^2 trata somente da porção do espaço amostral explicado pelas componentes principais. Entretanto, as falhas muitas vezes afetam primeiramente o espaço residual, explicado pelos autovetores correspondentes aos menores autovalores. De forma a complementar a estatística T^2 , a porção do espaço amostral correspondente aos menores autovalores pode ser monitorada através da estatística Q, que também é conhecida como SPE (*Squared Prediction Error*) definido por [Qin \(2003\)](#).

A estatística Q é uma distância entre a amostra original e sua projeção no modelo ACP obtido, cuja dimensão é reduzida ([DUNIA et al., 1996](#)). Esta distância é uma forma de se avaliar a qualidade do conjunto reduzido obtido, uma vez que durante o processo de redução dimensional há uma perda inerente de informações. Basicamente a estatística Q é a soma do quadrado de cada linha na matriz de resíduos, conforme Equação 3.12 ([CHIANG et al., 2001](#))

$$Q = \|r\|^2 = \|x - \hat{x}\|^2 = \|(I - PP^T)x\|^2 \quad (3.12)$$

onde, r é o vetor de resíduos, ou seja, uma projeção do vetor x no espaço residual e P a matriz de carga (*loading matrix*).

A fórmula para o limite superior de controle (Q_α) para um determinado nível de significância α , é mostrada na Equação 3.13 ([JACKSON; MUDHOLKAR, 1979](#)).

$$Q_\alpha = \theta_1 \left[\frac{c_\alpha \sqrt{\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{\frac{1}{h_0}} \quad (3.13)$$

onde, seus parâmetros são mostrados nas Equações de 3.14 a 3.17:

$$\theta_1 = \sum_{i=k+1}^m l_i \quad (3.14)$$

$$\theta_2 = \sum_{i=k+1}^m l_i^2 \quad (3.15)$$

$$\theta_3 = \sum_{i=k+1}^m l_i^3 \quad (3.16)$$

$$h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2} \quad (3.17)$$

onde, l são os autovalores da matriz de covariância dispostos em ordem decrescente. k é o número de componentes principais, m o número de variáveis. c_α representa uma distribuição normal com um nível de significância α . Normalmente o intervalo de confiança $(1 - \alpha)$ para esta aplicação se encontra entre 95% e 98% (JACKSON; MUDHOLKAR, 1979).

Quando a estatística Q é calculada para um dado vetor de dados, seu valor é comparado com o limite superior de controle (Q_α), e caso este limite de confiança é violado, uma falha é declarada (JACKSON; MUDHOLKAR, 1979). Logo, para os valores de Q_α temos as seguintes condições

Se $Q \geq Q_\alpha \implies$ Falha

Se $Q < Q_\alpha \implies$ Não-falha / condição normal

A estatística Q é normalmente o método preferível em relação a estatística T^2 de Hotelling, para detecção de falhas, pois é mais sensível a detecção de falhas com baixa magnitude (HARROU et al., 2015).

Uma vez calculada a estatística Q , caso alguma variável ultrapassou o limite superior calculado, significa que um distúrbio foi detectado nos dados sob análise. Logo, a contribuição de cada variável pode ser investigada. A contribuição c_{jk}^Q para cada variável j em período de tempo k e dada pela Equação 3.18.

$$c_{jk}^Q = (e_{new,jk})^2 = (x_{new,jk} - \hat{x}_{new,jk})^2 \quad (3.18)$$

onde, $x_{new,jk}$ é o j -ésimo elemento da matriz original, $\hat{x}_{new,jk}$ é parte deste elemento na matriz recomposta pelo modelo ACP, e $e_{new,jk}$ é o valor residual. Para encontrar o período de tempo k e para qual variável o distúrbio ocorreu, utiliza-se a estatística Q . Uma vez identificado o exato momento onde o distúrbio ocorreu, basta construir o gráfico da contribuição c_{jk}^Q para este período em particular, e verificar qual variável mais contribuiu para a variação do Q (WESTERHUIS et al., 2000).

Capítulo 4

Metodologia Proposta

Durante a operação do BOP, a ocorrência de uma falha pode passar despercebida ao operador mesmo quando o sistema gera alarmes relativos a essa falha. Na maioria das vezes os operadores simplesmente ignoram tais alarmes, e somente identificam que algo está errado quando os resultados da falha levam a graves consequências, ou quando o BOP não é aprovado durante a execução dos testes operacionais que ocorrem periodicamente. Quando o BOP não é aprovado nos testes ou algo fora do normal ocorre, a primeira providência é realizar uma análise manual no histórico de dados armazenado pelo sistema para tentar detectar e identificar a falha ocorrida. Tal análise demanda muito tempo e, na maioria dos casos, não leva a resultados eficazes. Além da detecção e identificação da falha, informações como a frequência de cada alarme e quais alarmes ocorrem em conjunto são relevantes para auxiliar os operadores na análise de uma potencial falha e em seu posterior diagnóstico.

Detectar e identificar as fontes de uma determinada falha mesmo sabendo de sua ocorrência não é uma tarefa trivial. Normalmente não se sabe o instante de tempo onde a falha ocorreu e um grande número de variáveis podem ser por ela afetadas, fazendo com que esta análise demande tempo e dinheiro dada a sua complexidade. Nesse contexto, um método capaz de detectar e identificar uma falha, isolando o sinal ou o conjunto de sinais responsáveis pela falha é uma informação valiosa para a equipe de operação e manutenção.

Testes estatísticos, tais como o T^2 de Hotelling e estatística Q, são aplicados ao subespaço dos Componentes Principais com o objetivo de detectar a variabilidade dos dados. Quando uma falha ocorre, ela afeta a projeção de toda a amostra no subespaço dos componentes principais afastando-a de seu valor provável (medido pelo índice T^2 de Hotelling) e contribuindo consideravelmente para o aumento do erro residual total (medido pela estatística Q). A estatística T^2 de Hotelling trata somente da parte do espaço

amostral descrita pelos componentes principais. Contudo, em alguns casos, as falhas afetam primeiramente o espaço residual, explicado pelos autovetores correspondentes aos menores autovalores, os quais são monitorados através da estatística Q .

A finalidade deste trabalho é propor uma metodologia para detectar a ocorrência de uma falha e identificar quais sensores contribuíram significativamente nessa falha. Para tanto, a metodologia é aplicada ao histórico de dados do BOP e compreende as seguintes etapas:

1. Preparação dos dados
 - Cálculo do Coeficiente de Variação
 - Identificação e remoção de *outliers*
2. Cálculo da frequência dos alarmes
3. Cálculo da matriz de frequência dos alarmes
4. Detecção e identificação de falhas
 - Cálculo dos Componentes Principais
 - Cálculo do T^2 de Hotelling
 - Cálculo da estatística Q
5. Simulação de experimentos para a validação da metodologia proposta

Com base nos estudos e pesquisas realizados no referencial teórico descrito no capítulo 3, as etapas definidas anteriormente, buscam responder as seguintes questões:

- Q1: Qual a frequência de cada alarme e quais são os alarmes que ocorrem com mais frequência?
- Q2: Quais alarmes ocorrem em conjunto?
- Q3: Em que ponto do histórico de dados uma falha é detectada?
- Q4: Quais as variáveis (sensores) que mais contribuem para uma determinada falha?

O fluxograma das etapas da metodologia proposta, onde são destacadas as respostas para as questões ($Q1 \dots Q4$) colocadas acima, pode ser visualizado na Figura 4.1.

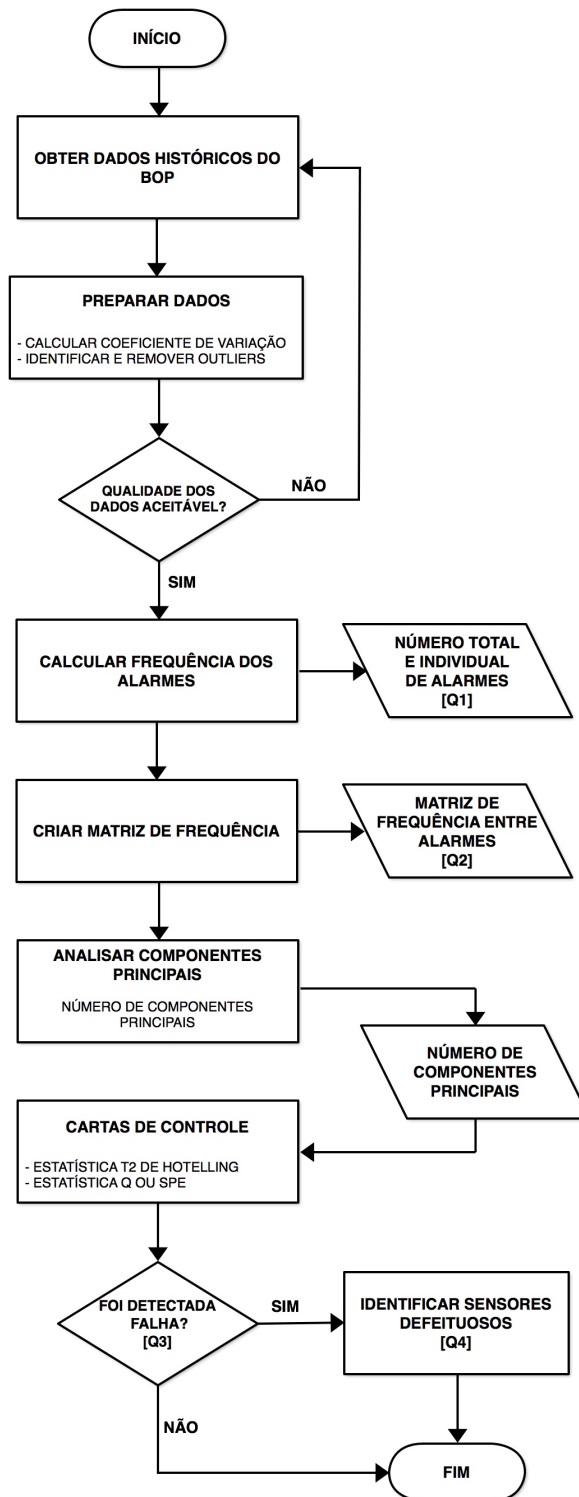


Figura 4.1: Fluxograma da metodologia proposta neste trabalho (o Autor)

Destaca-se que no Capítulo 5 serão descritas as etapas de aplicação da metodologia.

Capítulo 5

Aplicação da metodologia proposta

Neste capítulo é aplicada a metodologia desenvolvida para análise dos dados do sistema Preventor de Explosão Submarino (BOP), com objetivo detectar e identificar falhas no conjunto de dados histórico, além de extrair informações relevantes do conjunto de dados de alarme.

Para isto, a metodologia é aplicada aos dados históricos e em dados simulados. Para a simulação são inseridas falhas que podem ocorrer no dia-a-dia operacional, tais como *drift* nos valores ou problemas de repetibilidade, como descrito por [Mishra et al. \(2013\)](#).

5.1 Preparação dos dados

Esta seção corresponde a etapa 1 da metodologia proposta, e apresenta o histórico de dados provenientes do sistema BOP, o tratamento e o pré-processamento realizados. O banco de dados utilizado neste estudo, contém informações de três anos de operação, e é proveniente de um sistema de BOP a bordo de uma plataforma de perfuração, localizada na bacia de Campos-RJ.

O primeiro passo consiste em definir o número de sensores a ser utilizado, dada a sua relevância em termos de contribuição para falhas no sistema BOP. O estudo realizado por [Silva \(2002\)](#) obteve a lista dos componentes do BOP que naquele contexto, mais contribuíram para falha e conseqüentemente no tempo de parada de operação (*downtime*) do sistema, conforme mostra a Tabela 5.1. Já o artigo do Apêndice A propõe a aplicação do método AHP para a análise da contribuição de um grupo de componentes do BOP no tempo de *downtime*. Através da associação dos resultados obtidos por [Silva \(2002\)](#) e do artigo do Apêndice A, foram selecionados os dados provenientes de 38 sensores, os quais

refletem o universo dos componentes com maior incidência de falhas no sistema do BOP. A relação desses sensores é mostrada na Tabela 5.2.

Todo o histórico de dados provenientes do sistema BOP é armazenado em um banco de dados SQL. Neste banco de dados, todas as informações provenientes dos sensores, eventos de operação do sistema, ativação de funções, número do painel no qual uma determinada função foi realizada e qualquer outro evento relacionado à operação do BOP são armazenados em tabelas diárias de dados. De forma análoga, todos os alarmes gerados pelo sistema, quando o valor da variável monitorada ultrapassa os limites inferiores e superiores previamente definidos pelo operador, são também armazenados em uma tabela diária de alarmes.

Todas as informações provenientes das tabelas diárias de sensores e alarmes foram agregadas em uma nova tabela anual (Figura 5.1). Nesta tabela anual foi adicionada uma coluna denominada alarme, onde foi definido o valor 1 (um) para as linhas provenientes da tabela de alarmes e 0 (zero) para as linhas derivadas da tabela de dados dos sensores, de forma que os alarmes e os dados dos sensores pudessem ser avaliados de forma independente. A tabela anual foi exportada para o ambiente estatístico R, onde como primeiro passo foi realizada a análise do Coeficiente de Variação (CV), onde o conjunto de dados sob análise tem valor de dispersão de 11%. Em seguida foi realizada a detecção e remoção de *outliers* utilizando a função *boxplot* do pacote R (SANTOS-FERNÁNDEZ, 2012; MINELLI, 2013; ABEDIN, 2014).

O método para cálculo do CV e a identificação e remoção de *outliers* são detalhados nas Seções 3.3.1 e 3.3.2 respectivamente.

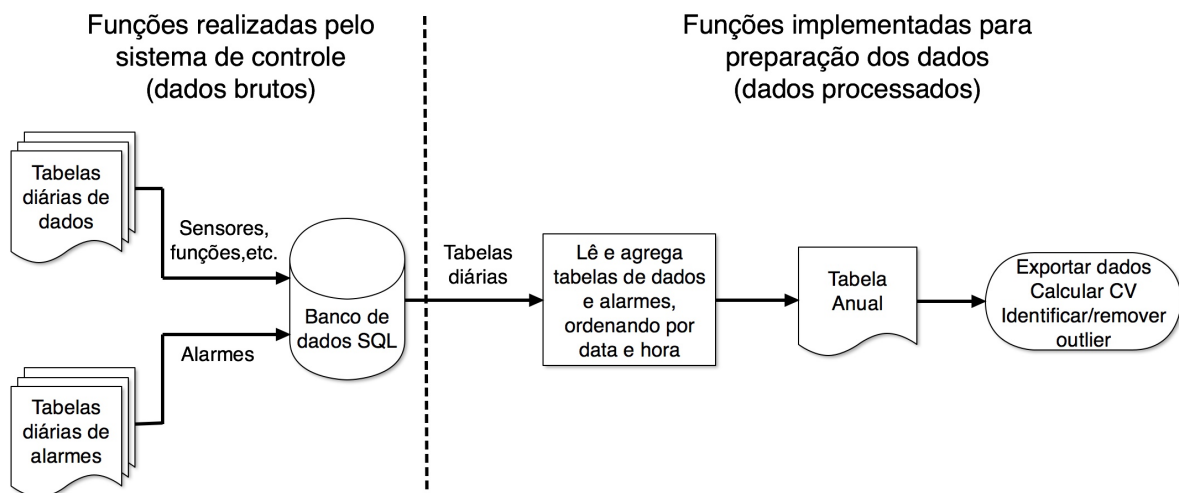


Figura 5.1: Fluxograma da preparação dos dados (o Autor)

Componente do BOP	Tempo Operacional (Dias)	<i>Downtime</i> total (h)	No de falhas	MTTF (dias)	<i>Downtime</i> por falha	Percentual do <i>downtime</i> total
Preventor Anular	9886	36,0	10	988,6	3,6	0,6%
Preventor de Gaveta	21227	950,5	30	707,6	31,7	15,4%
Vámulas gaveta	39017	1052	16	329,0	65,8	17,0%
Linhas de kill e Choke	5264	37,0	7	5573,9	5,3	0,6%
Sistema de controle multiplexado	3023	2597,5	109	27,7	23,8	42,0%
Sistema acústico	3480	51,5	17	204,7	3,0	0,7%

Tabela 5.1: Maiores contribuintes para o *downtime* total (SILVA, 2002)

Nºde identificação do sensor (ID)	Descrição
1	Pressão desconexão da LMRP
2	Pressão de travamento do conector do riser
3	Pressão hidrostática
4	Pressão piloto do manifold regulator
5	Pressão de destravamento fo conector do riser
6	Pressão de atuação do manifold regulator
7	Pressão regulada piloto do preventor anular superior
8	Pressão do POD de controle
9	Pressão regulada de atuação do preventor anular superior
10	Pressão piloto do POD de controle
11	Pressão de atuação do travamento do conector da cabeça de poço
12	Pressão de atuação do preventor anular inferior
13	Pressão de alimentação de 5000 psi
14	Pressão piloto do prventor anular inferior
15	Pressão de destravamento primário do conector da cabeça de poço
16	Pressão de destravamento secundário do conector da cabeça de poço
17	Pressão de alimentação do POD de controle
18	Pressão regulada piloto do conector da cabeça de poço
19	Pressão de atuação do conector da cabeça de poço
20	Pressão hidrostática
21	Não utilizado
22	Tensão de alimentação 60 VDC
23	Tensão de alimentação 33 VDC
24	Tensão de alimentação 24 VDC
25	Tensão de alimentação 12 VDC
26	Tensão de alimentação 120 VDC
27	Tensão de alimentação 5 VDC
28	Tensão de alimentação -12 VDC
29	Falha de aterramento(+15VDC)
30	Falha de terra (+120VDC)
31	Entrada de água - compartimento de solenóides (A)
32	Entrada de água - compartimento de solenóides (B)
33	Entrada de água - compartimento eletrônico
34	Vazamento de Flúido
35	Temperatura - compartimento eletrônico
36	Temperatura - compartimento de solenóides (A)
37	Temperatura - compartimento de solenóides (B)
38	Temperatura do processador

Tabela 5.2: ID e descrição dos alarmes utilizados (O Autor)

5.2 Período operacional

Esta seção corresponde a etapa 2 da metodologia proposta. Aqui, uma informação inicial a ser obtida, fundamental para a qualidade da análise dos dados, é em quais períodos o BOP se encontrou em operação. Isso é importante pois garante que os dados a serem analisados sejam aqueles relacionados à operação normal e real do equipamento, e não alguma informação espúria, adquirida durante um período de testes, ou quando o BOP se encontrava na superfície fora de operação. Cabe ressaltar que toda a análise realizada nesse trabalho tem como base os dados contidos no maior período operacional identificado.

Para definir o período operacional, apresenta-se a seguinte hipótese: o período de operação do BOP pode ser verificado através da análise dos dados provenientes de sensores de pressão embarcados no BOP. Após uma análise inicial para definir os sensores relevantes para inferir o início e o fim do período operacional, foram selecionados os sensores que medem a pressão hidrostática (cada POD de controle possui um par destes sensores - números 03 e 20) e o sensor de pressão que mede a pressão de fechamento do conector de travamento do BOP à cabeça do poço (número 11). Com isso, parte-se das seguintes premissas:

- a) Como se trata de um equipamento utilizado em águas profundas, definiu-se que o valor da pressão hidrostática deve ser maior que 1500 psi, o que corresponde aproximadamente a 1000 m de lamina d'água, ou seja:

$$P_{hidrostatica} \geq 1500 \text{ psi} \quad (5.1)$$

- b) Uma vez que a pressão nominal de trabalho é da ordem de 1500 psi, a pressão de travamento dos conectores de travamento da cabeça de poço deve ser maior que 1500 psi, ou seja:

$$P_{wellheadconector} \geq 1500 \text{ psi} \quad (5.2)$$

A metodologia descrita acima foi aplicada com sucesso a um conjunto de dados coletados no ano de 2010 em uma plataforma de perfuração em operação na bacia de Campos/RJ. A metodologia foi capaz de verificar com exatidão o período no qual o BOP estava efetivamente em operação, o que foi comprovado utilizando os relatórios diários de operação emitidos pela plataforma.

A Figura 5.2 mostra o gráfico com os sensores de pressão hidrostática e de travamento do conector da cabeça de poço (*wellhead connector*) no ano de 2010. Através da análise deste gráfico, verifica-se que entre abril e agosto de 2010, ambos os sensores possuem valores que correlacionados, confirmam a hipótese de que o BOP se encontrava em operação neste período. O Algoritmo 1 apresenta a implementação computacional da metodologia proposta.

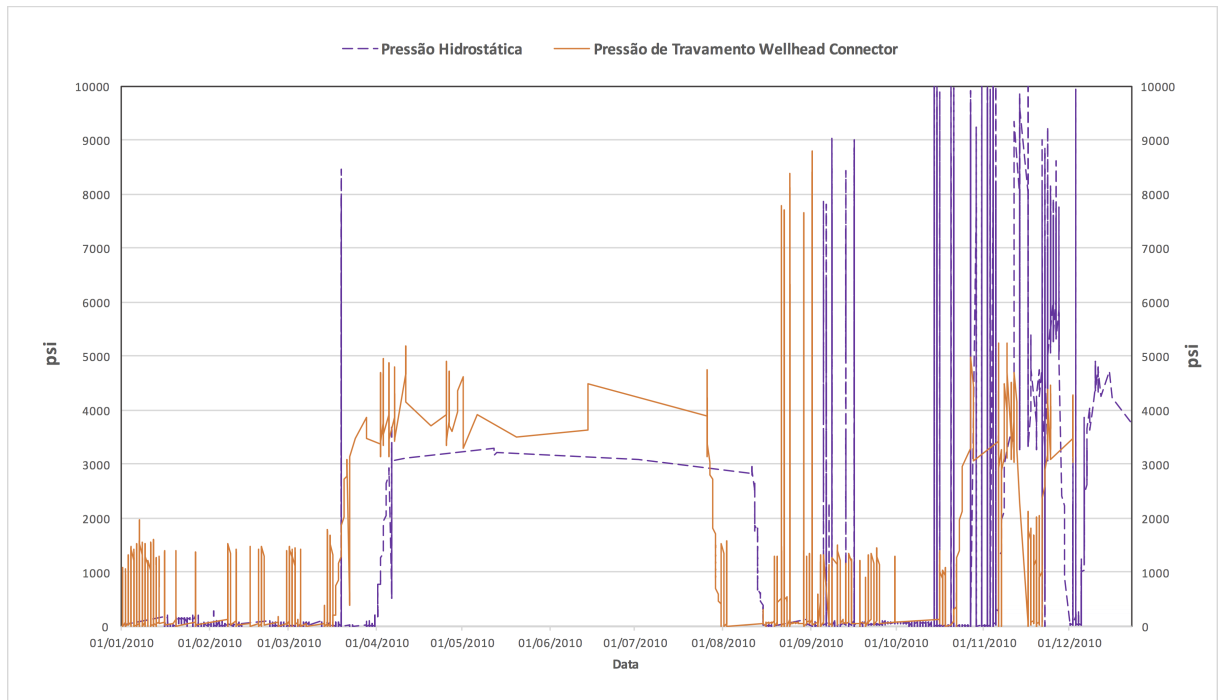


Figura 5.2: Pressão hidrostática versus Pressão de travamento do *wellhead connector* (o Autor)

Algoritmo 1: Definição do período operacional

```

input : Vetor data contendo a lista de datas e valor dos sensores
output: novo vetor de dados criado com o conjunto de dados no intervalo
         de operação int_opera, extraídos do conjunto de dados original
         data

S_PROF ← [3; 20] /* IDs dos sensores de pressão hidrostática
    */
S_WH ← 11 /* ID do sensor de pressão de fechamento do
    conector da cabeça de poço */
PROF ← 1500 /* Profundiade de operação */
PWH ← 1500 /* Pressão de fechamento do conector da cabeça de
    poço */
for i ← tamanho(data) to 1 do
    if (obj_id(data[i]) == S_PROF) e (valor(data[i]) >= PROF) then
        if (obj_id(data[i]) == S_WH) e (valor(data[i]) >= PWH) then
            int_opera ← data[i];
  
```

Analisando e cruzando as informações dos sensores, pode-se verificar o período de operação como mostra a Tabela 5.3. Para o conjunto de dados analisados foi selecionado o período entre 03/04/2010 à 13/08/2010, de acordo com as premissas 5.1 e 5.2 definidas anteriormente.

Pressão hidrostática		Pressão travamento wellhead connector	
Data	Pressão (psi)	Data	Pressão (psi)
03/04/2010	1937	03/04/2010	1854
04/04/2010	2056	04/04/2010	2014
⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮
12/08/2010	1872	12/08/2010	1913
13/08/2010	1595	13/08/2010	1503

Tabela 5.3: Período de operação

5.3 Frequência dos alarmes

O objetivo desta seção, relativo a etapa 3 da metodologia proposta, é analisar o histórico de dados de um BOP específico, e computar a frequência individual e total dos alarmes gerados pelo sistema. Tais alarmes são registrados pelo sistema de controle do BOP quando o valor da variável monitorada ultrapassa uma faixa de valores operacionais pré definidos. Assim como apresentado no início do Capítulo 4, a hipótese levantada nesta seção é de que os alarmes gerados pelo sistema são negligenciados pelo operador.

A análise de frequência para cada alarme é realizada através da contagem do número de ocorrências para cada código de alarme (OBJ_ID) presente no histórico de dados. Os alarmes foram agrupados pelo seu OBJ_ID independentemente do POD de controle ao qual pertencem, uma vez que a troca do POD de controle durante o período de operação pode ser realizada a qualquer momento pelo operador. Com o objetivo de definir a frequência de cada alarme ocorrido no período sob análise, foi implementado o Algoritmo 2.

Algoritmo 2: Cálculo da frequência de alarmes

```

input : Vetor dados contendo todos os alarmes ocorridos no período
          de operação;
output: vetor com o valor da frequência de cada alarme alm.cnt

/* Cada linha do conjunto de dados que corresponde a um
   alarme, tem o valor da coluna alarme igual 1          */
for i ← tamanho(data) to 1 do
    if (data[i].alarme == 1) then
        [ numero_alarmes[data[i].id]+ = 1;
    ]
    mostra(alm.cnt);
    geragrafico(alm.cnt);

```

O resultado de execução da rotina para o cálculo de frequência dos alarmes pode ser visto na Tabela 5.4.

	Código de identificação do alarme	Frequência
1	01	229
2	02	4
3	04	324
4	05	3
5	06	324
6	07	450
7	08	304
8	09	450
9	11	4
10	12	415
11	13	254
12	14	409
13	15	3
14	16	3
15	17	270
16	18	260
17	19	260
18	32	80656
19	36	2205
20	37	1953
Total		88780

Tabela 5.4: Frequência dos alarmes dos 20 sensores no período operacional

O gráfico com as frequências de cada alarme pode ser visto na Figura 5.3, onde o eixo x indica o código de identificação do alarme, visualizado na Tabela 5.2. Neste gráfico a maior parte das informações é mascarada por uma altíssima ocorrência de um único alarme. Este alarme (ID 32) se refere a entrada de água no compartimento de solenoide B e ocorreu 80656 vezes, o que equivale à 90,85% do número total de alarmes.




Figura 5.3: Frequência de alarmes (o Autor)

Outra informação relevante que pode ser obtida do conjunto de dados é o número de vezes que o operador reconheceu a existência de um determinado alarme (*Alarm Acknowledge*). Cada vez que o operador aperta o botão correspondente ao reconhecimento do alarme esta informação é gravada no banco de dados. Comparando o número total de alarmes com o número de reconhecimento de alarmes no período, observa-se que apenas 0,5 % dos alarmes foram reconhecidos pelo operador, como mostra a Tabela 5.5.

Nºtotal de alarmes	Nºde alarmes reconhecidos	% Nºde alarmes reconhecidos
88819	440	0,5%

Tabela 5.5: Total de alarmes e reconhecimento de alarmes no período sob análise

Esse resultado indica que a maioria dos alarmes não são reconhecidos pelo operador. No mesmo período foram encontradas apenas duas ocorrências relacionadas ao silenciamento do alarme sonoro. Cabe ressaltar, que sempre que um alarme ocorre, um sinal sonoro é ativado. Isso demonstra que o silenciamento dos alarmes não é razão para o baixo número de reconhecimentos de alarme. A conclusão baseada na análise dos dados

é de que os operadores simplesmente ignoram a quase totalidade dos alarmes.

5.4 Matriz de frequência

Nesta etapa 4 da metodologia, busca-se extrair do conjunto de dados a informação quais alarmes ocorrem em conjunto, mesmo que não possuam uma relação direta um com outro. Neste ponto deseja-se investigar a relação numérica entre alarmes; ou seja, quando um determinado alarme ocorre, quais outros alarmes ocorrem em conjunto, e com qual frequência.

Com esse objetivo foi desenvolvida uma matriz de frequência, que mostra o cruzamento de frequência entre alarmes. Esta matriz é uma matriz quadrada $n \times n$, onde n é o número de variáveis investigadas, e indica a relação entre os alarmes contidos no histórico de dados, em um determinado intervalo de tempo (t), onde se deseja investigar a relação em termos de frequência, entre elas. Neste estudo, o valor considerado de n foi 39, que corresponde ao número de sensores monitorados. Já o intervalo de tempo t foi definido inicialmente em 10 segundos, pois o sistema de controle é configurado de forma que caso o valor da variável se encontre fora do intervalo pré definido, existe um *delay* da ordem de 10 segundos para que o alarme relacionado a essa variável seja efetivamente ativado. Isto ocorre para evitar que uma variação rápida ou espúria não ative alarmes inadvertidamente. O Algoritmo 3 mostra o pseudocódigo de criação da matriz de frequência.

Algoritmo 3: Criação da matriz de frequência

```

input : Vetor data contendo a lista de dados; o intervalo de tempo
         t que precede o alarme analisado.

output: A matriz de correlação cm

/* O vetor data é lido de trás para a frente, pois o
   objetivo é recuperar alarmes anteriores          */
for i ← tamanho(data) to 1 do
  for j ← i to 1 do
    if i diferente de j then
      dif_tempo ← (datahora(data[j]) – datahora(data[i]));
      if dif_tempo ≤ t then
        lin ← ID(data[i]);
        col ← ID(data[j]);
        cm[lin, col] ++;
      else
        break ;
  
```

A Figura 5.4 ilustra o gráfico da matriz de frequência. O par de variáveis onde existe um maior cruzamento de frequência possui uma maior intensidade de cor. Na Tabela 5.6 é mostrado o resultado numérico para as maiores ocorrências de frequência entre alarmes. A descrição para cada um dos códigos de alarme (*obj_ids*) pode ser obtida na Tabela 5.2.




Figura 5.4: Matriz de cruzamento de frequência dos alarmes (o Autor)

	Código de Alarme	Código de Alarme	Total de frequência
1	07	09	538
2	12	14	513
3	18	19	413
4	04	06	322
5	09	07	308
6	14	12	298
7	19	18	280
8	08	17	277
9	32	36	249
10	36	32	238
11	36	37	171
12	06	04	162
13	17	08	145
14	37	36	72
15	08	32	52
16	12	32	50
17	17	32	50
18	14	32	49
19	32	12	49
20	32	14	48
21	32	04	41
22	32	06	41
23	32	08	41
24	13	17	31
25	32	17	31
26	04	32	28
27	06	32	28
28	13	08	26
29	08	13	23
30	07	32	20
31	09	32	20

Tabela 5.6: Maiores frequências de ocorrência entre alarmes

Estes resultados podem ser utilizados pelos operadores com o objetivo de verificar a influência entre sensores de acordo com os alarmes ativados. Com os resultados obtidos na Tabela 5.6 pode-se verificar, por exemplo, a relação entre os sensores 7 (Pressão piloto do regulador de pressão de atuação do anular superior) e 9 (Pressão do regulador de pressão de atuação do anular superior). O cruzamento de frequência entre estes sensores é alta, pois os mesmos se encontram no mesmo circuito hidráulico, e quando ocorre a variação de pressão, ambos os sensores são afetados igualmente e proporcionalmente. Outro exemplo é a relação não usual existente entre os sensores 32 (Entrada de água - compartimento de solenoides B) e o 36 (Temperatura - compartimento solenoides A). Essa relação pode indicar algum tipo de mal funcionamento do sistema, logo deve ser investigado pela equipe da plataforma.

5.5 Detecção e identificação de falhas

Nesta seção é aplicada a Análise de Componentes Principais (ACP) e as cartas de controle estatístico à dois conjuntos de dados; um de treinamento e um de teste. Os dados de treinamento são responsáveis por treinar o modelo, e correspondem aos dados considerados normais, ou seja, dentro da normalidade operacional. Já os dados de teste correspondem aos dados de alarmes e simulados, caracterizando dados anormais, ou seja, fora do limite normal de operacionalidade.

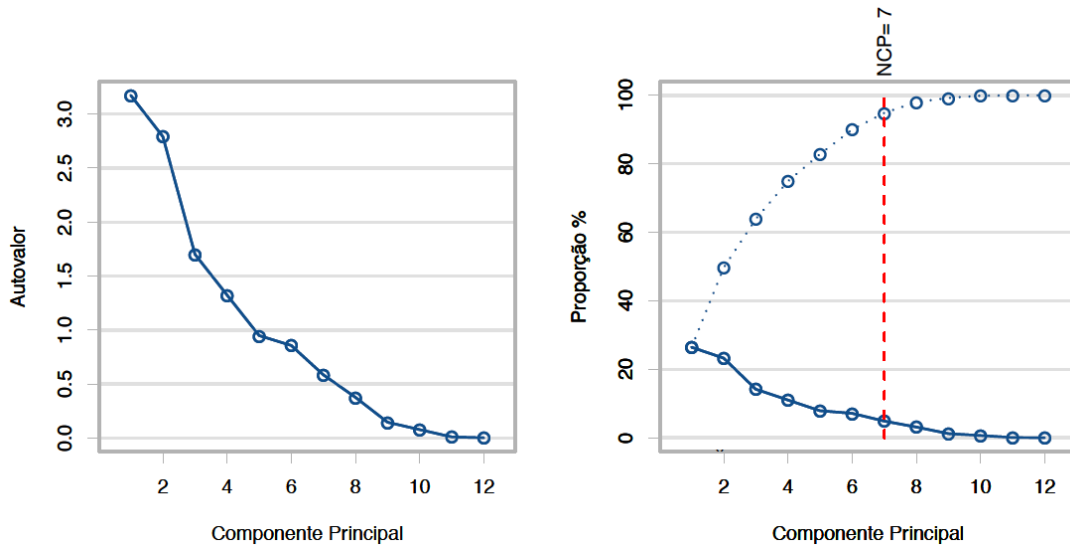
5.5.1 Dados de alarme

Nesta seção, a etapa 5 da metodologia que corresponde a detecção e identificação de falhas é aplicada ao conjunto de dados dos sensores e alarmes. A ideia principal é através dos dados dos sensores (treinamento), os quais não foram identificados como fora da condição normal de funcionamento (alarmes), treinar o modelo para que o mesmo seja capaz de detectar a variabilidade e conseqüentemente falhas no conjunto de alarmes (teste). Nesta aplicação da metodologia, com base no artigo do Apêndice A, foram utilizados apenas dados provenientes dos sensores de pressão (números de 1-20), que correspondem aos componentes do sistema BOP com alto índice de falha.

Foram selecionadas 200 amostras, uma vez que para o conjunto de dados de treinamento mais de 50% dos sensores não possuíam dados a partir deste ponto (*missing data*) e caso a ACP fosse aplicada com essa grande quantidade de dados faltantes, seus resultados não seriam confiáveis (MINGOTI, 2005).

O primeiro passo consiste em aplicar a Análise de Componentes Principais para ambos os conjuntos de dados (treinamento e teste), selecionando o número de componentes principais que representem ao menos 95% da variância total do sistema, conforme explicado na Seção 3.3.3. Na Figura 5.5 é mostrado o resultado para o cálculo da ACP para ambos os conjunto de dados, onde o número de componentes principais foi definido de acordo com o critério do percentual da variância descrito na Seção 3.3.3.

Dados de treinamento



Dados de teste

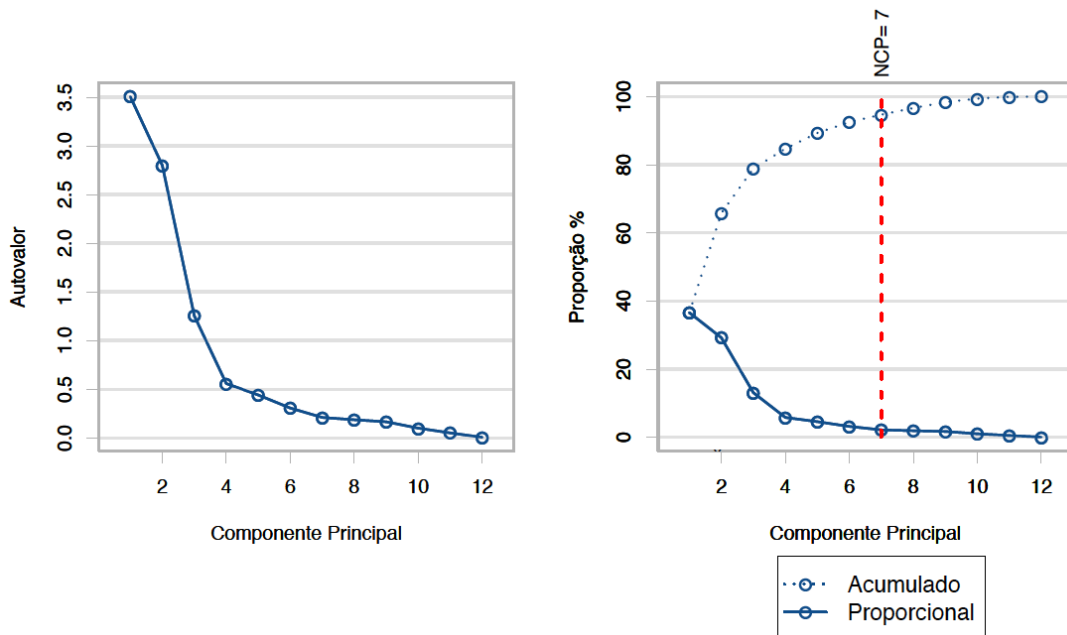


Figura 5.5: Resultado da ACP para os dados de treinamento (acima) e teste (abaixo) (o Autor)

Após o cálculo da ACP foram seccionados 7 componentes principais para o conjunto de dados de treinamento e de teste. Tais resultados, que incluem as matrizes de covariância, autovetores e autovalores para ambos os conjuntos de dados, foram utilizadas para a recomposição da matriz de dados original utilizando o número de componentes principais selecionados.

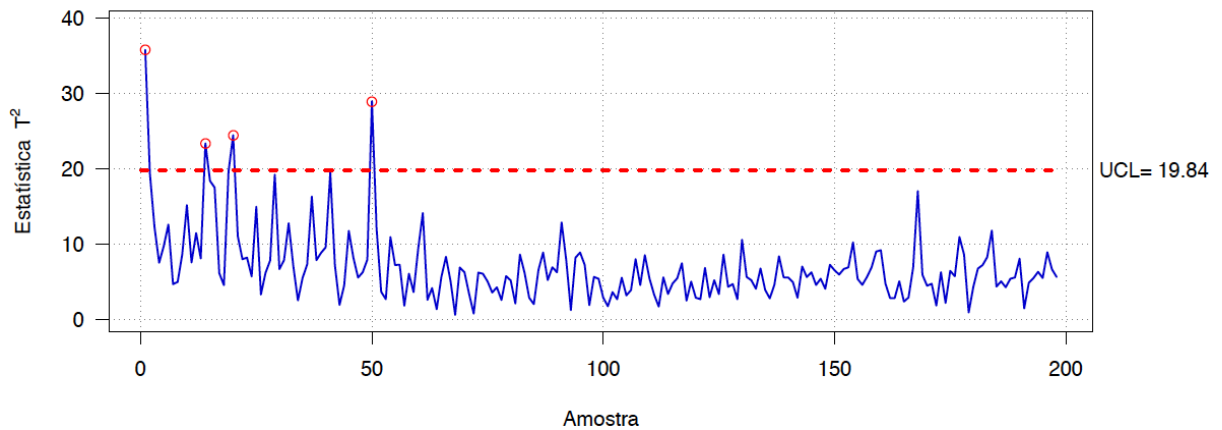
Essas informações provenientes da aplicação da ACP são indispensáveis para o cálculo da estatística T^2 de Hotelling e da estatística Q , incluindo o cálculo do valor do limite superior de controle (UCL) para ambas. O UCL calculado para o conjunto de dados de treinamento será utilizado como padrão para detecção da variabilidade no conjunto de dados de teste.

A estatística T^2 de Hotelling e o valor de seu limite superior são calculados através das equações 3.10 e 3.11 respectivamente, os quais serão utilizados posteriormente para detecção e identificação de possíveis falhas.

Na Figura 5.6 é mostrado o resultado da estatística T^2 de Hotelling e o valor do limite superior de 19,84 para o conjunto de dados de treinamento. O resultado demonstra que a grande totalidade dos dados de treinamento e teste estão abaixo do limite superior de controle, e por esta razão são considerados dentro dos padrões de normalidade. Vale ressaltar que os dados do conjunto de treinamento localizados acima do UCL pertencem ao período de estabilização dos sensores do equipamento.

Como os dados de teste estão reconhecidamente fora do limite operacional, pode-se concluir que a estatística T^2 de Hotelling não foi eficaz na detecção de falha neste caso. Isso ocorre, pois a estatística T^2 de Hotelling trata somente da porção do espaço amostral explicado pelos componentes principais (JUNIOR, 2015), e por essa razão, não é sensível a falhas com baixa magnitude (HARROU et al., 2015), como é o caso da variação entre o conjunto de dados de teste e treinamento. Uma vez, que os dados de teste possuem um valor com pouca magnitude acima ou abaixo do valor normal de operação.

Dados de treinamento



Dados de teste

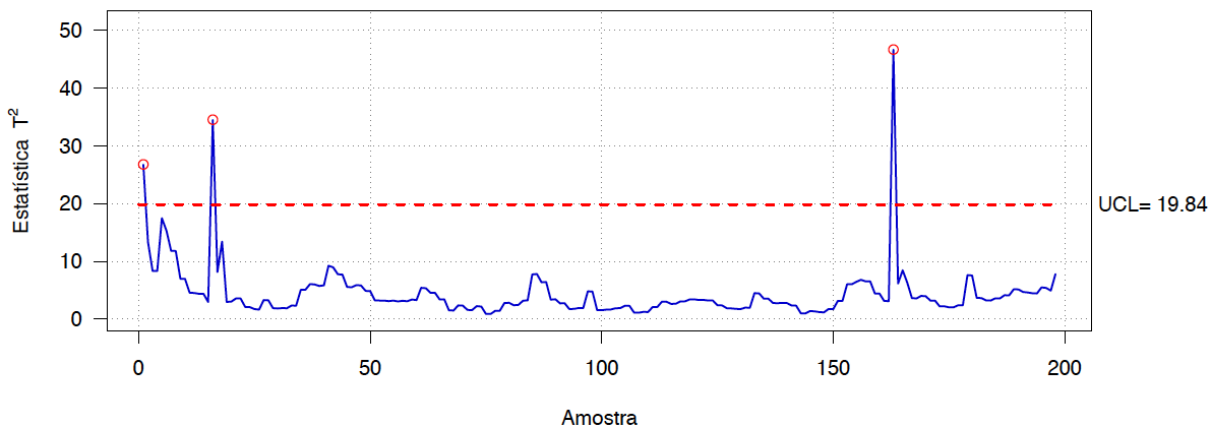
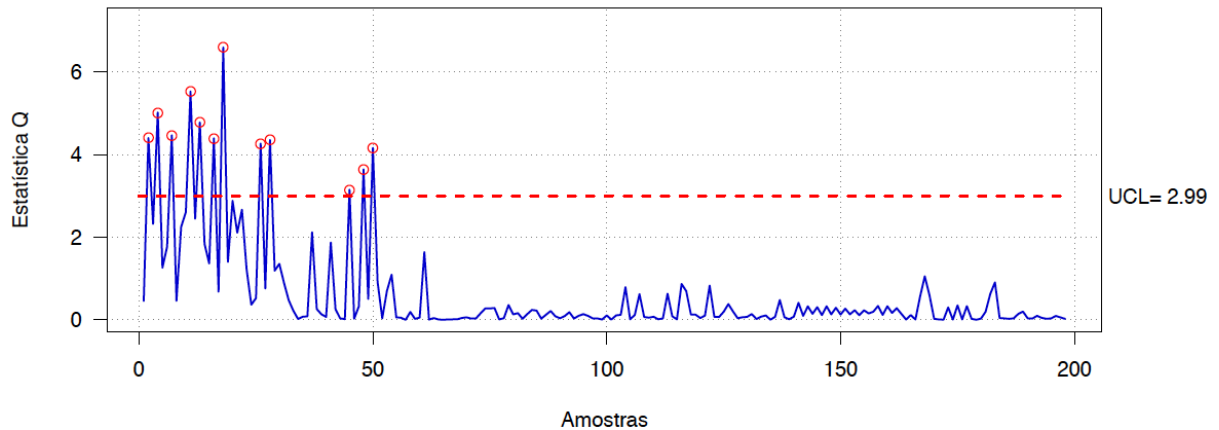


Figura 5.6: Estatística T^2 e limite superior para os dados de treinamento (acima) e teste (abaixo) (o Autor)

O cálculo da estatística Q e do valor de seu limite de controle superior são realizados utilizando as Equações 3.12 e 3.13 respectivamente.

A Figura 5.7 mostra o resultado do cálculo da estatística Q para o conjunto de dados de treinamento e o valor do limite de controle superior de 2,99. Observa-se que o conjunto de dados de teste apresentam todos os valores acima do limite superior calculado. Isso significa que todo o conjunto dados de teste possuem valores fora da normalidade operacional, e comprova a capacidade do modelo de identificar quais dados se encontram fora do limite operacional, que é o caso dos dados de alarme utilizados como teste do modelo.

Dados de treinamento



Dados de teste

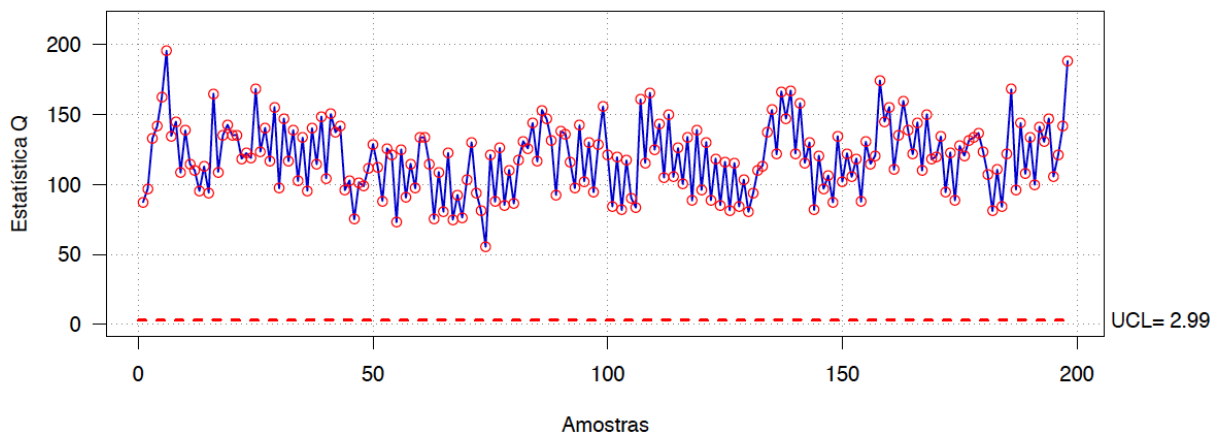


Figura 5.7: Estatística Q para os dados de treinamento (acima) e teste (abaixo)(o Autor)

A identificação do sensor com falha é realizado através da análise da matriz de resíduos para uma determinada amostra, utilizando a equação 3.18. Aqui um determinado ponto é escolhido para o cálculo e criação do gráfico de contribuição para este ponto. Como demonstra os resultados da estatística Q para o conjunto de dados de teste, a totalidade dos pontos estão fora da zona de normalidade, por essa razão pode-se selecionar um ponto aleatório para verificação. Neste caso foi selecionado aleatoriamente o ponto amostral número 50.

Na Figura 5.8 pode-se verificar a contribuição individual de cada sensor para a ocorrência de falha no ponto amostral 50. Neste caso, verifica-se que o sensor 17 exerce a maior influência para a falha detectada.




Figura 5.8: Contribuição individual por sensor para o ponto amostral 50 (o Autor)

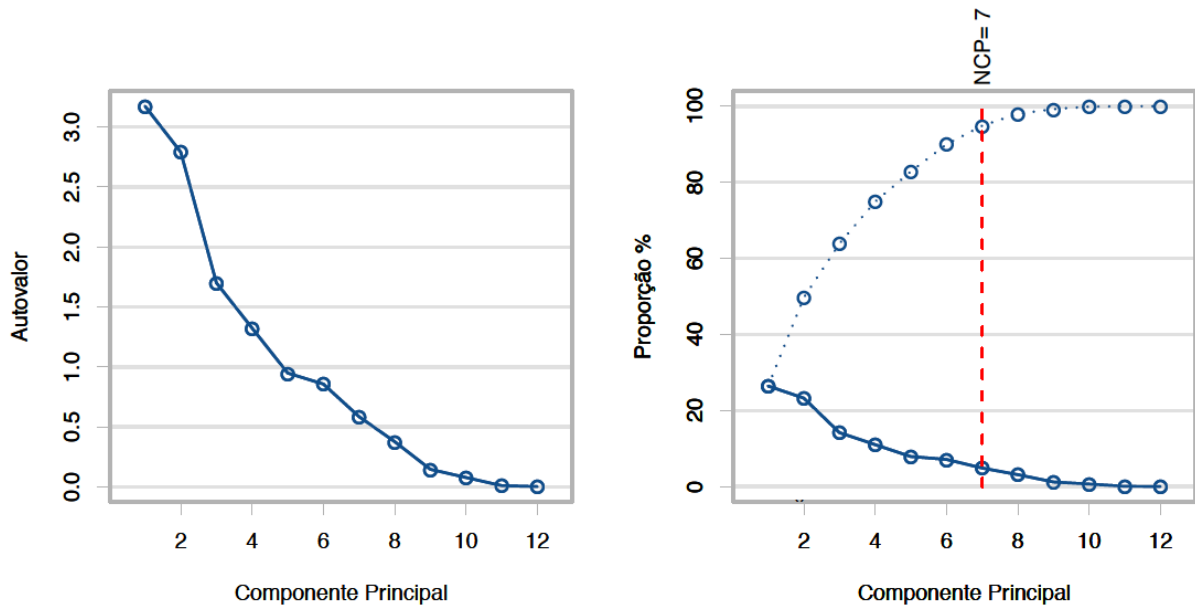
5.5.2 Simulação - Falha do tipo *sensor drift*

Como parte da etapa 6 da metodologia proposta, que tem como objetivo validar esta metodologia, além do fato que os dados do conjunto de teste quando aplicados aos dados de alarme (Seção 5.5.1) não responderam bem à estatística T^2 de Hotelling, os dados do conjunto de teste foram simulados tendo como base os dados do conjunto de treinamento.

Para a simulação de *sensor drift*, foi selecionado aleatoriamente o sensor número 17, onde seus dados foram simulados a partir da amostra número 100 (cem). Esta falha simulada é caracterizada pela inserção de informações de pressão que amentam de valor linearmente em função do tempo (*sensor drift*). Essa é uma falha comum para estes tipos de sensores devido suas características construtivas (MISHRA et al., 2013).

A Figura 5.9 mostra o resultado do modelo de ACP para os dados de treinamento e para os dados simulados. Para os dados de treinamento 7 componentes principais foram selecionados e para os dados simulados foram selecionados 6 componentes principais. Para ambos os conjuntos de dados o número de componentes principais foi definido de acordo com o critério do percentual da variância descrito na Seção 3.3.3.

Dados de treinamento



Dados simulados

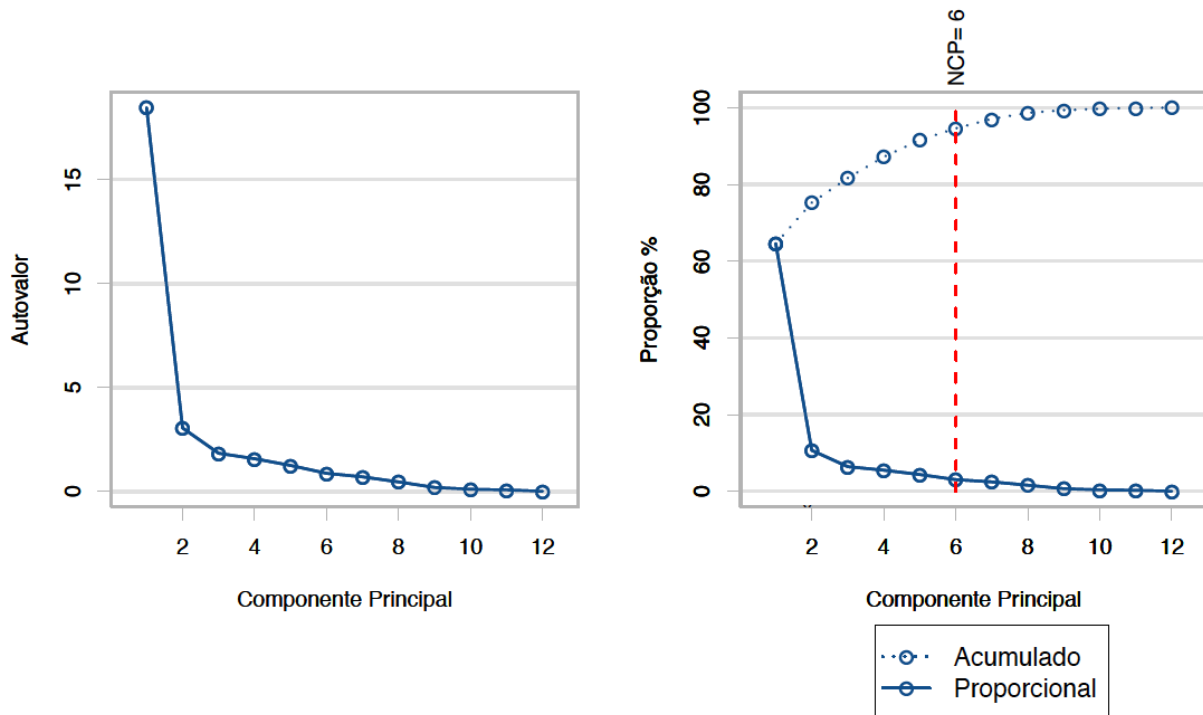


Figura 5.9: Resultado da ACP para os dados de treinamento (acima) e simulados (abaixo) (o Autor)

Na Figura 5.10 são mostrados os resultados para o cálculo da estatística T^2 de Hotelling e seu limite superior de controle. Neste caso, pode ser visto que aproximadamente a partir da amostra número 130 do conjunto de dados simulados, uma falha é detectada.

E mesmo sendo apenas a diferença entre os dados de treinamento e simulado os valores de pressão no sensor número 17, a variabilidade nos dados deste sensor altera completamente o comportamento da estatística T^2 de Hotelling, para os dados simulados em relação aos dados de treinamento.

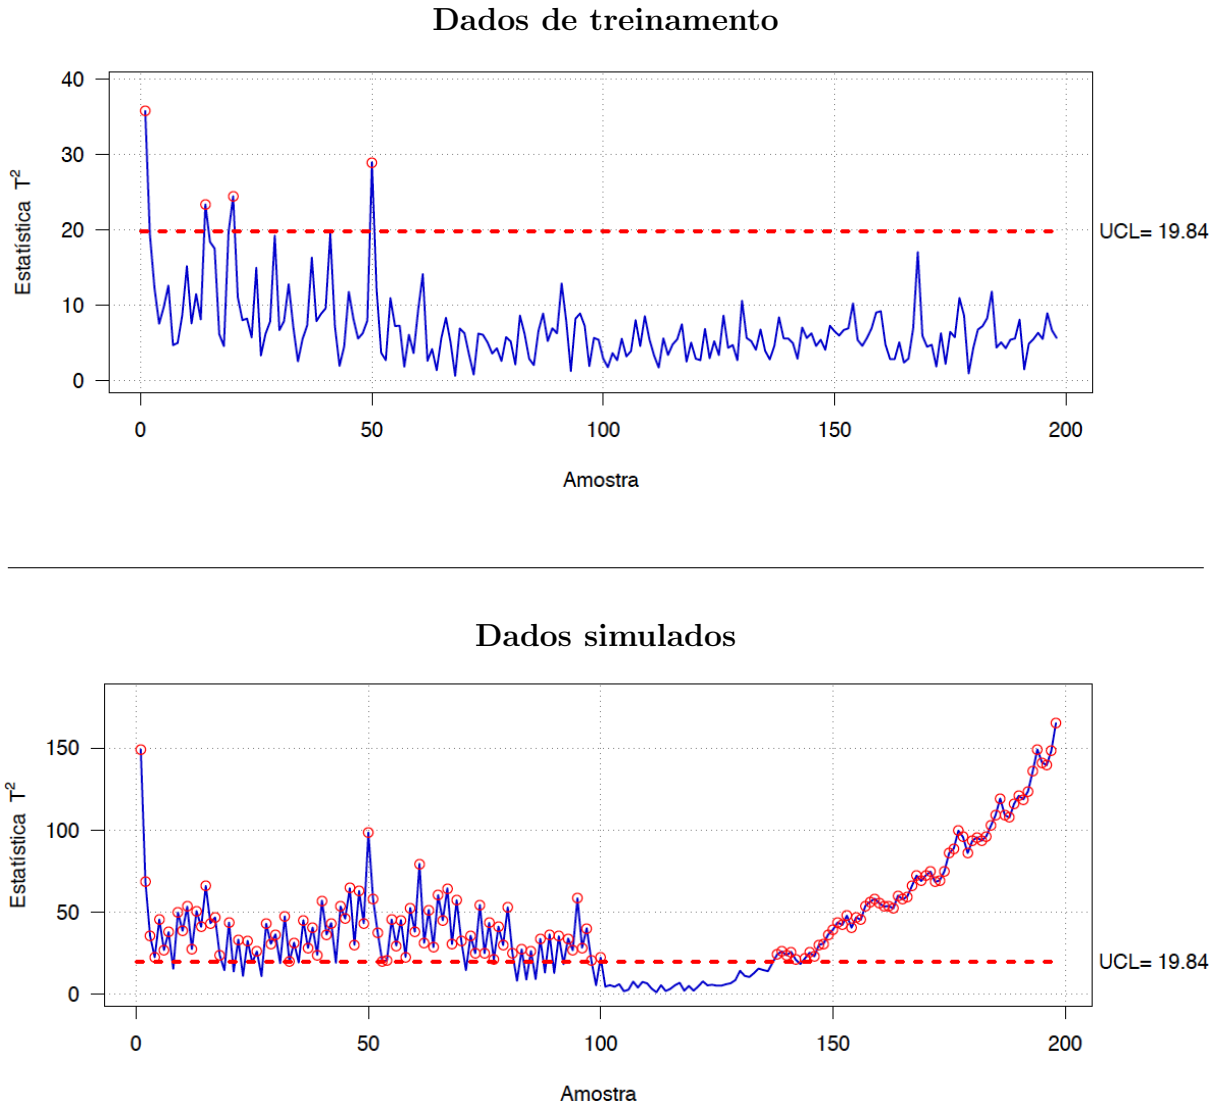



Figura 5.10: Estatística T^2 e limite superior para os dados de treinamento (acima) e simulados (abaixo) (o Autor)

Os resultados da estatística Q para ambos os dados de treinamento e simulado podem ser vistos na Figura 5.11. Para o conjunto de dados simulados, pode-se claramente através do resultado da estatística Q , identificar a ocorrência de falha a partir da amostra número 100 nos dados simulados.

Dados de treinamento



Dados simulados

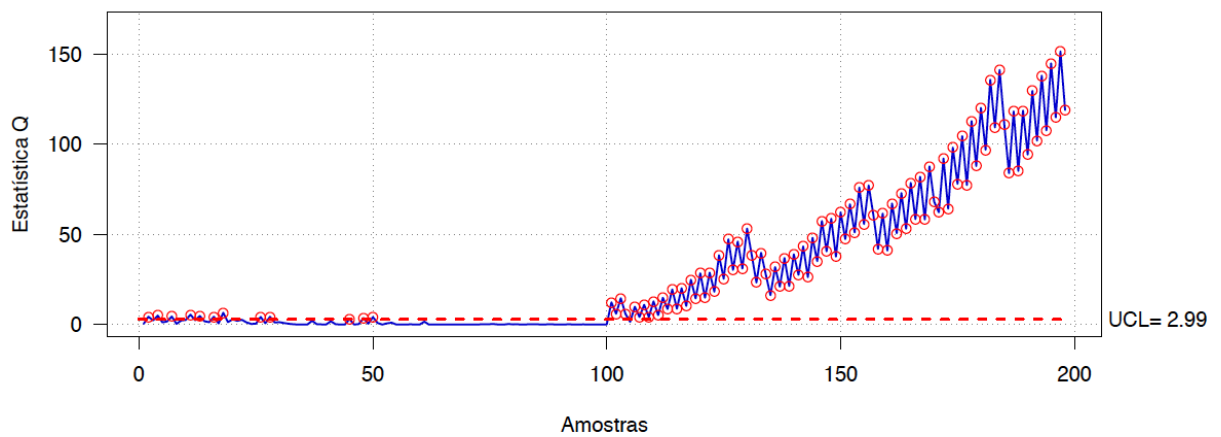


Figura 5.11: Estatística Q para os dados de treinamento (acima) e simulados (abaixo)(o Autor)

Uma vez obtido o resultado para a estatística Q , a contribuição para a falha a partir do ponto amostral número 100 pode ser verificada. A Figura 5.12 mostra o gráfico de contribuição para cada sensor. Como esperado, o sensor número 17 é o único contribuinte para a falha, uma vez que foi inserida uma "falha fictícia" em seus dados a partir da amostra número 100.




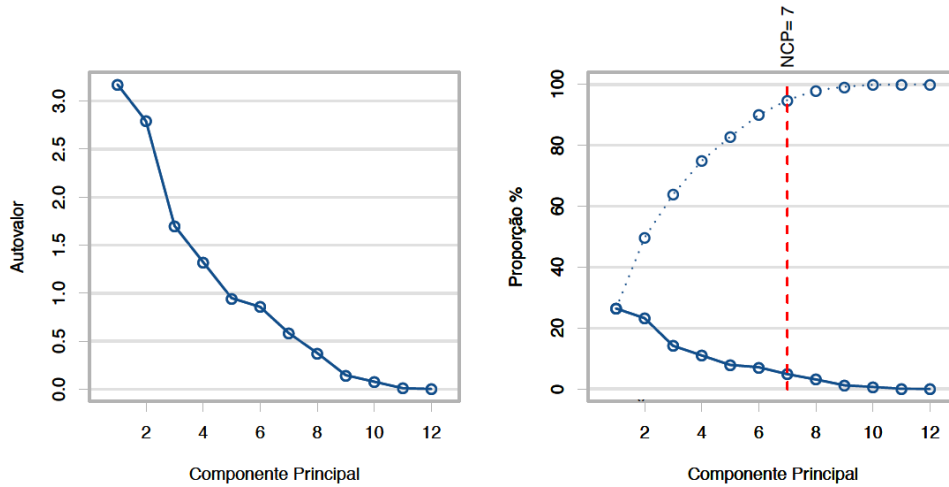
Figura 5.12: Contribuição individual por sensor para a simulação *sensor drift* (o Autor)

5.5.3 Simulação - Falha do tipo repetibilidade

Ainda como parte da etapa 6 da metodologia, que corresponde a simulação para a validação da metodologia, foi simulada uma falha de repetibilidade no sensor número 12, onde a partir da amostra número 100 seus dados foram repetidos com o valor fixo de 10000 psi. Valor este, correspondente à máxima pressão que o sensor avaliado é capaz de suportar. Essa é uma falha comum de ocorrer, dadas as características operacionais do sistema (MISHRA et al., 2013).

O resultado da ACP para os dados de treinamento e simulado podem ser visualizados na Figura 5.13. Assim como ocorreu para a simulação de *sensor drift* na Seção 5.5.2, para os dados de treinamento 7 componentes principais foram selecionados e para os dados simulados, 6 componentes principais foram selecionados. Em ambos os casos o número de componentes principais foi definido de acordo com o critério do percentual da variância descrito na Seção 3.3.3.

Dados de treinamento



Dados simulados

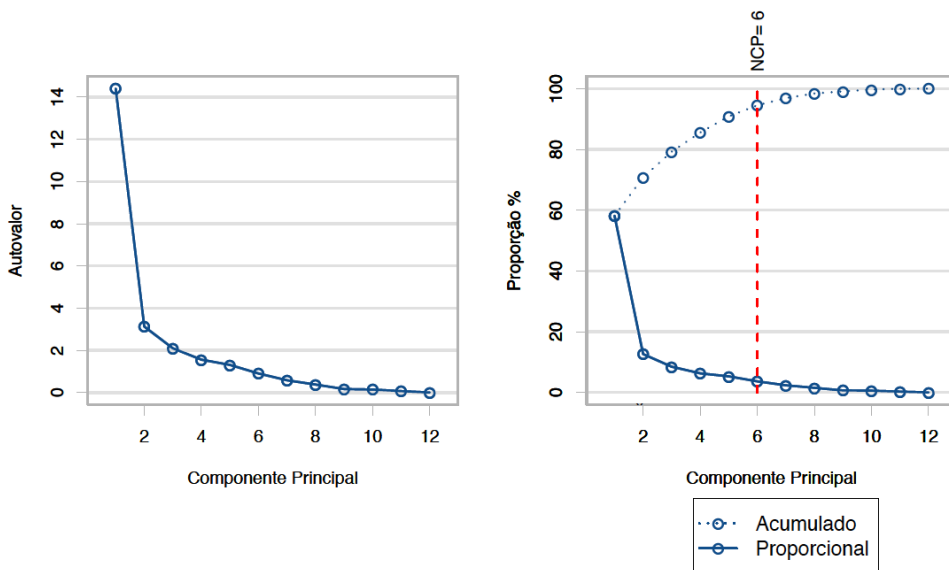
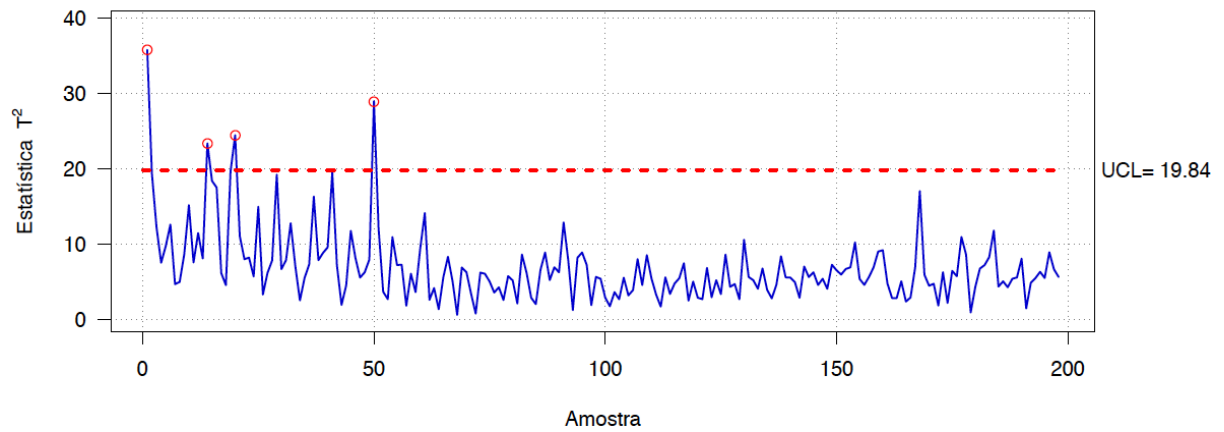


Figura 5.13: Resultado da ACP para os dados de treinamento (acima) e simulados (abaixo) (o Autor)

Os resultados para o cálculo da estatística T^2 de Hotelling e seu limite superior de controle são mostrados na Figura 5.14. Para esse resultado, observa-se que nos dados simulados a partir da amostra número 100, a curva pode ser considerada constante, indicando que para algum sensor do conjunto de dados de teste, seus valores estão constantes de forma anormal. É notório que o valor constante nos dados do sensor número 12 altera o comportamento da estatística T^2 de Hotelling para os dados simulados em relação aos dados de treinamento.

Dados de treinamento



Dados simulados





Figura 5.14: Estatística T^2 e limite superior para os dados de treinamento (acima) e simulados (abaixo) (o Autor)

Calculando-se a estatística Q para ambos os dados de treinamento e simulado, obtêm-se os resultados mostrados na Figura 5.15. Para o conjunto de dados simulados, observa-se claramente a ocorrência de falha a partir da amostra número 100, onde se iniciam os dados da simulação. A estatística Q indica que houve uma falha e a partir de qual amostra essa falha ocorreu.

Dados de treinamento



Dados simulados




Figura 5.15: Estatística Q para os dados de treinamento (acima) e simulados (abaixo)(o Autor)

Utilizando os resultados da estatística Q , a contribuição para a falha a partir do ponto amostral número 100 dos dados simulados pode ser inferida. Através da Figura 5.16 pode-se observar o gráfico onde a contribuição de cada sensor é visualizada. Como esperado, o sensor número 12 se mostra o único contribuinte para a falha de repetibilidade simulada, pois uma "falha fictícia" foi inserida em seus dados a partir da amostra número 100.




Figura 5.16: Contribuição individual por sensor para a simulação de repetibilidade (o Autor)

Esses resultados demonstram que o modelo desenvolvido neste trabalho foi capaz de detectar e identificar falhas, e que pode, com as devidas adaptações, ser utilizado em outros conjuntos de dados, uma vez treinado com dados dentro do limite de operacionalidade.

Capítulo 6

Conclusão

Neste trabalho é desenvolvida uma metodologia a ser utilizada para o aprimoramento da detecção e identificação de falhas em um Sistema Preventor de Explosões Submarino (BOP). São utilizadas ferramentas estatísticas e computacionais que aplicadas à um conjunto de dados históricos provenientes desse sistema, buscam a detecção e identificação de falhas. A ideia principal da metodologia é através dos dados dos sensores (treinamento), os quais não foram identificados como fora da condição normal de funcionamento (dados de alarmes), treinar o modelo para que o mesmo seja capaz de detectar a variabilidade e conseqüentemente falhas em conjunto de dados (teste). Além da detecção e identificação de falhas, a metodologia é capaz de extrair informações relevantes, como a frequência e relação entre alarmes. Mesmo que a metodologia proposta não seja capaz de prover o diagnóstico da falha, estas informações de frequência e relação entre alarmes e detecção e identificação de falhas, disponibilizadas aos operadores colaboram significativamente para a redução do tempo necessário para o diagnóstico e a posterior resolução da falha. Isso contribui significativamente para reduzir as perdas operacionais e aumentar a confiabilidade geral do sistema BOP.

A metodologia foi aplicada a um conjunto de dados reais notoriamente fora do limite operacional e a dados simulados com falhas que normalmente ocorrem neste tipo de equipamento/sensor, tais como: *sensor drift* e repetibilidade, onde em ambas as situações, a metodologia proposta foi capaz de detectar e identificar a origem da falha de forma consistente. Vale salientar que para a solução proposta ser eficiente, o conjunto de dados de treinamento, os quais necessariamente precisam estar dentro dos limites e condições normais de operação, deve possuir uma boa qualidade em termos estatísticos. Por essa razão ferramentas estatísticas, tais como, coeficiente de variação e análise e remoção de *outliers*, fazem parte da metodologia proposta.

A metodologia abordada nesta dissertação tem por objetivo principal auxiliar ao

operador na identificação das falhas ocorridas, contribuindo para o diagnóstico das mesmas e redução de perdas operacionais. Pelos resultados obtidos, considera-se que a metodologia desenvolvida pode ser facilmente adaptada para aplicação em históricos de dados provenientes de outros sistemas BOP.

Por fim, observa-se que nesta dissertação a detecção e identificação de falhas não ocorreu em tempo real. Em termos práticos é esperado que a metodologia de detecção e identificação de falhas ocorra de forma simultânea à operação do sistema. E ainda, ressalta-se a necessidade de ir além da detecção e identificação de falhas, contemplando as etapas de diagnóstico e remoção dos efeitos ocasionados pela falha, por meio da ação sobre a variável ou variáveis responsáveis por tal falha. Para trabalhos futuros a metodologia proposta nesse trabalho pode ser adaptada com o objetivo de implementar um modelo computacional para a análise de dados em tempo real, bem como técnicas de mineração de dados como por exemplo, Redes Neurais e Análise de *Clusters*, podem ser utilizadas para a busca por padrões de falha e análises de agrupamentos.

Referências

- ABEDIN, J. *Data manipulation with R*. [S.l.]: Packt Publishing, 2014. ISBN 9781783281091.
- ALEXANDRE, G. B.; LIMA, A. M. L.; NETO, J. Monitoramento de eventos anormais em processos industriais via análise de componentes principais. In: *Anais do XIX Congresso Brasileiro de Automática*,. Campina Grande: [s.n.], 2012. p. 3274–3281.
- A.P.I Spec. 16D. 2004.
- BEZERGIANNI, S.; KALOGIANNI, A. Application of Principal Component Analysis for monitoring and disturbance detection of a hydrotreating process. *Industrial & Engineering Chemistry Research*, v. 47, n. 18, p. 6972–6982, 2008.
- CAI, B.; LIU, Y.; FAN, Q.; ZHANG, Y. Application of Bayesian Networks to reliability evaluation of software system for subsea Blowout Preventers. *International Journal of Control and Automation*, v. 6, n. 1, p. 47–60, 2013.
- CHEN, M.; ZHENG, A.; LLOYD, J.; JORDAN, M.; BREWER, E. Failure diagnosis using decision trees. In: *International Conference on Autonomic Computing*. New York, NY: IEEE, 2004. p. 36–43.
- CHIANG, L. H.; RUSSELL, E. L.; BRAATZ, R. D.; RUSSELL, E. L. *Fault detection and diagnosis in industrial systems*. London: Springer London, 2001. 392 p. (Advanced Textbooks in Control and Signal Processing).
- DUNIA, R.; QIN, S. J.; EDGAR, T. F.; MCAVOY, T. J. Identification of faulty sensors using principal component analysis. *AIChE Journal*, v. 42, n. 10, p. 2797–2812, oct 1996. ISSN 0001-1541.
- FU, X. *Sensor fault detection and diagnosis of air handling units*. Tese (Doutorado) — Hong Kong Polytechnic University, 2004.
- GARCIA, C. H. Tabelas para classificação do coeficiente de variação. *Piracicaba - IPEF*, n. 1985, p. 10, 1989.
- GE/HYDRIL. *Deepwater Drilling System*. 2013. Disponível em: <http://hydrilpressurecontrol.com/>.
- GOMES, F. P. *Curso de estatística experimental*. 13. ed. Piracicaba: Nobel, 1990.
- HAIR, J.; ANDERSON, R.; TATHAM, R.; BLACK, W. *Análise multivariada de dados*. 5. ed. Porto Alegre: Bookman, 2005.

- HARROU, F.; KADRI, F.; CHAABANE, S.; TAHON, C.; SUN, Y. Improved Principal Component Analysis for anomaly detection: Application to an emergency department. *Computers & Industrial Engineering*, v. 88, p. 63–67, 2015.
- HE, X.; SÖRMAN, J.; ALME, I. A.; ROPER, S. BOP Risk Model development and applications. In: *Probabilistic Safety Assessment and Management PSAM 12*. Honolulu - Hawaii: [s.n.], 2014.
- HOLAND, P.; RAUSAND, M. Reliability of subsea BOP systems. *Reliability engineering*, v. 19, n. Junho, p. 263–275, 1987.
- HOTELLING, H. Analysis of a complex of statistical variables into Principal Components. *Journal of Educational Psychology*, v. 24, n. 7, p. 498–520, 1933.
- ISERMANN, R.; BALLÉ, P. Trends in the application of model-based fault detection and diagnosis of technical processes. *Control engineering practice*, v. 5, n. 5, p. 709–719, 1997.
- JACKSON, J. E.; MUDHOLKAR, G. S. Control procedures for residuals associated with Principal Component Analysis. *Technometrics*, v. 21, n. 3, p. 341–349, 1979.
- JENG, J.-c.; LI, C.-c.; HUANG, H.-p. Fault detection and isolation for dynamic processes using recursive principal component analysis (PCA) based on. *2011 International Symposium on Advanced Control of Industrial Processes (ADCONIP)*, n. October, p. 501–509, 2007.
- JOHNSON, R. A.; WICHERN, D. W. *Applied multivariate statistical analysis*. 6. ed. [S.l.]: Pearson Prentice Hall, 2007. 800 p. ISBN 0131877151.
- JORGE, N. D. M.; WOLFRAM, J.; CLARK, P. Reliability assessment of subsea Blowout Preventers. 20th International Conference on Offshore Mechanics and Arctic Engineering, Rio de Janeiro, p. 1–10, 2001.
- JUNIOR, G. C. Z. *Diagnóstico de falhas em processos industriais via causalidade de Granger*. Tese (Dissertação Mestrado) — Universidade Federal do Espírito Santo, 2015.
- KABACOFF, R. I. *Data analysis and graphics with R*. New York, NY: Manning Publications, 2011.
- KOURTI, T.; NOMIKOS, P.; MACGREGOR, J. F. Analysis, monitoring and fault diagnosis of batch processes using multiblock and multiway PLS. *Journal of Process Control*, v. 5, n. 4, p. 277–284, 1995.
- LIRA, A. C. d. Q.; GOMES, M. d. L. B.; CAVALCANTI, V. Y. S. d. L. Modelo de alinhamento estratégico de produção – MAP: contribuição teórica para a área de estratégia de produção. *Production*, v. 25, n. 2, p. 416–427, jun 2015.
- LIU, J.; LIM, K.-w.; SRINIVASAN, R.; DOAN, X.-t. On-line process monitoring and fault isolation using PCA. In: *International Symposium on Intelligent Control*. Limassol - Chipre: IEEE, 2005. p. 658–661.
- MACGREGOR, J.; KOURTI, T. Statistical process control of multivariate processes. *Control Engineering Practice*, v. 3, n. 3, p. 403–414, 1995.

- MALOUF, L. R. *Análises das operações de perfuração de poços terrestres e marítimos*. Tese (Projeto de Graduação) — Universidade Federal do Rio de Janeiro, 2013.
- MARTIN, E.; MORRIS, A.; ZHANG, J. Process performance monitoring using multivariate statistical process control. *IEE Proceedings of Control Theory and Applications*, v. 143, n. 2, p. 132–144, 2002. ISSN 1350-2379.
- MIHUT, M. Analyzing log files using Data Mining. *Journal of Applied Computer Science*, v. 2, n. 2, p. 32–34, 2008.
- MILNE, R. Strategies for diagnosis. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 17, n. 3, p. 333–339, 1987.
- MINELLI, M. *Data mining and business analytics with R*. 1. ed. [S.l.]: John Wiley & Sons, 2013. ISBN 9781118147603.
- MINGOTI, S. A. *Análise de dados através de métodos de estatística multivariada: Uma abordagem aplicada*. 1. ed. Belo Horizonte: Editora UFMG, 2005.
- MISHRA, R.; DUBEY, S. M.; SHRIVASTAVA, K. K. Analysis of system error log using Association Mining. *UACEE International Journal of Computer Science and its Applications*, p. 12–17, 2013.
- MONTGOMERY, D. *Introduction to statistical quality control*. 3. ed. [S.l.]: John Wiley & Sons, Inc., 2009.
- NOMIKOS, P.; MACGREGOR, J. Multivariate statistical process control charts for monitoring batch processes. *Technometrics*, v. 37, n. 1, p. 41–59, 1995.
- PETROMIN. Blowout Preventers – history, performance and advances. *Petromin*, v. 34, n. 7, p. 52–60, 2011.
- PYLE, D. *Data preparation for data mining*. 1. ed. San Francisco, CA: Morgan Kaufmann Publishers, 1999.
- QIN, S. J. Statistical process monitoring: basics and beyond. *Journal of Chemometrics*, v. 17, n. 8-9, p. 480–502, 2003.
- REIS, E. *Estatística descritiva*. 7. ed. Lisboa: Silabo, 1991.
- SANTOS-FERNÁNDEZ, E. *Multivariate statistical quality control using R*. New York, NY: Springer New York, 2012. v. 14. (SpringerBriefs in Statistics, v. 14). ISBN 978-1-4614-5452-6.
- SILVA, J. G. B. da. *Aplicação da Análise de Componentes Principais (PCA) no diagnóstico de defeitos em rolamentos através da assinatura elétrica de motores de indução*. Tese (Dissertação de Mestrado) — Universidade Federal de Itajubá, 2008.
- SILVA, S. G. da. *Confiabilidade de equipamentos submarinos de segurança de sondas flutuantes (BlowOut Preventers - BOP)*. 210 p. Tese (Dissertação de Mestrado) — Universidade Federal do Rio de Janeiro, 2002.
- TABACHNICK, B.; FIDELL, L. *Using multivariate statistics*. 5. ed. Boston: Pearson Education, 2007.

- VENKATASUBRAMANIAN, V. A review of process fault detection and diagnosis: Part III: Process history based methods. *Computers & Chemical Engineering*, v. 27, p. 293–311, 2003. ISSN 00981354.
- VICINI, L. *Análise multivariada da teoria à prática*. 1. ed. Santa Maria: Universidade Federal de Santa Maria, 2005.
- VILLEGAS, T.; FUENTE, M.; RODRÍGUEZ, M. Principal component analysis for fault detection and diagnosis. experience with a pilot plant. In: *Proceedings of the 9th WSEAS international conference on computational intelligence, man-machine systems and cybernetics*. Merida: [s.n.], 2010. p. 147–152.
- WESTERHUIS, J. A.; GURDEN, S. P.; SMILDE, A. K. Generalized contribution plots in multivariate statistical process monitoring. *Chemometrics and Intelligent Laboratory Systems*, v. 51, n. 1, p. 95–114, 2000.
- YAIRI, T.; KAWAHARA, Y.; FUJIMAKI, R.; SATO, Y.; MACHIDA, K. Telemetry-mining : A Machine Learning approach to anomaly detection and fault diagnosis for space systems. In: *Space Mission Challenges for Information Technology, 2006. SMC-IT 2006. Second IEEE International Conference on*. Tokyo, Japan: Research Center for Advanced Science and Technology University, 2006.

APÊNDICE A – Artigo não publicado

ANÁLISE DA CONTRIBUIÇÃO INDIVIDUAL DOS COMPONENTES DO SISTEMA PREVENTOR DE EXPLOSÃO SUBMARINO (BOP) PARA O TEMPO TOTAL NÃO PRODUTIVO UTILIZANDO O MÉTODO AHP

Vanderson Pimenta Carvalho*

Edwin Benito Mitacc Meza*

Ana Paula Sobral*

Alessandro Copetti*

Abstract

O sistema de prevenção de explosões em poços de petróleo submarinos (BOP) possui papel indispensável nas atividades exploratórias de petróleo. Como se trata de um equipamento de segurança, a rapidez e a eficiência na descoberta de potenciais falhas são de vital importância para a rentabilidade do trabalho, para a segurança de todos a bordo da plataforma de petróleo e para a proteção do meio ambiente. Por ser um sistema complexo e com um grande número de componentes associados, a identificação de falhas no sistema BOP e quais componentes à elas estão associados, não se mostra uma tarefa trivial. Alguns especialistas mais experientes conseguem de forma empírica identificar e associar algumas destas falhas.

Este trabalho objetiva contabilizar as falhas associadas a cada componente do BOP e sua contribuição para o aumento do tempo não produtivo (*downtime*) utilizando o conhecimento de especialistas. O método AHP (Analytic Hierarchy Process) foi utilizado para analisar os dados obtidos por um questionário e obter o fator de contribuição para o *downtime* de cada componente.

Palavras-chaves: BOP, AHP, downtime, falha, blowout preventer

* Universidade Federal Fluminense
Campus Rio das Ostras
Mestrado Profissional em Engenharia de Produção e Sistemas Computacionais

1. Introdução

Dentro da cadeia produtiva da indústria do petróleo e gás, as empresas operadoras, que tem como foco de negócio a produção de petróleo, gás e derivados, tem na perfuração dos poços de petróleo e gás o ponto culminante das prospecções. Nesta fase de perfuração de um poço de petróleo em águas profundas, é comum encontrar zonas de alta pressão ou algum outro problema no poço de petróleo que leve a diminuição da pressão hidrostática sobre a formação (SILVA, 2002). Ainda segundo Silva (2002), quando isso ocorre, existe a possibilidade de haver influxo de fluídos provenientes da formação para o poço, o que é denominado *kick*, que se não for contido, poderá ocasionar um fluxo indesejado e inesperado de hidrocarbonetos provenientes da formação para a superfície, denominado *blowout*. Este *blowout* poderá acarretar paradas de produção, perda de equipamentos e da própria plataforma, ocasionar perda financeira significativa, gerar desastres ambientais e perda de vidas. Diante disto, todo poço de petróleo durante a fase de perfuração possui um equipamento Preventor de Explosão Submarino (BOP – *BlowOut Preventer*).

O BOP consiste basicamente de um conjunto de válvulas submarinas instaladas em forma de pilha (*stack*), operadas através de controles ou comandos realizados a partir da superfície, responsáveis por controlar e monitorar os fluxos de hidrocarbonetos nos poços de petróleo e gás (PETROMIN, 2011). É importante ressaltar que, além dos inúmeros componentes passíveis de ocorrência de falhas, Jorge et al. (2001) identificaram que sistemas projetados para trabalhar em altas profundidades, tais como os sistemas de BOP considerados neste trabalho, apresentam mais falhas do que aqueles projetados para trabalho em baixas profundidades.

De acordo com Nguyen (2009), o risco de falha de um determinado sistema está diretamente associado a confiabilidade de cada componente individualmente. Estimar o risco associado a este sistema não é uma tarefa trivial devido a sua complexidade e falta de um histórico de dados sobre sua confiabilidade, bem como, as características empíricas de sua operação. Neste cenário, segundo Mazzuchi et al. (2008), uma estimativa subjetiva baseada na opinião de especialistas se torna bastante atraente.

Neste sentido, por exemplo, E. Araújo et al. (2010) apresentam uma proposta de utilização do método AHP para apoiar o processo de identificação das causas de falhas em sistemas de distribuição de energia elétrica. Para esse autor o método AHP oferece uma abordagem simplificada e intuitiva à problemas complexos através de sua decomposição

hierárquica, permitindo avaliar o grau de consistência das informações utilizadas no desenvolvimento do método.

Já em Mirabedini; Gorji (2001) é descrito a utilização do método AHP para diagnóstico de falhas em sistemas de geradores síncronos, com o objetivo de identificar a falha mais provável e reduzir seu impacto. De forma semelhante, em Nguyen (2009) utiliza-se o método AHP na estimativa de risco associado a falha do sistema de propulsão de um navio mercante. A contribuição para falha de cada componente do sistema de propulsão da embarcação foi obtida pelo processamento, utilizando o método AHP, das respostas dos engenheiros da embarcação a um questionário. O questionário continha o nome de cada subsistema e sua possível contribuição, em cinco (5) escalas linguísticas, para o risco de falha de todo o sistema.

Como o BOP é um equipamento de segurança, torna-se imperativo investigar a contribuição de cada componente para o tempo total no qual a plataforma está fora de operação (*downtime*). Conhecer o fator de contribuição é de suma importância, uma vez que não necessariamente o componente que mais impacta no tempo total de *downtime* é aquele que apresenta o maior número de falhas. Por este fato, o conhecimento do especialista é essencial.

Mesmo já existindo trabalhos relacionados a confiabilidade e análise de falhas do sistema BOP, como por exemplos Holand (2001) e Silva (2002), é importante ressaltar que a análise de falhas nos sistemas de BOP é algo extremamente incipiente, e foi identificado até o momento nenhum trabalho onde o método AHP foi aplicado a este tipo de análise para o referido equipamento. Outros trabalhos já atuaram na área de identificação de falhas utilizando o método AHP, conforme trabalhos citados anteriormente, mas nenhum com o foco no sistema de BOP

O presente trabalho propõe a aplicação do método AHP para a análise da contribuição de um grupo de componentes do BOP no aumento do tempo de parada de operação (*downtime*). Para obtenção da estimativa de contribuição de cada componente foram utilizados dados coletados através de um questionário, contendo de forma empírica a contribuição individual dos componentes e subsistemas para a falha e *downtime* no sistema como um todo.

2. Materiais e métodos

Neste capítulo é discutida a metodologia para a obtenção dos dados. Para este trabalho, os dados foram obtidos através das repostas para 27 perguntas submetidas a um grupo de dez especialistas (*subsea engineers*) – procedentes de diferentes empresas nacionais e internacionais – com mais de 5 anos de experiência com o BOP de um mesmo fabricante, com características técnicas semelhantes. Estes especialistas na operação e manutenção de um particular sistema de BOP responderam ao questionário de acordo com sua experiência e histórico de falhas no equipamento sob sua responsabilidade.

Os especialistas expressaram suas opiniões sobre a contribuição de um particular componente do subsistema do BOP em relação ao número total de falhas ocorridas e tempo de *downtime*, em uma escala de cinco (5) opções entre *very small* e *very high*. Tais opções expressam de forma linguística a preferência do especialista em relação a contribuição de um componente em particular como causa de falha e *downtime* no sistema. Para a criação e gerenciamento do questionário foi utilizado a ferramenta *Google Forms*.

As subseções 2.1 e 2.2 discutem falhas e situações de *downtime* no contexto de confiabilidade e a metodologia AHP.

2.1. Confiabilidade

De acordo com a Associação Brasileira de Normas Técnicas (1994), confiabilidade é a capacidade de um determinado item desempenhar uma função requerida sob condições específicas, durante um dado intervalo de tempo. Já a falha é definida como o término da capacidade do item desempenhar a função requerida. Logo, pode-se observar que confiabilidade e falha são antagônicos em suas definições. Ou seja, quando se reduz a possibilidade de falha se aumenta a confiabilidade e conseqüentemente o tempo do sistema em operação.

Segundo Silva (2002), quantitativamente a probabilidade é definida como a probabilidade de que um equipamento opere com sucesso por um período de tempo especificado e sob condições de operação também especificadas. A confiabilidade pode ser dividida em: Confiabilidade de componentes e sistemas.

A confiabilidade de componentes consiste em analisar, ao longo do tempo, como se comporta uma família de componentes idênticos ou mesmo um único componente. Com essa

análise é possível obter valores médios do tempo que este componente, em média, opera sem apresentar falha, bem como o tempo médio que este componente permanece em manutenção.

A confiabilidade de sistemas, por sua vez, utiliza dados estatísticos de tempo médio entre falhas e tempos médios de reparo de componentes do sistema. Estes dados são então combinados com o objetivo de verificar a disponibilidade do sistema como um todo.

Em manutenção se associa uma taxa de falhas decrescente ao período de mortalidade infantil ou falhas prematuras do equipamento. Neste período as falhas são atribuídas em sua maioria a deficiências iniciais do projeto e dos componentes, sendo sanadas à medida em que são identificadas. A uma taxa de falhas constante se associa o período de maturidade do equipamento. Neste período ocorrem falhas pouco previsíveis, puramente aleatórias, que obedecem a um processo de Poisson homogêneo. Finalmente, a uma taxa de falhas crescente se associa o período de mortalidade senil, por desgaste dos materiais. Neste período as falhas se tornam inevitáveis por perda na resistência dos materiais, indicando-se uma política de reposição preventiva. A Figura 1 sintetiza estas informações em um formato mais genérico da função $h(t)$ ao longo do ciclo de vida, a curva da banheira (*bath-tube curve*). A curva da banheira é uma construção abstrata que expressa a expectativa de falha de um item ao longo do tempo, dado que ainda não falhou até este tempo: segundo LAFRAIA (2001) é o valor esperado da taxa de falha ao longo de todo o tempo de observação.




Figura 1 - Curva da banheira e ciclo de vida de equipamentos (LAFRAIA, 2001)

Segundo Silva (2002), para os sistema de BOP a taxa de falha pode ser considerada constante. Isso ocorre devido ao controle de qualidade realizado, os testes de qualificação de componentes e testes de integração antes do equipamento entrar em operação, o que tende a eliminar as falhas da fase inicial (fase da mortalidade infantil). E as constantes manutenções e troca de componentes de forma preditiva, tentem a reduzir as falhas na fase de mortalidade senil.

2.2. O método AHP

O método AHP é um método de análise multicritério baseado em um processo de ponderação, onde os diversos atributos relevantes são representados por sua importância relativa. Este método, devido a sua eficácia, tem sido utilizado em diversas áreas de conhecimento onde a tomada de decisão utilizando variáveis empíricas e linguísticas é necessária (Saaty, 1999).

Abreu; Campos (2007) definem o método AHP como uma técnica de análise de decisão que se fundamenta na comparação de alternativas de escolha, duas a duas, onde o agente decisório realiza comparações paritárias relativas a duas alternativas da estrutura de decisão, perguntando-se qual elemento satisfaz mais e quanto mais. Através do AHP, busca-se responder à seguinte problemática: dado um conjunto n de alternativas, separar estas em classes equivalentes e fornecer uma pré-ordenação que expresse as posições relativas destas classes em concordância a critérios pré-estabelecidos.

Saaty (1999) observa que, apesar das diferenças entre os estímulos seguirem uma escala geométrica, a percepção destes pelo indivíduo obedece a uma escala linear. A escala recomendada por Saaty (1994), mostrada na Tabela 1, possui valores entre 1 e 9, com 1 significando a indiferença de importância de um critério em relação ao outro, e 9 significando a extrema importância de um critério sobre outro, com estágios intermediários de importância entre esses níveis 1 e 9. Além disso, segundo Costa (2002), desconsiderando as comparações entre os próprios critérios, que representam 1 na escala, apenas metade das comparações precisa ser feita, pois a outra metade são os valores recíprocos já comparados. O método AHP baseia-se no pensamento newtoniano e cartesiano, onde se divide um problema complexo em fatores, que podem ainda ser decompostos em novos fatores até ao nível mais baixo, claros e dimensionáveis e estabelecendo relações para depois sintetizar.

Tabela 1 - Escala de importância relativa.

1	Igual Importância	As duas atividades contribuem igualmente para o objetivo
3	Importância pequena de uma para a outra	A experiência e o julgamento favorecem levemente uma atividade em relação à outra.
5	Importância grande ou essencial	A experiência e o julgamento favorecem fortemente uma atividade em relação à outra.
7	Importância muito grande ou demonstrada	Uma atividade é fortemente favorecida em relação à outra
9	Importância absoluta	A evidência favorece uma atividade em relação à outra com o mais alto grau de certeza.
2,4,6,8	Valores intermediários	Quando se procura uma condição de compromisso entre as atividades.

Fonte: Saaty (1994)

Desta forma, de acordo com Costa (2002) este método baseia-se em três etapas de pensamento analítico:

Construção da hierarquia: Nesta etapa, os elementos chaves do problema para a tomada de decisão são identificados e agrupados em conjuntos afins, os quais são ordenados em camadas específicas, com o objetivo de buscar uma melhor compreensão do mesmo,

Definição de prioridades: Segundo Saaty (1994) “o ser humano tem a habilidade de perceber as relações entre as coisas que observa, comparar pares de objetos similares à luz de certos critérios, e discriminar entre os membros de um par através do julgamento da intensidade de sua preferência de um elemento sobre o outro”. Nesta etapa, cada objeto é comparado paritariamente pelos critérios definidos anteriormente. A quantidade de julgamentos necessários para a construção de uma matriz de julgamentos genérica M é $n(n-1)/2$, onde n é o número de elementos pertencentes a esta matriz. Os elementos de M são definidos pelas condições:

$$A = \begin{bmatrix} 1 & a_{12} & \cdots & a_{1n} \\ 1/a_{21} & 1 & \cdots & a_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ 1/a_{n1} & 1/a_{n2} & \cdots & 1 \end{bmatrix}, \text{ onde:}$$

$$a_{ij} > 0 \Rightarrow \textit{positiva}$$

$$a_{ij} = 1 \therefore a_{ji} = 1$$

$$a_{ij} = 1/a_{ji} \Rightarrow \textit{recíproca}$$

$$a_{ik} = a_{ij} \cdot a_{jk} \Rightarrow \textit{consistência}$$

Consistência lógica: o ser humano tem a habilidade de estabelecer relações coerentes entre objetos ou ideias de que estas se relacionem bem entre si e suas relações apresentem consistência Saaty (1999). Assim, o método AHP propõe calcular a Razão de Consistência dos julgamentos, denotada por $RC = IC/IR$, onde IR é o Índice de Consistência Randômico obtido para uma matriz recíproca de ordem n , com elementos não-negativos e gerada randomicamente. O Índice de Consistência (IC) é dado por $IC = (\lambda_{\text{máx}} - n)/(n-1)$, onde $\lambda_{\text{máx}}$ é o maior autovalor da matriz de julgamentos. Segundo Saaty (1999) a condição de consistência dos julgamentos deve ser $RC \leq 0,10$.

3. Aplicação do método AHP e análise dos resultados

Como busca-se a contribuição das falhas de cada componente do sistema ao tempo de *downtime*, se faz necessária a decomposição do sistema em componentes para garantir uma melhor aplicabilidade do método AHP, e facilidade na visualização dos resultados. Esta metodologia de divisão dos componentes em grupos baseou-se, de forma não categórica, na norma ISO14224. Esta norma descreve os princípios da coleta de dados e os termos e definições associados que constituem uma “linguagem de confiabilidade” que pode ser útil para a comunicação da experiência operacional.

Holand; Rausand (1987) em seu estudo sobre a confiabilidade dos sistemas BOP dividiram o sistema BOP em nove (9) grupos principais, sem no entanto especificar os componentes que compõem cada um destes grupos. Jorge et al. (2001) subdividiram o sistema de BOP em treze (13) grupos para análise de confiabilidade, tomando como base a posição de instalação de cada componente no sistema. No entanto, o trabalho não considerou alguns componentes importantes e agrupou outros que pertencem a distintos grupos funcionais.

Uma das contribuições deste trabalho foi dividir o sistema em componentes – também definidos como alternativas no método AHP – os quais foram agrupados em sete (7) grupos

de acordo ao subsistema que o mesmo pertence. Esta divisão baseou-se na experiência prévia de um dos autores em sistemas BOP. A Tabela 2 mostra a contribuição individual de cada componente para *downtime* do sistema, após a aplicação do método AHP utilizando os dados provenientes dos questionários.

Tabela 2 – Contribuição de cada componente do BOP e agrupamentos

Grupo	Componente	Contribuição
Surface Hydraulics	Surface Accumulators	1.7%
	Fluid Reservoir Unit (FRU)	0.6%
	High Pressure Unit (HPU)	0.6%
MUX Cable & Winches	Winches	0.7%
	MUX Cable	2.2%
	MUX Connector	0.7%
MUX POD Hydraulics	MUX POD Shear Seal Valves	4.9%
	MUX POD SPM Valves	1.2%
	MUX POD Seals and Accumulators	4.9%
	BOP MUX POD Hydraulics (including leakage)	12.2%
MUX POD Electronics	MUX POD Solenoid Valves	1.1%
	MUX POD Electrical Connectors and Cables	5.3%
	MUX POD Subsea Electronic Modules(SEM)	1.1%
	Subsea Transformer / Power	1.1%
	MUX POD Controls (including sensors, etc..)	5.3%
LMRP / STACK	Rigid Conduit and Hot Line	1.2%
	LMRP/STACK Seals	1.2%
	LMRP/STACK SPM Valves (including subsea manifold)	3.0%
	LMRP/STACK Hydraulics (including leakage)	3.0%
	LMRP/STACK Riser And Wellhead Connector	7.5%
	LMRP/STACK Accumulators	3.0%
	Stack Controls (Including cables and sensors on the stack)	7.5%
Surface Controls	Surface Control System - Hardware (Panels, cabling ,etc..)	3.4%
	UPS/UPQ Electrical Power Systems	1.1%
	Surface Control System – Software	3.4%
BOP preventers (RAMS, Annulars,etc..)	STACK RAM Preventers (including MPL)	20.2%
	LMRP/STACK Annular Preventer	2.2%

fonte: Os Autores

As informações provenientes dos questionários foram inseridas no programa *Expert Choice*, cuja contribuição de cada componente e de seu respectivo grupo foram calculadas através da comparação par-a-par utilizando a escala de cinco valores (1,3,5,7 e 9). A inconsistência do modelo calculada foi de 0,08, o que significa que os dados possuem consistência adequada de acordo com o valor definido pelo método AHP, já que, segundo Saaty (1999) o valor dever ser menor que 0,1. A contribuição individual dos sete (7) grupos é apresentada na Figura 1.




Figura 1 – Contribuição por grupo

O resultado mostrou que os grupos denominados: *BOP preventers (RAM, ANNULAR, etc.)* e *MUX POD Hydraulics*, contribuem significativamente nas falhas e *downtime*. Tais grupos não necessariamente constituem a causa do maior número de falhas, mas contribuem de maneira significativa para o maior número de horas em *downtime*.

Esse resultado pode ser confrontado com outros trabalhos. Holand (2001) conduziu um estudo sobre a confiabilidade dos BOPs, onde concluiu que o sistema preventivo (RAM, e ANNULAR) é responsável pelos maiores valores de tempo em *downtime*. Em especial, segundo Holand (2001), o maior causador de problemas operacionais são os atuais sistemas de travamento dos preventores de gaveta (RAM). Falhas em tais sistemas consomem um tempo considerável para serem sanadas, uma vez que a total desmontagem deste sistema é requerida para reparo. Jorge et al. (2001) em um estudo de confiabilidade do sistema BOP, concluem que problemas no sistema de controle hidráulico do POD MUX são fatores significantes para a falha geral do sistema e consequentemente *downtime*.

3.1. Análise dos logs de alarmes do BOP

Esta subseção analisa se o arquivo de log de um BOP específico apresenta alarmes dos componentes que mais apresentam problemas. Os alarmes são registrados pelo sistema de controle do BOP quando o valor da variável monitorada ultrapassa uma faixa de valores operacionais pré definidos. Duas hipóteses podem ser levantadas quanto aos alarmes não existirem ou os alarmes existirem em grandes quantidades.

A primeira hipótese é que não existam dados e alarmes gerados pelo sistema de controle relacionados aos componentes com maior índice de falha. Isso pode ser um

indicativo que o valor máximo e mínimo para ativação do alarme não está corretamente ajustado. A segunda hipótese é que os alarmes relacionados aos componentes com maior índice de falhas são negligenciados, devido a quantidade excessiva de alarmes gerada pelo sistema de controle do BOP.

Uma informação importante a ser obtida antes de se dar continuidade as demais análises de dados é verificar se o BOP se encontra em operação ou não, uma vez que essa informação influencia todos os dados adquiridos pelo sistema.

Para definir o período operacional, apresenta-se a seguinte hipótese: O período de operação do BOP pode ser verificado através da análise dos dados provenientes de sensores de pressão embarcados no BOP. Os sensores utilizados são os que medem a pressão hidrostática (cada POD de controle possui um par destes sensores - números 03 e 20), o sensor de pressão que mede a pressão de fechamento do conector de travamento do BOP à cabeça do poço (número 11) e o sensor de pressão do conector de travamento da parte superior do BOP (LMRP) (número 02) com a parte inferior (STACK). Com isso parte-se das seguintes premissas:

- a) Como se trata de um equipamento utilizado em águas profundas o valor da pressão hidrostática deve ser maior que 500 metros de lamina d'água, ou seja:

$$P_{hidrostática} \geq 500 \text{ psi}$$

- b) Uma vez que pressão nominal de trabalho é da ordem 1500 psi, a pressão de travamento dos conectores do riser e da cabeça de poço deve ser maior que 1000 psi, ou seja:

$$P_{riser \ connector} \geq 1000 \text{ psi}$$

$$P_{wellhead \ connector} \geq 1000 \text{ psi}$$

A metodologia descrita acima foi aplicada a um conjunto de dados coletados em 2010 de uma plataforma em operação na bacia de Campos. O método foi capaz de verificar que entre abril e agosto de 2010 o BOP estava efetivamente em operação, o que foi comprovado utilizando os relatórios diários emitidos pela plataforma.

Para o período operacional acima, a Tabela 3 apresenta o número de alarmes para cada componente do sistema.

Tabela 3 - Quantidade de alarmes para cada componente do BOP

Grupo	Componente	Existe sensor relacionado	# Alarmes no período	Contribuição em relação ao total de alarmes
Surface Hydraulics	Surface Accumulators	X	32	0.034%
	Fluid Reservoir Unit (FRU)	X	60	0.064%
	High Pressure Unit (HPU)	X	46	0.049%
MUX Cable & Whinches	Whinches			
	MUX Cable			
	MUX Connector			
MUX POD Hydraulics	MUX POD Shear Seal Valves			
	MUX POD SPM Valves			
	MUX POD Seals and Accumulators			
	BOP MUX POD Hydraulics (including leakage)	X	304	0.324%
MUX POD Electronics	MUX POD Solenoid Valves	X	0	0.000%
	MUX POD Electrical Connectors and Cables	X	10800	11.528%
	MUX POD Subsea Electronic Modules(SEM)	X	0	0.000%
	Subsea Transformer / Power	X	0	0.000%
	MUX POD Controls (including sensors, etc..)	X	74077	79.071%
LMRP / STACK	Rigid Conduit and Hot Line	X	30	0.032%
	LMRP/STACK Seals			
	LMRP/STACK SPM Valves (including subsea manifold)			
	LMRP/STACK Hydraulics (including leakage)	X	934	0.997%
	LMRP/STACK Riser And Wellhead Connector	X	549	0.586%
	LMRP/STACK Accumulators	X	0	0.000%
Surface Controls	Stack Controls (Including cables and sensors on the stack)	X	2	0.002%
	Surface Control System - Hardware (Panels, cabling ,etc,..)	X	0	0.000%
	UPS/UPQ Electrical Power Systems	X	203	0.217%
	Surface Control System – Software	X	4831	5.157%
BOP preventers (RAMS, Annular,etc..)	STACK RAM Preventers (including MPL)			
	LMRP/STACK Annular Preventer	X	1816	1.938%
		Total	93684	100.00%

Os resultados mostram que os grupos com maior contribuição de falha possuem pouco monitoramento de sensores. Com isso, uma possível predição do estado destes componentes em tempo real se torna difícil de ser implementada. Tais resultados também demonstram que alguns componentes, mesmo que monitorados, não possuem quantidade significativa de dados gravados, o que pode indicar que os limites de alarme destes componentes não estejam ajustados de maneira adequada para garantir um monitoramento adequado.

Com o objetivo de verificar a quantidade de alarmes reconhecidos (*Alarm Acknowledge*) pelos operadores através do acionamento de um botão para esta função, uma análise nos dados de alarme foi efetuada, onde extraiu-se a quantidade de reconhecimentos de alarmes no período sob estudo. Comparando-se este resultado com o número total de alarmes observou-se que somente 0,47% (440 alarmes) do universo total de alarmes foi reconhecido pelos operadores. Estes resultados indicam que os alarmes normalmente não são reconhecidos pelo operador, ou seja, são ignorados na maioria dos casos.

4. Conclusão

Este trabalho apresentou a aplicação do método AHP para a estimativa da contribuição de cada subsistema de um *BlowOut Preventer* (BOP) para o tempo total de *downtime*. O objetivo principal foi definir os componentes que quando falham geram um maior impacto na redução do tempo operacional. Através das informações provenientes do dia-a-dia operacional e da experiência dos especialistas aplicadas a um método científico, pode-se auxiliar na melhoria da confiabilidade geral do sistema de BOP e redução da perda financeira a ele associada. Uma vez definidos os itens mais críticos, os quais podem receber melhor atenção através da aplicação de uma política de manutenção preditiva, o que acarretaria uma melhoria operacional considerável e uma redução do tempo de *downtime* futuro. A utilização do método AHP possibilita que a opinião e a experiência dos especialistas tornem-se fundamentais para o sucesso da análise. O método se torna extremamente eficaz quando variáveis empíricas fundamentadas em tais experiências e opiniões podem ser agrupadas e analisadas de uma maneira cientificamente comprovada.

Referências bibliográficas

- ABREU, A. DE O.; CAMPOS, R. DE. O método ABC/AHP aplicado a uma industria de serviços. XXVII Encontro Nacional de Engenharia de Produção. p.1–9, 2007. Foz do Iguaçu - PR - Brasil.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Confiabilidade e manutenibilidade**. Brasil, 1994.
- COSTA, H. G. Introdução ao método de análise hierárquica. XXXVI - SBPO. 2002. Sao João del Rei - MG.
- E. ARAÚJO; LEMOS, F. A. B.; PRETTO, C. O. Aplicação do método AHP para auxílio na identificação de causas de falhas de sistemas elétricos. **XVIII Congresso Brasileiro de Automática**, 2010.
- HOLAND, P. Reliability of deepwater subsea blowout preventers. **SPE Drilling & Completion**, v. 16, n. 1, p. 12–18, 2001.
- HOLAND, P.; RAUSAND, M. Reliability of subsea BOP systems. **Reliability engineering**, v. 19, n. Junho, p. 263–275, 1987.
- JORGE, N. D. M.; WOLFRAM, J.; CLARK, P. Reliability assessment of subsea Blowout Preventers. , p. 1–10, 2001. Rio de Janeiro: 20th International Conference on Offshore Mechanics and Arctic Engineering.
- LAFRAIA, J. R. B. **Manual de confiabilidade, manutenibilidade e disponibilidade**. Rio de Janeiro: Qualitymark, 2001.
- MAZZUCHI, T. A.; LINZEY, W. G.; BRUNING, A. A paired comparison experiment for gathering expert judgment for an aircraft wiring risk assessment. **Reliability Engineering and System Safety**, 2008.
- MIRABEDINI, H.; GORJI, A. The sort of fault diagnosis in large synchronous generators by analytic hierarchy process (AHP) method. **Canadian Conference on Electrical and Computer Engineering 2001. Conference Proceedings (Cat. No.01TH8555)**, v. 2, p. 715–718, 2001.
- NGUYEN, H. The application of the AHP method in ship system risk estimation. **Polish Maritime Research**, v. 16, n. 1, p. 78–82, 2009.
- PETROMIN. Blowout Preventers – history, performance and advances. *Petromin*, v. 34, n. 7, p. 52–60, 2011.
- SAATY, T. L. **Fundamentals of decision making and priority theory with the analytic hierarchy process.(The Analytic Hierarchy Process Series)**. Pittsburgh, 1994.
- SAATY, T. L. **Decision making for leaders: the analytic hierarchy process for decisions in a complex world**. RWS publications, 1999.
- SILVA, S. G. DA. **Confiabilidade de equipamentos submarinos de segurança de sondas flutuantes (BlowOut Preventers - BOP)**, Universidade Federal do Rio de Janeiro, Departamento de Engenharia Oceânica, Dissertação de MEstrado. 2002.