PROGRAMA EQ-ANP

Processamento, Gestão e Meio Ambiente na Indústria do Petróleo e Gás Natural

Controle Estatístico Aplicado a Processos Contínuos

Caio Felippe Curitiba Marcellos

Tese de Mestrado

Orientador(es)

Prof. Maurício Bezerra de Souza Junior, D. Sc
Prof. Argimiro Resende Secchi, D. Sc.

Abril de 2013

CONTROLE ESTATÍSTICO APLICADO A PROCESSOS CONTÍNUOS

Caio Felippe Curitiba Marcellos

Tese submetida ao Corpo Docente do Curso de Pós-Graduação em Tecnologia de Processos Químicos e Bioquímicos da Escola de Química da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências.

Aprovado por:

_____
Maurício Bezerra de Souza Junior, D. Sc.
(orientador – presidente da banca)

_____
Argimiro Resende Secchi, D. Sc.
(orientador)

_____
Profª Ana Maria Frattini Fileti

_____
Eng. Mario Cesar M. Massa de Campos

_____
Profª Rossana Odette Mattos Folly

Rio de Janeiro, RJ - Brasil
Abril de 2013

Marcellos, Caio Felippe Curitiba.
Controle Estatístico Aplicado a Processos Contínuos / Caio Felippe Curitiba Marcellos Rio de Janeiro: UFRJ/EQ, 2013.
xii, 105 p.; il.
(Dissertação) – Universidade Federal do Rio de Janeiro, Escola de Química, 2013. Orientador(es): Maurício Bezerra de Souza Junior e Argimiro Resende Secchi
1. Monitoramento. 2. Monitoramento Adaptativo. 3. Compressão de gás. 4. Tese. (Mestrado – UFRJ/EQ). 5. Maurício Bezerra de Souza Junior e Argimiro Resende Secchi (na ordem normal) I. Controle Estatístico Aplicado a Processos Contínuos

AGRADECIMENTOS

Agradeço a Deus e à minha família por todo apoio e amor.

Agradeço aos meus orientadores por viabilizarem este trabalho por meio de toda a ajuda prestada, sempre com muita dedicação.

Agradeço ao pessoal do LADES pelo ambiente de amizade e aprendizagem, muitos conhecimentos foram adquiridos devido ao "conhecimento volátil" neste grupo. Em especial a Simone que me ajudou em diversos momentos, além de me oferecer oportunidades ao longo do mestrado e a Danielle que me orientou e me passou muitos ensinamentos durante os primeiros meses deste trabalho.

Devo agradecer também todos meus amigos pelos momentos de descontração.

Agradeço a Lívia por todo o companheirismo, vivência e carinho.

Ao apoio financeiro da **Agência Nacional do Petróleo** – ANP – e da **Financiadora de Estudos e Projetos** – FINEP – por meio do Programa de Recursos Humanos da ANP para o Setor de Petróleo e Gás – PRH-ANP/MCT, em particular ao **PRH 13**, da Escola de Química - Processamento, Gestão e Meio Ambiente na Indústria do Petróleo e Gás Natural.

Resumo da Tese de Mestrado apresentada ao Curso de Pós-Graduação em Tecnologia de Processos Químicos e Bioquímicos da Escola de Química/UFRJ como parte dos requisitos necessários para obtenção do grau de Mestre em Ciências, com ênfase na área de Petróleo e Gás Natural.

CONTROLE ESTATÍSTICO APLICADO A PROCESSOS CONTÍNUOS

Caio Felippe Curitiba Marcellos
Abril, 2013

Orientadores: Prof. Maurício Bezerra de Souza Junior, D. Sc.
Prof. Argimiro Resende Secchi, D. Sc.

Nos últimos anos, a necessidade de manter operações industriais seguras e confiáveis tem tomado grandes proporções. Na indústria de processos contínuos, em particular, estas questões são ainda mais importantes devido a suas características: alta velocidade de produção; automação intensificada; tempos de paradas causam grandes impactos e baixa flexibilidade de produção, já que frequentemente trabalha-se em capacidade máxima. No setor petroquímico as especificações de segurança são rígidas devido ao risco de se trabalhar com produtos inflamáveis, tóxicos e em altas pressões.

Este cenário atual vem aumentando os esforços no desenvolvimento de técnicas eficientes de detecção de falhas. Neste trabalho, estudou-se as cartas de controle estatísticos de processos. Essas técnicas são amplamente utilizadas na indústria de produtos manufaturados, onde suas hipóteses básicas costumam ser válidas: medidas independentes e identicamente distribuídas com distribuição normal de probabilidade. Contudo, no ambiente industrial de processos contínuos muitas vezes estas suposições são violadas. Desta forma, neste trabalho foram enfocadas as técnicas adequadas para a introdução do CEP aos processos contínuos, incluindo a obtenção de dados considerados sob controle a partir da série histórica da variável em análise.

Propôs-se uma metodologia para a identificação de intervalos sob controle de uma série temporal. Além disso, definiu-se um método para a atualização dos parâmetros de monitoramento de acordo com o estado momentâneo do processo e de pontos operacionais passados.

O estudo de caso analisado foi o sistema de compressão de gás natural em plataformas offshore, sendo considerados dados reais e dados simulados. Os resultados demonstram a capacidade de detecção de anormalidades das técnicas avaliadas. Também constata-se que a identificação de intervalos estáveis foi adequada e que a metodologia de atualização de parâmetros ao longo do monitoramento foi eficiente.

Abstract of a Thesis presented to Curso de Pós-Graduação em Tecnologia de Processos Químicos e Bioquímicos - EQ/UFRJ as partial fulfillment of the requirements for the degree of Master of Science with emphasis on Petroleum and Natural Gas.

STATISTICAL CONTROL APPLIED TO CONTINUOUS PROCESS

Caio Felippe Curitiba Marcellos
Abril, 2013

Supervisors: Prof. Maurício Bezerra de Souza Junior, D. Sc.
Prof. Argimiro Resende Secchi, D. Sc.

In recent years, the need to maintain safe and reliable industrial operations has taken great proportions. In the continuous process industry, in particular, this issue is even more important because the operation is often conducted in full capacity, with high production speed, huge impact downtimes and low production flexibility. The petrochemical industry safety specifications are rigid because of the risk of working with flammable and toxic products at stringent conditions.

This current scenario has increased efforts in developing efficient techniques for fault detection. In this work, statistical process control (SPC) charts were studied. These techniques are widely used in the industry of manufactured products, where their basic assumptions are often valid: measures are independent and identically distributed with normal distribution. However, in the industrial environment of continuous processes these assumptions are often violated. Thus, this study focused on the proper techniques for introducing the SPC to continuous processes.

A methodology for identifying intervals under control of a time series was proposed. Furthermore, a method for updating the monitoring parameters was defined according to the current state of the process and past operational points.

Natural gas compression systems of offshore platforms were chosen as case studies using real and simulated data. The results demonstrate the ability of the techniques to detect abnormalities. It is also shown that the identification of stable intervals is adequate and that the methodology of updating parameters along the monitoring is efficient.

ÍNDICE

1. INTRODUÇÃO 1
1.1. Motivação 1
1.2. Objetivo 2
1.3. Estrutura da Dissertação 3
2. REVISÃO BIBLIOGRÁFICA 4
2.1. Segurança de Processos 4
2.1.1. Alarmes Dinâmicos Baseados em Estados 7
2.2. Controle Estatístico de Processos e Controle Automático de Processos 8
2.3. Detecção de Falhas 10
2.4. Métodos Univariados de Monitoramento utilizando Cartas de Controle 13
2.5. Gráficos de Controle Estatístico de Processos Convencionais 15
2.5.1. Carta de X 15
2.5.2. Carta de Controle para Medidas Individuais 16
2.5.3. Gráfico de Controle CUSUM 18
2.5.4. Gráfico de Controle EWMA 18
2.5.5. Regras de Sensibilidade 19
2.5.6. Integração entre CEP e Controle Automático de Processos 20
2.6. Verificação das Hipóteses de Aplicação de CEP 21
2.6.1. Estacionariedade das observações 22
2.6.2. Independência ou autocorrelação das observações 23
2.6.3. Distribuição de probabilidade identicamente distribuída 27
2.6.4. Normalidade 27
2.7. Introdução aos Modelos de Série Temporal ARIMA 29
2.8. Técnicas Alternativas de Cartas de Controle sem o uso de Modelos de Séries Temporais 32
2.9. Gráficos de Controle Baseados nos Resíduos de Modelos de Séries Temporais 34
2.9.1. Modelo IMA(1,1): EWMA de Linha Central Móvel 36
2.9.2. Combinação do gráfico de valores originais com resíduos de modelos ARIMA 38
2.10. Métodos de Identificação da Região sob Controle para Treinamento das Cartas de Controle 38
2.11. Sistema de Compressão de Gás 40
3. METODOLOGIA 44
3.1. Identificação de Intervalos Estáveis da Série Temporal 44

3.1.1. Método de Identificação de Intervalos Estáveis Proposto 47
3.2. Monitoramento Univariado de Processos com Gráficos de Controle Estatístico 52
3.2.1. Verificação Estatística dos Estados Sob Controle 53
3.2.2. Monitoramento por Gráficos de Controle sem o Uso de Modelos de Séries Temporais 54
3.2.3. Monitoramento utilizando Modelos de Séries Temporais ARIMA 55
3.2.4. Integração do Monitoramento com os Intervalos Estáveis da Série Histórica 58
3.3. Estudo de Caso: Sistemas de Compressão de Gás 62
3.3.1. Sistema de Compressão por Simulação Dinâmica 62
3.3.2. Dados Reais de Sistemas de Compressão 65
3.3.3. Monitoramento do Resíduo da Eficiência do Compressor 65
3.4. Interface Gráfica de Usuário 66
4. RESULTADOS E DISCUSSÕES 68
4.1. Conjunto de Dados Reais Avaliados 68
4.2. Dados de Simulação 70
4.3. Identificação de Estados Sob Controle a partir da Série Histórica 76
4.4. Verificação Estatística dos Estados Sob Controle 80
4.5. Etapa de Treinamento das Cartas de Controle 84
4.6. Monitoramento por cartas de Controle com Integração com os Estados Sob Controle da Série Histórica 85
4.6.1. Abordagem utilizando Gráfico de Shewhart Convencional 86
4.6.2. Abordagem com Modelos de Séries Temporais 89
4.6.2.1. Monitoramento por EWMA de linha central móvel para T_D (C_1) 89
4.6.2.2. Monitoramento por ARIMA para T_D (C_1) 93
4.6.2.3. Monitoramento por EWMA de Linha Central Móvel para a Variável P_S (C_{SIM}) 95
4.6.2.4. Monitoramento do Resíduo da Eficiência do Compressor 98
4.6.2.5. Integração de CEP com o Controle Automático de Processos 101
5. CONCLUSÕES 104

ÍNDICE DE FIGURAS

Figura 1: Camadas de Proteção de Plantas Industriais (Adaptado de Alves, 2007) 5
Figura 2: Comparativo entre sistemas de segurança de processos com estado operacional único (a) e com múltiplos estados operacionais (b) (Adaptado de (AUTOMIND)-Site ISA-SP) 7
Figura 3: Métodos de Detecção de Falhas (Adaptado de Iserman, 2006)..... 13
Figura 4: Exemplo de uma carta de controle típica. LSC: limite superior de controle; LIC: limite inferior de controle e LC: limite central. 15
Figura 5: Regra de Sensibilidade Clássica (BALESTRASSI, 2000). 20
Figura 6: Exemplo de dados autocorrelacionados. Em (a) $\Delta tT = 0{,}25$ e (b) $\Delta tT = 4$. 25
Figura 7: Exemplo de um correlograma FAC demonstrando os valores da autocorrelação (ρ) para diferentes defasagens. 26
Figura 8: Distribuição Normal de Probabilidade (Montgomery, 2009). 27
Figura 9: Exemplo de gráfico EWMA de linha central móvel (Dados AR(2)). ... 38
Figura 10: Sistema de Compressão (Fonte: Campos e Teixeira (2006)). 42
Figura 11: Compressor Centrífugo (Fonte: Site Faculdade de Engenharia PUC-RS). 43
Figura 12: Exemplo comparativo de intervalo estável de CEP convencional (a) com o intervalo estável de Processos Contínuos (b)..... 46
Figura 13: Estrutura para o Monitoramento Estudado..... 52
Figura 14: Estrutura de Identificação de Modelos ARIMA (BOX e JENKINS, 1970) 56
Figura 15: Estrutura adotada para o monitoramento baseado em modelos ARIMA. 1º gráfico refere-se ao gráfico EWMA de linha central móvel ou à sua generalização aos demais modelos da família ARIMA. O 2º gráfico corresponde ao gráfico de Shewhart sobre os resíduos de predição com o modelo ajustado. Em ambos, a linha com marcadores em * (ou linha verde) representa os dados de treinamento e a linha sem marcadores os dados de teste (ou linha azul); os limites de controle superior (LSC) e inferior (LIC) são as linhas traçadas acima e abaixo dos dados; a linha central (LC) é a linha intermediária. No segundo gráfico têm-se ainda os limites de controle de um e dois desvios padrões representados por linhas tracejadas. 58
Figura 16: Fluxograma do monitoramento com acoplamento com os estados sob controle da série histórica. 61
Figura 17: Estrutura em Funções de Transferência do Sistema de Compressão (Fonte: Campos e Teixeira (2006)) 63
Figura 18: Configuração do Sistema Dinâmico (Adaptado de Andersson, 2000). 64
Figura 19: Diagrama no Simulink® para geração de dados simulados. 64
Figura 21: Interface Gráfica adotada 67
Figura 22: Dados Reais do Conjunto $C1$..... 69
Figura 23: Dados Reais do Conjunto C_2. 70
Figura 24: Dados de entrada da simulação (Conjunto C_{SIM}). 72
Figura 25: Respostas do Sistema Dinâmico para o conjunto de dados $CSIM$. . 73
Figura 26: Entradas da região de teste dos dados simulados. 74

Figura 27: Respostas da simulação na região de teste, em (a) pressão de sucção e saída de controle do PIC e em (b) a vazão de sucção e a saída de controle de FIC. 75
Figura 28: Comparação entre a identificação dos estados sob controle por teste T (a) e desvios relativos de média (b) para a variável P_s simulada. 78
Figura 29: Comparação entre a identificação dos estados sob controle por teste T (a) e desvios relativos de média (b) da variável T_D dos dados reais C_1. 79
Figura 30: Comparação entre a identificação dos estados sob controle por teste T (a) e desvios relativos de média (b) para a variável P_D conjunto C_2. 80
Figura 31: Verificação Estatística Gráfica para o intervalo EE2 da variável $\mathrm{Ps\ CSIM}$. 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada). 82
Figura 32: Verificação Estatística Gráfica para o intervalo EE5 da variável $\mathrm{TD\ (C1)}$. 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada). 83
Figura 33: Verificação estatística gráfica para o intervalo EE1 da variável $PD(C2)$. 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada). 84
Figura 34: Monitoramento por Shewhart Convencional dos dados de T_d (C_1).. 87
Figura 35: Continuação do Monitoramento da Figura 34. 88
Figura 36: Inclusão dos alarmes de segurança da variável T_D de C_1 ao gráfico de Shewhart da Figura 35. Os alarmes trip alto, alto alto, alto, baixo, baixo baixo, trip baixo são representados pelas linhas tracejadas, nos valores de 193 ºC, 184 ºC, 170 ºC, 130 ºC, 120 ºC e 110ºC, respectivamente. 89
Figura 36: Verificação dos resíduos do modelo IMA(1,1) (Intervalo EE5 dos dados $TD\ (C1)$). 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada). 90
Figura 37: Monitoramento por EWMA de LC Móvel e Resíduos (Dados: $TD\ (C1)$). 91
Figura 38: Continuação do Monitoramento apresentado na Figura 37. 92
Figura 39: Gráfico CUSUM sobre Resíduos do modelo IMA(1,1). A elipse no 2º gráfico indica a situação de mudança na média não detectada pela carta de Shewhart 93
Figura 41: Verificação Gráfica dos resíduos do Modelo ARIMA(1,1,1) para o Intervalo EE5 de $\mathrm{TD\ C1}$. 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada). 94
Figura 42: Monitoramento por ARIMA(1,1,1) e resíduos (Dados: $\mathrm{TD\ de\ C1}$). 95
Figura 43: Verificação Gráfica dos Resíduos do Modelo IMA(1,1) para a variável Ps simulada. 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a

distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada). 96
Figura 44: Monitoramento por EWMA de Linha Central Móvel e pelos resíduos (dados simulados). 97
Figura 45: Em (a) o resíduo da eficiência do compressor a partir dos dados do conjunto $C2$ usando a abordagem de (MIYOSHI et al., 2012). Em (b) a identificação dos intervalos estáveis considerando como dados históricos até o tempo de 1,2 dias. 99
Figura 46: Verificação Estatística Gráfica dos Resíduos da Eficiência antes (a) e após (b) o ajuste de um modelo IMA(1,1). 100
Figura 47: Monitoramento por EWMA de Linha Central Móvel para os Resíduos da Eficiência de Compressão. 100
Figura 48: (a) Separação dos Intervalos Estáveis; (b) Verificação gráfica dos resíduos IMA(1,1) 101
Figura 49: Monitoramento por EWMA de Linha Central Móvel para o desvio da variável controlada e seu *setpoint* (dados de simulação)o)..... 103

ÍNDICE DE TABELAS

Tabela 1: Classificação de Modelos ARIMA(p,d,q) 29
Tabela 2: Padrões FAC e FACP de Modelos ARIMA (Adaptado de KORZENOWSKI, 2009) 30
Tabela 3: Parâmetros da metodologia de Identificação de Intervalos Estáveis 51
Tabela 4: Características dos Dados Reais do Conjunto C_1 69
Tabela 5: Características dos Dados Reais do Conjunto C_2 70
Tabela 6: Parâmetros dos Controladores 71
Tabela 7: Perturbações induzidas nos dados de teste 73
Tabela 8: Parâmetros utilizados nos procedimentos de identificação de Estados Sob Controle 76
Tabela 9: Agrupamento de Intervalos Estáveis Identificados 78
Tabela 10: Agrupamento dos intervalos estáveis identificados para T_D do conjunto C_1. 79
Tabela 11: Agrupamento dos intervalos estáveis identificados para a variável P_d do conjunto C_2. 80
Tabela 12: Verificação estatística para intervalos estáveis das variáveis em estudo. 81
Tabela 13: Modelos ARIMA(1,1,1) para os Intervalos Estáveis de Td (C1) e Testes Estatísticos 94
Tabela 14: Parâmetros do Monitoramento com modelo IMA(1,1) e Testes Estatísticos para os Intervalos Estáveis de Ps simulado 96

NOMENCLATURA

ABREVIATURAS

CEP – Controle Estatístico de Processos

ASPC - Algorithmic Statistical Process Control

AEM - Abnormal Event Management

PCA – Principal Components Analisys

MMSE - Minimum Mean Squared Error Feedback Controller

CUSUM - Cumulative Sum Control Chart

EWMA - Exponentially Weighted Moving Average

UBM - Unweighted Batch Means

CCC - Comum Cause Charts

SCC - Special Cause Charts

IMA - Integrated Moving Average

ARIMA - Autoregressive Integrated Moving Average

ARMA - Autoregressive Moving Average

AR - Autoregressive

MA - Moving Average

1. INTRODUÇÃO

1.1. Motivação

A principal atribuição do monitoramento nas indústrias de manufaturas e nas indústrias de processos contínuos diverge devido às características particulares das mesmas. De modo geral, de um lado têm-se produtos finais personalizados de acordo com especificações exigidas e do outro produtos não diferenciados (commodities).

Os produtos não diferenciados possuem variações limitadas e preços por unidade baixos. Neste setor, o lucro se deve principalmente ao alto volume de vendas. Já a indústria de manufaturados possui valor por unidade de produto mais elevado e maior variação nos produtos.

Assim, monitoramento nas indústrias de manufaturados visa assegurar a qualidade e a conformidade de seus produtos. Neste contexto foram desenvolvidas as técnicas de Controle Estatístico de Processos (CEP) que visam identificar causas especiais de variabilidade. Dentre estas técnicas destacam-se as baseadas em cartas ou gráficos de controle de processos, como por exemplo, as cartas de Shewhart. (MONTGOMERY, 2009)

Nas indústrias de processos contínuos, uma das principais funções do monitoramento de processos é a segurança, tendo em vista que é usual o processamento de substâncias perigosas a elevadas pressões ou temperaturas.

Outro ponto de divergência entre estas indústrias é o comportamento esperado de suas variáveis. Nos processos de manufatura, esperam-se variáveis de comportamento normal, de medições independentes e de média fixa (μ) com flutuações na forma de ruído branco (e_t). Ou seja, espera-se o comportamento de uma variável Y_t na forma:

$$Y_t = \mu + e_t \qquad \text{(Eq. 1)}$$

Por outro lado, na indústria de processos contínuos as variáveis são caracterizadas pela existência de autocorrelação. A autocorrelação é essencialmente encontrada nesses processos devido a perturbações frequentes, como na carga de entrada do processo, desta forma, não é visualizada uma constância na média das variáveis.

A característica de dados autocorrelacionados fornece um caráter determinístico ao processo contínuo, sugerindo a possibilidade de compensações. Desta forma, o principal método adotado para reduzir a variabilidade nos processos

contínuos é o controle automático de processos por meio de controladores *feedforward* ou *feedback* (WIEL *et al.*, 1992). Sendo assim, o comportamento de uma variável nestes tipos de processos pode ser definido por:

$$Y_t = u_{t-1} + n_t + e_t \qquad \text{(Eq. 2)}$$

onde u_{t-1} é o efeito de qualquer ação de controle tomada no tempo (t-1) e n_t representa o efeito de um distúrbio autocorrelacionado no tempo t (MACGREGOR, 1990). Esta equação evidência as diferenças entre o comportamento de processos contínuos e processos de manufaturas.

1.2. Objetivo

Neste trabalho objetiva-se a estruturação de um procedimento para o monitoramento de processos contínuos utilizando os conceitos de controle estatístico de processos com enfoque nos gráficos de controle.

Tendo em vista que uma planta de processos industriais pode possuir diferentes pontos operacionais, é possível identificá-los a partir da análise de dados históricos. Desta forma, o procedimento proposto visa fornecer uma integração entre o monitoramento em tempo real com os pontos operacionais históricos. A integração é desejada para permitir a atualização de parâmetros e limites de monitoramento de acordo com o estado momentâneo do processo, fornecendo assim uma forma de alarme dinâmico.

A violação das hipóteses básicas do controle estatístico de processos pode ser contornada por duas formas principais: a alteração dos limites de controle ou a utilização de modelos de séries temporais. Assim, estudaram-se as duas abordagens.

O estudo de caso no qual foram avaliadas as técnicas estudadas e desenvolvidas remete a sistemas de compressão de gás em plataformas *offshore*. Em geral esses processos utilizam limites de alarme fixos dependentes de heurística e conhecimento de técnicos da operação, desta forma, o estudo de técnicas estatísticas visa uma alternativa para o monitoramento do processo.

1.3. Estrutura da Dissertação

O conteúdo deste trabalho foi divido em cinco principais capítulos, sendo o primeiro o introdutório contemplando o objetivo e a motivação.

O Capítulo 2 apresenta uma revisão bibliográfica acerca de sistemas de segurança em processos industriais e a abrangência dos métodos de detecção de falhas. Detalham-se as principais técnicas de controle estatístico de processos, métodos para a verificação das hipóteses básicas do CEP, além de alternativas para os casos em que elas são violadas. Também apresenta-se métodos de identificação de estados estacionários de uma série histórica e a integração entre o CEP e o controle automático de processos.

O Capítulo 3 trata da metodologia adotada para a aplicação do monitoramento. Inclui-se: método proposto para identificação de intervalos estáveis; verificação das hipóteses estatísticas; a estruturação das técnicas baseadas em gráficos de controle e a seu acoplamento com os intervalos estáveis identificados. Apresenta-se também o estudo de caso considerado.

Os resultados das aplicações das técnicas desenvolvidas sob o estudo de caso são apresentados no Capítulo 4, assim como discussões relativas ao monitoramento avaliado.

O Capitulo 5 apresenta as conclusões finais e algumas sugestões para trabalhos futuros.

2. REVISÃO BIBLIOGRÁFICA

2.1. Segurança de Processos

A natureza competitiva, associada aos avanços tecnológicos e à elevada demanda por materiais e produtos novos e em altas escalas, proporcionou o desenvolvimento de plantas industriais amplas e complexas.

O setor químico envolve processos produtivos que utilizam substâncias inflamáveis, tóxicas e explosivas, oferecendo grandes perigos a trabalhadores e população local, assim como para o meio ambiente do entorno. A ocorrência de uma falha em um equipamento pode rapidamente se propagar em vazamentos, presença de fogo e explosão.

Ao longo dos anos, diversos acidentes de plantas industriais ocorreram em âmbito mundial com elevada repercussão devido à extensão dos danos causados. Exemplos são os acidentes em Flixborough (Reino Unido, 1970), Seveso (Itália, 1976), San Juanico (México, 1984), Bhopal (Índia, 1984), Vila Socó (Brasil, 1984) e, mais recentemente, no Golfo do México (Estados Unidos, 2010) e Bacia de Campos (Brasil, 2011).

Neste contexto, surgiu o conceito de Segurança de Processos, que objetiva o gerenciamento dos riscos de operação de uma planta industrial. Entre as ferramentas aplicadas no gerenciamento dos riscos estão as camadas de proteção.

O conceito de camadas de proteção refere-se ao uso de medidas de segurança designadas para prevenir possíveis acidentes ou mitigar seus efeitos. Inclui-se o desenvolvimento de processos inerentemente mais seguros, otimização do sistema básico de controle, aplicação de sistemas instrumentados de segurança (SIS) e dispositivos como diques, barreiras e válvulas de alívio. A Figura 1 apresenta uma hierarquia típica aplicada em plantas industriais.

Figura 1: Camadas de Proteção de Plantas Industriais (Adaptado de Alves, 2007)

A camada referente ao Sistema de Controle Básico do Processo representa as malhas de controle designadas para manter o processo na região de operação segura. A camada que abrange os Alarmes Críticos e a Intervenção Humana corresponde às respostas do operador aos alarmes automáticos implantados. As funções Instrumentadas de Segurança utilizam conjuntos de sensores, atuadores e computadores lógicos programáveis com níveis de segurança específicos para detectar condições anormais e levar o processo a uma operação estável, incluindo o desligamento da mesma. As proteções físicas englobam os diques, barreiras e válvulas de alívio. As respostas emergenciais correspondem a brigada de incêndio, sistemas de inundação manual, facilidade de evacuação, etc. Enfim, as respostas de emergência da comunidade remete à evacuação da população no entorno (PCHARA, BARRERA e KIRST, 2010).

Os alarmes possuem elevada importância no sistema de segurança de plantas industriais, visto que fornecem informações diretamente aos operadores e aos mecanismos de intertravamento. Eles visam a operação confiável e de produtividade desejada.

A especificação dos alarmes depende da equipe envolvida com o projeto da planta ou com a operação. Em alguns casos, as especificações são realizadas por práticas consolidadas em outras aplicações industriais em que os técnicos envolvidos estão familiarizados. Os alarmes podem ser definidos como (MACDONALD, 2004):

- alarmes de processos, que indicam desvios nas variáveis ou na eficiência do processo. Normalmente estão incorporados com o sistema de controle da planta e compartilham os mesmos sensores. Quando a confiabilidade dos sensores é questionável pode ser necessário sensores independentes;
- alarmes de equipamentos e máquinas: visam a detecção de problemas relacionados a equipamentos e máquinas que afetam o processo;
- alarmes relacionados à segurança: alertam os operadores sobre condições potencialmente perigoras e requerem ações destes;
- alarme de desligamento: são os indicadores de que os sistemas instrumentados de segurança foram ativados;
- alarmes de fogo ou gás: corresponde a um tipo de alarme relacionado a segurança, mas frequentemente são dedicados e independentes de outros sistemas de alarme..

Na maioria dos processos industriais contínuos do setor químico ou petroquímico existe elevado número de alarmes devido ao advento dos sistemas de controle distribuídos e da tecnologia em instrumentação e automação. Diversos são os estudos voltados para o gerenciamento de alarmes, de modo a evitar excessivos alarmes, alarmes inconsistentes, avalanches de alarme em caso de falhas, etc.

É comum o uso da priorização de alarmes para orientar os operadores na tomada de ações em situações de anormalidades no processo. A EEMUA (*Engeneering Equipment and Materials User's Association*) sugere a atribuição de quatro prioridades: alarme crítico, prioridades altas, médias e baixas. A associação também indica boas práticas na atribuição dos alarmes: o número de alarmes críticos não deve ultrapassar 20, prioridade alta representando no máximo 5% do total de alarmes, prioridade média com 15% do total e a quantidade de alarmes baixos representando cerca de 80% dos alarmes de uma planta.

Na prática, processos industriais possuem diferentes estados operacionais, como partida, parada, mudanças de carga ou produtos e manutenção de equipamentos. Nesta situação a definição de alarmes de processos é dificultada uma vez que a maior parte das aplicações industriais consideram alarmes fixos. Esses alarmes não conseguem compreender a variabilidade natural de cada ponto operacional separadamente. Os alarmes dinâmicos baseados em estados são alternativas para a detecção de anormalidades em processos com múltiplos estados operacionais (MACDONALD, 2004).

2.1.1. Alarmes Dinâmicos Baseados em Estados

A Figura 2-a esquematiza as primeiras camadas de um sistema de segurança com estado operacional único, nota-se que a atribuição de alarmes fixos é suficiente para a detecção de anormalidades no processo. Por outro lado, quando há mais de um estado operacional os limites fixos não são adequados, como evidenciado no esquema da Figura 2-b.

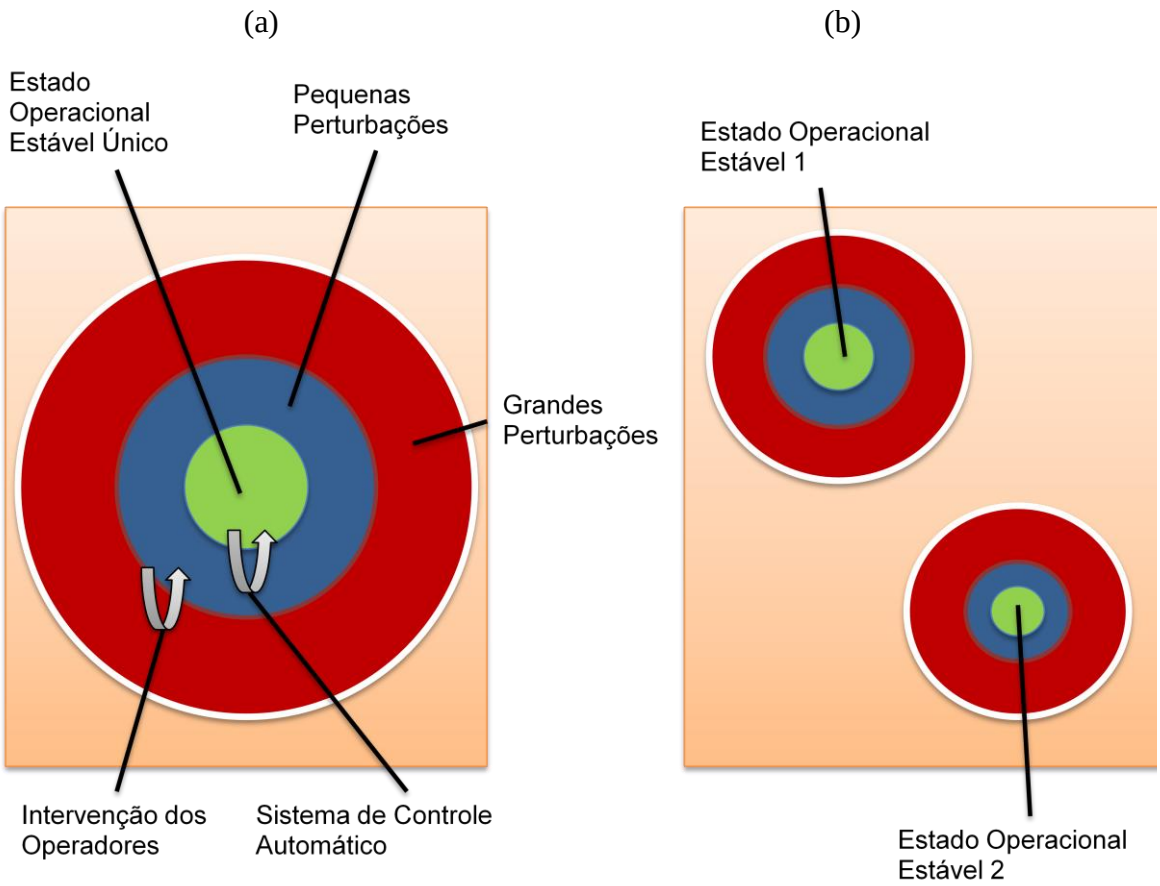

Figura 2: Comparativo entre sistemas de segurança de processos com estado operacional único (a) e com múltiplos estados operacionais (b) (Adaptado de (AUTOMIND)-Site ISA-SP) .

Para manter a alta performance e confiabilidade de plantas industriais com mais de um estado de operação, é aconselhável o uso de algoritmos de detecção de mudanças entre estes estados. Desta forma, pode-se alterar dinamicamente os valores dos alarmes para concordar com o comportamento de cada estado. Estes algoritmos são referenciados como alarmes baseado em estados (*state-based alarming*) (HOLLIFIELD e HABIBI, 2011).

A aplicação de alarmes dinâmicos é indicada para os casos: (i) diferentes cargas ou produtos (tipo ou qualidade); (ii) capacidades operacionais flexíveis e (iii) processos em que o número ou disposição dos equipamentos pode variar.

A estrutura utilizada para a aplicação de alarmes dinâmicos baseados em estados requer a detecção do estado operacional vigente por algoritmos computacionais e a confirmação dos operadores. Na situação de novo estado operacional detectado implementam-se as novas configurações de alarme. Caso haja falha no sistema de alarme dinâmico, deve-se voltar às configurações de alarme fixos padrões (HOLLIFIELD e HABIBI, 2011).

Esses sistemas são compostos por uma etapa de detecção de mudanças operacionais e de aplicação das mudanças na configuração dos alarmes. Eles podem ser totalmente automatizados ou comandados por operadores. A etapa de detecção é crucial nestes sistemas, assim seu funcionamento deve ser suficientemente confiável, podendo ser necessário o uso de sinais de mais de um sensor (HOLLIFIELD e HABIBI, 2011).

2.2. Controle Estatístico de Processos e Controle Automático de Processos

Durante muitos anos o controle automático de processos e o controle estatístico de processos foram desenvolvidos de forma relativamente isoladas. Ambas as metodologias, apesar de distintas e até divergentes em alguns aspectos, obtiveram sucessos significativos na condução ao aumento da qualidade e confiabilidade de processos. (WIEL *et al.*, 1992) Nas últimas décadas, entretanto, diversos autores iniciaram a análise e entendimento de integração entre as metodologias e da identificação das aplicações adequadas de cada uma.

Segundo Box e Kramer (1992) o termo "controle de processos" é utilizado para diferentes atribuições. Inclui-se os gráficos de controle, como gráfico de Shewhart, soma cumulativa (CUSUM) e média móvel exponencialmente ponderada (EWMA); esses gráficos são frequentemente utilizados para monitoramento de processos como parte do escopo de Controle Estatístico de Processos (CEP). Em contraste ao monitoramento do processo por CEP, Box e Kramer (1990) destacam outra atribuição para o termo controle de processos que é a regulação e ajuste do processo por controles *feedback* ou *feedforward*. A este tipo de controle de processos dá-se o nome de Controle Automático de Processos ou Controle de Engenharia de Processos. Os autores indicam que o termo CEP pode ser impróprio, pois o controle é propriamente uma função do Controle Automático. Segundo Box e Kramer (1990) uma melhor atribuição para o termo seria Monitoramento Estatístico de Processos, descrevendo mais adequadamente o seu papel.

O CEP e o controle automático de processos são originários de diferentes setores industriais. Enquanto o CEP surgiu para a indústria de peças, o controle automático foi desenvolvido para a indústria de processos. (BOX e KRAMER, 1990) O objetivo de controle na indústria de peças tipicamente busca a reprodução de peças individuais o mais acurado e preciso possível (BOX e JENKINS, 1970). Por outro lado, as preocupações da indústria de processos são o rendimento dos produtos, porcentagens de conversão e medidas de pureza, por exemplo. Desta forma, o objetivo é manter a média dessas medidas o mais alto possível (BOX e KRAMER, 1990).

Nas indústrias de manufaturas de peças, normalmente as condições de processo podem ser ajustadas adequadamente conforme interesse do operador, visto que não existem muitas fontes de distúrbios envolvidas. Entretanto, essas condições são difíceis de serem constantemente alteradas, visto que a mudança frequente aumenta os custos de produção. Já nas indústrias de processos, de modo geral, existem mais variáveis externas que não podem ser adequadamente controladas, ou seja, maior presença de distúrbios. Desta forma, a forma de correção mais comum é a compensação, como com o uso de controle *feedback* (BOX e KRAMER, 1990).

De acordo com Montgomery e Keats (1992) as duas técnicas possuem como objetivo comum a redução da variabilidade, entretanto, as formas de alcançá-lo são diferentes. O CEP busca por sinais que representam causas atribuíveis, que podem ser compreendidas como distúrbios que causam variabilidade. A maioria das técnicas de CEP assumem que os dados do processo são estatisticamente independentes e que flutuam em torno de uma média constante (WIEL, *et al.*, 1992).

Por outro lado, o Controle Automático de Processo busca reverter os efeitos de distúrbios por correções em variáveis manipuladas do processo. Nestes casos as médias das variáveis não se mantêm constante com o tempo e o objetivo é manter a variável de processo analisada em um valor desejado. O Controle Automático essencialmente atinge este objetivo pela transferência da variabilidade das variáveis de saída para as de entrada (WIEL, *et al.*, 1992).

Wiel et al. (1992) resumidamente define CEP como uma coleção de técnicas especialmente úteis em melhorar a qualidade de produtos por ajudar uma análise local e por detectar causas originais de variabilidade nas características de qualidade. O autor define o controle automático como um conjunto de técnicas para elaboração de algoritmos de manipulação de variáveis ajustáveis do processo para atingir o comportamento desejado. Ele ainda ressalta que o CEP é usado para melhorar um processo pela remoção de fontes de variabilidade, enquanto que o controle automático é usado para ajustar um processo existente.

Uma comparação entre o CEP e o controle automático revela as diferentes orientações considerando três áreas: (WIEL, TUCKER, *et al.*, 1992)

- Filosofia: ambos procuram reduzir desvios de uma característica a um valor alvo. Sendo que em CEP atingi esse objetivo pelo monitoramento do processo para detecção e remoção de causas atribuíveis. Enquanto que o controle automático contra-ataca os efeitos dessas causas via contínuo ajuste no processo;
- Contexto de aplicação: CEP é adequado para os casos em que se espera variáveis do processo independentes e identicamente distribuídas e deseja-se detectar desvios de uma condição ideal. Já o controle automático de processos é ineficiente para um processo de variáveis independentes e identicamente distribuídas;
- Tipo de variável a ser monitorada: o controle automático geralmente é desenvolvido para manter variáveis importantes do processo nos seus *setpoints*. Em contraste, o controle estatístico é mais usado sobre variáveis que representam características de qualidade. Assim, o CEP possui impacto direto sobre a qualidade das saídas do processo.

Nos últimos anos, houve alguns esforços para integrar estratégias de monitoramento (CEP) com de controle automático. Segundo Montgomery e Keats (1994) essa integração é útil, visto que o sistema integrado pode usar o controle automático para reduzir variações de qualidade previstas, enquanto que o CEP realiza o monitoramento do processo para detecção de causas anormais.

De acordo com Box e Jenkins (1970) a divisão entre a indústria de manufatura de peças e a indústria de processos químicos vem sendo diluída. Uma razão é que alguns processos atualmente são híbridos, contendo aspectos de indústria de peças e de processos químicos. Outra questão é o advento dos conglomerados industriais, nos quais os dois tipos de manufatura são encontrados em um mesmo espaço. Outra questão é a chamada "revolução da qualidade" que contribuiu na conscientização da importância de um tipo de indústria utilizar conceitos adotados pelo outro.

2.3. Detecção de Falhas

Nas últimas décadas o controle de processos teve uma notável evolução devido ao aumento das tecnologias em instrumentação e automação, que permitiu a aplicação de sistemas de controles complexos.

O progresso nas tecnologias de controle distribuído e controle baseado em modelos preditivos (MPC) contribuiu intensamente para diversos setores industriais, como petroquímico, cimento, aço e energia. Entretanto, uma importante tarefa ainda continua sendo largamente realizada manualmente pelos operadores da planta. Essa tarefa é a resposta a eventos anormais ocorridos no processo, englobando a detecção imediata, diagnóstico de suas causas originais e a tomada de decisões apropriadas no nível supervisório de controle para levar a planta de volta a uma condição estável de operação. Estas atividades são denominadas de Gestão de Eventos Anormais (*Abnormal Event Management* - AEM) (Venkatasubramanian et al., 2002).

Basseville e Nikiforov (2006) indicam que as principais aplicações de técnicas de detecção de falhas são no campo de processamento de sinais, análise de séries temporais, controles automáticos e controle de qualidade.

Existem diversas abordagens estudadas no campo de Detecção e Diagnóstico de Falhas (Fault Detection and Diagnosys - FDD). Segundo Isermann (2006) o objetivos desses métodos são:

- Detecção imediata de pequenas falhas de comportamento abrupto ou incipientes;
- Diagnóstico de falhas em atuadores e sensores;
- Supervisão de processos em estado transiente;
- Manutenção e reparo de condição de processos;
- Controle de qualidade na manufatura de produtos montados;
- Detecção e diagnóstico de falhas remotamente;
- Bases de gerenciamento de falhas e de sistemas tolerantes a falhas e reconfiguráveis.

As metodologias de detecção e diagnóstico de falhas podem ser classificadas em: métodos quantitativos baseados em modelos, métodos qualitativos e métodos baseados na informação histórica das variáveis observadas do processo. Os métodos baseados em modelos expressam o comportamento de uma determinada variável através de relações matemáticas e há necessidade do conhecimento prévio do processo estudado. Os modelos qualitativos requerem funções qualitativas centradas em diferentes partes do processo feitas por especialistas e em alguns casos, possuem caráter subjetivo e arbitrário. No caso dos métodos baseados na informação histórica das variáveis analisadas não é requerido o entendimento do processo a ser analisado. Esses métodos fazem o uso de metodologias estatísticas uni ou multivariável para entender a dinâmica do passado e, assim, prever o futuro (Venkatasubramanian et al., 2002).

Basseville e Nikiforov (2006) estruturam o estudo de detecção de falhas em duas partes. A primeira refere-se às mudanças em um parâmetro escalar de uma sequência independente, ou seja, os casos mais simplificados que consideram uma sequência de variáveis aleatórias independentes com certa densidade de probabilidade dependente de apenas um parâmetro escalar. Esta parte contempla os métodos de detecção de mudanças por checagem de limites (gráfico de *Shewhart*), gráficos de controle utilizando médias móveis, filtros derivativos e somas cumulativas. A segunda parte considerada por Basseville et al. (2006) compreende mudanças mais complexas: processos com variáveis dependentes caracterizadas por parâmetros multidimensionais. Neste caso há a distinção de detecção de eventos aditivos e espectrais nos parâmetros. Englobam-se nesta parte métodos para modelos lineares (regressões, modelos ARMA e modelos em estado-espaço) e para modelos não lineares.

Isermann (2006) realiza uma separação entre técnicas de detecção e de diagnóstico. Além disso, subdivide os métodos de detecção de falha em:

i. Detecção de falhas com checagem de limites;
ii. Detecção com modelos de sinais;
iii. Utilização de métodos de identificação de processos;
iv. Detecção com equações de paridade;
v. Métodos baseados em observadores e estimadores de estados;
vi. Detecção de falhas em malhas de controle fechadas;
vii. Utilização de Análise de Componentes Principais (Principal Components Analisys - PCA).

A Figura 3, adaptada de Iserman (2006) estrutura os principais métodos de detecção de falhas.

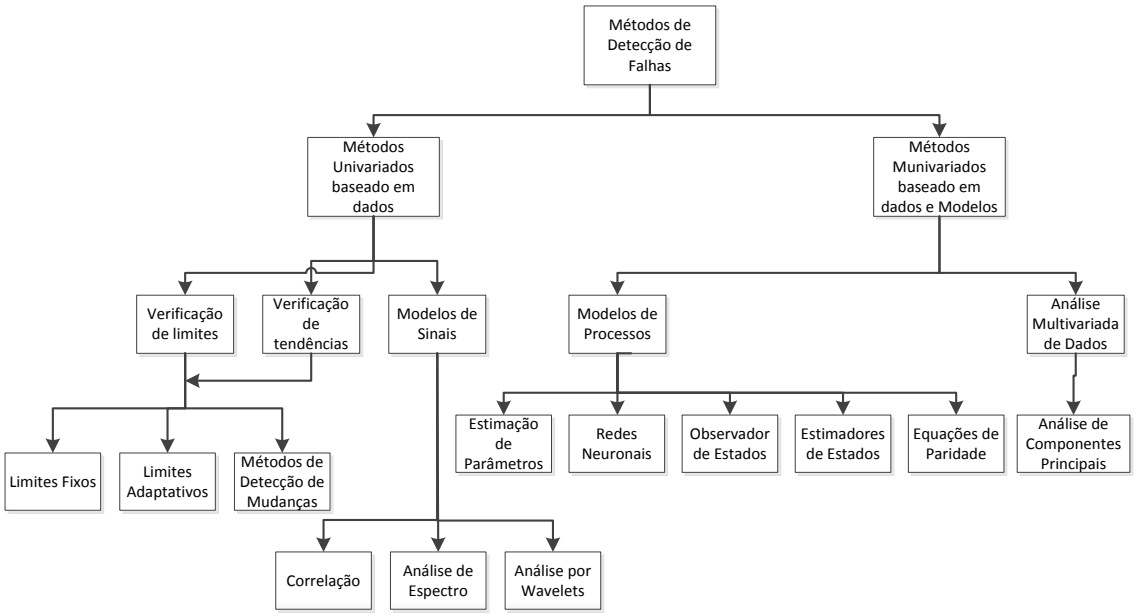

Figura 3: Métodos de Detecção de Falhas (Adaptado de Iserman, 2006)

2.4. Métodos Univariados de Monitoramento utilizando Cartas de Controle

No escopo de Detecção e Diagnóstico de Falhas de processos, os métodos de monitoramento baseados nas cartas de controle situam-se dentro das técnicas de detecção por verificação de limites. Essas técnicas são consideradas metodologias básicas de detecção de falhas e devido à aplicação facilitada e resultados adequados são extensamente utilizadas (ALLEN, 2006).

As cartas de controle foram propostas por Walter Shewhart em 1924. Essas técnicas fazem parte do Controle Estatístico de Processos e visam monitorar continuamente determinadas variáveis do processo consideradas de importância. Esses métodos foram desenvolvidos para a indústria de bens manufaturados, sendo a principal atribuição a melhora da qualidade dos produtos. Entretanto, como discutido anteriormente, esses conceitos também trazem benefícios a processos contínuos com controles automáticos. A forma geral de uma carta de controle é apresentada na Figura 4.

O Controle Estatístico de Processos (CEP) é uma ferramenta de monitoramento da qualidade de processos produtivos (e de serviços) com objetivo de fornecer informações para um diagnóstico mais eficaz na prevenção e detecção de defeitos/problemas nos processos avaliados e, consequentemente, auxilia no aumento

da produtividade e resultados da empresa, evitando desperdícios de matéria-prima, insumos, produtos, etc (MONTGOMERY, 2009).

A utilização de gráficos de controle no CEP é de extrema importância, os gráficos são elementos visuais para o monitoramento dos produtos e processos, são através deles que rapidamente se podem identificar alterações desproporcionais, causas especiais, alertando sobre a necessidade de agir no processo. Além disso, as cartas de controle fornecem informações para que o operador faça um diagnóstico sobre o processo, podendo conduzir a implantação de uma mudança que melhore seu desempenho (SAMOHYL, 2009).

Um objetivo das cartas de controle é estabelecer uma faixa de variação aleatória natural do processo, ou causas comuns de variação. Desta forma, as cartas de controle fazem a distinção das causas de variabilidade especiais, ou causas atribuíveis. As variabilidades são ocasionadas por eventos ou distúrbios no processo e devem ser identificadas para, então, serem devidamente corrigidas. As cartas de controle são usadas para monitorar a estabilidade do sistema. Neste contexto, o processo é dito sob controle estatístico se a distribuição de probabilidade da variável analisada não variar com o tempo (WOODALL, 2000).

De acordo com Santos (2007) existem cinco razões principais da popularidade de aplicação das cartas de controle na indústria de manufaturados: (i) contribuem com o aumento da produtividade, pois reduzem desperdícios, reduzem retrabalho e diminuem custos; (ii) são eficazes na prevenção de defeitos, pois ajudam o processo se manter sob controle; (iii) impedem ajustes desnecessários, visto que distingue entre as causas de variabilidade naturais das especiais; (iv) fornecem informações para o diagnóstico do operador, direcionando as mudanças necessárias para a melhora do processo; (v) exibem informações quanto à capacidade do processo, revelando parâmetros importantes para o monitoramento.

Para efetuar a aplicação do Controle Estatístico de Processos utilizando as cartas de controle é necessária a verificação das condições de observações independente e identicamente distribuídas com distribuição normal. Em algumas ocasiões, a suposição de normalidade pode ser moderadamente violada sem afetar os resultados. Entretanto, quando há autocorrelação nos dados (dependência das observações), o uso dos gráficos de controle não exibe bom desempenho. Podendo fornecer falsos alarmes, ou seja, indicar que o processo está fora de controle quando na verdade continua estável (MOREIRA JUNIOR, 2005) (BISGAARD e KULAHCI, 2011).

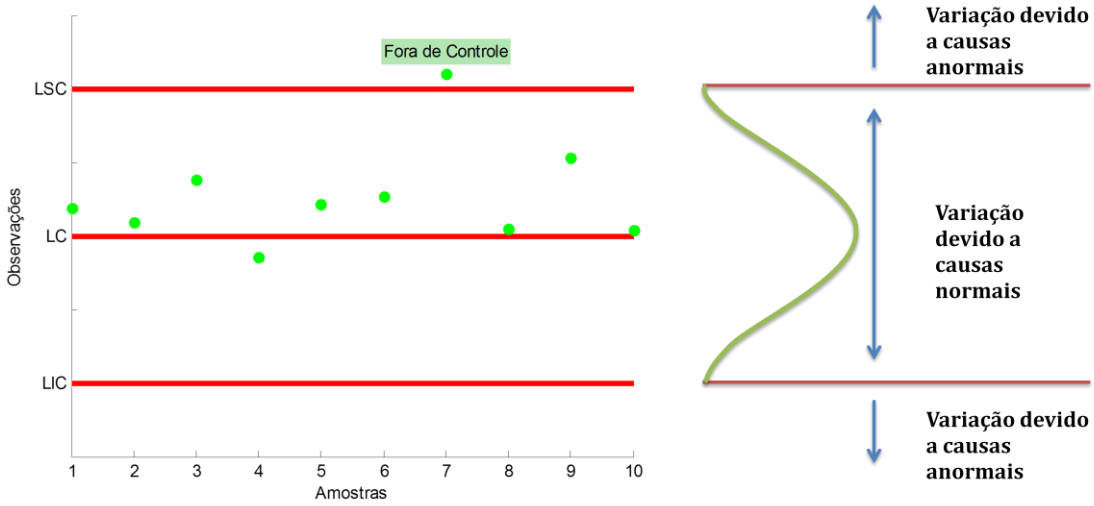

Figura 4: Exemplo de uma carta de controle típica. LSC: limite superior de controle; LIC: limite inferior de controle e LC: limite central.

2.5. Gráficos de Controle Estatístico de Processos Convencionais

Os gráficos de controle tradicionais são utilizados sob as considerações de observações estacionárias, independentes e identicamente distribuídas com distribuição de probabilidade normal.

O início das cartas de controle se deu com o estudo de Shewhart (1924) na *Bell Telephone Company.* Outras cartas de controle foram sendo estruturadas para aumentar a eficiência do monitoramento, como as cartas de Soma Cumulativa (CUSUM) e Média Móvel Exponencialmente Ponderada (EWMA).

As cartas de controle são classificadas de acordo com o tipo de dado em análise, por exemplo: cartas para dados contínuos, denominadas de cartas para variáveis e cartas para dados discretos ou cartas de atributos. As cartas de variáveis, em geral, seguem a um modelo padrão que fornece um limite superior, um limite inferior e uma linha central correspondente à média do processo. A seguir discute-se algumas dessas cartas.

2.5.1. Carta de $\overline{X}$

Utilizada para processos em que se pode estabelecer réplicas ou subgrupos de amostras. Nesse tipo de carta consideram-se conhecidos a média (μ) e o desvio padrão σ e que para cada subgrupo formado por N observações:

$$\bar{X} = \frac{x_1 + x_2 + \cdots _ x_N}{N} \quad \text{(Eq. 3)}$$

$\bar{X}$ possui média μ e desvio padrão dado por $\sigma_x = \frac{\sigma}{\sqrt{N}}$

Os limites de controle são estipulados a partir da probabilidade de falsos alarmes permitida α. Logo, têm-se para o limite superior de controle (LSC), limite inferior de controle (LIC) e linha central (LC) (MONTGOMERY, 2009):

$$LSC = \mu + c * \frac{\sigma}{\sqrt{N}} \quad \text{(Eq. 4)}$$

$$LIC = \mu - c * \frac{\sigma}{\sqrt{N}} \quad \text{(Eq. 5)}$$

$$LC = \mu \quad \text{(Eq. 6)}$$

O parâmetro c corresponde à folga entre os limites de controle e a linha central, em muitas aplicações seu valor típico é 3 (correspondendo a uma porcentagem de falsos alarmes de 0,27%).

Na prática a média e o desvio padrão não são conhecidos, então estimativas são realizadas. Uma das formas utilizadas de estimativa é a consideração de que o melhor estimador da média seria a média geral do processo, ou seja, considerando m subgrupos amostrais:

$$\hat{\mu} = \frac{1}{m} \sum_{i=1}^{m} \bar{x}_i \quad \text{(Eq. 7)}$$

Um estimador para o desvio padrão frequentemente utilizado é o de amplitudes amostrais. Sendo x_{max} o maior valor de cada subgrupo, x_{min} o menor valor e d_2 um parâmetro em função do tamanho das amostras encontrado na literatura (MONTGOMERY, 2009):

$$\bar{R} = \frac{1}{m} \sum_{i=1}^{m} (x_{i_{max}} - x_{i_{min}}) \quad \text{(Eq. 8)}$$

$$\hat{\sigma} = \frac{\bar{R}}{d_2} \quad \text{(Eq. 9)}$$

Usam-se então os limites de controle baseados nos estimadores:

$$LSC = \hat{\mu} + c\,\hat{\sigma} \quad \text{(Eq. 10)}$$

$$LIC = \hat{\mu} - c\,\hat{\sigma} \quad \text{(Eq. 11)}$$

$$LC = \hat{\mu} \quad \text{(Eq. 12)}$$

2.5.2. Carta de Controle para Medidas Individuais

As cartas de $\bar{X}$ são usadas para casos em que é possível obter número considerável de réplicas das observações. Entretanto, para a indústria de processos contínuos e de batelada um número elevado de réplicas pode ser inviável, visto que requeria alta redundância de equipamentos de medidas e aumentaria demasiadamente o custo do processo.

Desta forma, uma variação adotada para tratar dados com amostragem individuais é a utilização da amplitude móvel de duas observações consecutivas como forma de estimar a variabilidade do processo.

Este método determina a variabilidade do processo ao fazer uma média das amplitudes móveis de duas observações sucessivas. Ou seja:

$$mr = |x_t - x_{t-1}| \quad \text{(Eq. 13)}$$

$$\overline{mr} = \frac{1}{n}\sum_{i=1}^{n} \bar{x}_i \quad \text{(Eq. 14)}$$

onde mr representa a amplitude móvel, x_t uma determinada observação e x_{t-1}a observação imediatamente anterior, n o número total de pontos e $\overline{mr}$ a média aritmética de mr (ARAUJO, 2010).

Os limites do gráfico de controle são gerados então pela projeção de uma linha horizontal acima e abaixo das medições. A distância entre essas linhas e a linha média das medições é proporcional à amplitude móvel média ($\overline{mr}$ ou *Average Moving Range*). Segundo Montgomery (2004), a amplitude móvel média é uma estimativa apropriada do desvio padrão para casos de medidas individuais, pois há uma facilidade de cálculo e, para tamanhos amostrais pequenos, o valor do estimador proposto é praticamente o mesmo. Assim, para esta estimativa usa-se:

$$\hat{\sigma} = \frac{\overline{mr}}{d_2} \quad \text{(Eq. 15)}$$

sendo d_2 tabelado e para esta situação seu valor é de 1,128 já que duas observações consecutivas são utilizadas para calcular a amplitude móvel. Os limites de controle superior (LSC), inferior (LIC) e central (LC) para o gráfico de medições da variável serão ($\bar{x}$ é a média das observações) (MONTGOMERY, 2009):

$$LSC = \bar{x} + N_{mr}\,\hat{\sigma} \quad \text{(Eq. 16)}$$

$$LIC = \bar{x} - N_{mr}\,\hat{\sigma} \quad \text{(Eq. 17)}$$

$$LC = \bar{x} \quad \text{(Eq. 18)}$$

O valor de N_{mr} corresponde a um parâmetro que deve ser ajustado de acordo com a variabilidade esperada do processo. A atribuição deste valor é de extrema importância na aplicação do monitoramento, visto que o mesmo indicará os limites de alarme. Assim, valores pequenos podem levar a alarmes frequentes, que podem ser falsos, ou seja, não representam uma real condição anormal do processo. Já valores elevados podem perder a eficiência de detecção, isto é, não identificar instantes iniciais de alteração da condição de operação. Entretanto, segundo a literatura de controle estatístico este valor situa-se entre 3 e 6. De acordo com Montgomery (2009),

para a distribuição normal de uma variável aleatória, os limites formados com a utilização do valor $N_{mr} = 3$ incluem 99,73% de sua variabilidade, ou seja, apenas 0,27% das medições realizadas no processo não atendem os limites de tolerância.

2.5.3. Gráfico de Controle CUSUM

O gráfico de soma cumulativa (CUSUM) é designado para detectar pequenas variações na média de um processo. Sua fundamentação baseia-se no cálculo das estimativas de soma cumulativa. A técnica foi originalmente proposta por Page (1961) e sua sensibilidade para detecção de pequenas mudanças na média de processos deve-se a utilização de toda informação da sequência de dados.

A estimativa da soma cumulativa é definida pela soma dos desvios dos valores com a média do processo, ou seja:

$$C_i = \sum_{j=1}^{i} \left(\overline{y_j} - \mu_0\right) \qquad \text{(Eq. 19)}$$

sendo $\overline{y_j}$ a média da amostra de tamanho $n \geq 1$ e μ_0 o valor alvo (a média do processo).

Usualmente utiliza-se o gráfico CUSUM tabular, que emprega uma estatística C^+ para acumular desvios positivos em relação ao alvo μ_0 e uma outra C^- para o acúmulo dos desvios negativos. Esses parâmetros de monitoramento são denominados CUSUM unilaterais superior e inferior e podem ser definidos como (MONTGOMERY, 2009):

$$C_i^+ = \max\left[0, y_i - (\mu_0 + K) + C_{i-1}^+\right] \qquad \text{(Eq. 20)}$$

$$C_i^- = \max\left[0, (\mu_0 - K) - y_i + C_{i-1}^-\right] \qquad \text{(Eq. 21)}$$

em que os valores de inicialização são: $C_0^+ = C_0^- = 0$ e K é o valor de folga. Uma sugestão para a definição de K é a metade do valor dado pela distância entre μ_0 e o valor de média que deseja-se detectar. Considera-se processo fora de controle quando alguma dessas estatísticas exceda um limiar definido pelo parâmetro H, cujo valor típico corresponde a 5σ.

2.5.4. Gráfico de Controle EWMA

O gráfico de controle de médias móveis exponencialmente ponderadas corresponde a outra abordagem eficiente para detectar pequenas mudanças de média. Segundo Montgomery (2009) a performance deste gráfico é equivalente ao CUSUM. A técnica foi introduzida por Roberts (1959) e considera um maior peso para as observações mais atualizadas, diferente do CUSUM.

Define-se a estatística EWMA por:

$$z_i = \lambda x_i + (1-\lambda) z_{i-1} \qquad \text{(Eq. 22)}$$

em que λ é um parâmetro do monitoramento que varia de 0 a 1 e a inicialização da estatística z pode ser a média do processo ou a média de dados preliminares.

A variância de z_i, considerando dados independentes e aleatórios com variância dada por σ, é dada por:

$$\sigma_{z_i}^2 = \sigma^2 \left(\frac{\lambda}{2-\lambda}\right)\left(1-(1-\lambda)^{2i}\right) \qquad \text{(Eq. 23)}$$

A partir do desvio padrão obtêm-se os limites de controle:

$$LCS = \mu_0 + c\,\sigma\sqrt{\left(\frac{\lambda}{2-\lambda}\right)(1-(1-\lambda)^{2i})} \qquad \text{(Eq. 24)}$$

$$LC = \mu_0$$

$$LCI = \mu_0 - c\,\sigma\sqrt{\left(\frac{\lambda}{2-\lambda}\right)(1-(1-\lambda)^{2i})} \qquad \text{(Eq. 25)}$$

em que c é a largura dos limites de controle (MONTGOMERY, 2009).

Montgomery (2009) indica que em geral utiliza-se valores para λ no intervalo $0{,}05 \leq \lambda \leq 0{,}25$ e o valor tradicional de $c = 3$ fornece bons resultados.

2.5.5. Regras de Sensibilidade

Uma condição fora de controle normalmente é indicada pelas cartas de controle tendo como referência seus limites. Quando um ou mais pontos aparecem além da faixa permitida (entre os limites de controle superior e inferior) o processo é considerado como fora de controle. Contudo, outro fator deve ser observado: padrões não aleatórios que podem ser formados mesmo dentro da faixa permitida (Montgomery, 2009). As observações são esperadas a apresentarem um comportamento aleatório, desta forma, quando uma sequência de pontos forma um padrão singular é uma indicação de uma possível causa especial.

Existem diversas regras estruturadas na literatura que tentam identificar os padrões formados nas cartas de controle e são conhecidos como corridas ou zonas de observações ou *Run Tests* ou *Zone Tests* (BALESTRASSI, 2000). Entre as regras mais mencionadas e aplicadas está a regra de Western Eletric (1958) apresentada na Figura 5, onde o desvio padrão é 5 e a média igual a zero.

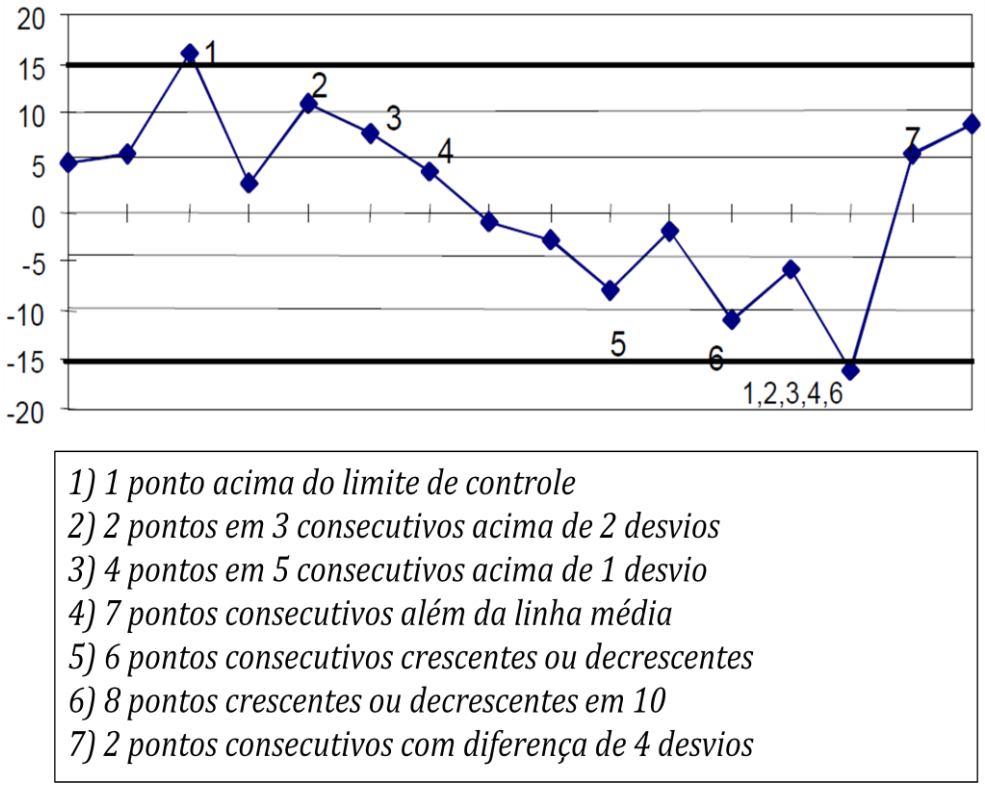

Figura 5: Regra de Sensibilidade Clássica (BALESTRASSI, 2000).

2.5.6. Integração entre CEP e Controle Automático de Processos

A integração de atividades relacionando CEP com controle automático pode levar a aprimoramentos substanciais na qualidade do processo, já que eles possuem algumas características que se complementam.

Montgomery e Keats (1994) realizaram simulações que mostram que o uso de cartas de controle (Shewhart, EWMA e CUSUM) sobre o resíduo gerado pela saída dos processos em malha fechada de controle automático com seu *setpoint* é capaz de detectar eficientemente causas anormais no processo. E, caso o efeito dessas causas seja anulado, reduz-se drasticamente a variabilidade do processo quando comparado com o uso isolado de controle automático.

O caso de estudo dos autores foi a modificação proposta por MacGregor (1990) do experimento do funil de Deming (1950). O experimento original foi proposto pelo estatístico William Edwards Deming para provar suas teorias da inutilidade e danos ao processo provocado pela sobrecompensação de uma situação estável. Seu experimento consistia de um funil que lançava pequenas bolas de vidro sobre uma superfície com um alvo demarcado.

Consideraram-se quatro regras propostas com o objetivo de obter o melhor desempenho, ou seja, maior precisão e acurácia: (i) manter o funil fixo e mirando o alvo na superfície; (ii) a cada lançamento, mover o funil de sua última posição compensando o erro, ou seja, o funil é movimentado exatamente o negativo do último erro; (iii) mover o funil a partir do alvo para compensar o erro, o funil possuindo como referência o alvo, e não a última posição; (iv) no lançamento n, posicionar o funil no lançamento n-1.

Segundo Deming (1950), apud MacGregor (1990), a regra (i) é a situação ótima correspondendo a uma distribuição estável com a menor variância. A regra (ii) produz resultados com o dobro da variação da primeira regra. A experimentação da regra (iii) também ocasiona aumento da variabilidade. Enfim, a regra (iv) produz os piores resultados, resultando no descolamento em uma direção preferencial.

A modificação proposta pro MacGregor (1990) incluiu a situação de médias variantes, para isso acrescentou um termo de autocorrelação ao processo. Nesse caso adaptado, relatou que a regra (ii), que pode ser comparada ao controle *feedback* integral, produz uma menor variabilidade do que a situação sem nenhuma ação corretiva (primeira regra).

Wiel et al. (1992) propõe o termo *Algorithmic Statistical Process Control* (ASPC) para a forma de integração de CEP com o controle de processos. Em seus estudos os autores consideram importante a disponibilidade de dados históricos para permitir um bom preditor para o processo. Deve haver também uma variável de caráter compensatório, cujo ajuste produz efeitos previsíveis no desempenho do processo. O estudo dos autores foi focado em controladores do tipo Mínimo Erro Quadrático da Média (Minimum Mean Squared Error Feedback Controller - MMSE) utilizando modelos ARMAX. A malha fechada de controle foi monitorada utilizando gráficos de controle do tipo CUSUM. O caso de estudo foi um processo de polimerização em batelada.

2.6. Verificação das Hipóteses de Aplicação de CEP

A maioria das técnicas de CEP convencionais assumem as hipóteses para dados sob controle (MONTGOMERY, 2009):

- Estacionariedade das observações;
- Medições independentes e identicamente distribuídas;
- Distribuição de probabilidades normais.

Desta forma, antes de iniciar as aplicações das cartas de controle é requerida a verificação destas suposições. A seguir são descritas algumas das técnicas utilizadas para este procedimento. Caso haja alguma violação das suposições é necessário utilizar métodos corretivos para a aplicação das cartas de controle.

2.6.1. Estacionariedade das observações

A base da aplicação de técnicas estatísticas para monitoramento de processos é a estacionariedade dos dados. Essa consideração é fundamental também para o desenvolvimento dos modelos de séries temporais do tipo autoregressivo de médias móveis. Entretanto, na prática, as séries temporais de medições de processos contínuos apresentam algum grau de não estacionariedade. Em aplicações práticas a estacionariedade da maioria dos processos é induzida por ações de controle tomadas em intervalos regulares ou continuamente aplicadas (BISGAARD e KULAHCI, 2011).

Uma série temporal é dita estacionária quando a distribuição de probabilidade de um conjunto de n observações desta série permanece igual a de um outro conjunto de n observações deslocada em k unidades de tempo (BROCKWELL e DAVIS, 1991). Entretanto, para fins práticos basta a definição de estacionariedade como um processo de variância finita com média e variância constantes no tempo e com correlação entre diferentes membros da série dependente apenas do atraso. Essa definição é referida como estacionariedade fraca e, em outras palavras significa que uma série temporal de z_t apresenta $\mathbb{E}\,(z_t) = \mu$ independente de t e autocovariância $Cov(z_{t+k}, z_t)$ dependente apenas de k para todo t (BOX, JENKINS e REINSEL, 1994). Neste caso a série temporal é dita como um processo integrado de ordem zero, por outro lado, quando a série é não estacionária o processo é considerado como de ordem d, sendo d o número de diferenciações necessárias para que o processo se torne de ordem zero (GUJARATI, 2004).

Normalmente a avaliação da estacionariedade pode ser realizada por inspeção visual. Entretanto, existem testes estatísticos para numericamente indicar esta característica. Dentre eles pode-se citar o DF (Dickey-Fuller), ADF (Augmented Dickey-Fuller), o PP (Phillips-Perron), KPSS (Kwiatkowski, Phillips, Schmidt e Shin) e o LMC (Leybourne-McCabe) (KORZENOWSKI, 2009).

Estes testes foram desenvolvidos para verificar a presença de raiz unitária ou a ordem de integração de uma série temporal. Quando uma série temporal é não estacionária, diz-se que a variável que a representa possui raiz unitária e que é uma série de passeio ou caminho aleatório.

O teste DF simples é aplicado a um processo regressivo de primeira ordem AR(1), ou seja: $y_t = \rho y_{t-1} + u_t$. A regressão de y_t sobre y_{t-1} fornecerá o valor do parâmetro ρ. O ruído branco de média zero e variância constante é representado por u_t. Assim, testa-se a hipótese nula em que $\rho = 1$ (série não estacionária) contra a hipótese de estacionariedade em que $\rho < 1$ considerando uma estatística de teste e confrontando-a com valores críticos apresentados por Mackinnon (1991). Ampliando a aplicação do teste DF, o teste ADF considera situações com tendência na série temporal e diferentes formas de autocorrelação, como ordens maiores para a correlação autoregressiva e a situação de média variante. (ANDRADE, 2006) Para isto, utiliza o modelo:

$$\Delta y_t = \beta_1 + \beta_2 t + \delta y_{t-1} + \sum_{i=1}^{m} \alpha_i \, \Delta y_{t-i} + a_t \qquad \text{(Eq. 26)}$$

O teste PP baseia-se no modelo $y_t = c + \delta t + \rho \, y_{t-1} + e_t$ e verifica a hipótese nula em que $\rho = 1$ (série não estacionária). O teste considera a situação de tendência e de heterocedasticidade. O teste utiliza as estatísticas do ADF para computar as correlações sobre o termo e_t. Uma vantagem do teste PP sobre o ADF consiste no fato de que é não paramétrico (não necessita fornecer as ordens autoregressivas), por outro lado possui a desvantagem pelo fato de se basear em teorias assintóticas, ou seja, requer número de amostrar relativamente elevados (MAHADEVA e ROBINSON, 2004).

2.6.2. Independência ou autocorrelação das observações

A autocorrelação está presente em dados gerados pela maioria dos processos contínuos e de batelada, visto que o valor de um determinado parâmetro sob monitoramento depende do seu valor passado. Os processos contínuos, como indústrias de papel, de alimentos, de produtos químicos e petroquímicos usualmente exibem severas autocorrelações. Essa característica está mais evidente em dados coletados com alta frequência de amostragem e é relacionada com a dinâmica do processo. O principal efeito da autocorrelação na aplicação das cartas de controle é a geração de limites de controle de largura menor que a requerida. Desta forma, há exibição de maior taxa de falsos alarmes (PSARAKIS e PAPALEONIDA, 2007).

Gujarati (2004) define autocorrelação como a correlação entre membros de séries de observações ordenadas no tempo (séries temporais) ou no espaço. Segundo Tintner (1965) a autocorrelação é uma correlação atrasada de uma determinada série com ela mesma, com atraso de certo número de unidades de tempo.

Montgomery (2009) demonstra analiticamente a ocorrência de autocorrelação em um sistema simplificado composto por um tanque de mistura homogênea com volume V, com vazão de entrada e saída f, concentração de certo material w_t na corrente de entrada no instante t e x_t a concentração na corrente de saída no tempo t. O balanço de massa fornece:

$$x_t = w_t - T\frac{dx_t}{dt} \qquad \text{(Eq. 27)}$$

com T correspondente a constante de tempo do sistema ($T = V/f$). Na situação de um degrau w_o na concentração de entrada (tempo zero), têm-se:

$$x_t = w_o(1 - e^{-\frac{t}{T}}) \qquad \text{(Eq. 28)}$$

Na prática, as observações de x_t não são contínuas, mas sim espaçadas conforme o tempo de amostragem Δt, logo:

$$x_t = x_{t-1} + (w_t - x_{t-1})\left(1 - e^{-\frac{\Delta t}{T}}\right) = a\, w_t + (1 - a)x_{t-1} \qquad \text{(Eq. 29)}$$

com $a = 1 - e^{-\frac{\Delta t}{T}}$.

Considerando ainda que w_t é uma variável aleatória não correlacionada, então a autocorrelação de x_t é dada por:

$$\rho = 1 - a = e^{-\frac{\Delta t}{T}} \qquad \text{(Eq. 30)}$$

Nota-se então que a autocorrelação (ρ) depende do tempo de amostragem (Δt) e da constante de tempo T. Entretanto, na prática deseja-se amostragem menor que a constante de tempo para um melhor acompanhamento do processo. Neste caso, a autocorrelação começa a ser relevante, por exemplo, com $\frac{\Delta t}{T} = 0{,}25$ têm-se a observações demonstradas na Figura 6-a. Caso Δt for significativamente maior que T o sistema não será autocorrelacionado Figura 6-b

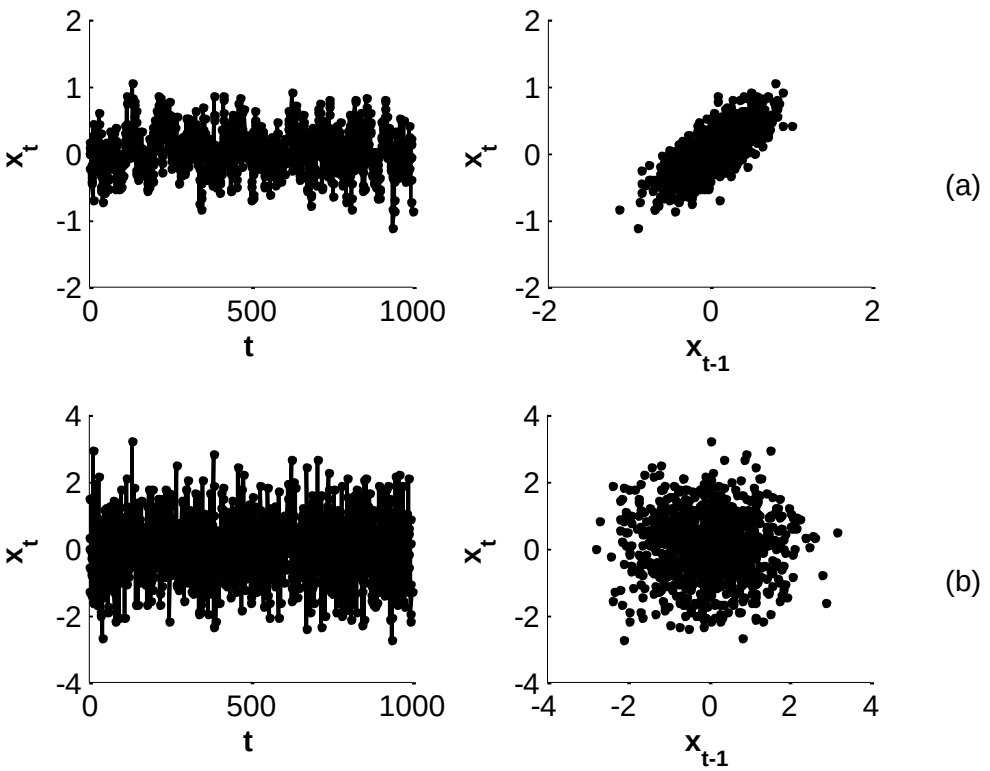

Figura 6: Exemplo de dados autocorrelacionados. Em (a) $\frac{\Delta t}{T} = 0,25$ e (b) $\frac{\Delta t}{T} = 4$.

A hipótese de dados sem autocorrelações é frequentemente violada nas aplicações de gráficos de controle estatístico. Entretanto esta conduta pode levar a conclusões equivocadas na análise do gráfico. Psakis e Papaleonida (2007) indicam que mesmo baixos níveis de autocorrelação podem afetar a utilização das cartas de controle. Os autores referenciam trabalhos de Harris e Ross (1991), Johnson e Bagshaw (1974), Padgett et al. (1992) e Alwan (19922) que mostraram a influência das cartas CUSUM e EWMA na presença de autocorrelação.

Entre os testes utilizados para a indicação de autocorrelação nos dados pode-se citar: teste de Durbin-Watson (1950), desenvolvido para a aplicação principal em testes dos resíduos obtidos com modelos de regressão linear, teste Q de Ljung-Box (1978) para os resíduos de modelos ARIMA e enfim, os correlogramas das funções de autocorrelação (FAC) e autocorrelação parcial (FACP).

A função de autocorrelação (ρ_h), considerando uma série temporal com $Y_1, Y_2, \dots, Y_t$, $\bar{Y}$ a média das amostragens e h unidades de tempo em atraso: (BOX, JENKINS e REINSEL, 1994)

$$\rho_h = \frac{\sum_{i=h+1}^{t}(Y_i - \bar{Y})(Y_{i-h} - \bar{Y})}{\sum_{i=1}^{t}(Y_i - \bar{Y})^2} \qquad \text{(Eq. 31)}$$

O desvio padrão é dado por:

$$SE_\rho = \sqrt{(1 + 2\sum_{i=1}^{h-1}\rho_i^2)/N} \qquad \text{(Eq. 32)}$$

Sabendo que aproximadamente 95% de nível de confiança é obtido com dois desvios padrão é possível detectar a presença de autocorrelação a partir do gráfico gerado pela função de autocorrelação limitado pela linha correspondente a $2\,SE_{\rho}$. A Figura 7 demonstra um gráfico FAC com os limiares (a defasagem zero sempre resultará em $\rho = 1$).

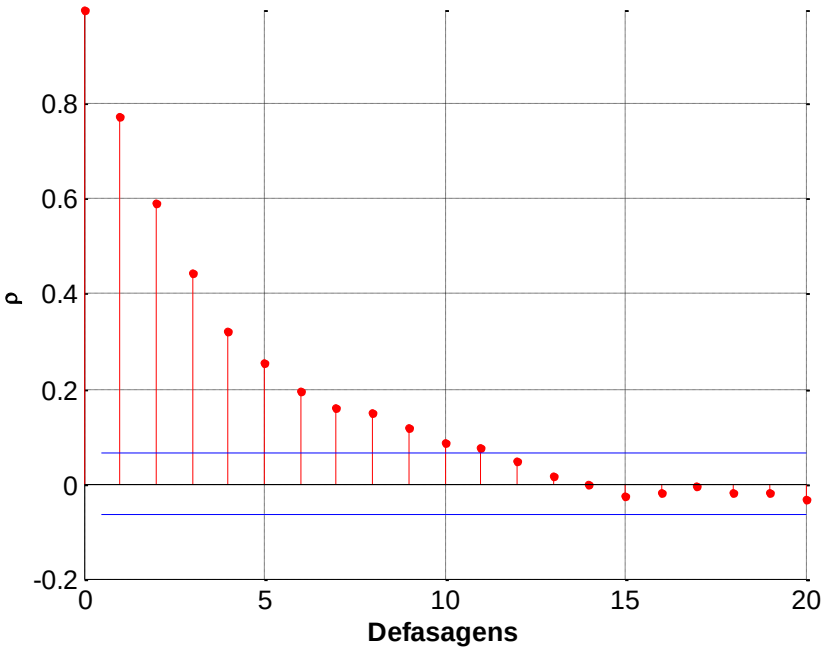

Figura 7: Exemplo de um correlograma FAC demonstrando os valores da autocorrelação (ρ) para diferentes defasagens.

Autocorrelações positivas produzem coeficientes de FAC (ρ_k) de 0 a 1 e exibem um comportamento do tipo senoidal. As autocorrelações negativas fornecem coeficientes FAC de -1 a 0 e possui um comportamento padrão "dente de serra" (YOUNG e WINISTOFER, 2001).

A função de autocorrelação parcial (FACP) calcula a correlação entre observações defasadas em k períodos depois de remover o efeito das observações intermediárias. Na sua determinação utiliza-se regressão múltipla, diferentemente do FAC que utiliza apenas métodos de regressão simples em sua formulação (MOREIRA JUNIOR, 2005).

O teste Q de Ljung-Box utiliza a estatística $Q = T(T-2)\sum_{k=1}^{s}\frac{\rho_k^2}{T-k}$ que segue a distribuição qui-quadrada. Na equação T é o número de amostras, s o número de atrasos considerado e ρ_k a autocorrelação para k defasagens.

2.6.3. Distribuição de probabilidade identicamente distribuída

Outra importante hipótese das cartas de controle corresponde à distribuição de probabilidade identicamente distribuída. Isto é, variância constante ao longo da série temporal (homocedasticidade).

Os testes mais indicados para esta verificação são: teste de Park, teste de Glejser, teste de Goldfeld-Quandt, teste de Breusch-Pagan-Godfrey e o teste geral de heterocedasticidade de While (GUJARATI, 2004). Uma forma simplificada de verificar a homocedasticidade é a comparação de variância entre subgrupos da série temporal, por exemplo, via teste F (KORZENOWSKI, 2009).

2.6.4. Normalidade

Dentre as diferentes distribuições de probabilidade estudadas, a distribuição normal provavelmente é a mais importante, tanto na teoria quanto na aplicação da estatística. (MONTGOMERY, 2009) A distribuição normal pode ser definida pela equação:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi)}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \qquad -\infty < x < \infty \qquad \text{(Eq. 33)}$$

onde a média é μ e a variância é $\sigma^2 > 0$. Usualmente usa-se a notação: $N(\mu, \sigma^2)$ para caracterizar a distribuição normal. Obtêm-se 68,26% da população sobre a faixa $\mu - \sigma < x < \mu + \sigma$; 95,46% para $\mu - 2\sigma < x < \mu + 2\sigma$ e 99,73% para $\mu - 3\sigma < x < \mu + 3\sigma$.

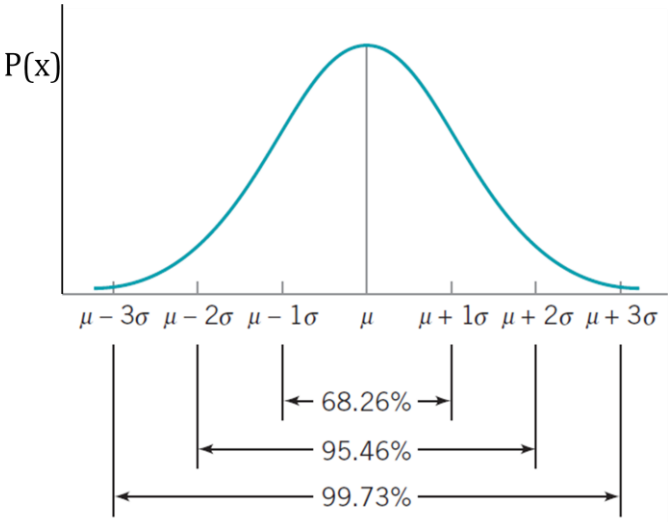

Figura 8: Distribuição Normal de Probabilidade (Montgomery, 2009).

A distribuição normal apresenta características que a fazem ser a mais utilizada: definida por dois parâmetros de alta importância estatística (μ e σ); é simétrica e monomodal (apenas um máximo), logo a média, a moda e a mediana são coincidentes; facilidades de processamento matemático, visto que muitas conclusões analíticas só podem ser explicadas por esta distribuição (as distribuições χ^2 e F de Fisher foram desenvolvidas para análises de resultados considerando variáveis normais). Além disso, o Teorema do Limite Central – que diz que observações geradas por distribuições de probabilidade quaisquer com números $x_1, x_2, \dots, x_N$ e com médias e variâncias μ_{Xi} e σ_{Xi}^2, respectivamente, e com a soma S_N definida por $S_N = \sum_{i=1}^{N} x_i$, a distribuição de probabilidade de S_N se aproxima de uma curva normal quando N é suficientemente grande – contribui para a utilização da distribuição de probabilidade como modelo probabilístico da distribuição de erros de medida (PINTO e SCHWAAB, 2007).

Nos instrumentos de medição é razoável assumir que: (i) os erros são positivos e negativos, com uma distribuição aleatória em torno de um valor zero de forma simétrica; (ii) quanto maior o valor absoluto do erro menor a probabilidade de sua ocorrência (PINTO e SCHWAAB, 2007). Essas condições são satisfeitas pela distribuição normal, logo é coerente a utilização deste modelo de distribuição para analisar os dados obtidos por sensores em plantas industriais.

Entre os principais testes estatísticos para a determinação de distribuição normal os mais utilizados são: teste de Shapiro-Wilk (1965) adequado para pequenas amostras; teste de Kolmogorov-Smirnov (1933) para maiores amostras e o teste de Lilliefors (1967) que desenvolveu uma modificação do teste de Kolmogorov-Smirnov. Há ainda o teste de Jarque-Bera (1980) para ser utilizado considerando possível autocorrelação entre os dados (MONTGOMERY, 2009).

Outra forma de identificar a aderência à distribuição normal é a utilização de gráficos de normalidade ou histogramas. Recomenda-se o uso dos histogramas para grandes números de observações, entretanto a inspeção por esta forma pode ser inconclusiva. Desta forma, os gráficos de probabilidade normal e os testes estatísticos de normalidade são mais apropriados.

Desvios na normalidade ocorrem frequentemente nos dados de processos industriais. Entretanto, desvios moderados são tolerados pelas técnicas de controle estatístico de processos. O principal problema em dados fora da distribuição normal seria um ligeiro aumento do número de alarmes falsos, sendo maior de acordo com o grau de violação da normalidade (MONTGOMERY, 2009).

2.7. Introdução aos Modelos de Série Temporal ARIMA

A compreensão dos modelos de séries temporais no monitoramento de processos autocorrelacionados é importante devido à capacidade destes modelos de extrair dos dados informações relativas a estas correlações. Desta forma, o resíduo obtido entre os dados medidos e o valor predito pelo modelo consegue eliminar a autocorrelação e as técnicas convencionais de CEP podem ser devidamente aplicadas. Os modelos de série temporal ARIMA foram desenvolvidos por Box e Jenkins (1970) e possuem aplicação principal na área de Econometria.

A escolha de um período de tempo de uma variável aleatória na qual se pretende realizar uma análise corresponde ao estudo de uma amostra ou estudo de uma realização particular de um processo estocástico subjacente. Essa amostra é definida como série temporal, isto é, um conjunto de observações de determinada variável em um intervalo de tempo que expressa uma realização particular do comportamento desta variável. Baseado nestas realizações, tenta-se inferir as características estocásticas do processo (GUJARATI, 2004).

Os modelos de séries temporais ARIMA(p,d,q) ou *Autoregressive Integrated Moving Average* possui p termos autoregressivos, q termos de média móvel e d corresponde ao número de diferenciações discretas necessárias para tornar a série estacionária. Segundo Bisgaard e Kulahci (2011) o tipo de não estacionariedade encontrado na maioria dos processos é aquele em que o nível do valor muda, mas o processo exibe homogeneidade na variabilidade. Nesses casos $d = 1$, ou seja, $\Delta y_t = y_t - y_{t-1}$, normalmente é capaz de conceber estacionariedade. Nos casos em que tanto o nível quanto a inclinação da série variam, mas mantendo a variabilidade constante, $d = 2$ tende a atingir um a estacionariedade. Diferenciações discretas de ordens superiores são possíveis, mas dificilmente aplicadas. Exemplos e classificações de processos estocásticos ARIMA são apresentados na Tabela 1:

Tabela 1: Classificação de Modelos ARIMA(p,d,q)

Modelo	Descrição
$y_t = a_t$	Ruído branco - ARIMA(0,0,0)
$y_t = \phi_t\, y_{t-1} + \ldots + \phi_p y_{t-p} + a_t$	Autoregressivo de Ordem p - ARIMA(p,0,0) ou AR(p)
$y_t = a_t - \theta_1 a_{t-1} - \ldots - \theta_q a_{t-q}$	Média Móvel de Ordem q - ARIMA(0,0,q) ou MA(q)
$y_t = \phi_t\, y_{t-1} + \ldots + \phi_p y_{t-p} - \theta_1 a_{t-1} - \ldots - \theta_q a_{t-q} + a_t$	Autoregressivo de Média Móvel - ARIMA(p,0,q) ou ARMA(p,q)

As funções de autocorrelação FAC e de autocorrelação parcial FACP possuem papel crucial na identificação do modelo de série temporal. A Tabela 2

resume as recomendações de Box, Jenkins e Reinsel (1994), além das restrições dos parâmetros dos modelos:

Tabela 2: Padrões FAC e FACP de Modelos ARIMA (Adaptado de KORZENOWSKI, 2009)

Modelo	Comportamento FAC	Comportamento FACP	Restrições de parâmetros
$\mathrm{ARIMA}(1,\mathrm{d},0)$	Decaimento exponencial	Defasagem 1 significantemente diferente de zero	$-1 < \phi < 1$
$\mathrm{ARIMA}(0,\mathrm{d},1)$	Defasagem 1 significantemente diferente de zero	Decaimento exponencial	$-1 < \theta < 1$
$\mathrm{ARIMA}(2,\mathrm{d},0)$	Mistura de exponenciais com ondas senoidais amortecidas	Defasagens 1 e 2 significantemente diferentes de zero	$-1 < \phi_2 < 1$ $\phi_2 - \phi_1 < 1$ $\phi_2 + \phi_1 - 1 < 1$
$\mathrm{ARIMA}(0,\mathrm{d},2)$	Defasagens 1 e 2 significantemente diferentes de zero	Mistura de exponenciais com ondas senoidais amortecidas	$-1 < \theta_2 < 1$ $\theta_2 - \theta_1 < 1$ $\theta_2 + \theta_1 - 1 < 1$
$\mathrm{ARIMA}(1,\mathrm{d},1)$	Decai exponencialmente após o lag 1	Decai exponencialmente após o lag 1	$-1 < \phi < 1$ $-1 < \theta < 1$

Processos ARIMA(p,d,0) com p superiores a 2 possuem FAC decaindo exponencialmente, alterando o sinal ou não, com um padrão senoidal amortecido e FACP com as primeiras p defasagens diferentes de zero. Os modelos ARIMA(0,d,q) apresentam os q primeiros *lags* diferentes de zero no FAC e decaem exponencialmente, com sinais alterando ou não e padrão senoidal amortecido para o FACP (TOLOI, C. e MORETTIN, 1985).

Box, Jenkins e Reinsel (1994) indicam um ciclo iterativo para a modelagem de séries temporais ARIMA constituído por: identificação do modelo; estimação dos parâmetros e verificação. O procedimento de identificação inicia com a diferenciação discreta da série temporal para torná-la estacionária, caso seja não estacionária, e, baseado nas funções FAC e FACP é possível determinar um modelo provável. Os métodos de estimação de parâmetros não serão descritos e referências para tais métodos podem ser obtidas em Box, Jenkins e Reinsel (1994). Uma das abordagens mais utilizadas na estimação de parâmetros é a máxima verossimilhança.

Existem diversos programas computacionais que oferecem pacotes estatísticos para ajustes de séries temporais: SPSS®, Minitab®, Ewiews®, R® e Matlab®. Desta forma, com a utilização destes pacotes, é possível obter o modelo mais adequado à série temporal em questão de forma prática. A comparação de diferentes modelos ajustados pode ser feita pela menor soma quadrática dos erros, em alternativa às análises de FAC e FACP.

Segundo Bisgaard e Kulahci (2011), deve-se atentar à obtenção de modelos parcimoniosos, ou seja, modelos o mais simples possível. A simplicidade de modelos é atrativa, pois são mais compreensíveis, fáceis de usar e interpretar e de se explicar. Modelos com muitos parâmetros são mais difíceis de serem corretamente estimados e tendem a sobre ajustar os dados, ou seja, tornam-se muito particulares para os dados a quais foram ajustados.

As etapas descritas por Box, Jenkins e Reinsel (1994) para a identificação de modelos de séries temporais são detalhadas pelos seguintes passos:

1. Estabelecer a estacionariedade da série temporal. Caso a série não seja estacionária, fazer a diferenciação discreta até obter dados estacionários. A FAC e a FACP decaem exponencialmente para séries estacionárias (ou ficam em zero após alguns *lags*);
2. Identificar um modelo de série temporal para os dados, podendo utilizar os padrões encontrados nos gráficos FAC ou FACP;
3. Especificar o modelo e estimar os parâmetros;
4. Proceder a verificação da qualidade do ajuste aos dados pelo modelo para assegurar que o este é válido. Os resíduos devem ser descorrelacionados, homocedásticos e normalmente distribuídos com média constante;
5. Após a escolha do modelo e de sua verificação, pode-se usá-lo para predições.

Existem critérios desenvolvidos para direcionar a escolha correta do modelo ARIMA. Entre eles pode se destacar os critérios da parcimônia extensamente aplicados em Econometria: (i) *Akaike Information Criterion* (AIC) ou Critério de Informação de Akaike; (ii) *Schwartz Bayesian Criterion* (SBC) ou Critério Bayesiano de Schwartz. Definidos por:

$$AIC = \ln(\hat{\sigma}_e^2) + \frac{2}{T}\,(p+q) \qquad \text{(Eq. 34)}$$

$$SBC = \ln(\hat{\sigma}_e^2) + \frac{(p+q)\ln(T)}{T} \qquad \text{(Eq. 35)}$$

onde T é o número de observações avaliadas e $\hat{\sigma}_e^2$ a variância estimada dos resíduos. O melhor modelo será aquele que apresentar o menor valor de AIC e SBC (GUJARATI, 2004).

2.8. Técnicas Alternativas de Cartas de Controle sem o uso de Modelos de Séries Temporais

Os gráficos de controle são usados frequentemente como forma de monitoramento de parâmetros de um processo. Muitas vezes as suposições básicas de controle estatístico de processos são violadas pelos dados de processo, o que é usual na indústria de processos químicos e de monitoramento online das variáveis. Segundo Montgomery (2009) desvios quanto à normalidade dos dados são toleráveis, entretanto, a violação da independência dos dados tende a inviabilizar o uso das cartas de controle para monitoramento online de processos. Devido a isso, estratégias para a utilização de cartas de controle sobre dados autocorrelacionados vêm sendo desenvolvidas para permitir um monitoramento mais eficiente.

Uma ação simples para mitigar a questão da autocorrelação é diminuir a amostragem dos dados. Entretanto, esse método pode levar a perda de conhecimento do processo, de modo que a detecção de mudanças no processo pode ser atrasada. Logo, não é aconselhável utilizar esta alternativa.

Outra forma de se trabalhar com dados autocorrelacionados em cartas de controle é a modificação das cartas de controle tradicionais. Para isso, faz-se ajuste tanto dos limites de controle, para que considerem a autocorrelação, como da metodologia de estimativa do desvio padrão do processo (VANBRACKLE e REYNOLDS, 1997).

Esses métodos são uma alternativa para os casos em que o ajuste por modelos ARIMA é difícil de ser aplicado em um monitoramento online. Assim, essas técnicas utilizam modificações nas cartas de controle convencionais para monitorar diretamente os dados de processo autocorrelacionados.

Runger e Willemain (1996) propuseram um gráfico de controle baseado nas "médias de bateladas não ponderadas" (*Unweighted Batch Means* - UBM). Na qual os dados de processo são divididos em grupos sucessivos de observações sequenciais com pesos entre seus membros iguais. Sendo uma batelada j-ésima defina por:

$$\bar{x}_j = \frac{1}{b}\sum_{i=1}^{b} x_{(j-1)b+i} \qquad j = 1,2, ... \qquad \text{(Eq. 36)}$$

A vantagem desse método é que apesar de acrescentar o parâmetro relativo ao tamanho de cada batelada de dados (b), não é necessário o ajuste de um modelo de série temporal. A UBM nada mais é que a divisão dos dados em intervalos sequenciais de tamanho b com o cálculo da média para cada um deles. Desta forma, reduz-se a autocorrelação dos dados e é possível empregar os gráficos de controle estatístico tradicionais. De acordo com Montgomery (2009) existem formas empíricas

de se determinar o tamanho de cada batelada sem a necessidade do uso de modelos de temporais, mas a partir desses modelos é possível obter boas estimativas. Este método assemelha-se ao gráfico de controle $\bar{X}$.

O tamanho das bateladas (b) pode ser estimado pelo procedimento empírico proposto por Fishman (1978), citado por Runger e Willemain (1996), que sugere iniciar com $\mathrm{b} = 1$ e ir dobrando até encontrar uma autocorrelação para o lag-1 suficientemente pequena. Runger e Willemain (1996) indicam valores de b para o caso de um processo AR(1).

Mingoti e Fidelis (2001) apresentaram um estudo para a utilização da geoestatística na estimativa do desvio-padrão de dados autocorrelacionados que não requerem o uso de modelos de séries temporais. Os autores avaliaram esta metodologia para os gráficos CUSUM e EWMA. Mingoti & Yassukawa (2008) estudaram a técnica para o gráfico de Shewhart, considerando os limites de controle calculados analogamente ao gráfico original, mas com a estimativa da variância baseada na geoestatística de Houlding (2000). Na estimativa do desvio padrão utiliza-se a função de semi-variograma amostral de Matheron (1963), que é função da autocorrelação (ρ_k) (MINGOTI e FIDELIS, 2001). Os autores afirmam que os estimadores construídos por metodologia de geoestatística representam melhor a variabilidade natural de dados do que a variância amostral S^2 e de estimadores que usam a amplitude amostral. As equações envolvidas para o cálculo do desvio padrão pela metodologia da geoestatística podem ser encontradas em Mingoti & Yassukawa (2008).

Zhang (1998) propôs a utilização de um gráfico EWMA restringido para processos estacionários, o EWMAST. Nele os limites de controle são maiores do que o EWMA convencional para processos autocorrelacionados. O autor usa a condição de que um gráfico EWMA de um processo estacionário é assintoticamente estacionário, assim os valores gerados pelo EWMA dos dados serão estacionários e, a partir da estimativa do desvio padrão desses valores, faz-se o monitoramento destes valores em um gráfico com linha central igual a média do processo e limites superiores e inferiores análogos à carta de Shewhart ($\mu \pm c\,\widehat{\sigma_z}$). Onde c possui os valores usuais (tipicamente 3) e $\widehat{\sigma_z}$ corresponde a estimativa do desvio padrão obtida dos valores de EWMA das observações. Entretanto, a adequada eficiência deste método se restringe a baixos níveis de autocorrelação e mudanças na média reduzidas.

Wardell et al. (1992) considerou um gráfico de controle para medidas individuais autocorrelacionadas por uma estrutura do tipo ARMA(1,1). De acordo com Box e Luceno (1997), para a estimativa do desvio padrão de dados

autocorrelacionados baseados em modelos de série temporal, foi usada a seguinte forma:

$$\sigma_x = \sqrt{\frac{1-2\,\phi\,\theta+\theta^2}{1-\phi^2}\sigma_a} \qquad \text{(Eq. 37)}$$

em que σ_a é o desvio padrão dos resíduos obtidos com o ajuste do modelo ARMA(1,1), ϕ e θ são parâmetros do modelo. Assim os limites podem ser calculados por $\mu \pm c\sigma_x$, com c tomado pelos valores típicos do CEP.

Jiang, Tsul e Woodall (2000) introduziram o gráfico ARMAST para dados autocorrelacionados, cuja variável sob monitoramento é a estatística Z_t baseada no modelo ARMA:

$$Z_t = \theta_0\, X_t + \alpha \sum_{k=1}^{t-1} \phi^{k-1} X_{t-k} \qquad com \;\; \alpha = \phi\theta_0 - \theta \qquad \text{(Eq. 38)}$$

em que θ_0 e ϕ são os parâmetros do modelo ARMA(1,1) e $\theta_0 = 1 + \theta - \phi$. A estatística Z_t obtida é monitorada, por um gráfico análogo ao de Shewhart. Os autores fornecem um procedimento para o ajuste ótimo dos parâmetros para permitir o monitoramento de uma variável sob uma mudança de média de valor específico.

Wheeler (1994) e Gilbert et al. (1997) propuseram uma alteração para os limites de gráficos de controle de medidas individuais baseados em amplitudes móveis para incorporar a variabilidade provocada pelos efeitos da autocorrelação. Os autores indicam que as adaptações são adequadas para dados com autocorrelação do tipo AR(1). A proposta seria estimar a variabilidade dos dados a partir da autocorrelação de lag 1 (ρ_1), na forma:

$$Limites\ de\ Controle = \bar{x} \pm N_{mr}\,\hat{\sigma} \qquad \text{(Eq. 39)}$$

$$\hat{\sigma} = \overline{mr}\,F \qquad \text{(Eq. 40)}$$

Considerando N_{mr} o multiplicador escolhido para dados sem autocorrelação (normalmente 3) e F correspondendo ao fator introduzido pelos autores Wheeler (1994) e Gilbert et al. (1997):

$$F_{Wheeler} = \frac{1}{d_2\sqrt{1-r_1^2}} \qquad \text{(Eq. 41)}$$

$$F_{Gilbert} = \frac{1}{2\sqrt{\frac{1-r_1}{\pi}}} \qquad \text{(Eq. 42)}$$

2.9. Gráficos de Controle Baseados nos Resíduos de Modelos de Séries Temporais

Existe outra estratégia utilizada para eliminação da autocorrelação que é o ajuste de modelos de séries temporais para prever cada observação a partir dos

dados passados e então obter os resíduos entre o valor real e o predito. A partir destes resíduos aplica-se os gráficos de controle tradicionais ou com algumas modificações (PSARAKIS e PAPALEONIDA, 2007). Tipicamente, assume-se que os dados do processo seguem um modelo do tipo autoregressivo de média móvel (Autoregressive Moving-Average - ARMA) da forma:

$$Y_i - \phi_1 Y_{i-1} - \phi_2 Y_{i-2} - \cdots - \phi_p Y_{i-p} = a_1 - \theta_1 a_{i-1} - \theta_2 a_{i-2} - \cdots - \theta_q a_{i-q} \quad \text{(Eq. 43)}$$

Neste modelo, $\tilde{\phi}$ e $\tilde{\theta}$ são parâmetros constantes, p é a ordem da parte autoregressiva, q é a ordem da parte de média móvel e a_i é considerado como independente e identicamente distribuído (i.i.d.) e de distribuição normal com variância σ_a^2. Esta estratégia requer a hipótese que o modelo escolhido para ajuste seja corretamente representativo, gerando os resíduos dados por:

$$e_t = y_t - \hat{y}_t \quad \text{(Eq. 44)}$$

sendo $y_t e\ \hat{y}_t$ os valores medidos e estimados pelo modelo, respectivamente.

Caso o modelo represente corretamente os dados, espera-se que os resíduos sejam normais, independentes e identicamente distribuídos, logo os gráficos de controle convencionais podem ser aplicados.

Os pontos considerados fora de controle nesses gráficos indicarão que os parâmetros exatos de autocorrelação dos dados mudaram, isto é, o padrão estocástico presente nos dados pode ter sofrido alterações, evidenciando que os dados não possuem mais as características iniciais de treinamento. A mudança do padrão estocástico dos dados pode ser causada por uma possível anormalidade do processo.

É importante verificar as hipóteses de normalidade e i.i.d dos resíduos antes de aplicar os gráficos de controle. Alguns autores apontam que o gráfico de controle de Shewhart para resíduos não são sensíveis para pequenas mudanças na média do processo. Desta forma, para aumentar esta sensibilidade de detecção pode-se utilizar os gráficos CUSUM ou EWMA sobre os resíduos.

Alwan e Roberts (1988) sugeriram a aplicação de dois gráficos para o monitoramento: (i) Gráfico das Causas Comuns (*Comum Cause Charts* - CCC) que usa os valores preditos pelo modelo ARIMA ajustado; (ii) Gráfico das Causas Especiais (*Special Cause Charts* - SCC) que usa os gráficos de controle tradicionais para o monitoramento dos resíduos. O CCC na realidade não é um gráfico de controle, visto que não apresenta limites de controle, ele serve como um guia para a visualização dos níveis reais da variável. Já o SCC essencialmente é um gráfico convencional (*Shewhart*, CUSUM ou EWMA) para os resíduos.

Segundo Bisgaard e Kulahci (2011) processos químicos possuem uma natureza não estacionária e o modelo mais comumente utilizado para dados não estacionários é o modelo integrado de média móvel IMA(1,1).

2.9.1. Modelo IMA(1,1): EWMA de Linha Central Móvel

O modelo IMA(1,1) requer que a diferenciação da série temporal dada por $\Delta y_t = y_t - y_{t-1}$ seja estacionária. Além disso, o valor da média ao longo da série temporal deve possuir certa variação. Algumas propriedades do modelo IMA(1,1) podem ser compreendidas escrevendo o modelo IMA(1,1) dado por $y_t = y_{t-1} + a_t - \theta a_{t-1}$ no tempo $t - 1$:

$$y_{t-1} = y_{t-2} + a_{t-1} - \theta a_{t-2} \qquad \text{(Eq. 45)}$$

substituindo esta equação na anterior resulta em:

$$y_t = (y_{t-2} + a_{t-1} - \theta a_{t-2}) + a_t - \theta a_{t-1} \qquad \text{(Eq. 46)}$$

$$y_t = y_{t-2} + (1 - \theta) a_{t-1} - \theta a_{t-2} + a_t \qquad \text{(Eq. 47)}$$

Aplicando recursivamente esta substituição, obtêm-se:

$$y_t = (1 - \theta) \sum_{j=1}^{\infty} a_{t-j} + a_t \qquad \text{(Eq. 48)}$$

Tal expressão torna o modelo em função do ruído branco a_t e indica que o modelo IMA(1,1) está entre o modelo de passeio aleatório (quando $\theta = 0$) e o modelo de ruído branco puro (quando $\theta = 1$). Desta forma, este modelo possui uma flexibilidade de uso, podendo ser aplicado em uma variedade de situações práticas. (BISGAARD e KULAHCI, 2011)

O modelo também pode ser reescrito na forma:

$$y_t = (1 - \theta)(y_{t-2} + \theta y_{t-2} + \theta^2 y_{t-3} + \ldots) + a_t \qquad \text{(Eq. 49)}$$

na qual o termo do segundo parênteses corresponde ao método de médias móveis exponencialmente ponderadas (EWMA), podendo notar que os pesos dados para instantes passados diminuem com o tempo, visto que $|\theta| < 1$.

Montgomery e Mastrangelo (1991) sugeriram a modelagem de qualquer processo no formato ARIMA(0,1,1), também representado por IMA(1,1), seguido da aplicação do gráfico de Shewhart para os resíduos. O embasamento foi que gráficos EWMA em certas situações podem ser usados para dados autocorrelacionados e a substituição do parâmetro λ por $(1 - \theta)$ o torna equivalente ao ARIMA(0,1,1). Essa substituição fornece a previsão de um passo adiante do processo. Ou seja, se $\hat{y}_{t+1}(t)$ é a previsão da observação no tempo $t + 1$ realizada no tempo t, então $\hat{y}_{t+1}(t) = z_t$, sendo $z_t = \lambda x_t + (1 - \lambda) z_{t-1}$ a estatística EWMA.

Têm-se então a sequência de erros, utilizando um passo no horizonte de predição, $e_t = y_t - \hat{y}_t$ sendo normal e i.i.d nos casos em que o modelo é corretamente ajustado aos dados. A minimização da soma quadrática desses erros fornecerá o parâmetro λ ótimo, não sendo necessárias as metodologias utilizadas na estimação de parâmetros para os modelos ARIMA.

Montgomery e Mastrangelo (1991) afirmam que se os dados forem positivamente autocorrelacionado e a média do processo não varie rapidamente, o EWMA com um adequado valor de λ fornece um excelente preditor.

O campo de predições e análise de séries temporais há muitos anos utilizam esta metodologia. Processos de primeira ordem tendem a ser bem representados por este método. Aconselha-se a utilização conjunta do gráfico para os resíduos (e_t) e do gráfico para os valores reais das observações, no qual a predição via EWMA é sobreposta. Montgomery (2009) argumenta que ambos gráficos são necessários, visto que os técnicos envolvidos com o monitoramento em tempo real não conseguem compreender adequadamente o processo apenas visualizando os gráficos dos resíduos (MONTGOMERY, 2009).

Montgomery e Mastrangelo (1991) também apresentaram uma metodologia que permite o monitoramento combinado dos dois gráficos mencionados acima. Considerando que os resíduos (e_t) são normalmente distribuídos, a probabilidade de se obter os resíduos dentro dos limites de 3σ será:

$$P[-3\sigma \leq e_t \leq 3\sigma] = 99{,}73\% \qquad \text{(Eq. 50)}$$

$$P[-3\sigma \leq y_t - \hat{y}_t \leq 3\sigma] = 99{,}73\% \qquad \text{(Eq. 51)}$$

$$P[-3\sigma + \hat{y}_t \leq y_t \leq \hat{y}_t + 3\sigma] = 99{,}73\% \qquad \text{(Eq. 52)}$$

Desta forma, lembrando que nesse método a estatística EWMA é dada por $z_t = \hat{y}_{t+1}(t)$ e considerando que z_t é um preditor adequado, no período $t + 1$ os limites de controle e a linha central podem ser tomados como:

$$LC_{t+1} = z_t \qquad \text{(Eq. 53)}$$

$$LIC_{t+1} = z_t - 3\sigma \qquad \text{(Eq. 54)}$$

$$LSC_{t+1} = z_t + 3\sigma \qquad \text{(Eq. 55)}$$

σ é o desvio padrão dos resíduos.

Assim, a observação y_{t+1} poderá ser comparada com esses limites móveis. Desta forma, combina-se em apenas um gráfico as informações do controle estatístico e da dinâmica do processo. Frequentemente este tipo de gráfico é referido como gráfico de controle EWMA de linha central móvel (Figura 9).

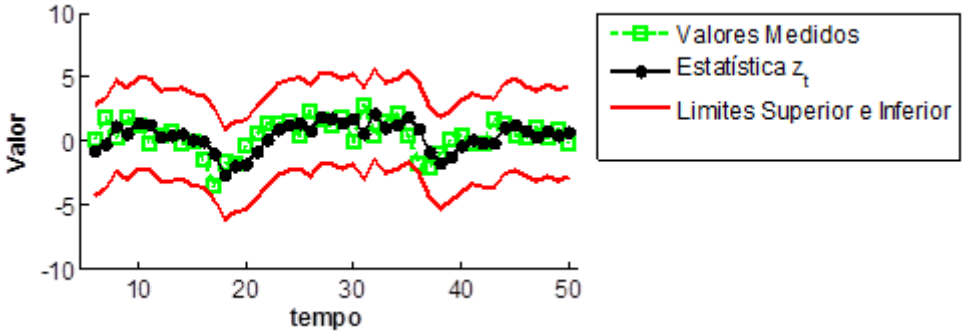

Figura 9: Exemplo de gráfico EWMA de linha central móvel (Dados AR(2)).

2.9.2. Combinação do gráfico de valores originais com resíduos de modelos ARIMA

Moreira Junior (2005) fornece uma generalização do método de Montgomery e Mastrangelo (1991) de EWMA de linha central móvel estendendo o gráfico combinado de resíduos e observações originais para outros modelos ARIMA.

Procedendo as etapas comuns de obtenção de um modelo adequado ARIMA e geração dos resíduos, o autor indica o uso da linha central e dos limites de controle móveis como no método de Montgomery & Mastrangelo (1991). Apesar de não fornecer demonstrações matemáticas para validar o método, define a metodologia como eficiente. Os valores dos limites são:

$$LSC = \hat{y}_t + 3\hat{\sigma}_e \qquad \text{(Eq. 56)}$$

$$LIC = \hat{y}_t - 3\hat{\sigma}_e \qquad \text{(Eq. 57)}$$

$$LC = \hat{y}_t \qquad \text{(Eq. 58)}$$

O valor de $\hat{\sigma}_e$ corresponde ao estimador do desvio padrão dos resíduos. O autor argumenta que o desempenho do gráfico proposto é idêntico ao gráfico de resíduos, com a facilidade de visualização dos valores reais das variáveis medidas.

2.10. Métodos de Identificação da Região sob Controle para Treinamento das Cartas de Controle

Existem diversos métodos que buscam a identificação de estados estacionários de uma série de dados. Eles podem ser mono ou multivariáveis e são classificados entre os que utilizam a decomposição da série em segmentos e os que analisam toda a série temporal sem segmentá-la. Os últimos são baseados em indicadores calculados a partir de estatísticas paramétricas e não paramétrica, de

estimativas das derivadas, de representações do tipo tempo-escala, tempo-frequência e de métodos de aprendizagem de máquinas (MEJIA et al., 2010).

Mejia et al (2010) apresentaram um estudo comparativo entre diversos métodos de identificação de estados estacionários encontrados na literatura. Além disso, propuseram dois novos métodos: (i) método baseado na estimativa da autocorrelação local e na relação sinal ruído e (ii) método baseado na estimativa da derivada.

Os métodos da literatura avaliados pelos autores foram: (i) método de Cao e Rhinehart (1995) baseado na análise comparativa do valor da razão das variâncias de ruído estimadas com um valor de projeto; (ii) método proposto por Cong em 1998, cujo princípio consistie na análise comparativa do valor da medida estatística (C_i) função de um resíduo (diferença entre dados e valor filtrado) e da variância local do processo com um valor crítico pré-estabelecido utilizando janelas móveis; (iii) método de Bebar de 2005 baseado na análise comparativa do valor do índice de estacionariedade $I_{BWW,i}$ obtido por um teste estatístico não paramétrico, denominado Teste de Corrida de Wald-Wolfovitz, com um valor de estacionariedade limiar de projeto (MEJIA *et al.*, 2010).

Canabarro (2011) e Caumo (2006) descreveram uma metodologia de identificação de estados estacionários proposta por Jiang et al. (2003) baseado em transformações *wavelets*. A particularidade dessa metodologia é que realiza a identificação pontualmente, sendo adequada para algumas aplicações em tempo real. O método requer a filtragem dos dados para então efetuar o cálculo das derivadas primeira e segunda da série temporal. A partir dessas derivações e de parâmetros de ajuste, calcula-se um índice de estado estacionário $B_i(t)$ para identificar se um ponto é estacionário ($B_i(t) = 1$) ou não ($B_i(t) = 0$).

Essa metodologia não se mostrou adequada para a identificação de intervalos sob controle pelo fato de fornecer pontos em estado estacionário e não intervalos. Ou seja, o método consegue detectar intervalos de tempo ($t_1 < t < t_1 + \Delta t$) com alta densidade de pontos em estado estacionário, mas não todos. Esse fato dificulta a separação da série temporal em intervalos de estado estacionário. Além disso, o método é muito sensível aos parâmetros de ajuste, visto que a filtragem dos dados interfere fortemente no cálculo das derivadas. Desta forma, são requeridos diversos testes de parâmetros para uma correta identificação.

2.11. Sistema de Compressão de Gás

O sistema de compressão de Unidades Estacionárias de Produção de petróleo é uma parte fundamental de sua operação. Os compressores são essenciais porque permitem a realização do *gas lift* (método para elevação de petróleo), a utilização de gás combustível na própria planta e a obtenção da pressão necessária para a exportação de gás.

Na indústria, o monitoramento das variáveis de processo das turbomáquinas baseia-se em limites de alarme hierárquicos: trip alto, alto alto, alto, baixo, baixo baixo, trip baixo. Os valores destes limites são estabelecidos em função de regras heurísticas baseadas, principalmente, na experiência de pessoal especializado na operação dos compressores. Quando um limite é ultrapassado, a equipe responsável pelo monitoramento comunica a equipe de engenharia e manutenção para determinar o procedimento adotado para diagnosticar e contornar uma operação fora dos limites normais (MIYOSHI, 2011). Desta forma, o estudo de técnicas baseadas em dados históricos pode fornecer um monitoramento mais eficiente por utilizar conceitos estatísticos.

Um sistema de compressão típico é composto por um vaso de sucção, pelo compressor e por um vaso de descarga. Entretanto, em algumas situações utiliza-se mais de um ciclo de compressão. Nestes casos, frequentemente é adicionado um refrigerador entre os ciclos de modo a diminuir a temperatura da corrente gasosa, logo, reduzindo o trabalho requerido na compressão.

Os compressores possuem características de serviço que corresponde à pressão de sucção, temperatura de sucção, natureza molecular do gás (composição) e pressão de descarga. Esses valores definirão as grandezas associadas com o desempenho do compressor, por exemplo: vazão de operação (mássica ou volumétrica), potência de compressão, temperatura de descarga do gás e eficiência.

Os compressores geralmente utilizados em sistemas de compressão de gás em plataformas *offshore* são os centrífugos. Nestes compressores quando a vazão aspirada cai abaixo de um determinado valor ocorre um fenômeno conhecido como *surge*. Nesta situação há oscilações de pressões e vazões, com a possível ocorrência de vazão total reversa, ou seja, o gás volta da descarga (pressão alta) para a sucção da máquina. Este fenômeno leva a ruídos audíveis e fortes vibrações, que em alguns casos podem resultar em danos para os mancais, selos ou rotor (CAMPOS e TEIXEIRA, 2006). Desta forma, um sistema de controle automático capaz de

assegurar a operação da máquina a uma distância confiável do ponto de *surge* é necessário. Este sistema de controle é denominado controle *anti-surge*.

De modo a permitir que o sistema de compressão opere sob condições desejadas é necessário o controle de capacidade, o qual pode ser estruturado para manter a vazão, a pressão de sucção ou a pressão de descarga em um valor constante. Nos compressores centrífugos utilizados em plataformas offshore a variável manipulada do controle de capacidade costuma ser a rotação do acionador: turbina a vapor ou turbinas a gás (CAMPOS e TEIXEIRA, 2006).

Diversos são os estudos no sentido de desenvolver estratégias eficientes de controle *anti-surge* e de capacidade, por exemplo, no uso de desacopladores para mitigar a interação entre os dois sistemas de controle e no uso de controles adaptativos para trabalhar as características não lineares do sistema.

Simulações dinâmicas de compressores representam uma ferramenta adequada para o conhecimento do sistema e na elaboração das estratégias de controle. Além disso, estas simulações podem ser usadas no estudo de técnicas de monitoramento uni ou multivariáveis de processo.

A Figura 10 ilustra um esquema de compressão típico. Têm-se o controle de capacidade efetuado pelo controlador PIC que monitora a pressão de sucção e atua no governador da turbina, correspondente ao controlador de rotação do conjunto rotativo (SIC). A abertura da válvula de vapor para a turbina corresponde ao aumento da potência para o compressor. O controlador PIC situado no vaso de sucção é um sistema de segurança para casos de sobrepressões. O controle *anti-surge* é efetuado pelo controlador FIC, que recebe medições da vazão de descarga e atua na válvula de reciclo. O vaso de descarga corresponde a uma capacitância imaginária correspondente ao volume das linhas de descarga até a válvula de retenção (CAMPOS e TEIXEIRA, 2006).

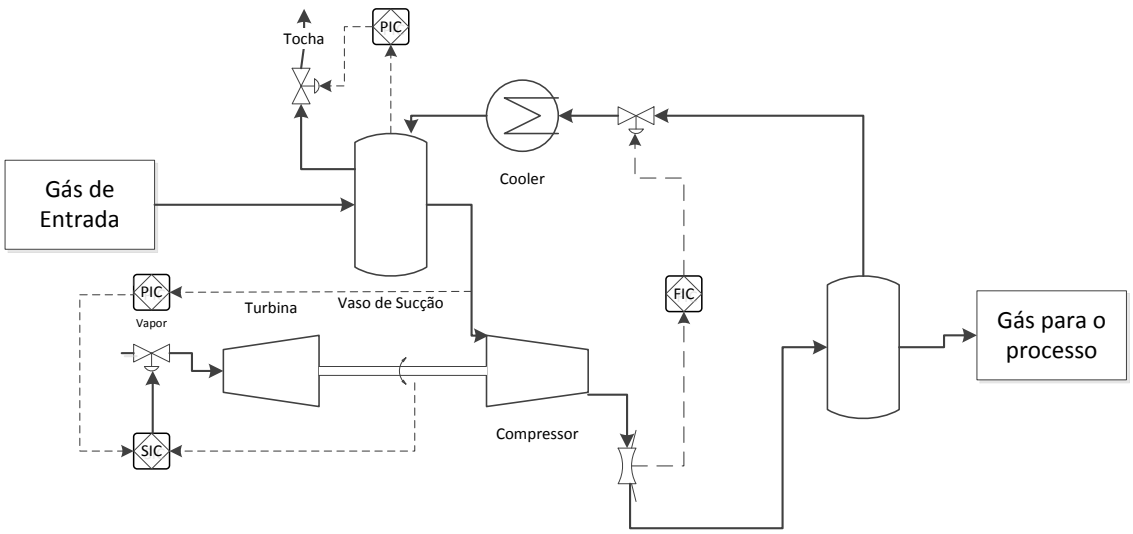

Figura 10: Sistema de Compressão (Fonte: Campos e Teixeira (2006)).

Campos e Teixeira (2006) classificam os componentes do sistema de compressão em capacitâncias e equipamentos de fluxos. Nas capacitâncias do sistema existem variáveis externas associadas à corrente de suprimento e à corrente de saída e envolve equações de balanços de massa que definirão a pressão local. Os equipamentos de fluxo definem a vazão através desses componentes em função do estado termodinâmico de entrada e da pressão de saída.

A simulação dos compressores depende da geometria do impelidor e do difusor. O gás é aspirado continuamente pela abertura central do impelidor e descarregado a alta velocidade pela periferia do mesmo devido à força centrífuga causada pela rotação do sistema. Na saída do impelidor o gás tende a descrever uma trajetória em forma de espiral através do difusor, onde há a desaceleração do gás. Nesta etapa de desaceleração que ocorre a elevação da pressão. Após o difusor, o gás é recolhido pela voluta e conduzido à descarga do compressor, na voluta o gás tende a manter as propriedades de escoamento invariáveis (RODRIGUES, 1991).

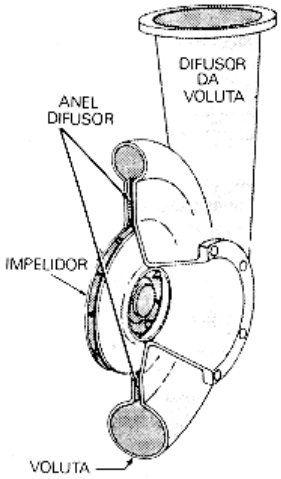

Figura 11: Compressor Centrífugo (Fonte: Site Faculdade de Engenharia PUC-RS).

As características geométricas do compressor, como diâmetro interno e externo do impelidor, largura do impelidor na saída e entrada e ângulos de inclinação das pás, indicarão a energia transferida para o gás por unidade de massa (*Head*) e a eficiência do mesmo sob determinada rotação e vazão. Assim, para a obtenção de informações acerca do comportamento e desempenho dos compressores é necessário estabelecer relações entre as suas variáveis (RODRIGUES, 1991).

A forma mais utilizada de relacionar as variáveis de um compressor é o uso das curvas características fornecidas pelos fabricantes do equipamento. Entretanto, existem conjuntos de equações desenvolvidas para este propósito, como apresentado por Jiang et al. (2006), que utilizam as relações geométricas do compressor. Além disso, nos últimos anos, têm-se utilizado *softwares* de fluidodinâmica computacional para a simulação de compressores, como no trabalho de Moura (2008).

As curvas características correspondem a uma estratégia eficiente e simples para a simulação de compressores, mas requerem a sua disponibilidade ou obtenção experimental. Existem diferentes curvas características, mas as mais utilizadas na simulação são as curvas de *head* e eficiência politrópica em função da vazão volumétrica na sucção e da rotação. Um procedimento iterativo pode ser utilizado para determinar a vazão de operação para uma determinada condição de serviço dada pela rotação, característica do gás, pressão e temperatura de sucção e pressão de descarga (RODRIGUES, 1991).

3. METODOLOGIA

Neste capítulo apresenta-se o desenvolvimento das técnicas adotadas para a aplicação de cartas de controle de processos ao monitoramento univariável de processos contínuos.

O procedimento utilizado propõe a interação do monitoramento em tempo real com os intervalos estáveis identificados pela análise da série temporal. Assim, são discutidas as metodologias de identificação de intervalos estáveis a partir da série histórica de uma variável. Apresenta-se também a estrutura que define a forma em que é aplicada a interação citada.

3.1. Identificação de Intervalos Estáveis da Série Temporal

O monitoramento *online* de uma planta de processo por técnicas de CEP exige a identificação das regiões de operação estável (sob controle) para que os parâmetros do monitoramento sejam estimados. Esses parâmetros são aqueles presentes nos modelos utilizados e os que definirão os limites de controle. Desta forma, no início de um projeto de desenvolvimento de metodologias de monitoramento é necessária a utilização de dados históricos da planta. Tais dados deverão ser analisados e tratados para a identificação das regiões sob controle.

A identificação dos intervalos sob controle da série temporal de uma determinada variável é uma etapa crucial para o correto monitoramento. Contudo, os critérios que definem dados sob controle podem variar de acordo com o tipo de processo. Assim, em certas ocasiões, a identificação automática dessas regiões é dificultada, sendo requerida a inspeção visual de algum técnico com conhecimento do processo.

Os dados históricos de plantas de processo modernas se caracterizam pela grande quantidade de malhas de controle. Essas malhas são gerenciadas por um sistema de controle distribuído que, dentre as suas diversas funções, efetua a coleta e o armazenamento de dados. Para gerenciar a alta quantidade de dados coletados existe um sistema específico de processamento antes do armazenamento definitivo. Esse sistema é composto pelos processos de exceção e compressão. O primeiro ocorre no nó ou ponto de coleta e a tarefa é a redução do número de pontos enviados para o servidor do software de coleta visando eliminar variações de sinais irrelevantes.

No segundo processamento, a função é a redução final da quantidade de pontos armazenados e ocorre no próprio servidor do software de coleta (LPS/COPPE-UFRJ; CENPES, 2011).

Para proceder a identificação dos intervalos sob controle de uma variável para a qual se deseja o monitoramento é necessário definir o que esta condição de operação sob controle representa. No controle estatístico convencional de processos, uma variável sob controle é definida por uma média constante somada a erros aleatórios normais de média nula. Entretanto, para as variáveis de processos industriais complexos, com a presença de comportamento dinâmico e frequentes ajustes de controles *feedback*, essa definição não é adequada. Nesses processos, existe a violação de hipóteses básicas do CEP, principalmente quanto à autocorrelação das observações e até mesmo quanto à estacionariedade.

Uma planta industrial normalmente opera sob um número finito de estados operacionais. Entre eles é possível destacar a inicialização (*startup*), mudanças do tipo degrau/rampa e paradas (*shutdown*). Os estados de uma unidade de processo podem ser classificados em modos e transições. Os modos correspondem à operação contínua, por exemplo, quando não há equipamentos adicionados ou retirados. Durante um modo, o processo tende a um estado quase estacionário, na qual há leves perturbações que podem ser desprezíveis. Desta maneira, as variações encontram-se dentro de um estreito intervalo. As transições correspondem às descontinuidades da operação, como mudanças de referência, abertura de válvulas, mudanças na configuração de equipamentos, perturbações consideráveis, sintonia, falhas em equipamentos, etc. Nas transições, algumas variáveis do processo permanecem constantes, enquanto outras sofrem significativas variações (MEJIA et al., 2010).

Plantas industriais complexas, com altos números de malhas de controle, muitas vezes não apresentam um modo operacional com características de estado estacionário (média constante e sem autocorrelação). Isso ocorre devido a diversos fatores, como a sintonia dos controladores PID utilizados, que muitas vezes são ajustados para fornecer uma variável de controle oscilatória, visto que desta forma o *setpoint* é atingido de forma mais rápida. Além disso, os altos números de malhas de controle podem causar interferência entre elas, de modo que a ação de uma determinada malha leva outra malha a atuar. Outro ponto importante é a presença de distúrbios frequentes, de modo que as malhas de controle ficam constantemente atuando, por exemplo, variações na carga e na temperatura ambiente.

Em casos como esses, pode ser adequado utilizar critérios baseados nos conceitos de estabilidade de sistemas dinâmicos para a identificação dos intervalos sob controle. Um conceito de estabilidade frequentemente utilizado é a BIBO

(*Bounded Input, Bounded Output*). Esta definição considera um sistema dinâmico como estável quando cada entrada finita produz uma saída também finita, independente do seu estado inicial. O termo finito utilizado significa que a variável permanece entre um limite inferior e superior, por exemplo, senóides e degraus (STEPHANOPOULOS, 1984). Esta definição de estabilidade pode guiar a identificação dos intervalos dos dados históricos considerados sob controle que definirão os parâmetros do monitoramento.

A Figura 12-a demonstra um exemplo de estado estável para a aplicação dos conceitos de controle estatístico de processos convencionais. Neste caso o processo deve possuir média constante com variabilidade devido a erros aleatórios de média nula e distribuição normal.

Devido aos fatores supracitados, as medições da indústria de processos contínuos possuem autocorrelação e em alguns casos sofrem o efeito de ações de controladores. Desta forma, a média do processo não se estabiliza em um valor único. A Figura 12-b ilustra um exemplo de um possível estado sob controle da indústria de processos químicos (série temporal modelada a partir de uma estrutura ARIMA(1,1,1)).

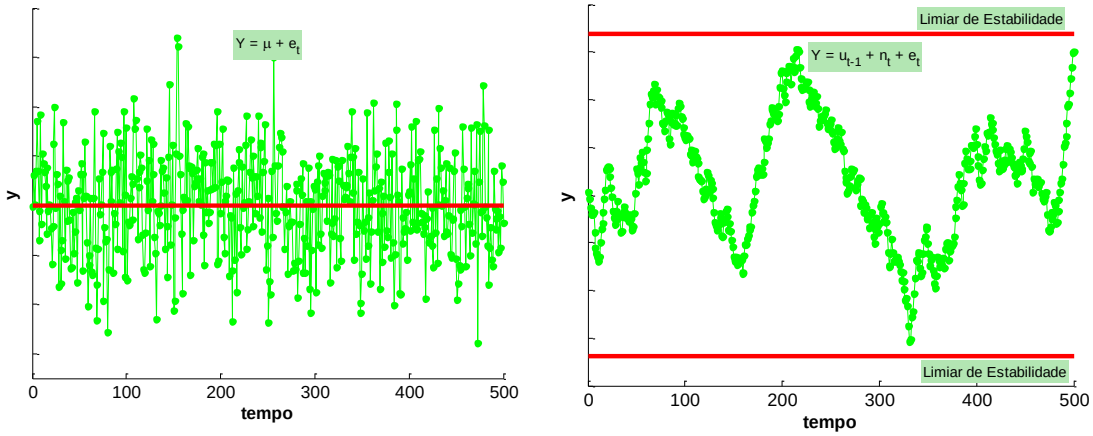

(a) (b)

Figura 12: Exemplo comparativo de intervalo estável de CEP convencional (a) com o intervalo estável de Processos Contínuos (b)

Jiang et al. (2003) e Mejia et al. (2010) consideram que no ponto de vista de operação de plantas industriais, o conceito de estado estacionário é diferente da "estacionariedade" estatística do CEP convencional. Segundo os autores, um estado estacionário de plantas industriais requer apenas que a inclinação de cada variável seja pequena, isto é, menor que um limiar (I_{SS}):

$$\left|\frac{y(t)-y(t_0)}{t-t_0}\right| < I_{SS} \quad para \ \forall\, t \in [t_0 - \Delta t\,, t_0 + \Delta t] \qquad \text{(Eq. 59)}$$

Segundo Jiang et al. (2003) essa relação pode ser bem representada pela derivada do sinal com o tempo. Entretanto, para sinais ruidosos essa consideração

não é viável, já que os ruídos tendem a aumentar o valor desta relação, mesmo em situações de estado estável.

Diante do exposto acima, propõe-se aqui um método de separação de intervalos estáveis de uma série temporal considerando duas abordagens: intervalo estável como estacionário (ruídos brancos com uma média constante) e intervalo estável considerando pequenas variações na média como tolerável, ou seja, que permite certa variabilidade da mesma.

3.1.1. Método de Identificação de Intervalos Estáveis Proposto

O método proposto para a separação de intervalos estáveis utilizou o conceito de médias de bateladas não ponderadas (Unweighted Batch Means - UBM). Essa metodologia sugere a divisão da série temporal em grupos sucessivos de tamanho L contendo observações também sucessivas para a representação da média do processo. Desta forma, há atenuação da autocorrelação dos dados e do ruído do processo.

Aplicando esta divisão da série de dados é possível comparar a média e variância entre dois subgrupos sucessivos para a identificação de intervalos de mesma média e variância (ou de médias com variação tolerável). A metodologia agrupa intervalos que são considerados de mesma média e variância, separando dos intervalos que possuem médias e/ou variâncias diferentes.

O teste de comparação de variâncias utilizou o teste F de igualdades de variância. A hipótese nula indica que duas populações com distribuições normais possuem a mesma variância. O teste é elaborado para duas amostras independentes e identicamente distribuídas seguindo a distribuição normal. Para a realização do teste sobre duas amostras X_1 com n_1 observações e desvio padrão s_1 e X_2 com n_2 observações e desvio padrão s_2 deve-se obter a estatística F, calculada por $F = \frac{s_1^2}{s_2^2}$, e compara-a com valores críticos dependentes do nível de significância (α) adotado. Como o teste é bilateral, os valores críticos são $F_{\frac{\alpha}{2}}$ e $F_{1-\frac{\alpha}{2}}$ da distribuição F com $n_1 - 1$ e $n_2 - 1$ graus de liberdade no numerador e denominador, respectivamente. Assim, se F for maior que $F_{1-\frac{\alpha}{2}}$ ou menor que $F_{\frac{\alpha}{2}}$ rejeita-se a hipótese nula indicando que as amostras não possuem variâncias iguais sob o nível de significância adotado. Caso contrário, não rejeita-se a hipótese nula o que indica igualdade nas variâncias das amostras.

Desta forma, de modo a permitir o uso deste teste estatístico, utilizou-se a diferenciação discreta das observações de cada intervalo para reduzir autocorrelações. Além disso, utilizou-se de níveis de significância reduzidos, desta forma, a rejeição da hipótese nula só ocorrerá para diferenças de variâncias significativas.

Duas formas de comparação de média podem ser aplicadas conforme a definição de estado estável considerada. Caso o estado estável seja considerado como estado estacionário (média constante) pode-se utilizar o teste estatístico *T-test* para a comparação da média de duas amostras. Este teste utiliza a estatística t para a comparação de um intervalo x_1 com outro intervalo x_2. Considerando as variâncias das amostras iguais e dados independentes, têm-se:

$$t = \frac{|\overline{x}_1 - \overline{x}_2|}{S_{x_1 x_2}\sqrt{\frac{1}{n_1}+\frac{1}{n_2}}} \qquad \text{(Eq. 60)}$$

em que

$$S_{x_1 x_2} = \sqrt{\frac{(n_1-1)S_{x_1}^2 + (n_2-1)S_{x_2}^2}{n_1+n_2-2}} \qquad \text{(Eq. 61)}$$

A partir do valor de t calculado, compara-o com o valor de $t_{critico}$ dado pelo nível de significância desejado e pelo grau de liberdade $n_1 + n_2 - 2$, esse valor pode ser obtido por tabelas ou por algum software estatístico. Quando a estatística t for maior que o valor $t_{crítico}$ rejeita-se a hipótese nula, ou seja, as médias entre as amostras não são iguais. Nas equações acima, considera-se n_1 e n_2 o tamanho de cada amostra, S_{x_1} e S_{x_2} o desvio padrão amostral e $\overline{x}_1$ e $\overline{x}_2$ as médias de cada intervalo.

A comparação de médias pelo *T-test* utiliza a fundamentação teórica de que um estado estacionário deve conter subintervalos de médias estatisticamente iguais. Entretanto, existem situações na prática em que pode ser mais adequado permitir uma pequena variação de média nos intervalos estáveis.

Nesses casos, baseado na consideração de Jiang et al. (2003) e Mejia et al. (2010), que permite uma mudança de média, desde que esta mudança seja menor que um limiar pré estabelecido, e do conceito de bateladas de observações, propôs-se a utilização de uma relação entre a variação das médias dos subgrupos tomando como base a média do subgrupo com as observações antecessoras, ou seja:

$$d_{MÉDIA} = \begin{cases} 0 \;\; se \;\; \frac{|\overline{x}_1 - \overline{x}_2|}{|\overline{x}_1|} \leq LIM_{MÉDIA} \\ 1 \;\; se \;\; \frac{|\overline{x}_1 - \overline{x}_2|}{|\overline{x}_1|} > LIM_{MÉDIA} \end{cases} \qquad \text{(Eq. 62)}$$

Desta maneira, $d_{MÉDIA}$ assumirá valor nulo se a variação das médias for pequena (quando a relação acima for menor que $LIM_{MÉDIA}$) e valor unitário quando a

variação das médias for significativa. Com isto, este critério de comparação permite que um estado sob controle contenha pequenas variações na média, condição frequente em plantas industriais. Nos casos em que a média da variável situa-se em torno de zero, a relação acima pode não ser adequada, neste caso é preferível utilizar apenas a relação $|\overline{x}_1 - \overline{x}_2| \leq LIM_{MÉDIA}$ para definir intervalos de mesma média. Este teste difere-se do *T-test*, pois permite maiores variações na média, visto que o teste t mesmo para reduzido nível de significância rejeitará a hipótese nula de médias equivalentes a partir de certa diferença entre as médias dos intervalos.

Considerando um subgrupo de observações anterior ($\underline{x}_a$) e um subgrupo posterior ($\underline{x}_b$), ambos contendo L valores em sequência da série de dados (y_i) com N números de pontos, o procedimento de identificação de intervalos estáveis pode ser estruturado como:

I. Inicialização com a definição do tamanho dos subgrupos L e atribuição dos valores de $\underline{x}_a$ e $\underline{x}_b$: (os parâmetros j e k são contadores do procedimento)

$$j \leftarrow 0 \quad ; \quad k \leftarrow 0$$

$$\underline{x}_a = \begin{bmatrix} y_{jL+1} \\ y_{jL+2} \\ \vdots \\ y_{jL+L} \end{bmatrix}$$

$$j \leftarrow 1$$

$$\underline{x}_b = \begin{bmatrix} y_{jL+1} \\ y_{jL+2} \\ \vdots \\ y_{jL+L} \end{bmatrix}$$

II. Realiza-se teste estatístico de variância (teste F) entre os intervalos $\underline{x}_a$ e $\underline{x}_b$. Além disso, compara-se a média dos subgrupos utilizando o teste estatístico *T-test* ou com a relação entre as médias proposta, $d_{MÉDIA}$:

a. Caso confirmado igualdade de ambos os testes, os intervalos são agrupados e será considerado como o novo intervalo anterior, ou seja,

$$\underline{x}_a = \begin{bmatrix} \underline{x}_a \\ \underline{x}_b \end{bmatrix}$$

b. Caso haja rejeição de algum dos testes, os intervalos não serão agrupados e o intervalo $\underline{x}_a$ formará um intervalo de dados candidato a estado sob controle ($\underline{C}_k$). Além disso, este intervalo assumirá os valores do intervalo sucessor:

$$k \leftarrow k + 1$$

$$\underline{C}_k = \underline{x}_a$$

$$\underline{x}_a = \underline{x}_b$$

III. Incrementa-se j:

$$j \leftarrow j + 1$$

e enquanto $j\,L < N$ atribui-se o próximo subgrupo posterior:

$$\underline{x}_b = \begin{bmatrix} y_{jL+1} \\ y_{jL+2} \\ \vdots \\ y_{jL+L} \end{bmatrix}$$

IV. Retoma a etapa II até o fim da série de dados. No final do procedimento, ou seja, quando $j\,L \geq N$, considera-se também o último intervalo como candidato a estado sob controle: $k \leftarrow k + 1$ e $C_k = \underline{x}_a$.

O procedimento acima retornará, então, possíveis candidatos a estado sob controle da série temporal, cujos valores estão armazenados nas variáveis C_k. Tendo em vista que a finalidade desejada é a obtenção de estados sob controle representativos, ou seja, com uma duração significativa, faz-se a comparação da duração de cada vetor C_k com um limite pré-estabelecido. A duração de C_k pode ser expressa em unidades de tempo ou, simplesmente, pelo número de elementos do vetor. Desta forma, quando a duração de C_k for maior que o limite estabelecido o intervalo correspondente a C_k representará um intervalo estável de operação da planta. Caso contrário, o vetor C_k não é indicado como estado estável. O limite pré-estabelecido pode ser dado como múltiplo do tamanho dos subgrupos L, visto que o tamanho do vetor C_k depende do número de confirmações das comparações de médias e variâncias. Enfim, testando todos os vetores C_k, obtêm-se os intervalos estáveis da série temporal.

Após a obtenção dos intervalos de estados sob controle, pode haver ocorrência de intervalos de mesma condição operacional, ou seja, intervalos de mesma média e variância. Logo, deve-se fazer um agrupamento destes para a organização final dos intervalos estáveis.

O agrupamento é realizado fazendo a comparação de cada intervalo com todos os outros intervalos. Para isso, realizam-se testes comparativos de médias (teste T ou desvio relativo de média) e de variâncias.

Este procedimento irá finalizar a etapa de identificação de intervalos estáveis e ao final do mesmo espera-se obter as regiões operacionais da variável observada.

Esses intervalos poderão ser armazenados de forma a criar uma base de dados própria para cada variável relevante do processo.

Esta metodologia de identificação de intervalos estáveis depende de alguns parâmetros: o tamanho dos subgrupos L; nível de significância do teste F; o nível de significância do teste T ou o limiar $LIM_{MÉDIA}$ para o teste de média e a duração mínima para um intervalo ser considerado estável.

Os níveis de significância dos testes estatísticos possuem uma faixa pequena de variação, valores típicos são de 0,0001 a 0,1, desta forma seu ajuste é facilitado. A duração mínima para a consideração de um intervalo estável também é relativamente fácil de ser ajustada, pode-se utilizar um múltiplo inteiro de L, por exemplo de 2 a 15.

O tamanho do subgrupo L é um parâmetro de alta influência na metodologia, por isso, é conveniente o teste de diferentes valores para um ajuste correto. Seu valor dependerá do tempo de amostragem e da dinâmica do processo em questão.

Finalmente, quando permitido variações pequenas na média, ou seja, utilizado o critério do desvio relativo de média, o parâmetro LIM_{MEDIA} torna-se outro parâmetro de grande influência da metodologia, também requer testes de diferentes valores para sua correta estimação. A Tabela 3 relaciona os parâmetros usados na metodologia.

Tabela 3: Parâmetros da metodologia de Identificação de Intervalos Estáveis

Descrição	Sigla	Faixa de valores típicos
Número de pontos dos subintervalos de comparações de média e variância	L	10 a 100
Multiplicador de L para tempo limite de confirmação de Estado Sob Controle	$N_{t_{conf}}$	2 a 15
Nível de significância do teste de Média e de Variância	α_T e α_F	0,0001 a 0,05
Limite da comparação por desvios relativos de médias	$LIM_{MÉDIA}$	0,0001 a 0,5

Deve-se ressaltar as limitações da metodologia, visto que ainda depende de alguns parâmetros de ajuste. Entretanto, considerando que a definição de um estado sob controle pode ser relativa, isto é, dependente do processo industrial e da variável que se deseja monitorar, a metodologia de desvios relativos de média torna-se vantajosa, visto que permite uma flexibilidade de identificação de intervalos estáveis.

3.2. Monitoramento Univariado de Processos com Gráficos de Controle Estatístico

Nesta seção, apresentam-se os métodos e a estrutura utilizada para o monitoramento de variáveis de processos industriais. O fluxograma da Figura 13 representa a estrutura adotada para a realização do monitoramento univariável:

Inicialmente faz-se a identificação dos intervalos estáveis a partir da série histórica da variável em análise. Em seguida, realiza-se a verificação das hipóteses de normalidade, estacionariedade e autocorrelação de cada estado sob controle identificado. O termo estacionariedade utilizado aqui refere-se a uma série temporal sem tendência na média, entretanto, a média ao longo do intervalo pode sofrer variações em torno de uma média global (*drift mean*). De acordo com as características estatísticas dos dados, pode-se utilizar as técnicas baseadas em modelos de séries temporais ou a reamostragem e modificações de limites de controle.

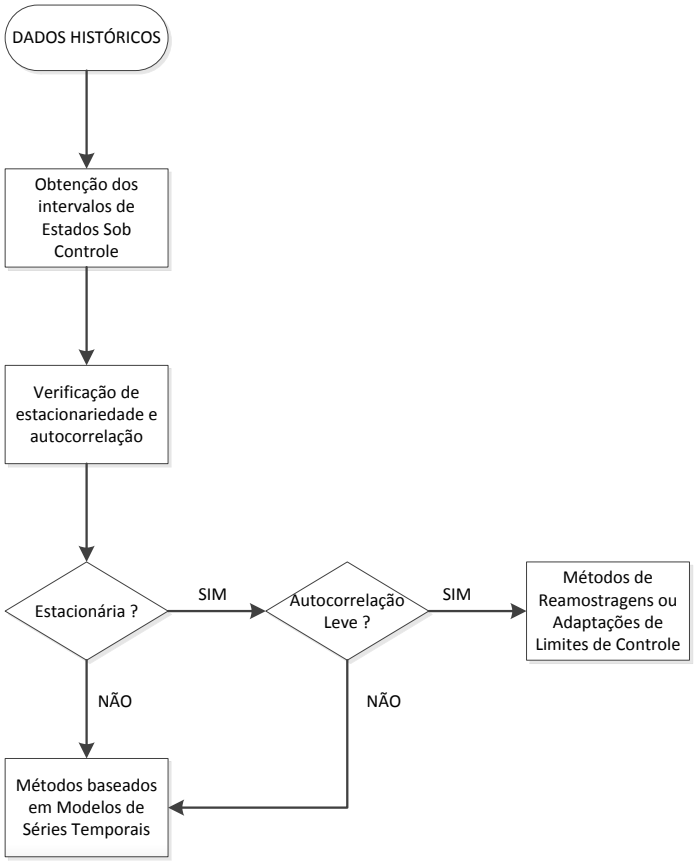

Figura 13: Estrutura para o Monitoramento Estudado

3.2.1. Verificação Estatística dos Estados Sob Controle

O monitoramento de uma determinada variável do processo requer o conhecimento estatístico dos dados considerados sob controle. Este conhecimento é necessário para indicar a técnica adequada de monitoramento.

As cartas de controle convencionais empregadas nas indústrias de manufatura exigem que as observações sob controle sejam independentes e identicamente distribuídas com distribuição de probabilidade normal. Entretanto, como salientado anteriormente, os dados de processos industriais geralmente exibem dinâmica e autocorrelação entre as observações. Nesses casos, deve-se utilizar técnicas capazes de remover os efeitos da autocorrelação.

Na análise dos dados considerados como sob controle realizaram-se testes estatísticos para a verificação das hipóteses de normalidade, independência e estacionariedade. A condição de dados homoscedásticos foi considerada válida, visto que na separação dos intervalos estáveis são realizados testes estatísticos simultâneos para a comparação da variância entre os subgrupos de observações.

A consideração de estacionariedade dos dados é importante tanto para a aplicação dos gráficos de controle como para a utilização dos modelos de séries temporais autoregressivos de médias móveis. Neste trabalho foi considerado o teste Dickey-Fuller Aumentado (ADF) e o teste de Phillips-Perron (PP), amplamente utilizados em Econometria (ANDRADE, 2006). Os testes verificam a hipótese nula de presença de raiz unitária na série temporal, ou seja, série temporal não estacionária. Quando os testes rejeitam a hipótese nula, ou seja, retornam valor 1, a série temporal analisada é dita estacionária sob o nível de significância considerado.

Existem diversos testes para determinar se a distribuição dos dados é normal, entre eles: Jarque-Bera, Kolmogorov-Smirnov e Lilliefors (KORZENOWSKI, 2009). Entretanto, segundo Moreira (2005) a violação leve ou moderada da suposição de normalidade é tolerável pelos métodos de monitoramento por cartas de controle. Uma das formas de determinar o grau de violação desta suposição seria a visualização dos dados por histogramas, ou pode-se alterar o nível de significância dos métodos estatísticos acima.

A hipótese de dados autocorrelacionados pode ser verificada pelos correlogramas FAC e FACP, além de testes estatísticos, como o teste Q de Ljung-Box (KORZENOWSKI, 2009). Devido às limitações das cartas de controle estatístico convencionais em monitorar dados autocorrelacionados, a verificação desta condição é crucial para a correta detecção de causas especiais de variabilidade.

Após a verificação das principais hipóteses para a utilização dos conceitos de CEP, pode-se prosseguir com o monitoramento da variável escolhida. Foram investigadas duas abordagens para o monitoramento univariado: uma utilizando modelos de séries temporais (incluindo a técnica EWMA de linha central móvel, um caso particular dos modelos ARIMA) e outra considerando as cartas de controle convencionais (com reamostragem ou modificações nos limites de controle).

Como mencionado por Jiang et al. (2003) e Mejia et al. (2010) um estado sob controle do ponto de vista de operação em indústrias de processos contínuos permite uma pequena inclinação das observações, desta forma, a suposição de estacionariedade pode ser violada. A hipótese de independência é usualmente violada por esses tipos de processos, devido ao seu caráter dinâmico.

Quando as hipóteses para a aplicação dos gráficos de controle são respeitadas ou possuem desvios leves, as regras de sensibilidade consolidadas de CEP fornecem resultados adequados na detecção de condições fora de controle. A regra adotada foi a de Western Eletric Inc. (1958). Entretanto, quando existe violação das hipóteses de CEP é possível estruturar diferentes regras de sensibilidade em uma tentativa de definir situações fora de controle. Por exemplo, é possível a utilização das seguintes relações para detecção de condição fora de controle: (i) x observações acima ou abaixo dos limites de controle entre as últimas y medições; (ii) w observações todas acima ou todas abaixo da linha central entre as últimas z medições. Os valores de z, y, w, z devem ser escolhidos de acordo com a variável a ser monitorada, logo significa uma dificuldade para o ajuste do método adequado.

Nas situações em que há violação da estacionariedade e da independência dos dados deve-se utilizar modelos de série temporal ARIMA, destacando o modelo IMA(1,1), que corresponde à técnica de monitoramento EWMA de linha central móvel. Quando não há violação da estacionariedade e com baixa presença de autocorrelação uma técnica possível é a utilização das bateladas de médias não ponderadas (UBM), que corresponde às cartas de controle convencionais quando a batelada possui tamanho unitário, além das adaptações dos limites de controle propostas por Gilbert (1997) e Wheeler (1994).

3.2.2. Monitoramento por Gráficos de Controle sem o Uso de Modelos de Séries Temporais

Em situações práticas muitas vezes a utilização de modelos de séries temporais não é viável, visto que pode possuir implementação e interpretação

complexa. Nesses casos uma alternativa é utilizar métodos de adaptação de limites de controle capazes de corrigir os efeitos da autocorrelação.

Técnicas para gráficos de controle de médias de bateladas não ponderadas (UBM) de Runger e Willemain (1996) e modificações de limites de controle pelas correções de Wheeler (1994) e Gilbert (1997) são estratégias para lidar com a autocorrelação nos dados sem a necessidade de identificar modelos de série temporal.

O método de médias de bateladas não ponderadas requer uma escolha adequada do tamanho dos subgrupos de observações (b). No caso de $b = 1$ tem-se os gráficos de controle convencionais para medidas individuais. Runger e Willemain (1995) fornecem indicações para o tamanho dos subgrupos para processos autocorrelacionados do tipo AR(1). Contudo, dependendo do tipo e intensidade da autocorrelação o valor de b necessário pode ser muito elevado, de modo que o desempenho do monitoramento deteriora-se, visto que o tempo necessário para a detecção de uma causa especial será maior.

As modificações nos limites de controle propostas por Wheeler (1994) e Gilbert (1997) foram originalmente desenvolvidas para processos do tipo AR(1), ou seja, com modelo $y_t = \phi_1 y_{t-1} + a_t$. Entretanto, segundo Moreira Jr (2005) as modificações podem ser eficientes para ordens maiores de autocorrelação autoregressiva.

O método das médias de bateladas não ponderadas é útil para os casos em que a frequência de amostragem é elevada, sendo uma estratégia simples de diminuir a autocorrelação dos dados. Desta forma a combinação das médias de bateladas com as modificações nos limites de controle propostas por Wheeler (1994) e Gilbert (1994) pode mitigar os efeitos da autocorrelação sobre os gráficos de controle.

3.2.3. Monitoramento utilizando Modelos de Séries Temporais ARIMA

A aplicação do monitoramento baseados nos modelos de séries temporais corresponde a uma solução robusta para o problema de desvios de autocorrelação nos dados. Além disso, essa metodologia permite a consideração de um estado sob controle não estacionário (com uma leve tendência) através do termo de integração dos modelos ARIMA. Desta forma, o monitoramento utilizando modelos de séries temporais ARIMA corresponde a uma técnica eficiente para dados de plantas industriais complexas, com diversas malhas de controle.

Os modelos ARIMA(p,d,q) genéricos englobam um conjunto de possíveis modelos que podem ser testados pela combinação das ordens dos filtros de autoregressão (p), integração (d) e de médias móveis (q). Por isso, é necessária a identificação do modelo correto e da estimação de seus parâmetros. Entretanto, é importante que o modelo seja o mais parcimonioso possível, ou seja, representativo o suficiente, mas de forma simples. Segundo Vaz Junior (2006) ordens elevadas tendem a tornar a aplicação do modelo lenta e a funcionarem apenas para os dados com os quais foram estimados. O fluxograma da Figura 14 indica a estrutura proposta por Box e Jenkins (1994) para a escolha do modelo.

O monitoramento por modelos ARIMA utiliza a previsão de um instante adiante. Assim, o resíduo gerado pelos dados reais com a previsão é monitorado pelos gráficos de controle convencionais (Shewhart, CUSUM ou EWMA).

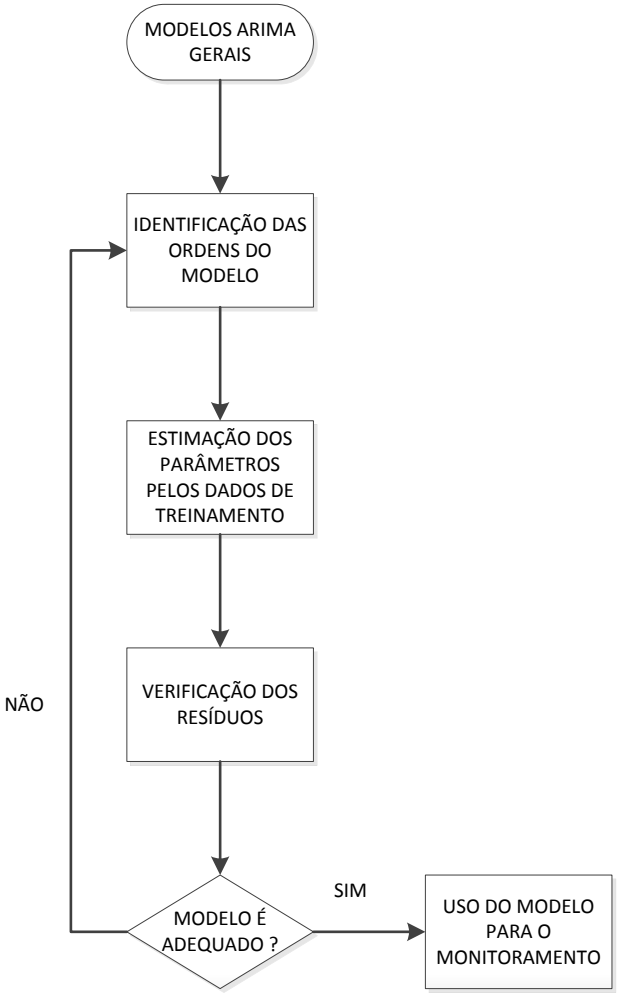

Figura 14: Estrutura de Identificação de Modelos ARIMA (BOX e JENKINS, 1970)

Um caso particularmente importante dos modelos ARIMA é o IMA(1,1) no qual é baseado o gráfico EWMA de linha central móvel proposto por Montgomery e

Mastrangelo (1991). Este método é indicado para situações em que a média do processo não se mantém sempre fixa. Montgomery (2009) e Bisgaard e Kulahci (2011) indicam que esta metodologia é adequada para processos químicos. A vantagem desta metodologia é a combinação do gráfico de resíduos com o gráfico dos valores reais, deste modo o corpo técnico responsável pelo monitoramento em uma planta industrial é capaz de acompanhar a dinâmica do processo.

Moreira Jr. (2005) indicou o uso da mesma estrutura proposta por Montgomery e Mastrangelo (1991) de combinação dos gráficos de resíduos com os valores reais para os demais modelos ARIMA(p,d,q). Segundo o autor, o gráfico combinado possui a mesma eficiência de monitoramento que os gráficos de resíduos.

Diante das técnicas apresentadas, a estrutura implementada para o monitoramento baseado em modelos de séries temporais foi a utilização de dois gráficos: o primeiro utilizando o formato EWMA de linha central móvel, considerando a generalização proposta por Moreira Junior (2005), e o segundo usando os resíduos obtidos pela previsão com o modelo. Desta forma, é possível acompanhar a dinâmica da variável com seu valor original (primeiro gráfico) e utilizar os conceitos consolidados de Controle Estatístico de Processos pelo segundo gráfico, visto que os resíduos apresentam comportamento conforme as suposições dos gráficos de controle convencionais, quando o modelo é corretamente identificado. A Figura 15 indica esta estrutura.

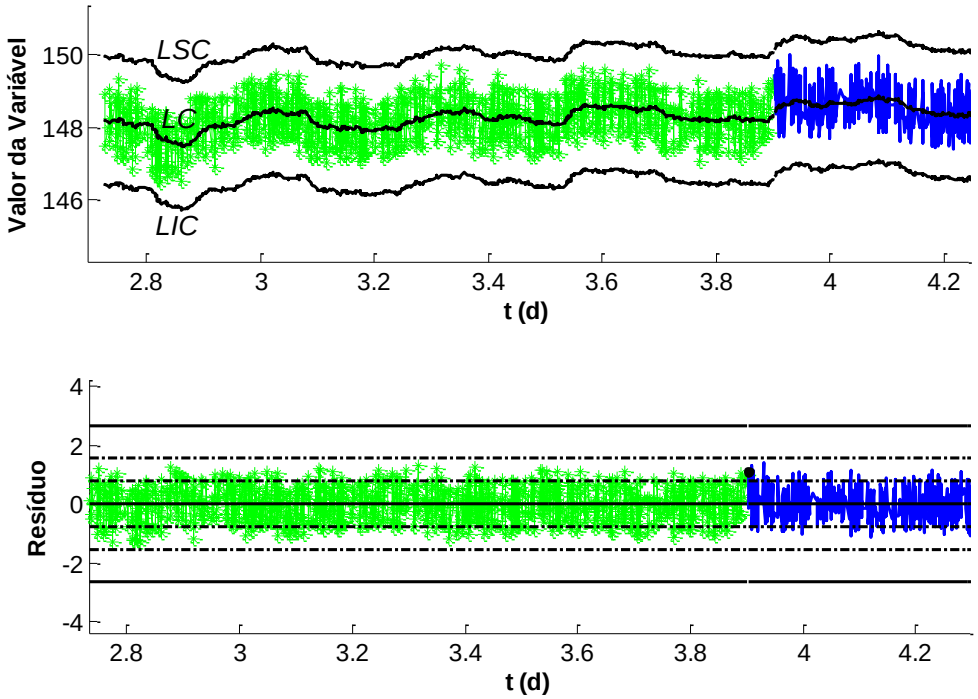

Figura 15: Estrutura adotada para o monitoramento baseado em modelos ARIMA. 1º gráfico refere-se ao gráfico EWMA de linha central móvel ou à sua generalização aos demais modelos da família ARIMA. O 2º gráfico corresponde ao gráfico de Shewhart sobre os resíduos de predição com o modelo ajustado. Em ambos, a linha com marcadores em * (ou linha verde) representa os dados de treinamento e a linha sem marcadores os dados de teste (ou linha azul); os limites de controle superior (LSC) e inferior (LIC) são as linhas traçadas acima e abaixo dos dados; a linha central (LC) é a linha intermediária. No segundo gráfico têm-se ainda os limites de controle de um e dois desvios padrões representados por linhas tracejadas.

3.2.4. Integração do Monitoramento com os Intervalos Estáveis da Série Histórica

O acoplamento do monitoramento univariável com os estados sob controle identificados na série histórica permite a atualização de limites de controle e de parâmetros de modelos de acordo com o ponto operacional vigente do processo.

Considerando a situação em que uma variável monitorada sai de controle, existem três situações possíveis:

1. Evento anormal no processo (falha no processo);
2. Novo ponto operacional atingido, isto é, uma mudança de ponto operacional;
3. Alarme falso.

A situação em que se evidencia um evento anormal no processo deve ser avaliada pelos operadores da planta de modo a identificar a causa e, assim, poder removê-la.

A mudança de ponto operacional indica que valores de uma ou mais variáveis do processo foram alterados, entretanto, manteve-se sob controle com o passar do tempo. Como destacado por Mejia et al. (2010) uma planta de processo possui modos operacionais finitos, por conseguinte, eles podem ser identificados pela análise da série histórica. Desta forma, a mudança de um ponto operacional para outro pode ser determinada durante o monitoramento pela realização de comparações com os estados sob controle previamente identificados.

Neste contexto, o procedimento de interação entre o monitoramento e os estados sob controle identificados objetiva identificar se uma determinada condição fora de controle assinalada refere-se a uma mudança de uma condição operacional estável para outra igualmente estável ou se houve evento anormal no processo. Desta forma, a necessidade de buscar as causas para a correção se restringiria para os casos em que não for encontrado estado estável compatível na base de dados.

Em uma situação de monitoramento em tempo real, a comparação do estado atual do processo com os estados identificados na série histórica pode ser feita por testes estatísticos de média e variância. Desta forma, é necessário estipular o tamanho da janela de observações que representará o estado atual do processo. Além disso, os níveis de significância dos testes estatísticos são requeridos.

A janela definida para a indicação do estado momentâneo do processo deve ser representativa o suficiente, ou seja, possuir número de pontos adequado para a caracterização do comportamento vigente. A identificação de ponto operacional histórico compatível requer que o processo atual também esteja sob controle. Desta forma, antes de efetivamente realizar a comparação do estado atual do processo com os estados sob controle passados, definiu-se realizar a divisão da janela de confirmação em duas partes para compará-las e determinar se possuem médias e variâncias compatíveis. Este procedimento indica que o processo não possui tendências nas medições. Somente com a confirmação destes testes faz-se a busca por intervalos estáveis históricos compatíveis.

A metodologia de integração do monitoramento com os estados sob controle da série histórica foi avaliada para as duas abordagens estudadas: técnicas sem o uso de modelos de séries temporais, os quais possuem limites fixos de monitoramento e as técnicas baseadas em modelos de séries temporais.

Na abordagem sem a utilização de modelos, o procedimento visa a adaptação dinâmica de limites de controle de um gráfico de Shewhart para medidas

individuais, englobando as modificações nos limites de controle de Wheeler (1994) e Gilbert (1997) e as bateladas de média não ponderada.

Quando utilizadas as técnicas baseadas em modelos de séries temporais, o procedimento visa a atualização dos parâmetros do modelo pelos valores do estado referencial. Desta forma, faz-se uma ressintonia dos parâmetros do modelo ao longo do monitoramento, de modo a preservar a sua capacidade preditiva. As tomadas de decisão foram baseadas no gráfico de resíduos, visto que a partir dele é possível utilizar as regras de sensibilidade comuns ao CEP convencionais para detectar comportamentos não aleatórios ou fora de controle.

A metodologia estruturada permite a identificação de diferentes modelos de séries temporais para cada estado sob controle da série histórica. Entretanto, particular atenção foi dada ao modelo IMA(1,1) que gera o gráfico EWMA de linha central móvel. Isso devido às diversas referências que indicam o gráfico para o monitoramento de processos contínuos (MONTGOMERY e MASTRANGELO, 1991; BISGAARD e KULAHCI, 2011 e MONTGOMERY, 2009). Além de sua implementação mais simples, pois necessita da estimação de apenas um parâmetro (λ). Assim, na estimação de parâmetros de modelo para o caso particular IMA(1,1) utilizou-se minimização da soma quadrática dos erros. Já as outras estruturas ARIMA(p,d,q) foram estimadas utilizando funções do Matlab®: *arima, estimate, infer e forecast*.

O procedimento pode ser dividido em duas etapas: a detecção de condição fora de controle e a identificação se esta condição possui um referencial histórico de média e variância compatível.

A estruturação deste método pode ser representada pelos passos abaixo e pelo fluxograma da Figura 16. O procedimento é univariável, logo é necessária a escolha de uma variável que represente o processo.

I. Definição do tamanho do intervalo que representará o estado atual do processo (N_{comp});
II. Inicialização do procedimento com atribuição dos limites de controle e parâmetros iniciais;
III. No recebimento de novas medições, aplicar as regras de sensibilidade que definirão as situações fora de controle;
IV. Caso seja considerado como situação fora de controle, explicita-se tal situação e aguarda a entrada de novas observações para caracterizar o estado momentâneo do processo (N_{comp});
V. Com as medições obtidas durante este tempo, realizam-se testes estatísticos de comparação de média e variância com os estados sob

controle da série histórica a fim de identificar possíveis referenciais de operação estável;

a. Caso haja alguma confirmação histórica, significa que a operação atual está em condição sob controle previamente conhecida e os parâmetros de monitoramento serão atualizados para os valores contidos na base de dados;
b. Em caso de não ser encontrada similaridade histórica, os parâmetros são mantidos nos valores atuais e o processo é considerado como fora de controle, alertando o operador.

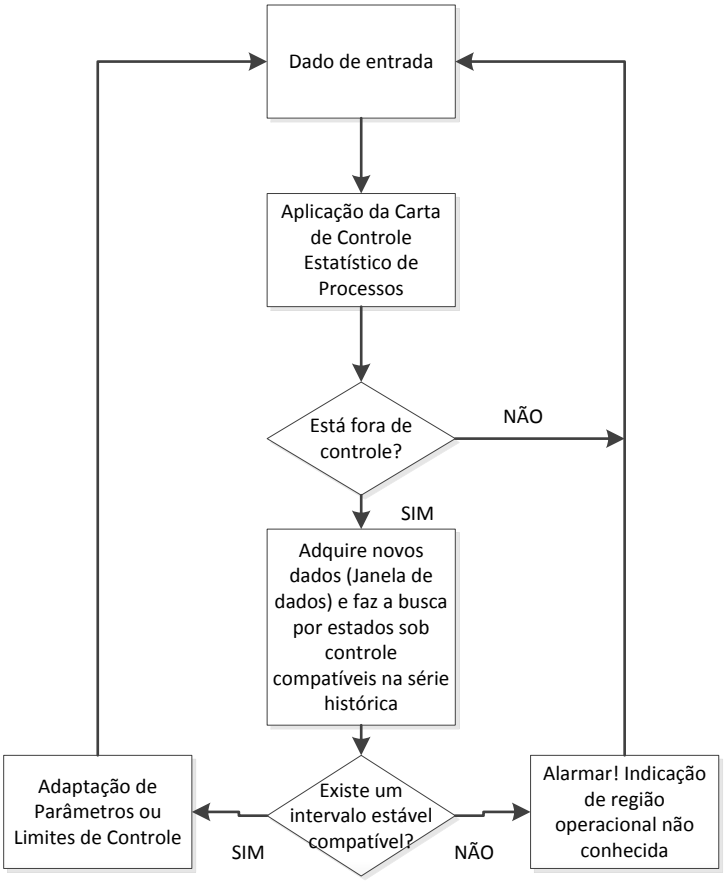

Figura 16: Fluxograma do monitoramento com acoplamento com os estados sob controle da série histórica.

Na mudança de um estado operacional sob controle para outro existe um tempo até que o processo se estabilize. Desta forma, o procedimento pode não identificar o novo estado operacional imediatamente, sendo necessário um tempo maior para que o processo atinja a estabilidade e, assim, o estado sob controle compatível ser devidamente identificado.

3.3. Estudo de Caso: Sistemas de Compressão de Gás

As metodologias de monitoramento univariável analisadas foram utilizadas para o estudo de detecção de falhas em sistemas de compressão de gás, sendo avaliados dados reais oriundos do sistema de compressão de plataforma *offshore* e de simulações dinâmicas utilizando funções de transferência. As simulações foram realizadas apenas para testes e validação da metodologia por considerar dados de comportamento conhecidos.

3.3.1. Sistema de Compressão por Simulação Dinâmica

De forma a simplificar o equacionamento do sistema dinâmico representante do ciclo de compressão, utilizaram-se funções de transferência. Foi utilizado a integração entre rotinas do MatLab® com o Simulink® para gerar dados simulados com a finalidade de testar as metodologias de monitoramento.

As funções de transferências empregadas são citadas por Campos e Teixeira (2006) e foram desenvolvidas por Campos (1990). A utilização de funções de transferência simplifica o sistema e permite simulações dinâmicas mais robustas. Tendo em vista que o objetivo da simulação é a geração de dados com comportamento conhecido, as simplificações necessárias para o uso das funções de transferência (como a linearização) não representam um entrave.

A Figura 17 demonstra a estrutura das funções de transferência que relacionam as saídas dos controles de capacidade (PIC) e *anti-surge* (FIC) com a pressão de sucção e a distância do *surge* (correspondente da vazão de descarga). As equações abaixo demonstram as funções de transferência desenvolvidas por Campos (1990):

$$G_{11} = -\frac{1{,}87}{48{,}5s^2 + 8{,}96s + 1} \quad \text{(Eq. 63)}$$

$$G_{21} = \frac{1{,}59}{10{,}1s^2 + 2{,}22s + 1} \quad \text{(Eq. 64)}$$

$$G_{12} = \frac{0{,}21}{12s^2 + 4{,}86s + 1} \quad \text{(Eq. 65)}$$

$$G_{22} = \frac{0{,}66}{5s^2 + 7{,}21s + 1} \quad \text{(Eq. 66)}$$

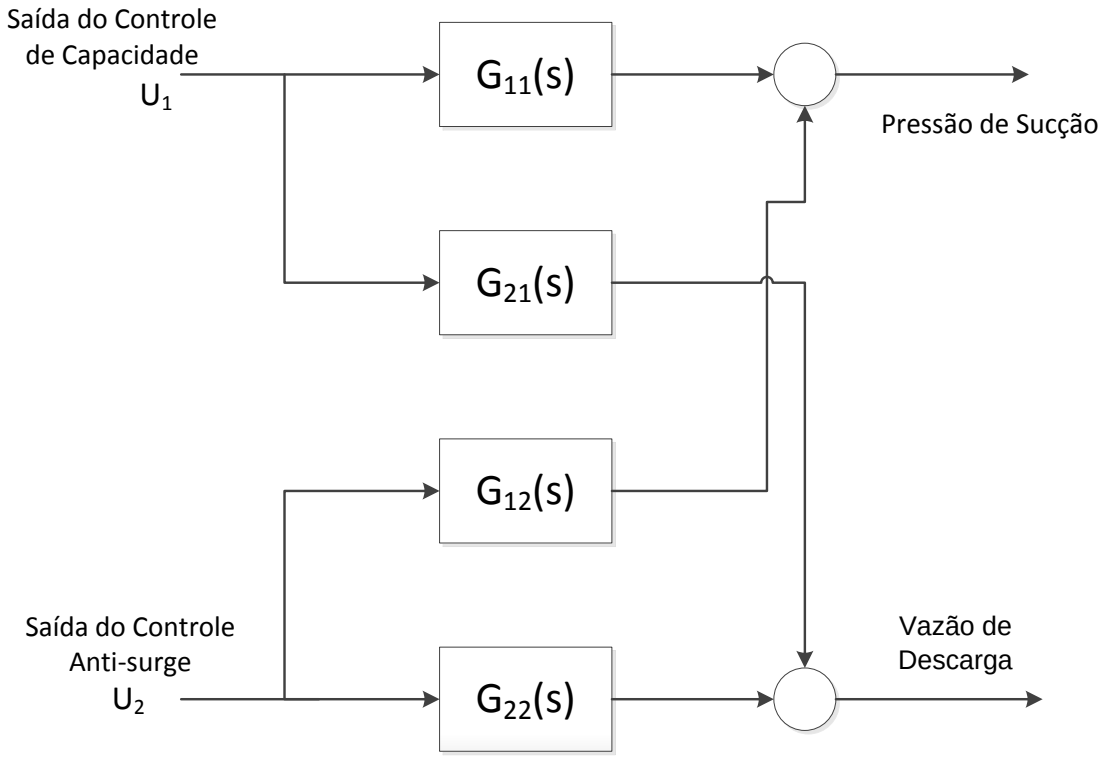

Figura 17: Estrutura em Funções de Transferência do Sistema de Compressão (Fonte: Campos e Teixeira (2006))

A simulação utilizando as funções de transferência simplifica o modelo, permitindo flexibilidade nos testes desejados. Esta metodologia pode apresentar erros no valor absoluto das variáveis, entretanto, uma vez que o objetivo da simulação é a obtenção do comportamento dinâmico esta abordagem se torna adequada.

O sistema dinâmico foi implementado para fornecer dados com comportamento conhecido de modo a facilitar a interpretação dos resultados das cartas de controle de processo. Além disso, com a introdução de controles regulatórios PID, é possível avaliar o desempenho das cartas de controle em processos integradas ao controle automático, visto que as plantas de indústria químicas tendem a possuir estes mecanismos de controle.

O sistema dinâmico estruturado possui os controladores de capacidade e *anti-surge* e considera perturbações nos sinais de entrada dos controladores. Além disso, considerou-se ruídos nos sensores das variáveis controladas. A configuração do modelo dinâmico é representada na Figura 18 e a estrutura implementada no Simulink® é indicada na Figura 19. O sistema dinâmico foi desenvolvido no domínio discreto, de modo a respeitar o tempo de amostragem das medições enviadas aos controladores. A conversão do domínio contínuo para o domínio discreto foi realizada por funções próprias do *software* Matlab®, sendo considerado *data-hold* de ordem

zero e tempo de amostragem de 10s. Após a conversão as funções de transferência ficaram da seguinte forma:

$$G(z)_{11} = \frac{-0{,}977\,z - 0{,}5134}{z^2 - 0{,}3606\,z + 0{,}1576} \qquad \text{(Eq. 67)}$$

$$G(z)_{21} = \frac{2{,}072\,z + 0{,}7344}{z^2 + 0{,}654\,z + 0{,}111} \qquad \text{(Eq. 68)}$$

$$G(z)_{12} = \frac{0{,}1988\,z + 0{,}04074}{z^2 + 0{,}1234\,z + 0{,}01742} \qquad \text{(Eq. 69)}$$

$$G(z)_{22} = \frac{0{,}5014\,z + 0{,}01916}{z^2 - 0{,}2113\,z + 5{,}464 \cdot 10^{-7}} \qquad \text{(Eq. 70)}$$

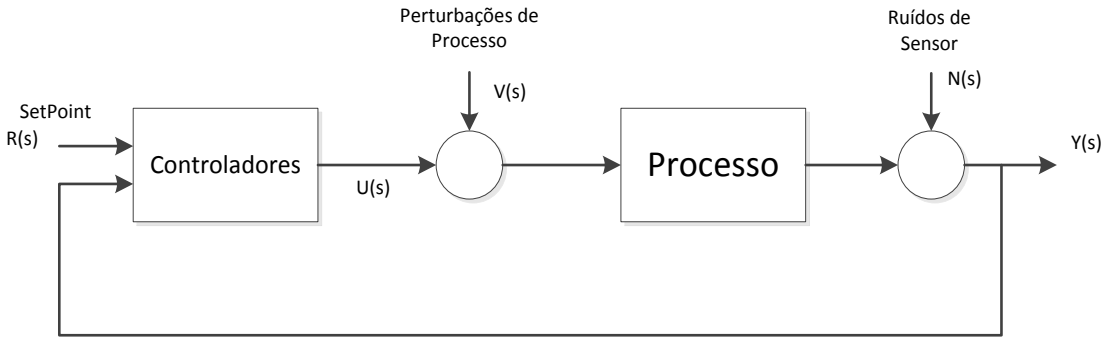

Figura 18: Configuração do Sistema Dinâmico (Adaptado de Andersson, 2000).

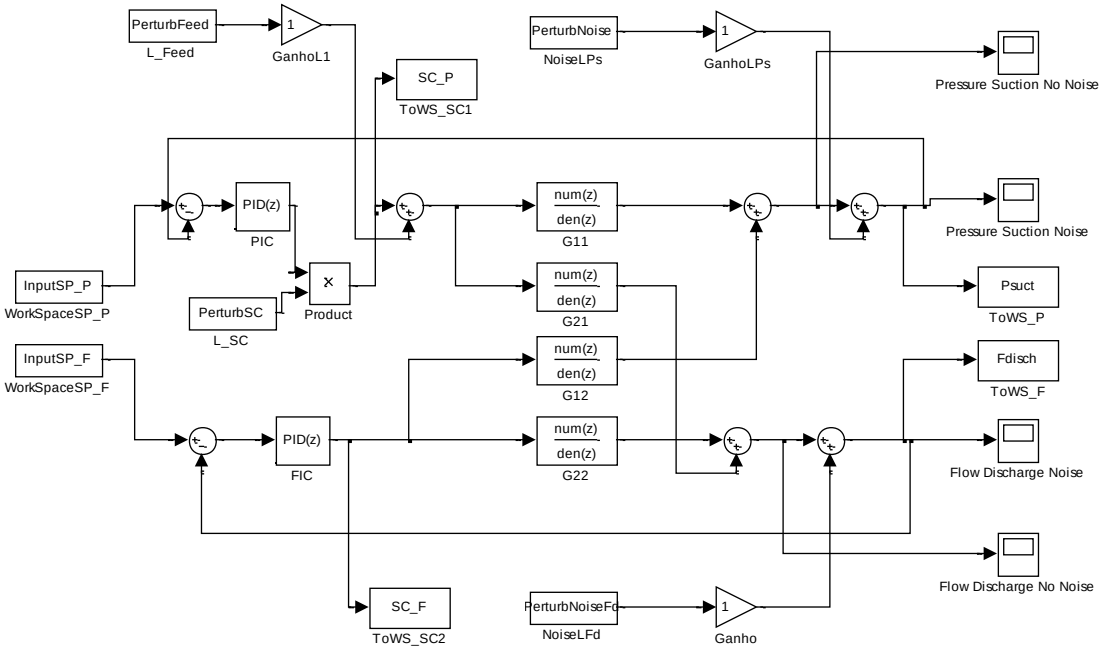

Figura 19: Diagrama no Simulink® para geração de dados simulados.

Para a geração dos dados considerou-se a divisão do tempo de simulação em duas partes: uma correspondendo aos dados históricos, ou seja, as séries temporais que serão o treinamento dos parâmetros da metodologia; e uma segunda parte correspondendo aos dados de teste (dados de entrada do monitoramento).

Na região de dados históricos utilizaram-se diferentes *setpoints* para o controle de pressão de sucção. Desta forma, os diferentes pontos operacionais de uma planta industrial foram reproduzidos. Em processos complexos o *setpoint* dos controles regulatórios são governados por um controle em uma camada hierárquica superior, que altera estes valores de forma a otimizar ou aumentar a confiabilidade dos sistemas.

A região de dados de testes foi dividida em diferentes tipos de perturbações, de forma a testar o desempenho dos métodos de detecção de anormalidades por cartas de controle univariáveis.

3.3.2. Dados Reais de Sistemas de Compressão

De forma a validar as técnicas de monitoramento estudadas utilizou-se de dados reais de um sistema de compressão offshore. As variáveis relevantes destes sistemas são (MIYOSHI *et al.*, 2012):

- Pressão de sucção;
- Pressão de descarga;
- Temperatura de sucção
- Temperatura de descarga;
- Vazão volumétrica de sucção;
- Rotação do compressor.

3.3.3. Monitoramento do Resíduo da Eficiência do Compressor

Miyoshi et al. (2012) desenvolveram uma metodologia híbrida para o monitoramento da performance de compressores de uma plataforma offshore que engloba a modelagem fenomenológica com a abordagem de controle estatístico de processos. Foi utilizada modelagem rigorosa para a estimação das propriedades termodinâmicas: eficiência e *head* politrópicos.

Os autores utilizaram os resíduos gerados pela comparação dos valores calculados pela modelagem termodinâmica com os dados obtidos pelas curvas características fornecidas pelos fabricantes. Os resíduos foram monitorados por cartas

de controle convencionais, deste modo, incorporaram-se informações multivariáveis ao monitoramento univariável por cartas de controle.

O modelo fenomenológico foi implementado no software desenvolvido por Soares e Secchi (2003): EMSO (Environment for Modeling, Simulation and Optimization) de acordo com a modelagem de compressor baseada em Botros (1994). As variáveis de entrada, obtidas pelos sensores de campo foram: vazão, pressão e temperatura de sucção, pressão e temperatura de descarga e rotação da turbina.

3.4. Interface Gráfica de Usuário

De modo a facilitar a utilização das rotinas computacionais desenvolvidas e da estrutura de monitoramento considerada, desenvolveu-se uma interface gráfica no Matlab® (Figura 20) contemplando as funcionalidades:

- Importação de dados;
- Visualização das variáveis;
- Identificação dos intervalos estáveis de uma série histórica;
- Verificação Estatística de intervalos de dados;
- Aplicação de modelos ARIMA
- Simulação do monitoramento em tempo real utilizando os métodos estudados.

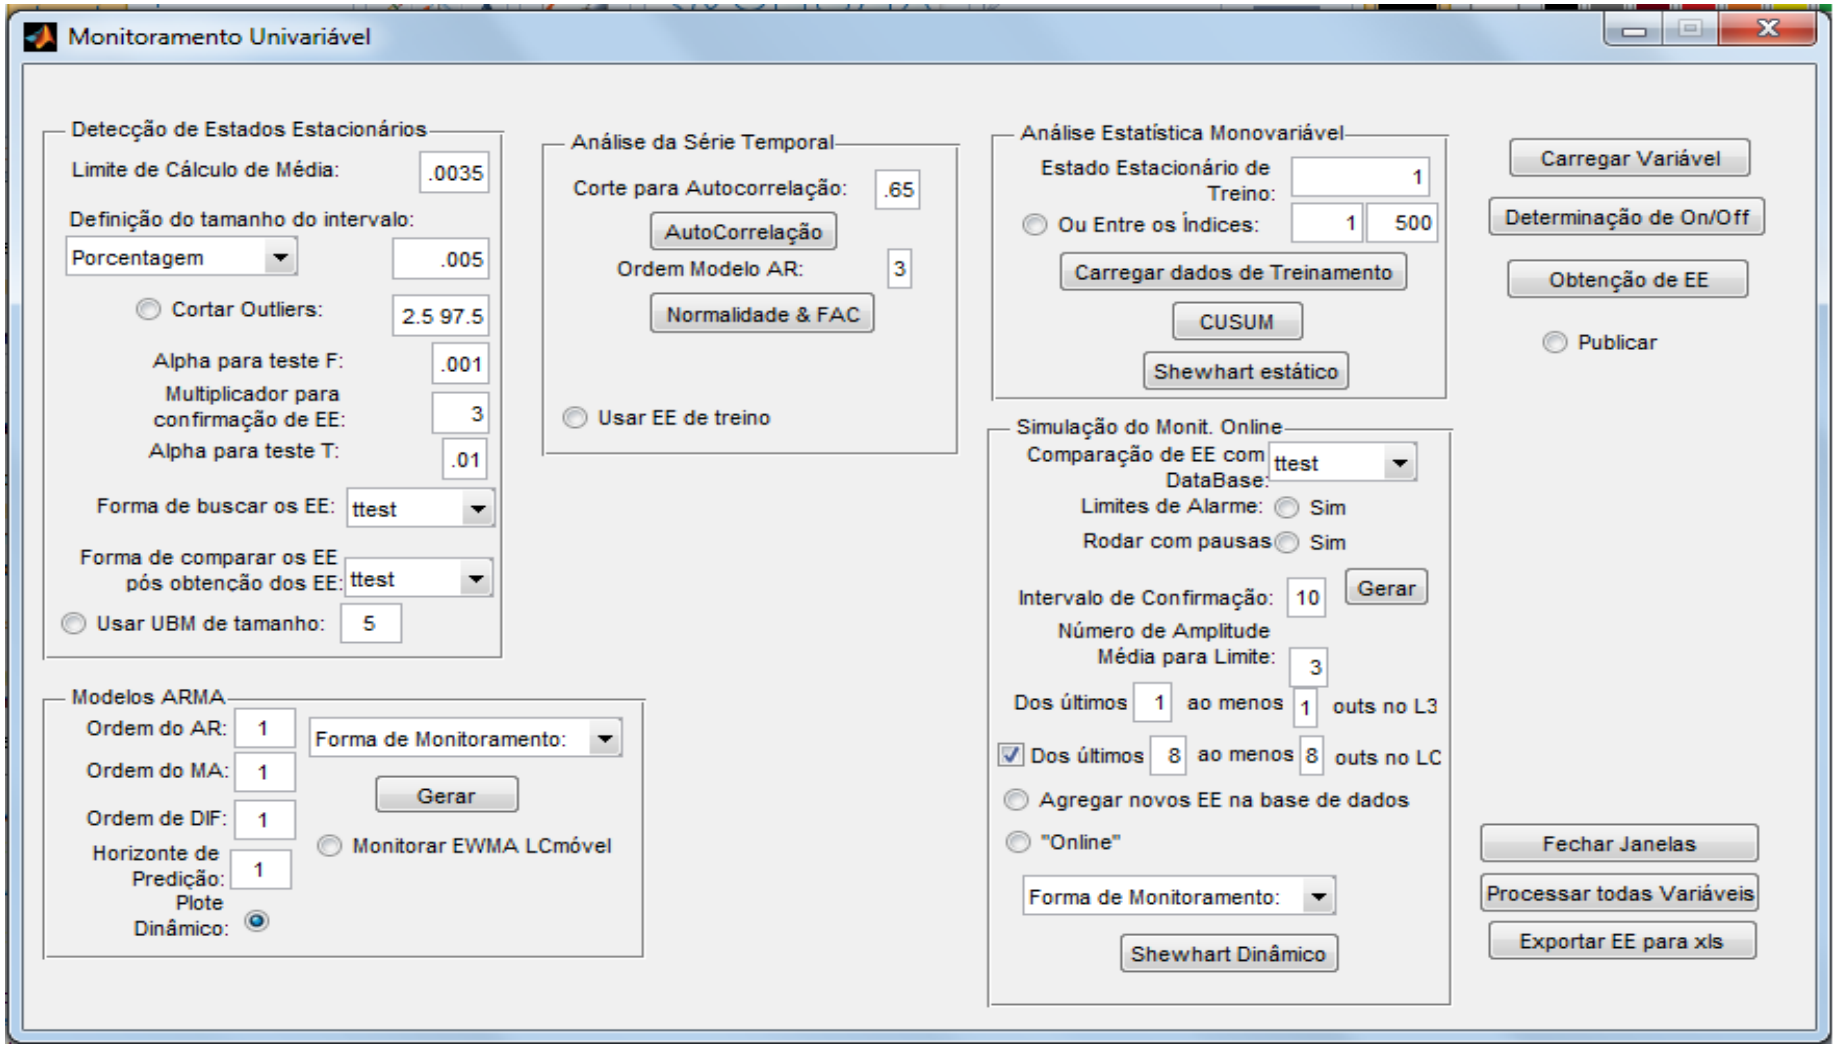

Figura 20: Interface Gráfica adotada

4. RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados obtidos utilizando as técnicas de monitoramento discutidas anteriormente. As rotinas computacionais desenvolvidas foram todas elaboradas no software MatLab® e Simulink®. Algumas das funções utilizadas pertencem a *Toolboxs* específicas, como *Econometrics*, *Statistics* e *System Identification.*

A metodologia de monitoramento pode ser composta nas etapas:

1. Aquisição da série histórica dos dados;
2. Identificação de estados sob controle da variável analisada;
3. Verificação das características estatísticas de cada intervalo considerado estável;
4. Monitoramento pelas cartas de controle com integração com os estados sob controle identificados.

O estudo de caso deste trabalho corresponde a um sistema de compressão de gás. A seguir são discutidos os dados gerados pelo modelo do sistema utilizando as funções de transferência propostas por Campos (1990) e os dados reais do ciclo de compressão de uma plataforma *offshore*.

4.1. Conjunto de Dados Reais Avaliados

Utilizaram-se dois conjuntos de dados reais inéditos na literatura de um sistema de compressão de gás de uma plataforma de petróleo nacional. O primeiro conjunto corresponde a 10 dias de operação do segundo estágio de um sistema de compressão (C_1). Já o segundo refere-se à operação ao longo de dois dias (C_2).

A diferença entre os dois conjuntos analisados é que o primeiro constitui uma série histórica longa, contendo os diferentes pontos operacionais do sistema. Esses dados não possuem anotações referentes a eventos anormais no sistema. Com este conjunto foi possível avaliar as metodologias como um todo, incluindo a detecção das regiões de operação estacionárias.

Por outro lado, o conjunto de dados C_2 corresponde a uma série histórica específica de dois dias de operação, na qual existe um evento anormal conhecido. Este conjunto foi utilizado para avaliar principalmente a capacidade de detecção de uma anormalidade no processo.

As variáveis do conjunto C_1 podem possuir tempos de amostragens e número total de medições diferentes, o que não é um empecilho para o monitoramento

proposto, visto que o mesmo analisa cada variável separadamente. Além disso, algumas variáveis não possuem medições igualmente espaçadas, ou seja, possuem tempos de amostragens diferentes ao longo de sua série temporal. Dependendo do grau de variação do tempo de amostragem de certa variável o monitoramento pode ser comprometido.

A Tabela 4 indica as características do primeiro conjunto de dados utilizados, sendo N_{pontos} o total de pontos da série histórica, $\bar{t}_{amostragem}$o tempo de amostragem médio (minutos). Na Figura 21 são apresentados os gráficos dessas variáveis em função do tempo de operação. Os dados foram obtidos do software de coleta de dados de plantas industriais (*Plant Information* – PI), assim o tempo entre as medições de uma determinada variável pode não ser constante devido aos processos de exceção e compressão de dados.

Tabela 4: Características dos Dados Reais do Conjunto C_1

Variável	Sigla	Unidade	N_{pontos}	$\bar{t}_{amostragem}$ (min)
Pressão de Sucção	Ps	bar	321	44,45
Pressão de Descarga	Pd	bar	2058	7,00
Temperatura de Descarga	Td	$ºC$	8218	1,75
Rotação	Ncomp	rpm	3592	4,00
Vazão de Sucção	Fs	m^3/h	54767	0,26 (ou 15s)

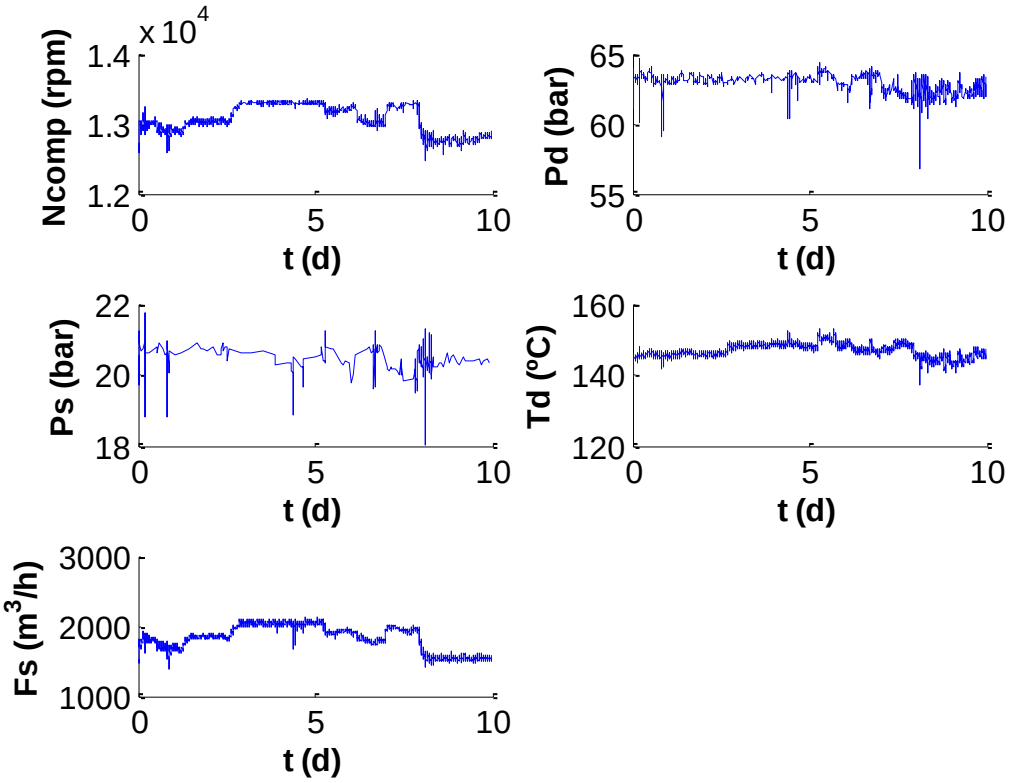

Figura 21: Dados Reais do Conjunto C_1.

O conjunto de dados C_2 utilizado possui tempos de amostragens iguais para todas as variáveis (um minuto) e total de 2880 pontos. A Tabela 5 destaca as variáveis utilizadas neste conjunto e a Figura 22 mostra o comportamento dinâmico das mesmas.

Tabela 5: Características dos Dados Reais do Conjunto C_2

Variável	Sigla	Unidade
Pressão de Sucção	Ps	bar
Pressão de Descarga	Pd	bar
Temperatura de Sucção	Ts	$^{\circ}C$
Temperatura de Descarga	Td	$^{\circ}C$
Rotação	Ncomp	rpm

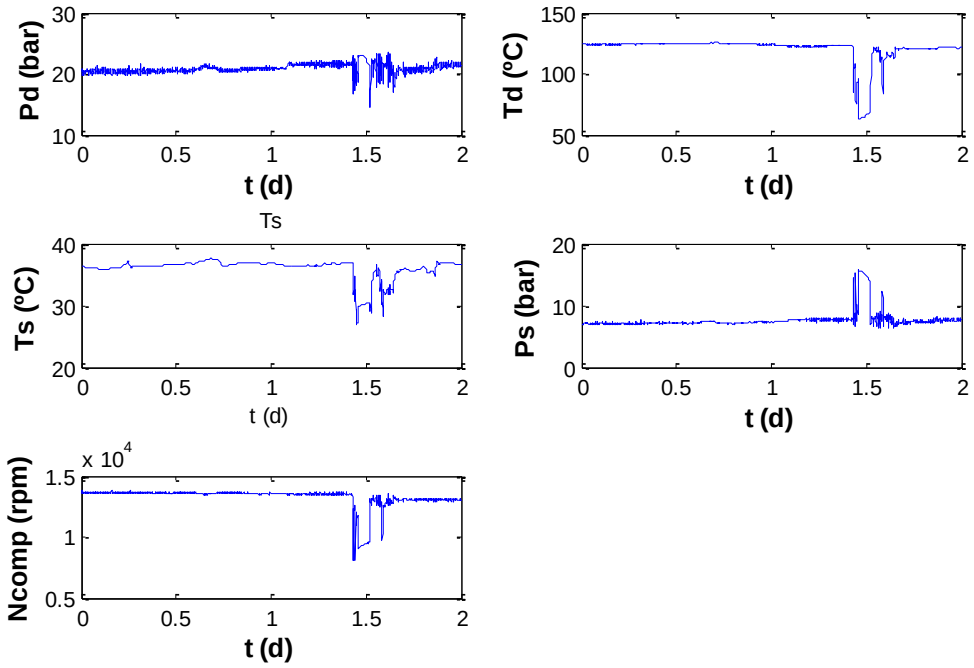

Figura 22: Dados Reais do Conjunto C_2.

4.2. Dados de Simulação

O conjunto de dados de simulação gerados pelo modelo no Simulink® C_{SIM} foi dividido em uma região correspondente aos dados históricos e uma região subsequente de dados para teste das cartas de controle para detecção de anormalidades no processo.

O controle de capacidade (PIC) controla a pressão de sucção e o controle *anti-surge* (FIC) controla a vazão de sucção. Os parâmetros dos controladores PI foram retirados de Campos e Teixeira (2006):

Tabela 6: Parâmetros dos Controladores

Controlador	Ganho (K_c)	Tempo Integral (τ_I)
Capacidade	-0,6	20 s
Anti-surge	4,0	120 s

Em todo o tempo de simulação, considerou-se uma perturbação de processo senoidal de baixa frequência. Esta perturbação foi utilizada para representar uma planta industrial na qual o processo nunca atinge a estacionariedade estatística, visto que a média está constantemente variando. Desta forma, as suposições das cartas de controle convencionais não são respeitadas. Aos sensores das variáveis medidas adicionou-se ruído de média nula e variância σ_e^2 conhecida, que influenciam os controladores do processo.

A Figura 23 mostra as variáveis ajustadas para a definição do comportamento do sistema na região de dados históricos. O setpoint da pressão de sucção foi variado em degraus para gerar diferentes pontos operacionais da planta. Os valores estão na forma de variável desvio.

A simulação dinâmica do sistema foi realizada para gerar uma série temporal com comportamento conhecido para o teste das técnicas de monitoramento. Desta forma, os sinais das perturbações de processo e as funções de transferência relacionadas foram ajustados apenas para gerar uma saída com comportamento desejável, isto é, não foram baseadas em uma perturbação real específica. Assim sendo, a unidade de medida da perturbação na entrada do processo não foi especificada. As saídas dos controladores considerou-se apenas o valor do sinal, de forma que as unidades de medidas também não são explicitadas. Campos (1990) e Campos e Teixeira (2006) fornecem maiores detalhes sobre a modelagem do sistema dinâmico pelas funções de transferência consideradas.

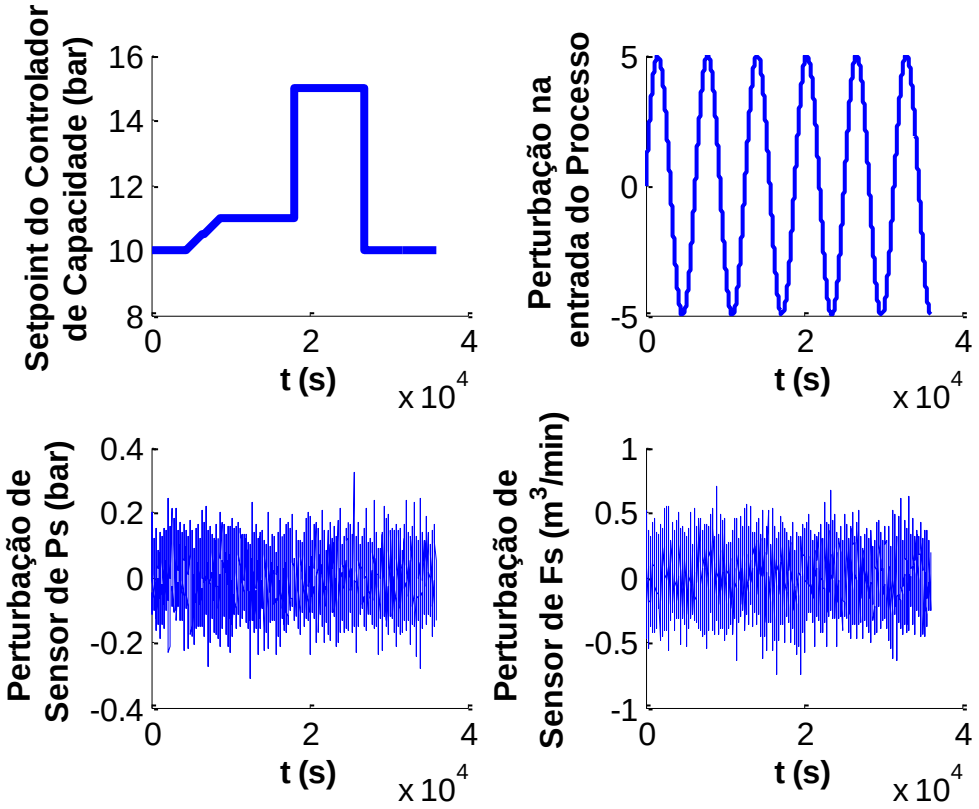

Figura 23: Dados de entrada da simulação (Conjunto C_{SIM}).

Essas condições resultam nas respostas do sistema dinâmico da Figura 24, sendo apresentada a saída do controlador de capacidade e a saída do controlador *anti-surge*, ambas em variáveis-desvio. Apresentam-se também as variáveis controladas: a pressão de sucção e a vazão aspirada pelo compressor.

A resposta do modelo fornece variáveis-desvio para a pressão e vazão, mas a partir de valores atribuídos para a condição de estado estacionário de referência obtiveram-se valores absolutos dessas variáveis. O valor de estado estacionário foi $10\ bar$ e $25\ m^3/min$ para a pressão e vazão, respectivamente.

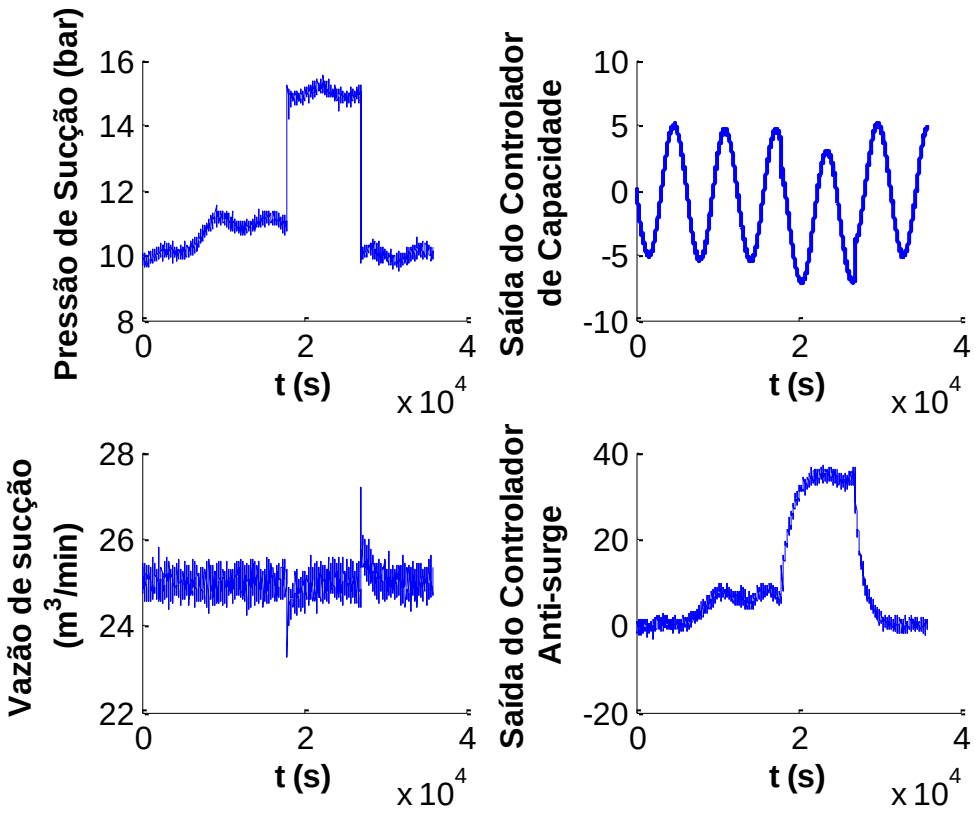

Figura 24: Respostas do Sistema Dinâmico para o conjunto de dados C_{SIM}.

Subsequentes aos dados acima, correspondentes à série histórica utilizada para o treinamento das cartas de controle, estão os dados de simulação para testes das técnicas de monitoramento. A estes dados foram atribuídas perturbações que simulam possíveis eventos anormais no processo. A Tabela 7 indica as perturbações testadas pelo sistema dinâmico com seus respectivos intervalos. A Figura 25 apresenta os gráficos dessas perturbações e a Figura 26 mostra as respostas da simulação.

Tabela 7: Perturbações induzidas nos dados de teste

Intervalo	Evento	Intensidade	Tempo Inicial ($10^4 s$)	Tempo Final ($10^4 s$)
1	Degrau na Perturbação de entrada do Processo	+ 5	3,601	4,051
2	Condições Iniciais	-	4,052	4,502
3	Degrau no setpoint de P_s	+ 5	4,503	4,953
4	Condições Iniciais	-	4,954	5,404
5	Variância na Perturbação de sensor de P_S	$1{,}15 * \sigma_e$	5,405	5,855
6	Condições Iniciais	-	5,856	6,306
7	Perda de sinal da saída de controle de capacidade	Constante em zero	6,307	6,757
8	Condições Iniciais	-	6,758	7200

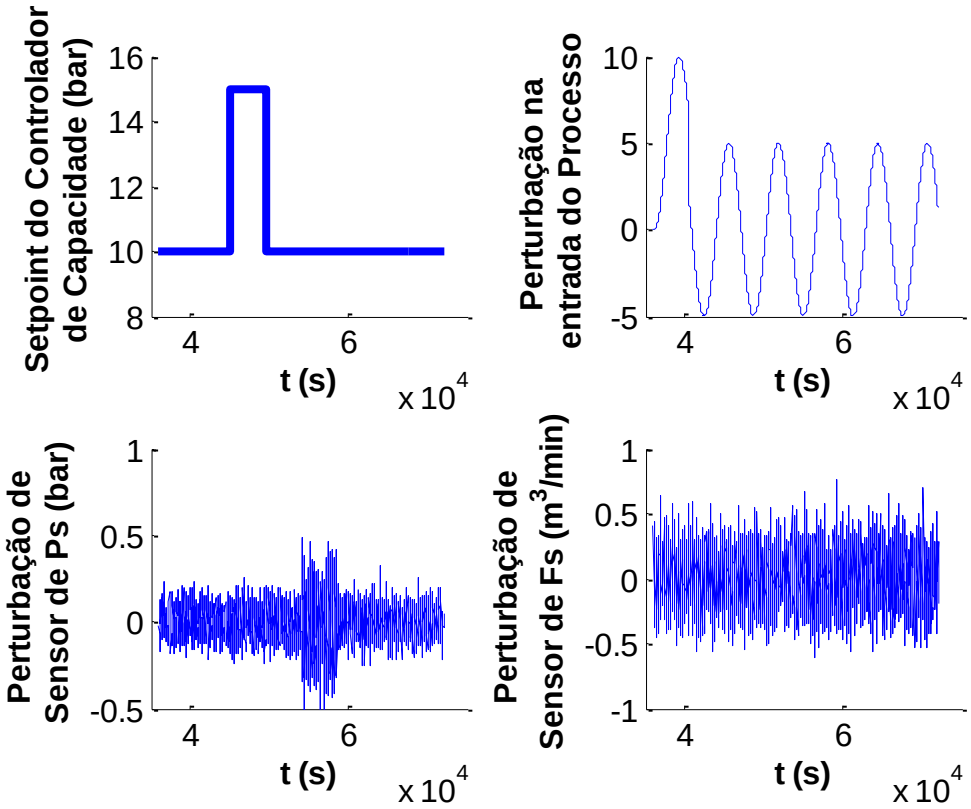

Figura 25: Entradas da região de teste dos dados simulados.

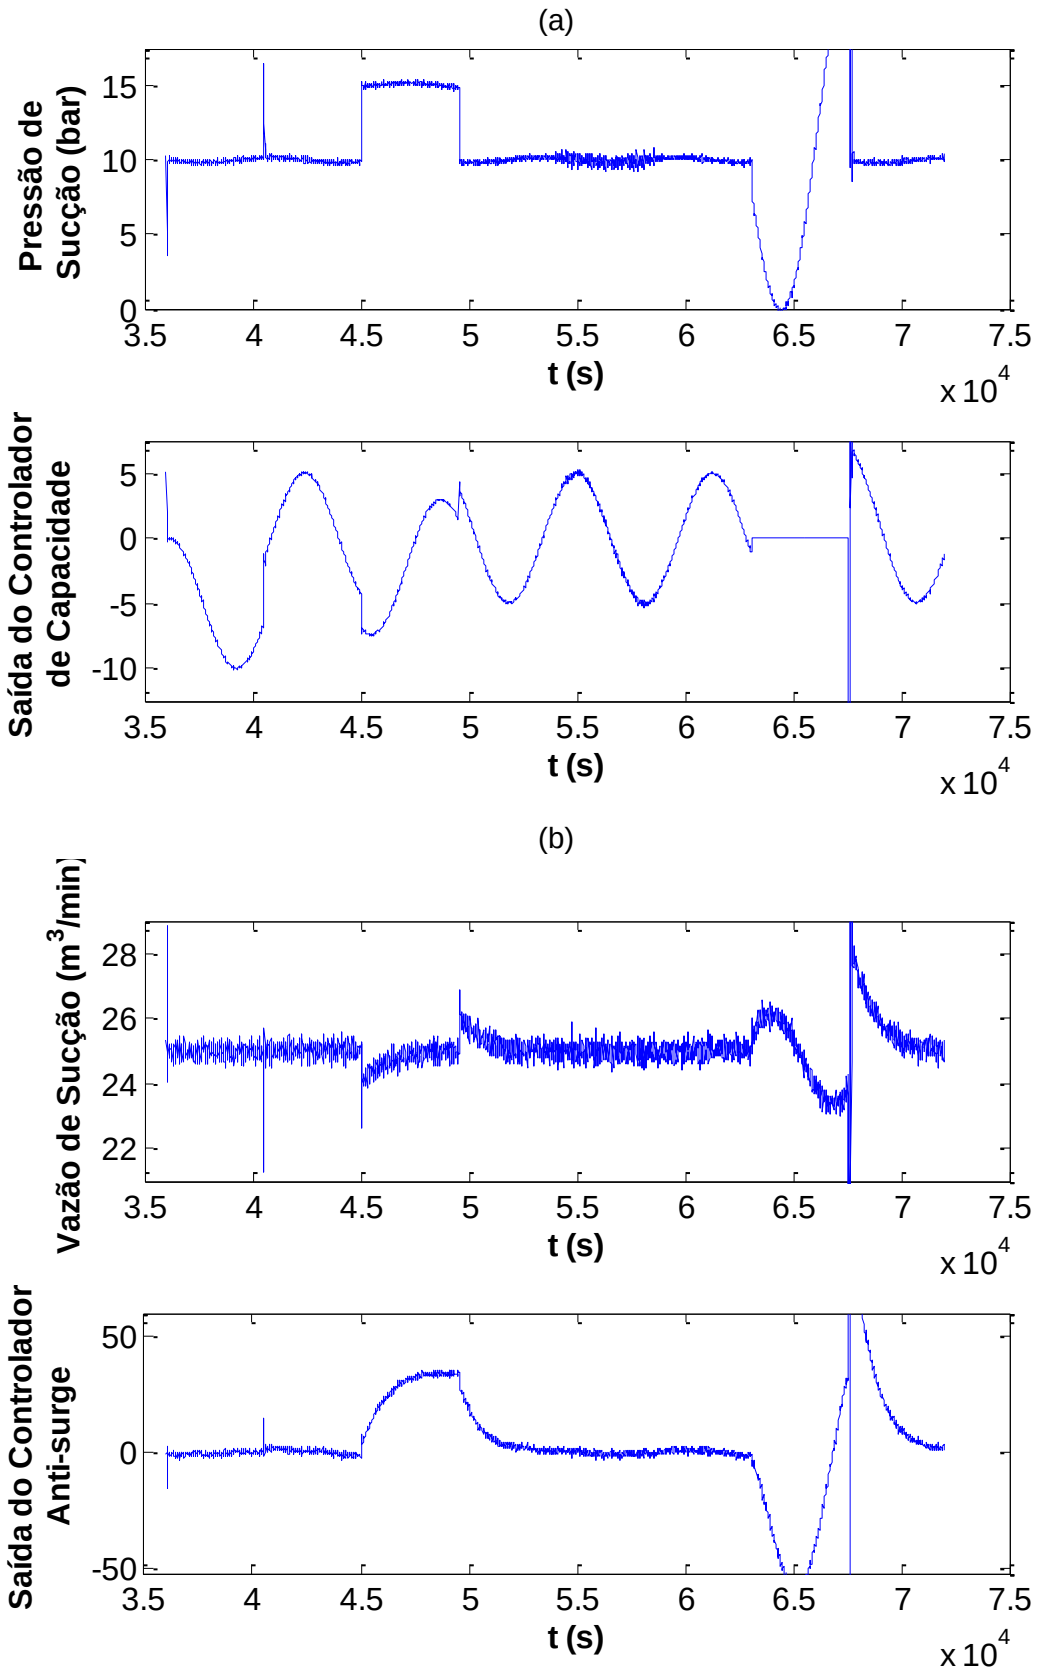

Figura 26: Respostas da simulação na região de teste, em (a) pressão de sucção e saída de controle do PIC e em (b) a vazão de sucção e a saída de controle de FIC.

De modo a exemplificar a aplicação dos procedimentos de monitoramento univariável por cartas de controle estatístico de processos, escolheu-se a temperatura de descarga do conjunto de C_1 (10 dias de operação), a pressão de descarga de C_2 (2 dias) e a pressão de sucção dos dados simulados (C_{SIM}). As escolhas foram baseadas apenas nas características de coleta dos dados reais disponibilizados. Isto é, buscou-se a escolha de variáveis com tempos de amostragens curtos e constantes durante toda a série temporal de análise. No caso dos dados de simulação a pressão de sucção foi a variável escolhida, pois os testes de diferentes perturbações foram realizados para provocar a variabilidade da mesma.

4.3. Identificação de Estados Sob Controle a partir da Série Histórica

A metodologia de obtenção dos intervalos estáveis possui duas abordagens que definem estados sob controle como estado estacionário de média constante e estados sob controle com mudanças aceitáveis na média. Na primeira abordagem utiliza-se o teste estatístico T de comparação de média, enquanto a segunda permite certa variação na média por utilizar comparações de intervalos sucessivos pelo desvio relativo de média entre eles. Os parâmetros utilizados em ambas as abordagens são listados na Tabela 8. Eles foram obtidos via inspeção visual da identificação de estados sob controle.

Tabela 8: Parâmetros utilizados nos procedimentos de identificação de Estados Sob Controle

Parâmetro	Abordagem *T-test*			Desvios Relativos de Média		
	$P_s(C_{SIM})$	$T_D(C_1)$	$P_D(C_2)$	$P_s(C_{SIM})$	$T_D(C_1)$	$P_D(C_2)$
L	20	40	20	20	40	20
$N_{t_{conf}}$	10	5	5	10	5	5
α_T	0,001	0,0001	0,0001	-	-	-
α_F	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001
$LIM_{MÉDIA}$	-	-	-	0,025	0,0035	0,01

Nas figuras da etapa de identificação de estados sob controle da série histórica foi considerada a legenda para os gráficos em tonalidades de cinza, assim como para imagem colorida, desta forma é possível interpretar os resultados nas duas diferentes situações. Têm-se:

- Regiões de operação instáveis: indicadas pelos intervalos da série temporal em linhas contínuas fracas sem marcações nos pontos de medições (linhas em vermelho);
- Regiões de operação sob controle: intervalos de dados com marcações circulares nos pontos de medições (intervalos em verde);
- Média dos intervalos sob controle: representadas por uma linha horizontal grossa de tonalidade clara sobre os intervalos sob controle (linha em amarelo);
- Inícios e términos de intervalos sob controle: demarcados por pontos circulares pretos em maior dimensão de tamanho;
- Numeração dos estados sob controle: apresentados por uma caixa de texto com a indicação EEi, sendo i o número do intervalo sob controle.

Como mostrado na

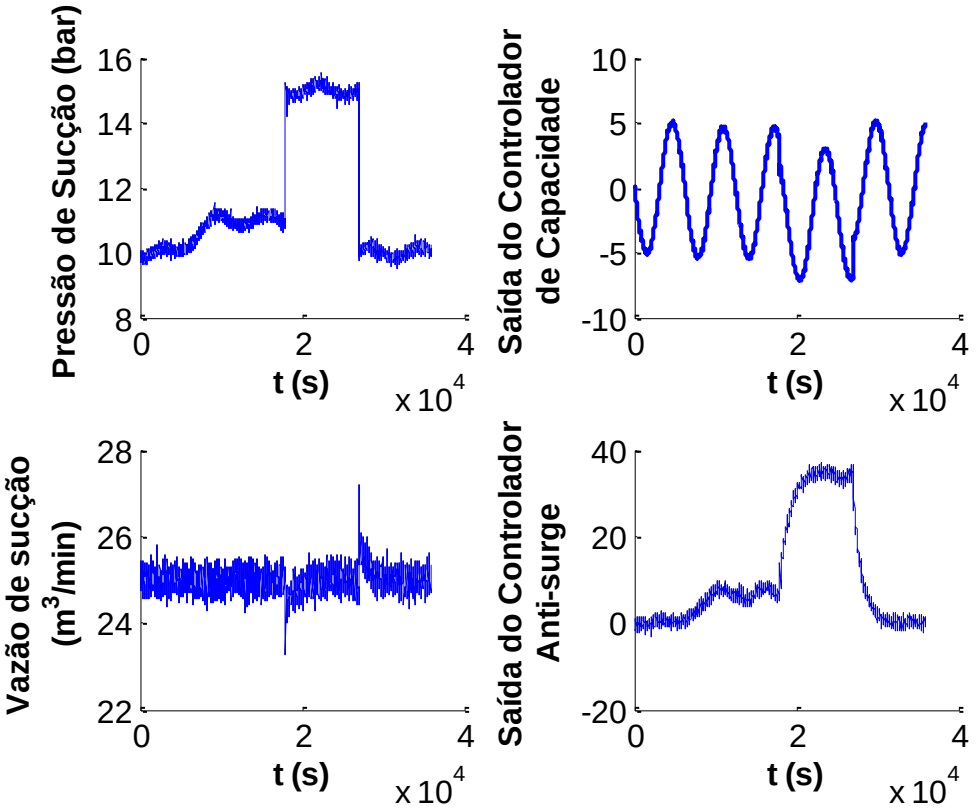

,

a pressão de sucção dos dados simulados (região de treinamento) possui comportamento senoidal de baixa frequência, desta forma, a metodologia que utiliza teste T para comparação de média não é adequada, pois não considera desvios na média do processo. Assim utilizou-se a abordagem de desvio relativo entre médias de intervalos sucessivos. A Figura 27 compara o resultado da identificação dos intervalos

estáveis da série temporal utilizando a abordagem de teste estatístico *T-test* e o desvio relativo entre médias de intervalos sucessivos.

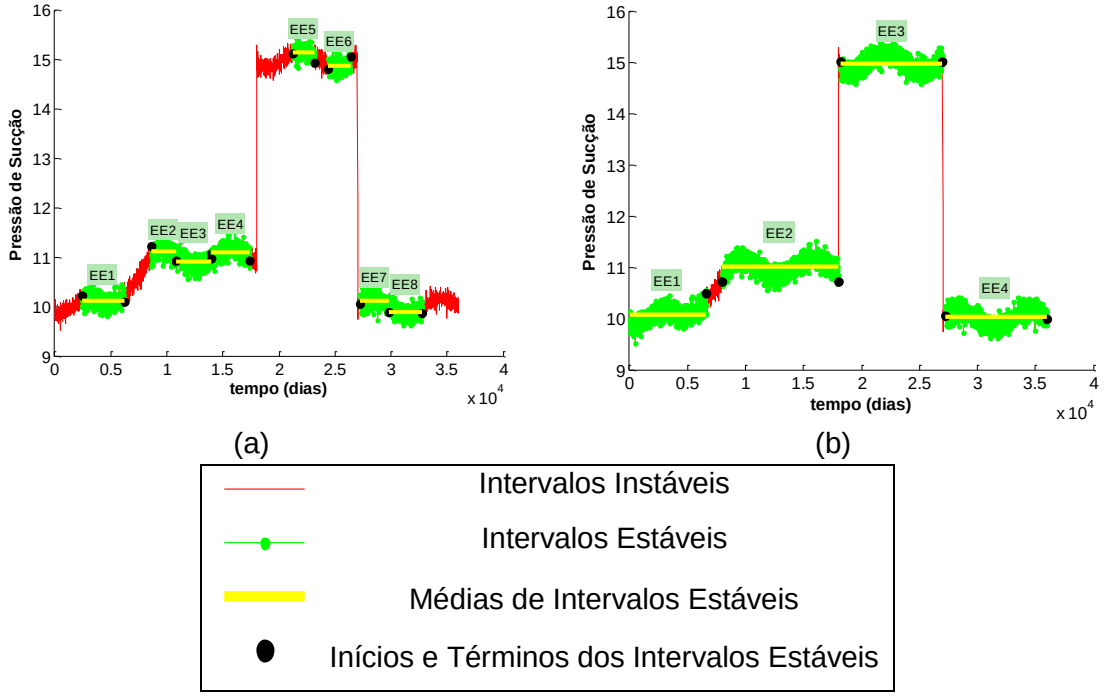

Figura 27: Comparação entre a identificação dos estados sob controle por teste T (a) e desvios relativos de média (b) para a variável P_s simulada.

A etapa de identificação dos estados sob controle de operação é seguida pela etapa de análise de estados sob controle similares. Esta etapa irá indicar intervalos estáveis compatíveis, ou seja, de média e variância próximas. Este procedimento é realizado por uma comparação mútua entre os estados sob controle por meio de testes de média (*T-test* ou por desvios relativos) e testes de variância. A Tabela 9 informa o resultado deste procedimento para a abordagem *T-test* e de desvios relativos de média.

Tabela 9: Agrupamento de Intervalos Estáveis Identificados

	Abordagem *T-test*	Desvios Relativos de Média
Equivalentes	1 e 7 2 e 4	1 e 4
Distintos	3; 5; 6 e 8	2 e 3

A metodologia também foi avaliada para dados reais. Utilizou-se os dados do conjunto C_1, sendo exemplificado pela variável temperatura de descarga (T_D), considerou-se apenas a região de treinamento. Esta variável possui um caráter dinâmico em toda sua série temporal, de modo que a consideração de média constante não representa corretamente o comportamento do estado sob controle da variável. A Figura 28 mostra os resultados obtidos para a identificação dos estados

sob controle (temperatura em ºC e tempo em dias) e a Tabela 10 apresenta a listagem fornecida pelo procedimento de comparação mútua entre os estados sob controle.

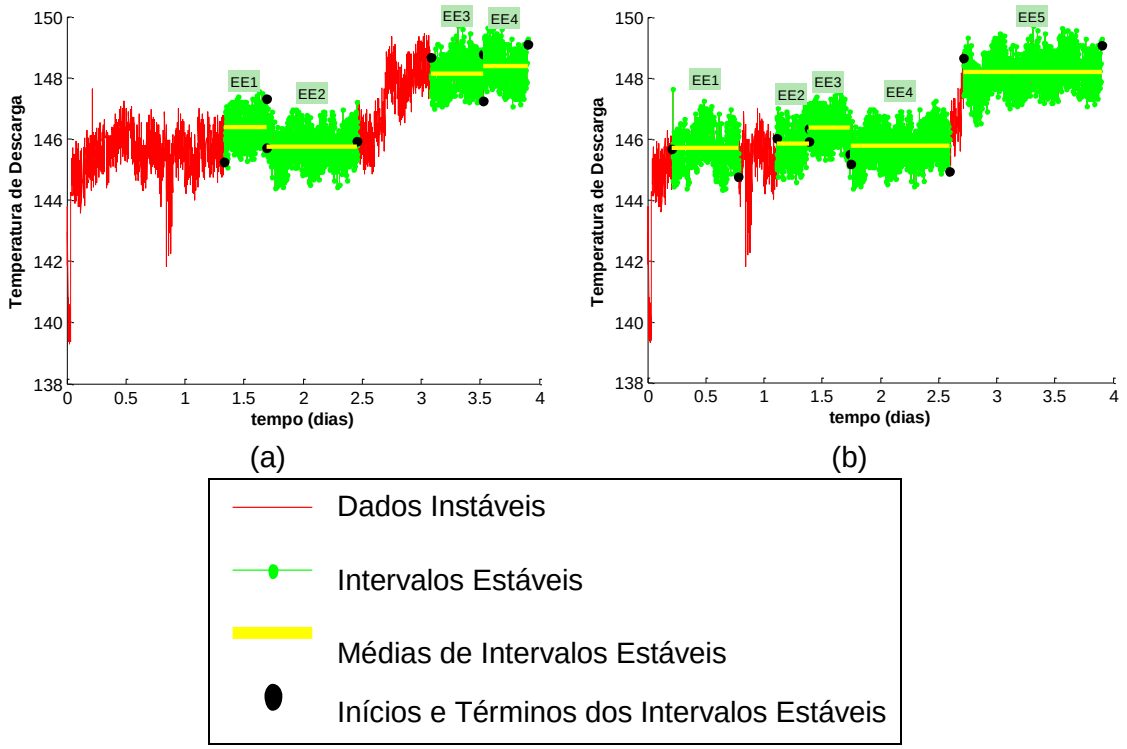

Figura 28: Comparação entre a identificação dos estados sob controle por teste T (a) e desvios relativos de média (b) da variável T_D dos dados reais C_1.

Tabela 10: Agrupamento dos intervalos estáveis identificados para T_D do conjunto C_1.

	Abordagem *T-test*	Desvios Relativos de Média
Equivalentes	-	1; 2 e 4
Distintos	1; 2; 3 e 4	3 e 5

Os resultados para a variável pressão de descarga do conjunto C_2 são representados na Figura 29 sendo os estados sob controle similares identificados na Tabela 11. Nota-se que a identificação por ambas as abordagens retornaram aproximadamente os mesmos intervalos estáveis.

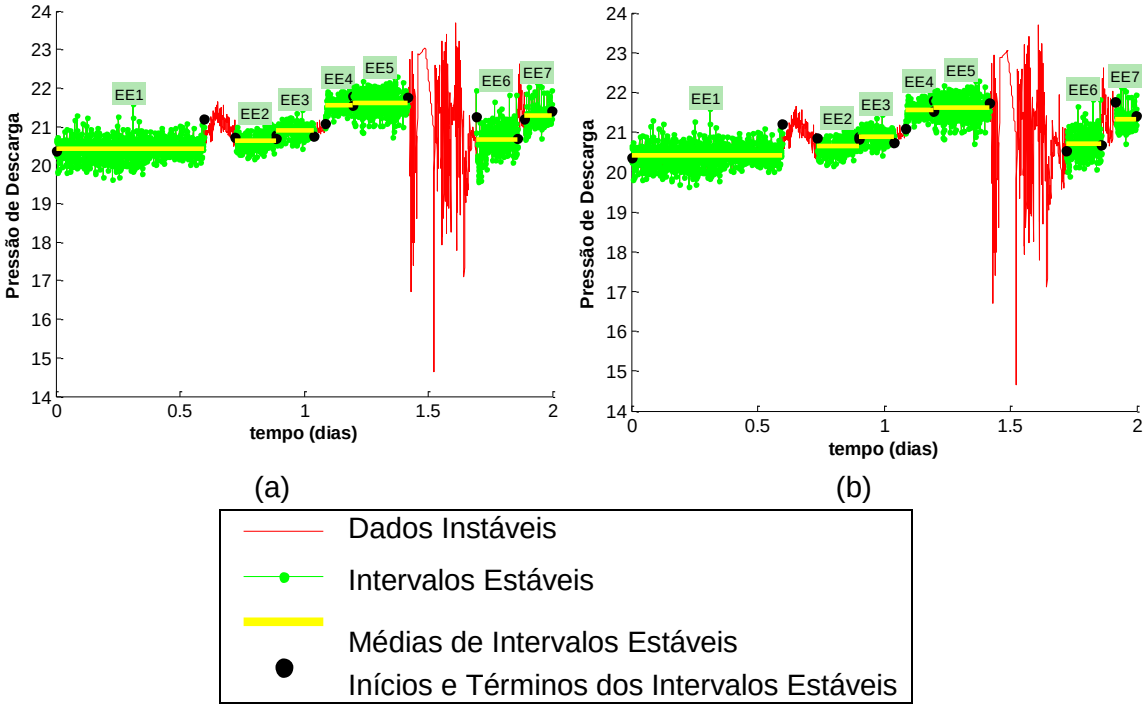

Figura 29: Comparação entre a identificação dos estados sob controle por teste T (a) e desvios relativos de média (b) para a variável P_D conjunto C_2.

Tabela 11: Agrupamento dos intervalos estáveis identificados para a variável P_d do conjunto C_2.

	Abordagem *T-test*	Desvios Relativos de Média
Equivalentes	-	4 e 7
Distintos	1; 2; 3; 4; 5; 6 e 7	1; 2; 3; 5 e 6

Os resultados da identificação de estados sob controle mostram-se satisfatórios para o objetivo de reconhecimento dos intervalos de operação regular, ou seja, sem perturbações severas. A metodologia de separação por desvios relativos de médias é indicada tendo em vista a sua flexibilidade para permitir variações na média, o que não é visto pela abordagem de *T-test*. Entretanto, o método requer o ajuste de parâmetros para fornecer a identificação conforme o comportamento sob controle da variável.

4.4. Verificação Estatística dos Estados Sob Controle

Esta etapa é importante para direcionar a metodologia de monitoramento adequada para os dados estáveis em questão, sendo avaliado a estacionariedade, a autocorrelação e a normalidade dos dados.

A estrutura de monitoramento utilizada possui como principal ponto para a escolha da abordagem adequada a autocorrelação das medições sob controle, sendo então uma hipótese de importante análise.

De modo a exemplificar os resultados da verificação de suposições de CEP para os dados analisados, considerou-se apenas o estado sob controle identificado com a maior duração pela abordagem por desvios relativos de média. No conjunto C_1, C_2 e C_{SIM} os intervalos avaliados foram o EE5, EE1 e EE2, respectivamente. A Tabela 12 apresenta os resultados dos testes estatísticos para estes intervalos.

Para a verificação de normalidade utilizaram-se os testes de Kolmogorov-Smirnov (KS), Lilliefors (Lf) e Jarque-Bera (JB) (todos com $\alpha = 0{,}5$), a hipótese nula dos testes significam que os dados possuem distribuição normal.

Os testes de autocorrelação foram o Ljung-Box *Q-test* (LBQ) e o correlograma FAC. No teste LBQ a hipótese nula indica dados sem autocorrelação. O correlograma FAC, na realidade, corresponde a um gráfico contendo os valores de FAC (ρ_h) para diferentes *lags*. Considerou-se que qualquer valor acima do limite de dois desvios-padrão (SE_ρ) entre esses *lags* retorna valor 1, correspondendo a dados autocorrelacionados.

A verificação da estacionariedade foi realizada pelos testes Augmented Dickey-Fuller (ADF) e Phillips-Perron (PP), nos quais a hipótese nula indica dados não estacionários. Nestes testes considerou-se o modelo de dados na forma autoregressiva com desvio de média (ARD - *Autoregressive with Drift*) com 2 *lags* e nível de significância igual a 0,05.

As figuras desta seção apresentam os testes estatísticos gráficos, são eles: correlograma FAC; histograma com ajuste de distribuição normal e o gráfico de normalidade comparando a distribuição dos dados com a distribuição normal.

Tabela 12: Verificação estatística para intervalos estáveis das variáveis em estudo.

Variável	Normalidade			Autocorrelação		Estacionariedade	
	K-S	Lf	JB	LBQ	FAC	ADF	PP
P_s (C_{SIM})	Não	Não	Não	Sim	Sim	Sim	Sim
T_D (C_1)	Não	Não	Não	Sim	Sim	Sim	Sim
P_D (C_2)	Não	Sim	Não	Sim	Sim	Sim	Sim

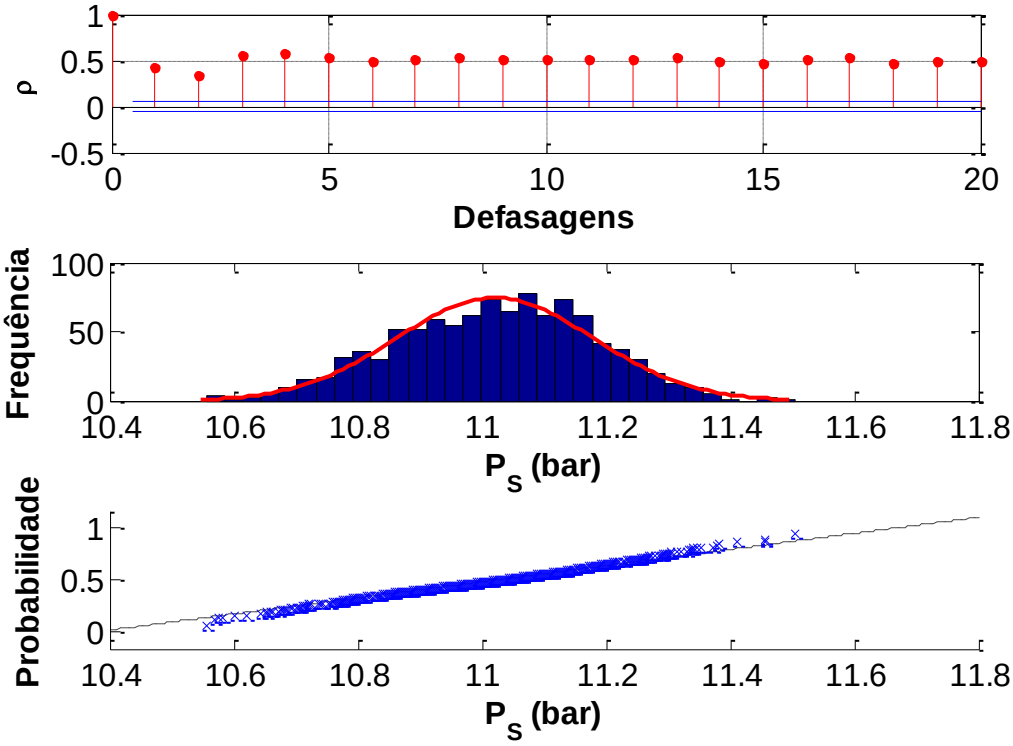

Figura 30: Verificação Estatística Gráfica para o intervalo EE2 da variável $\mathbf{P_s}$ $(\mathbf{C_{SIM}})$. 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada).

A verificação estatística da variável P_S do conjunto de dados C_{SIM} indica que o estado sob controle analisado possui autocorrelação em todas defasagens consideradas (correlograma FAC). Os dados analisados de C_{SIM} apresentam também desvio na normalidade, que pela inspeção do histograma pode ser considerado uma violação baixa. Os testes de estacionariedade indicam que o intervalo não possui tendências.

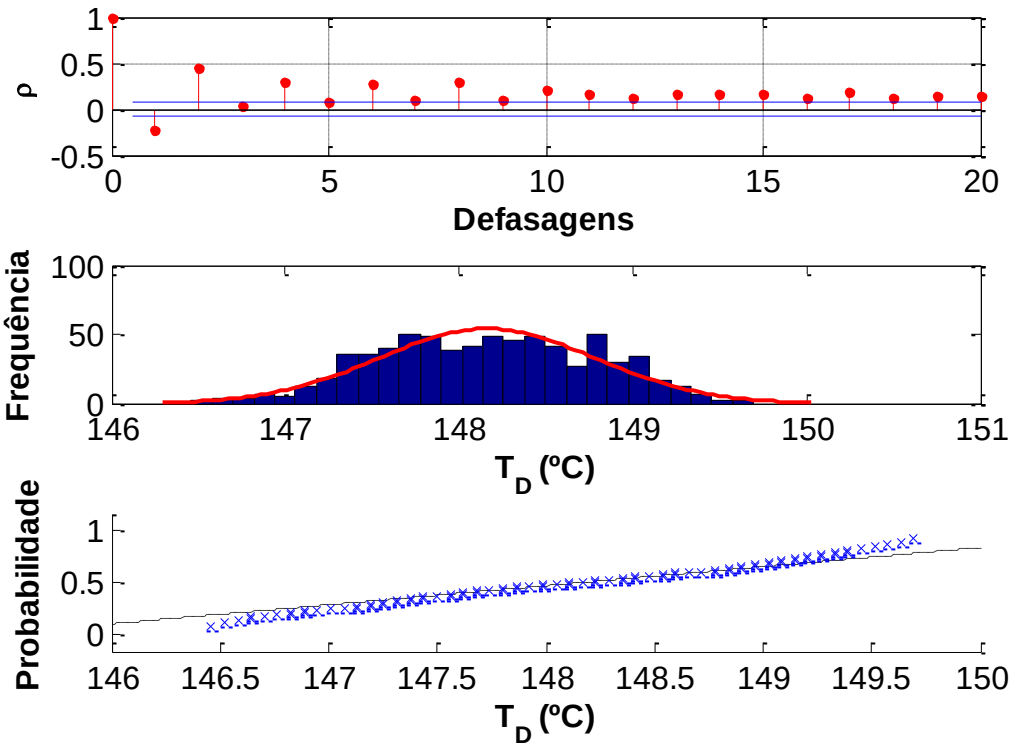

Figura 31: Verificação Estatística Gráfica para o intervalo EE5 da variável T_D (C_1). 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada).

A variável T_D do conjunto C_1 apresenta autocorrelação entre os dados para diversas defasagens demonstradas pelo correlograma FAC. Os testes estatísticos de normalidade rejeitam a hipótese nula com a significância de 5% e o histograma confirma o desvio na normalidade. Os dados apresentam estacionariedade (testes ADF e PP).

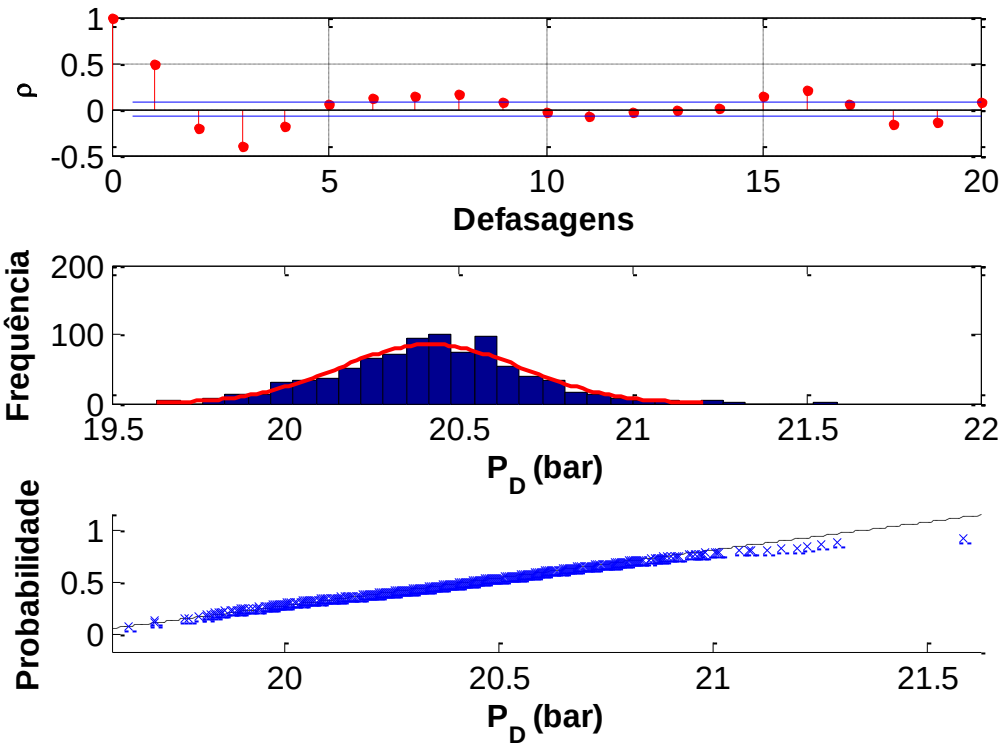

Figura 32: Verificação estatística gráfica para o intervalo EE1 da variável $P_D(C_2)$. 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada).

A variável P_D do conjunto de dados C_2 apresenta correlação baixa entre as observações, desvio de pequena magnitude na normalidade e estacionariedade da série temporal (Figura 32 e Tabela 12).

4.5. Etapa de Treinamento das Cartas de Controle

Após a verificação da estacionariedade, normalidade e autocorrelação dos dados considerados como sob controle, avalia-se o procedimento adequado para o monitoramento por cartas de controle.

O fluxograma da Figura 13 indica que dados sob controle com caráter não estacionário requerem o uso de modelos de séries temporais para eliminar a não estacionariedade pelo termo de integração (ordem d dos modelos ARIMA). Quando a série é estacionária, mas com autocorrelações significativas é adequado o uso de modelos de séries temporais para eliminar esta dependência entre as observações. Nos casos de intervalo estável sem tendências e com autocorrelação baixa, é possível utilizar as técnicas de médias de bateladas não ponderadas e modificações nos limites de controle.

O treinamento das cartas de controle utiliza os intervalos estáveis obtidos dos dados históricos para a determinação dos parâmetros de monitoramento. A identificação dos parâmetros adequados para todos estados sob controle formará um banco de dados que poderá ser consultado durante a etapa de monitoramento propriamente dita.

4.6. Monitoramento por cartas de Controle com Integração com os Estados Sob Controle da Série Histórica

A aplicação das técnicas e procedimentos de monitoramento considerando a consulta aos estados sob controle identificados é apresentada em diferentes abordagens.

Inicialmente exemplifica-se o uso do gráfico de Shewhart convencional com adaptações de limites de controle. Consideraram-se os dados de T_D do conjunto C_1, mesmo infringindo as hipóteses básicas do controle estatístico de processos. A ideia neste exemplo é mostrar a dificuldade dos gráficos de controle convencionais em monitorar processos contínuos de plantas industriais.

A outra abordagem refere-se aos modelos de séries temporais da família ARIMA para a redução da autocorrelação nos dados.

Para a apresentação da metodologia de monitoramento utilizada, foram considerados seis diferentes cenários:

1. Gráfico de Shewhart Convencional para T_D (C_1);
2. Monitoramento por IMA(1,1) (EWMA de linha central móvel) para T_D (C_1);
3. Monitoramento por ARIMA para T_D (C_1);
4. Monitoramento por IMA(1,1) (EWMA de linha central móvel) para a variável P_S (C_{SIM});
5. Monitoramento do Resíduo da Eficiência do Compressor (obtido pelos dados do conjunto C_2 e da metodologia de Miyoshi et al. (2012);
6. Integração de CEP com o Controle Automático de Processos.

Os três primeiros casos fornecem uma comparação entre as técnicas de monitoramento univariável por gráficos de controle estatístico para uma mesma série temporal, no caso a T_D (C_1).

O quarto cenário ilustra a interação entre o monitoramento e os estados sob controle de uma forma mais clara ao utilizar dados de simulação, nos quais as mudanças no comportamento da variável são conhecidas.

O quinto caso apresenta a junção da abordagem estatística com a fenomenológica abordada por Miyoshi et al. (2012) ao utilizar os resíduos da eficiência do compressor e aplicar as técnicas estudadas de monitoramento para dados autocorrelacionados.

Enfim, o sexto caso apresentado mostra uma possível integração de técnicas de controle estatístico de processos com o controle automático.

4.6.1. Abordagem utilizando Gráfico de Shewhart Convencional

A abordagem utilizando o gráfico de Shewhart convencional é ilustrada pela série temporal da variável temperatura de descarga T_D do conjunto de dados C_1. O correlograma da Figura 31 indica que existe autocorrelação nas medições, de modo que os gráficos de controle convencionais podem levar a falsos alarmes. O histograma mostra que a média não se mantém em um único valor, o que também não é adequado para as cartas de controle convencionais. As modificações dos limites de controle de Wheeler (1994) e Gilbert (1997) tentam reduzir os efeitos da autocorrelação, entretanto devido à média não constante, os gráficos de controle convencionais não são adequados.

A Figura 33 mostra o resultado da aplicação do procedimento para esta variável. Utilizou-se como dados de partida o estado sob controle referenciado na Figura 28 por EE5 (entre os tempos 2,7 e 3,9). As regras de sensibilidade adotadas para definir pontos fora de contorno foram: um ponto fora dos limites superior ou inferior e 20 últimos pontos todos acima ou todos abaixo da linha central.

Devido ao caráter de média variante do estado sob controle, as regras de sensibilidade devem ser adaptadas para a variável em questão. Desta forma, são necessários testes para a escolha adequada de parâmetros, tornando o procedimento ineficiente.

A confirmação do estado sob controle compatível na série histórica foi realizada pelo teste comparativo de desvio relativo entre médias e considerou-se um intervalo de confirmação de 100 pontos.

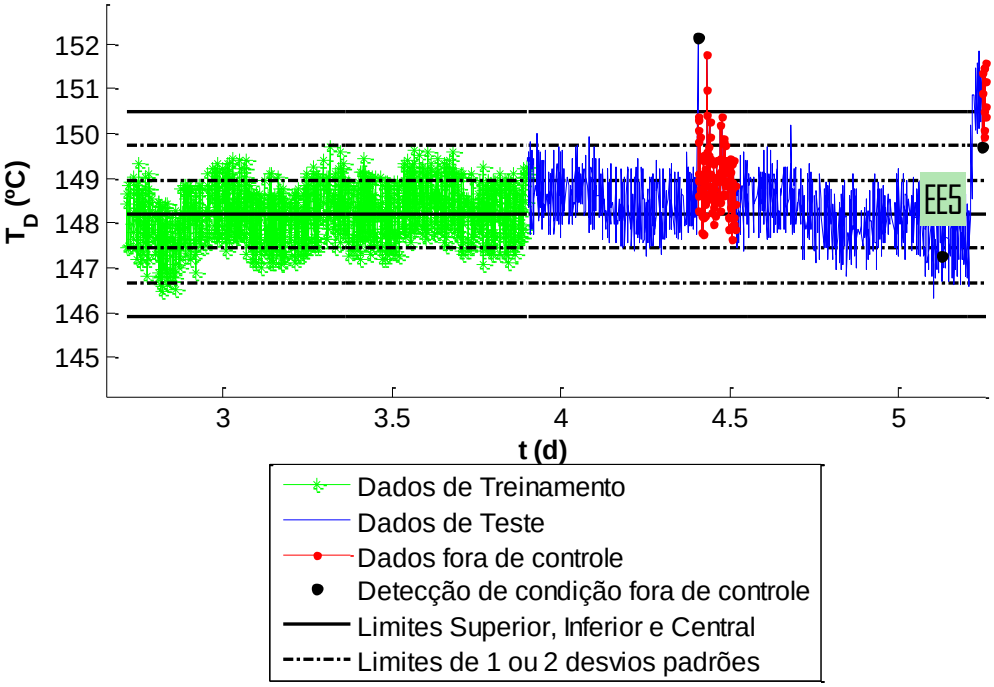

Figura 33: Monitoramento por Shewhart Convencional dos dados de T_d (C_1).

A Figura 33 mostra que no tempo de 4,4 e 5,1 detectou-se condição fora de controle (pelas regras de sensibilidade adotadas). No tempo de 5,1 a busca de estados sob controle compatíveis retornou o intervalo EE5 e no tempo 4,40 não foram encontrados estados compatíveis.

A Figura 34 indica a continuação do monitoramento até o final da série de dados. Nota-se que houve adaptações nos limites de controle nos tempos 6,9; 7,5 e 8,1. Desta forma, apesar de não ser possível a utilização das regras de sensibilidade consolidadas para o controle estatístico de processos, tal metodologia permite a atribuição de alarmes dinâmicos que se adaptam automaticamente conforme o estado operacional momentâneo do processo.

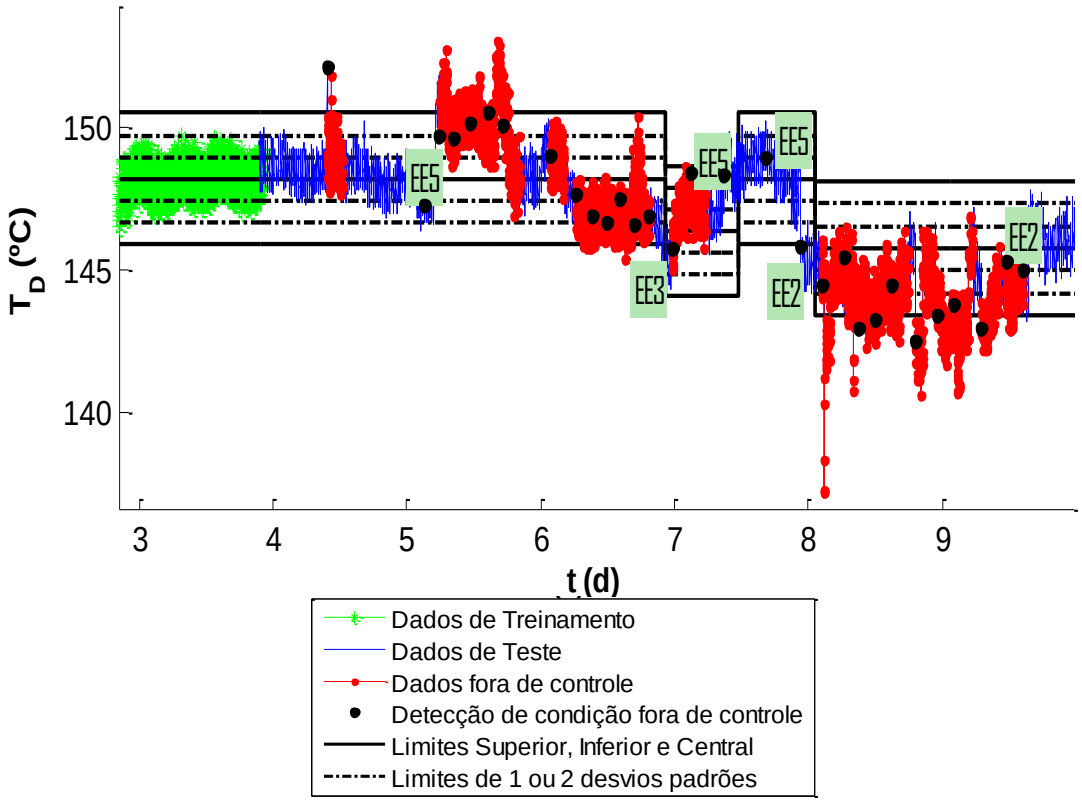

Figura 34: Continuação do Monitoramento da Figura 33.

A Figura 35 indica os valores de alarmes fixos de segurança aplicados para o monitoramento da variável em questão. Esses alarmes são importantes para a confiabilidade do sistema e dos equipamentos, mas não são capazes de acompanhar o processo e muitas vezes só são acionados quando os efeitos de uma falha já possuem consequências prejudiciais ao processo.

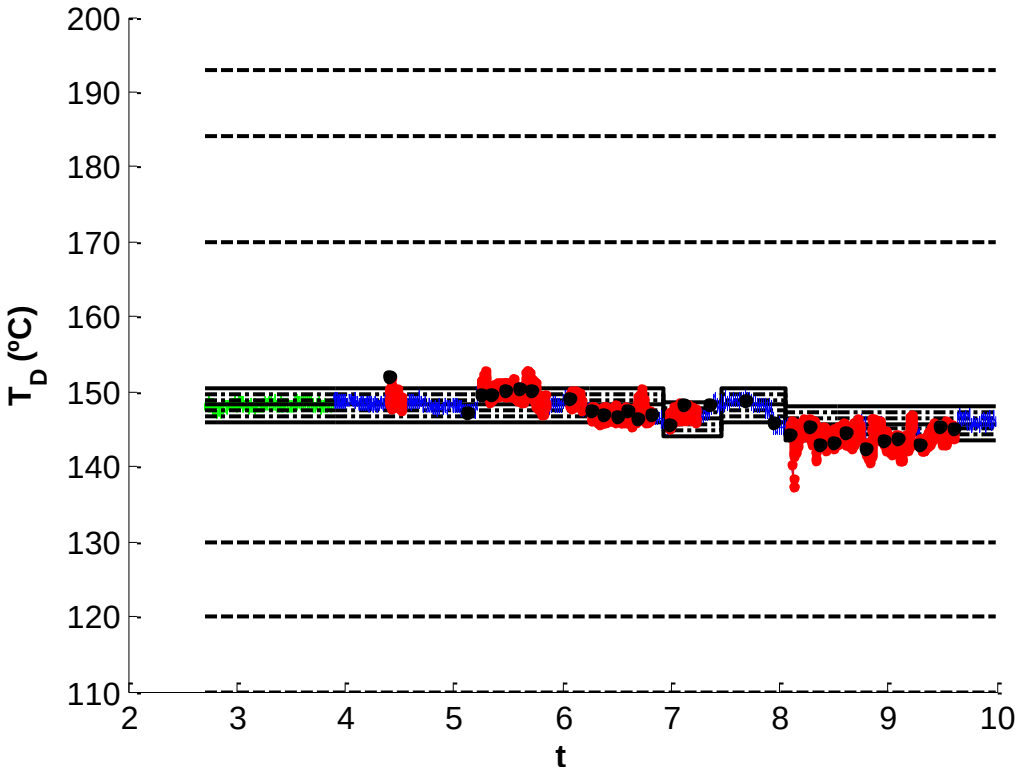

Figura 35: Inclusão dos alarmes de segurança da variável T_D de C_1 ao gráfico de Shewhart da Figura 34. Os alarmes trip alto, alto alto, alto, baixo, baixo baixo, trip baixo são representados pelas linhas tracejadas, nos valores de 193 ºC, 184 ºC, 170 ºC, 130 ºC, 120 ºC e 110ºC, respectivamente.

4.6.2. Abordagem com Modelos de Séries Temporais

Nesta abordagem considera-se os modelos ARIMA para a eliminação da autocorrelação dos dados e da variabilidade da média do processo. Um caso especial corresponde aos modelos IMA(1,1), o qual é utilizado no gráfico EWMA de linha central móvel.

4.6.2.1. Monitoramento por EWMA de linha central móvel para T_D (C_1)

A Figura 36 indica que os resíduos gerados pela previsão do modelo para os dados de treinamento ainda possuem autocorrelação e há desvio da distribuição normal. Entretanto a autocorrelação foi reduzida e o modelo eliminou a variabilidade na média das observações, como pode ser identificado por inspeção visual e pelos histogramas. Esta técnica permite a utilização de regras de sensibilidade consolidadas do CEP para a identificação de condições fora de controle. Foram consideradas as

regras de Western Eletric (1958). Considerou-se também a adaptação no limite de controle proposta por Wheeler (1994) para ajustar os limites de controle de acordo com a autocorrelação residual para o *lag* 1.

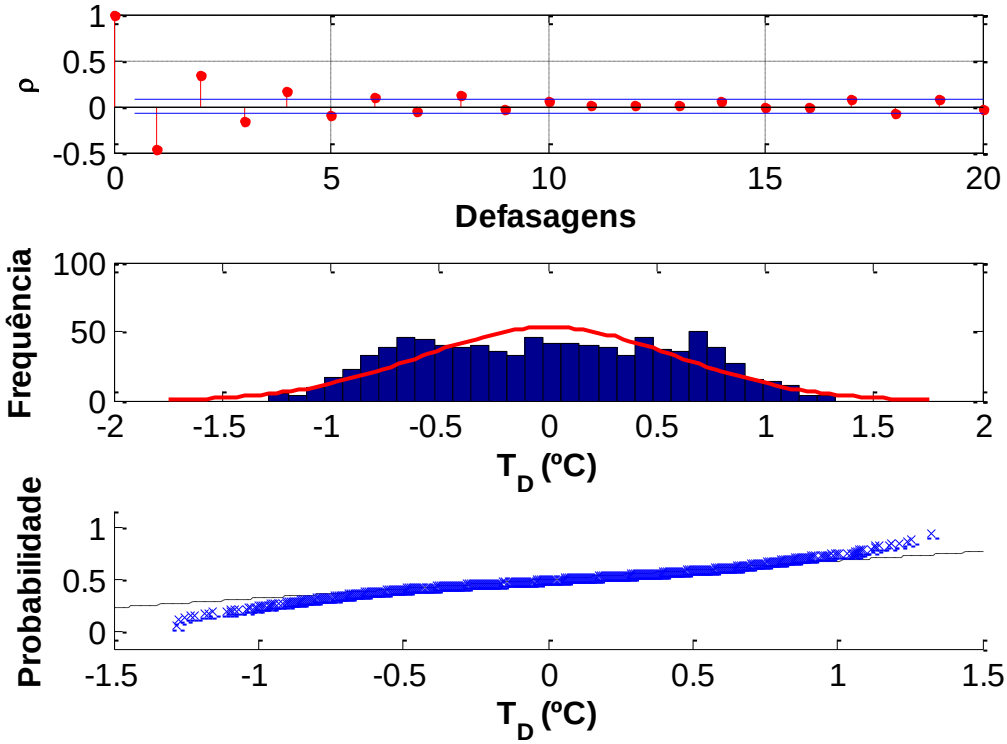

Figura 36: Verificação dos resíduos do modelo IMA(1,1) (Intervalo EE5 dos dados T_D (C_1)). 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada).

O gráfico do monitoramento com EWMA de linha central móvel é assinalado na Figura 37. Os dados de treino correspondem ao intervalo estável EE5. O número de pontos requerido para a comparação do estado momentâneo com os dados históricos também foi 100.

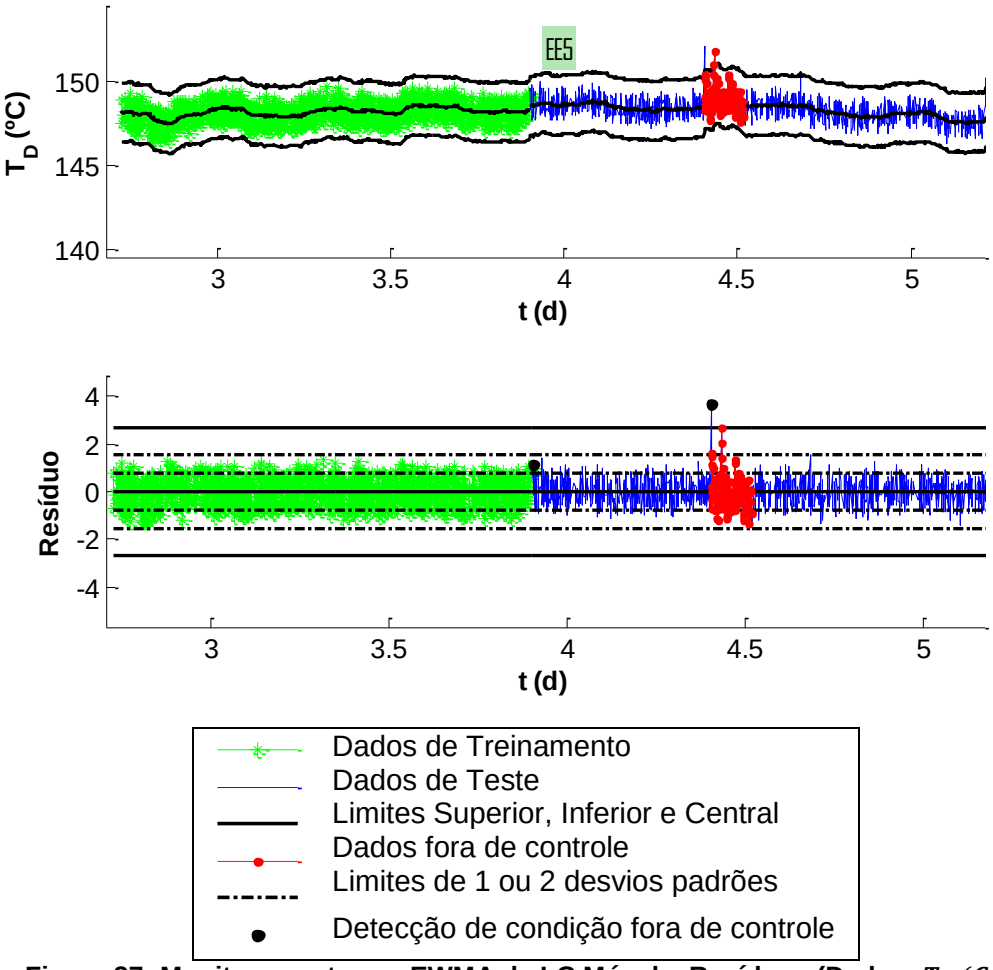

Figura 37: Monitoramento por EWMA de LC Móvel e Resíduos (Dados: T_D (C_1)).

Na Figura 37 nota-se que foi observado ponto fora de controle no tempo 3,9 (ponto em preto) no gráfico dos resíduos, mas a busca nos dados históricos retornou o estado 5 como compatível. Já a detecção de ponto fora de controle no tempo 4,4 não encontrou estado sob controle compatível, sendo uma possível anormalidade no processo.

A Figura 38 demonstra a continuação do monitoramento para o restante dos dados. Pode-se notar que existe uma ocorrência menor de detecções de pontos fora de controle em comparação com o gráfico de Shewhart convencional. Além disso, nota-se que os limites de controle da metodologia EWMA de linha central móvel vão automaticamente se adaptando, funcionando como uma espécie de rastreador dos dados. No tempo de aproximadamente 7,5 nota-se uma mudança na média do processo que não foi assinalada pelas regras de sensibilidade sob os resíduos no gráfico de Shewhart. Nestes casos, o gráfico de soma cumulativa (CUSUM) é uma alternativa adequada para identificar pequenas variações na média (Figura 39).

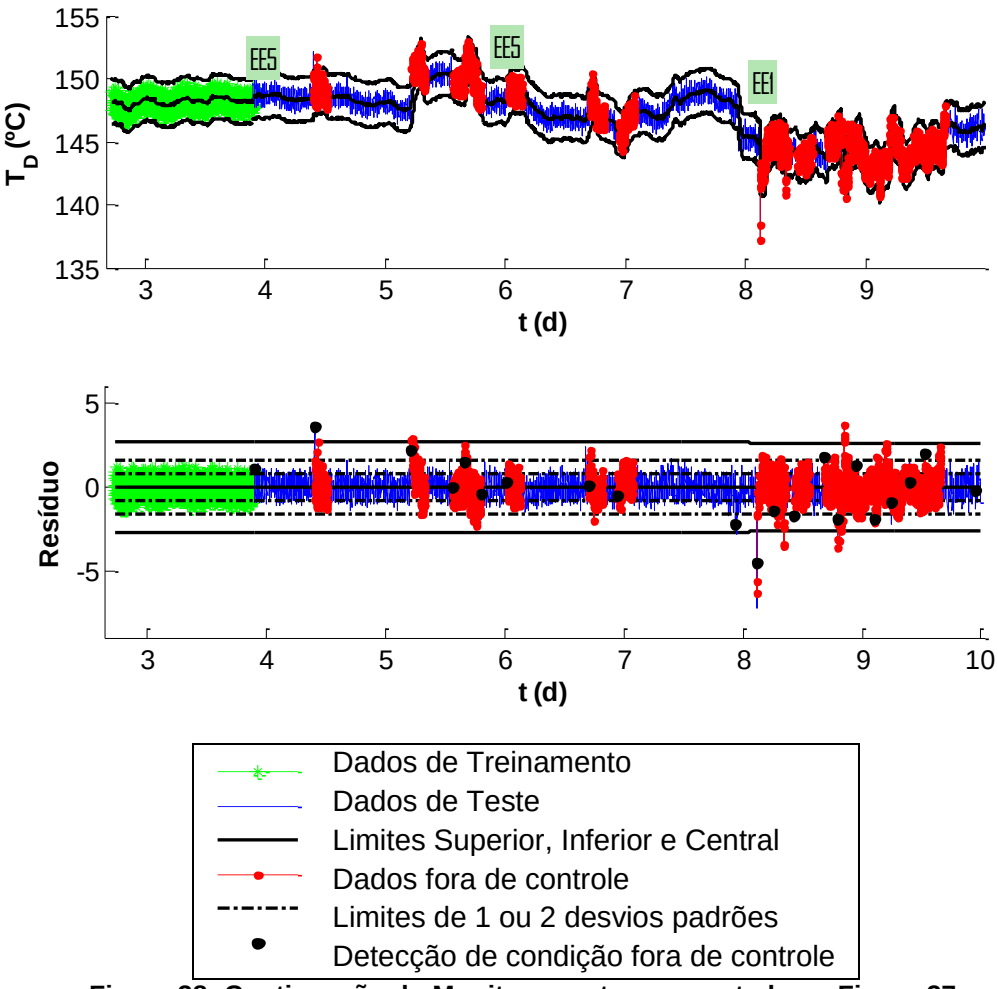

Figura 38: Continuação do Monitoramento apresentado na Figura 37.

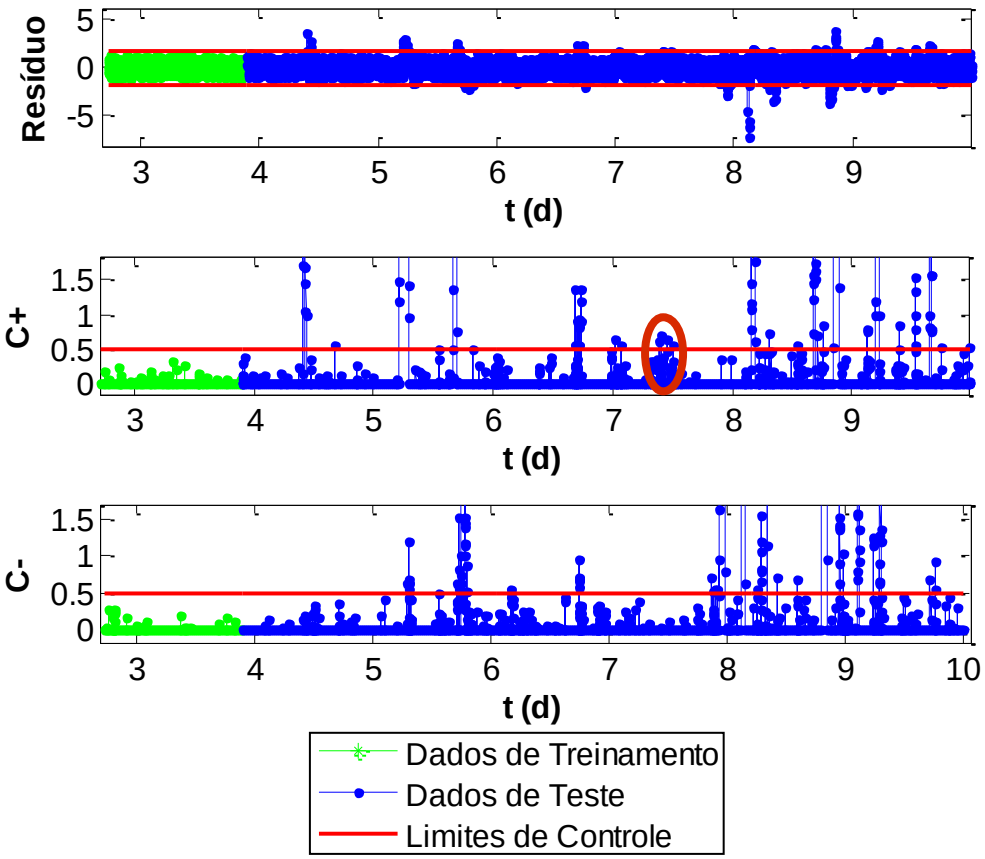

Figura 39: Gráfico CUSUM sobre Resíduos do modelo IMA(1,1). A elipse no 2º gráfico indica a situação de mudança na média não detectada pela carta de Shewhart

4.6.2.2. Monitoramento por ARIMA para T_D (C_1)

A abordagem por modelos ARIMA requer o ajuste das ordens do modelo (p, d e q). A variável em análise T_D do conjunto C_2 foi identificada com ordens autoregressiva, de média móvel e de integração igual a 1 (critérios AIC, SBC e mínino erros quadráticos). A verificação dos resíduos é apresentada na Figura 40. Testes estatísticos para os 5 estados sob controle dos dados históricos são apresentados na Tabela 12. O teste de normalidade com nível de significância de 5% de Lilliefors retornou distribuição normal para todos os estados, além disso, o teste de autocorrelação LBQ indicou resíduos descorrelacionados. Desta forma, as suposições dos gráficos de controle tradicionais são respeitadas. A Tabela 12 também indica valores dos parâmetros ARIMA de cada intervalo estável.

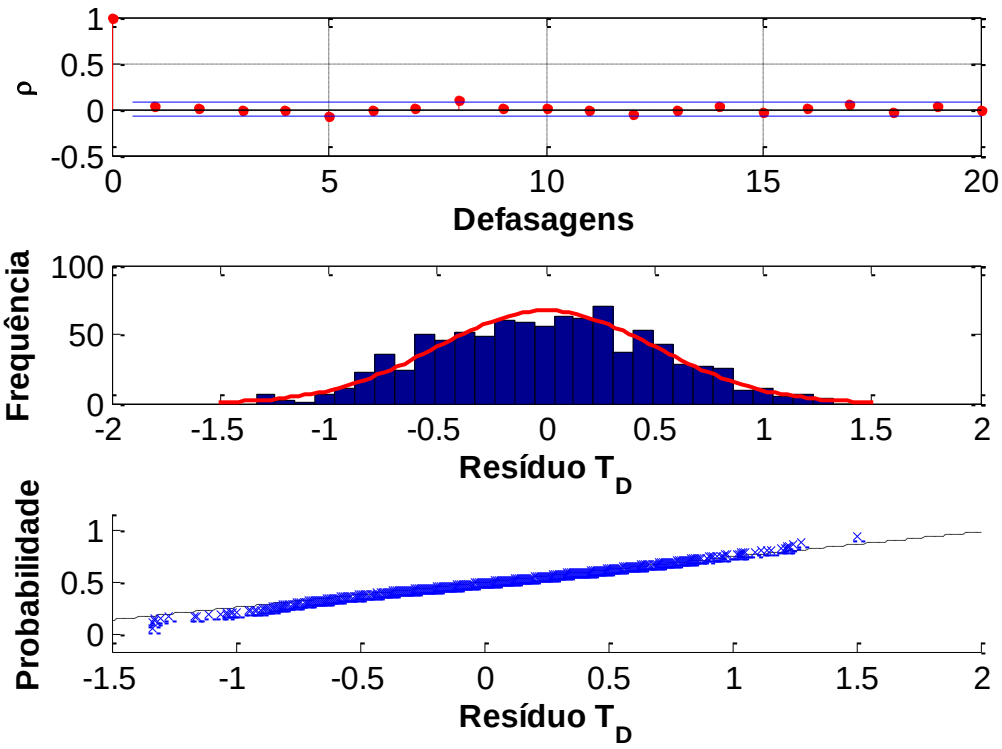

Figura 40: Verificação Gráfica dos resíduos do Modelo ARIMA(1,1,1) para o Intervalo EE5 de T_D (C_1). 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada).

Tabela 13: Modelos ARIMA(1,1,1) para os Intervalos Estáveis de Td (C1) e Testes Estatísticos

Estado Estável	JB	Lf	LBQ	ARIMA			
				Constante	AR	MA	Variância
1	0	0	0	-0,000456	-0,521	-0,800	0,278
2	0	0	0	0,00428	-0,539	-0,835	0,281
3	1	0	0	-0,00241	-0,547	-0,855	0,245
4	0	0	0	0,000655	-0,548	-0,898	0,239
5	1	0	0	0,000768	-0,541	-0,857	0,252

O monitoramento utilizando o modelo ARIMA(1,1,1) é indicado pela Figura 41. O intervalo de confirmação de estado sob controle compatível foi de 100 pontos e consideraram-se as regras de sensibilidade de detecção de situações fora de controle de Western Eletric (1958). Na Figura 41, o primeiro gráfico utiliza a metodologia similar a de EWMA de linha central móvel proposta por Moreira Junior (2005). O segundo gráfico representa os resíduos da previsão, pelos quais são realizadas as detecções de pontos fora de controle. Nesta figura são considerados todos os dados de teste, ilustrando o procedimento de monitoramento utilizado.

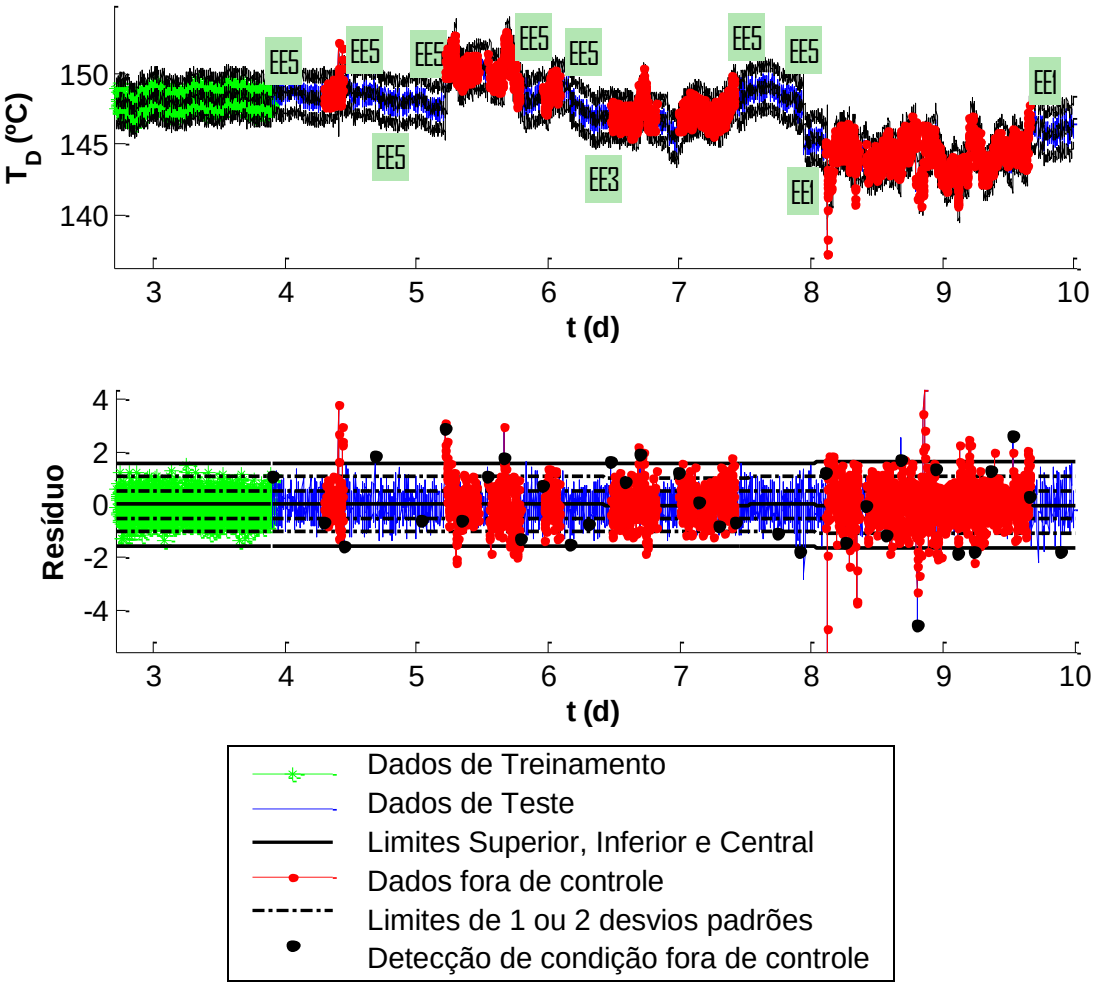

Figura 41: Monitoramento por ARIMA(1,1,1) e resíduos (Dados: T_D de C_1).

No gráfico da Figura 41 nota-se maior número de detecção de pontos fora de controle estatístico do que o gráfico de EWMA de linha central móvel. Desta forma, houve mais buscas por estados sob controle históricos compatíveis, resultando em um maior número de atualizações de parâmetros de monitoramento. O maior número de pontos fora de controle detectados pode ser devido a um sobreajuste do modelo.

4.6.2.3. Monitoramento por EWMA de Linha Central Móvel para a Variável P_S (C_{SIM})

A identificação dos estados sob controle da série temporal histórica da variável P_s dos dados simulados forneceu 4 intervalos estáveis, sendo que o primeiro e o último são considerados como equivalentes (média e variância similares). Desta forma, têm-se 3 pontos operacionais sob controle identificados desta variável.

Inicia-se o monitoramento no tempo de $36000s$ que divide os dados simulados entre o grupo considerado como dados históricos e o grupo de teste.

Pelos testes estatísticos verificou-se que as regiões estáveis da série histórica possuem estacionariedade de acordo com o teste de Dickey-Fuller Aumentado (ADF), mas apresentam elevada autocorrelação e desvio na normalidade. Desta forma, os gráficos convencionais de Shewhart não devem ser utilizados.

A verificação estatística dos resíduos obtidos pelo modelo IMA(1,1) para os estados sob controle identificados é apresentado na Tabela 14. Nota-se que o modelo foi capaz de fornecer uma distribuição de probabilidade normal e reduz a autocorrelação drasticamente, apesar de não eliminá-la completamente, como ilustrado pela Figura 42 que indica o correlograma FAC para o estado sob controle de número 4.

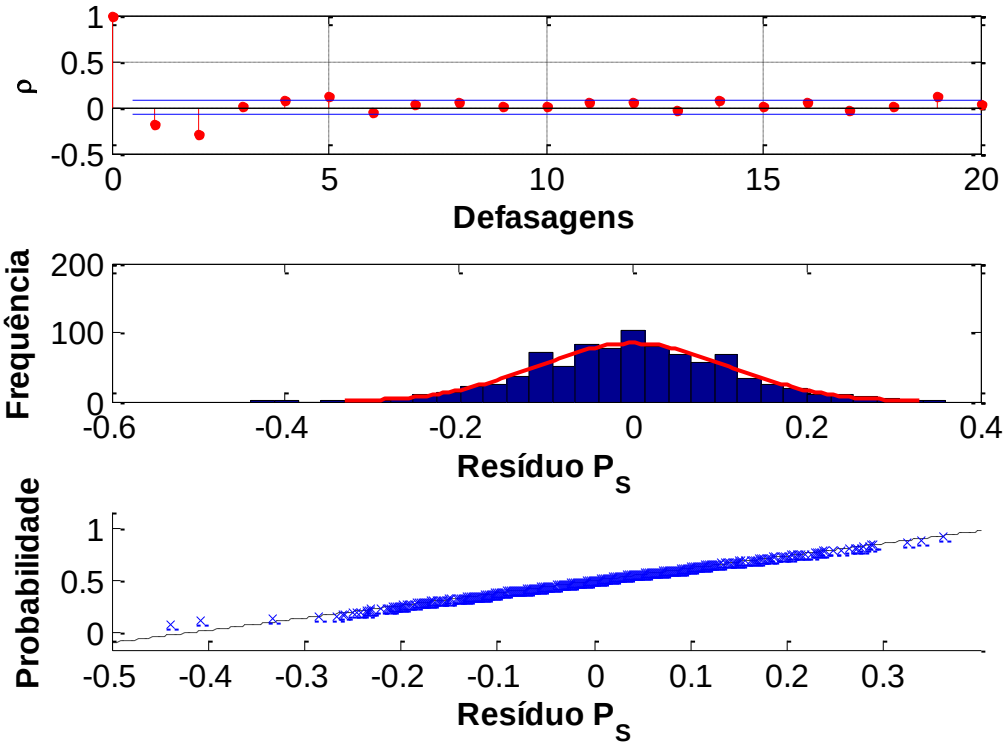

Figura 42: Verificação Gráfica dos Resíduos do Modelo IMA(1,1) para a variável P_s simulada. 1º gráfico o correlograma FAC; 2º gráfico o histograma com curva da distribuição normal ajustada e o 3º gráfico comparando a distribuição de probabilidade dos dados (pontos com marcações) com a distribuição normal (linha inclinada).

Tabela 14: Parâmetros do Monitoramento com modelo IMA(1,1) e Testes Estatísticos para os Intervalos Estáveis de Ps simulado

Estado Estável	JB	Lf	LBQ	EWMA de Linha Central Móvel Parâmetro - λ
1	0	0	1	0,0614
2	0	0	1	0,0722
3	0	0	1	0,0586
4	0	0	1	0,0586

A Figura 43 apresenta o monitoramento por EWMA de linha central móvel, com atualizações de parâmetros de acordo com a estrutura proposta de consulta aos intervalos estáveis históricos quando detectadas condições fora de controle. Inicia-se o monitoramento a partir do último estado sob controle identificado (número 4 da Figura 27-b (EE4)).

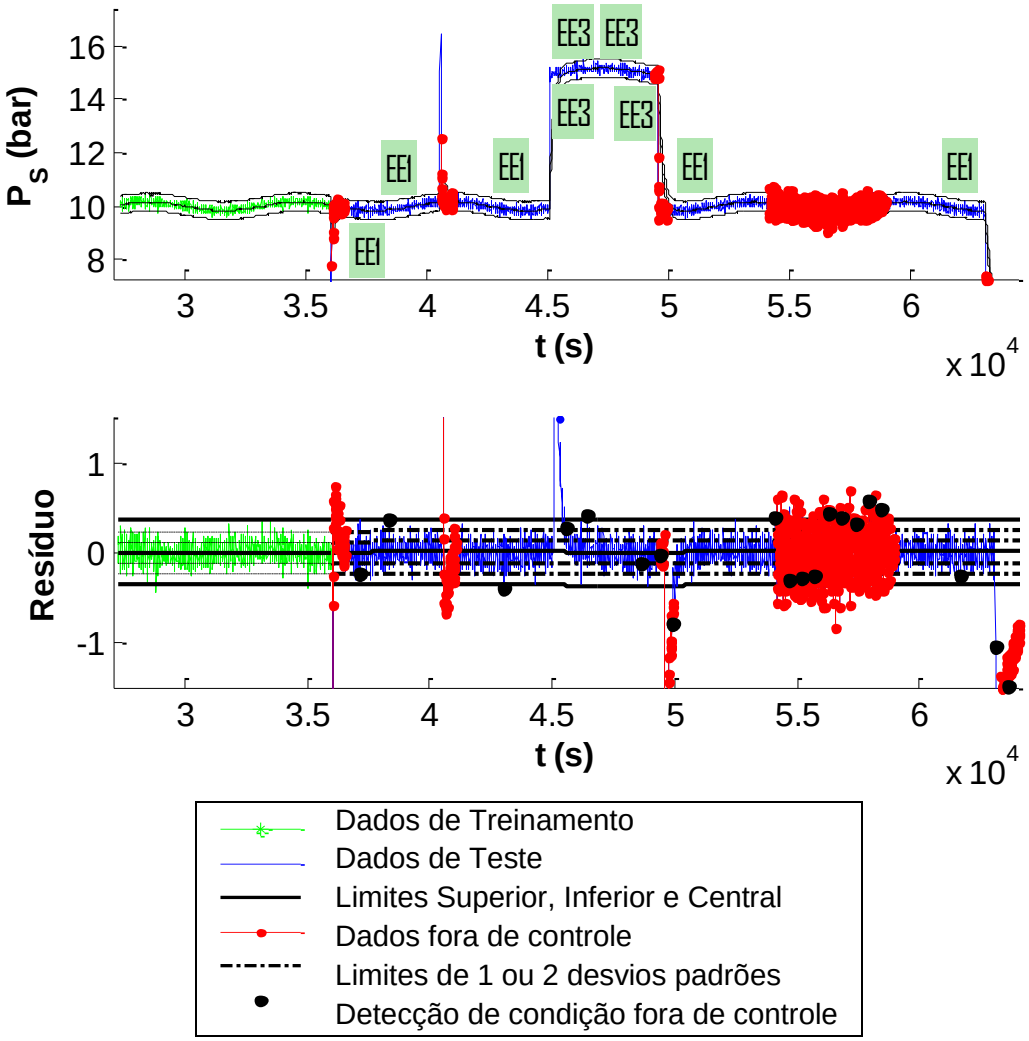

Figura 43: Monitoramento por EWMA de Linha Central Móvel e pelos resíduos (dados simulados).

Pela Figura 43 nota-se que na perturbação do tempo 36000s de simulação a técnica detectou a anormalidade nos dados e não foi encontrado nenhum ponto operacional previamente conhecido. O mesmo ocorreu para a perturbação simulada no tempo 40500s, caracterizando situações relevantes para identificação das causas de variabilidade. Nos tempos 37120, 38360, 43010 e 46540 segundos houve detecção de anormalidades no processo, entretanto pela metodologia de comparação com os estados sob controle históricos pode-se concluir que foram alarmes falsos, visto que

as observações posteriores possuem média e variância equivalentes ao do ponto operacional vigente.

No tempo de 45040 segundos a perturbação degrau simulada foi detectada e pela comparação com os estados históricos encontrou-se o estado número 3 como equivalente, assim os parâmetros do monitoramento são atualizados de modo a manter a capacidade preditiva do modelo de séries temporais utilizado. Enfim, a partir do tempo 54150s até 58950s nota-se que houve detecção do aumento da variabilidade nas medições e não foram determinados estados históricos equivalentes, de modo que a anormalidade representa uma possível falha no processo.

4.6.2.4. Monitoramento do Resíduo da Eficiência do Compressor

O resíduo da eficiência do compressor corresponde a uma técnica híbrida de monitoramento utilizando métodos estatísticos e abordagem fenomenológica (MIYOSHI *et al.*, 2012). O resíduo da eficiência é obtido pelo valor calculado a partir da modelagem fenomenológica com o obtido via curva característica (Figura 44). Na Figura 44-b apresenta-se a identificação dos estados sob controle obtidos, considerando a separação por comparações de médias por desvios para permitir pequenas variabilidades. Considerou-se como tempo de divisão entre dados históricos e dados de teste, o tempo de 1,2 dias de operação. Utilizou-se um limite de variação de média ($LIM_{MÉDIA}$) de 0,3, tamanho da janela para as comparações sucessiva de médias de 20 pontos, $\alpha_F = 0{,}001$ e $N_{t_{conf}} = 5$ (Obs: os gráficos não estão na mesma escala).

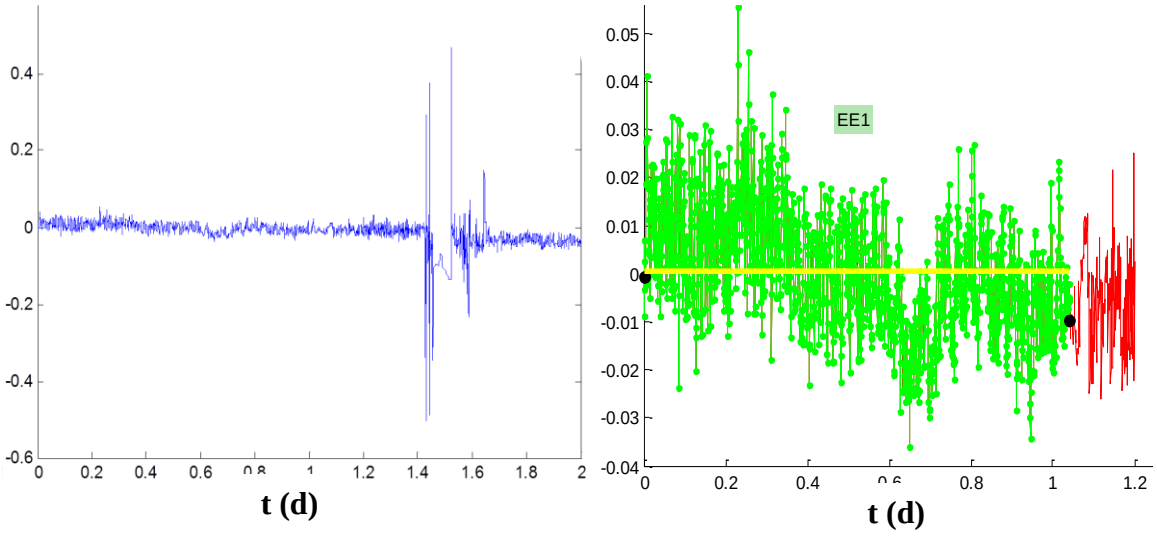

(a) (b)

Figura 44: Em (a) o resíduo da eficiência do compressor a partir dos dados do conjunto C_2 usando a abordagem de (MIYOSHI et al., 2012). Em (b) a identificação dos intervalos estáveis considerando como dados históricos até o tempo de 1,2 dias.

O correlograma e o histograma do estado sob controle identificado é apresentado na Figura 45-a e mostra a existência de correlação entre as observações. Além disso, os testes de normalidade com nível de significância em 5% rejeitam a hipótese de dados normais.

Para a total eliminação da autocorrelação nos dados considerados sob controle foram requeridos modelos ARIMA de ordens elevadas, sendo o mais simplificado o modelo ARIMA(4,3,1). Entretanto, a redução da autocorrelação obtida com modelos mais simples, como o IMA(1,1) já viabiliza o monitoramento baseado em cartas de controle.

Desta forma, utilizou-se o modelo IMA(1,1) para remoção da variabilidade da média das observações e da autocorrelação, sendo o correlograma e o histograma dos resíduos (dado original subtraído do previsto) mostrado na Figura 45-b. Os testes de normalidade (JB, Lf e KS) também consideram os dados com desvio na normalidade. Nota-se que o modelo eliminou em grande parte a autocorrelação das observações.

A Figura 46 ilustra o monitoramento pela abordagem EWMA de linha central móvel com a integração com estados sob controle históricos, sendo considerados 20 pontos para a comparação do estado momentâneo com os valores da base de dados. Nota-se que a aplicação do modelo IMA(1,1) foi capaz de diminuir a variabilidade na média das observações consideradas sob controle. Apesar de uma autocorrelação remanescente, foi aplicado o gráfico de Shewhart convencional com as regras de sensibilidade Western Eletric (1958) sobre os resíduos de predição, visto que fornece uma estratégia adequada para o monitoramento devido à estabilização da média em torno de zero.

Pelo gráfico da Figura 46 percebe-se que a técnica detecta anormalidade sem referencial histórico a partir do tempo 1,15 devido ao comportamento dos dados diferente daquele em que o modelo IMA(1,1) foi ajustado. No tempo 1,43 há uma brusca alteração nos valores, logo a técnica foi capaz de identificar uma anormalidade previamente a um evento de maior variabilidade.

Após o tempo 1,62 os dados voltam a uma regularidade na média, sendo um possível ponto operacional estável. Entretanto, como não foi identificado um referencial histórico para este estado operacional, os resíduos da previsão continuam identificando causas anormais de variabilidade. Uma maneira adequada para tratar

esta questão seria a identificação da estabilidade nos dados e incorporar o novo ponto operacional à base de dados estáveis.

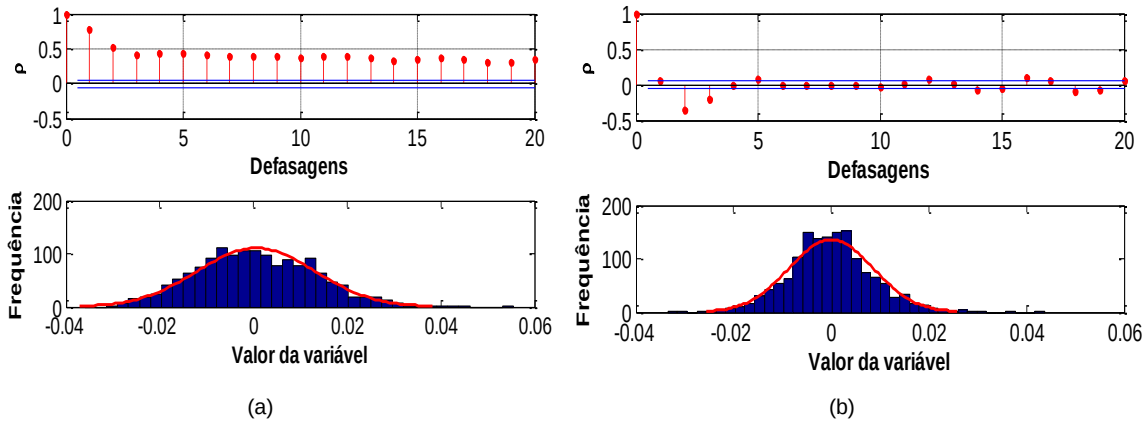

Figura 45: Verificação Estatística Gráfica dos Resíduos da Eficiência antes (a) e após (b) o ajuste de um modelo IMA(1,1).

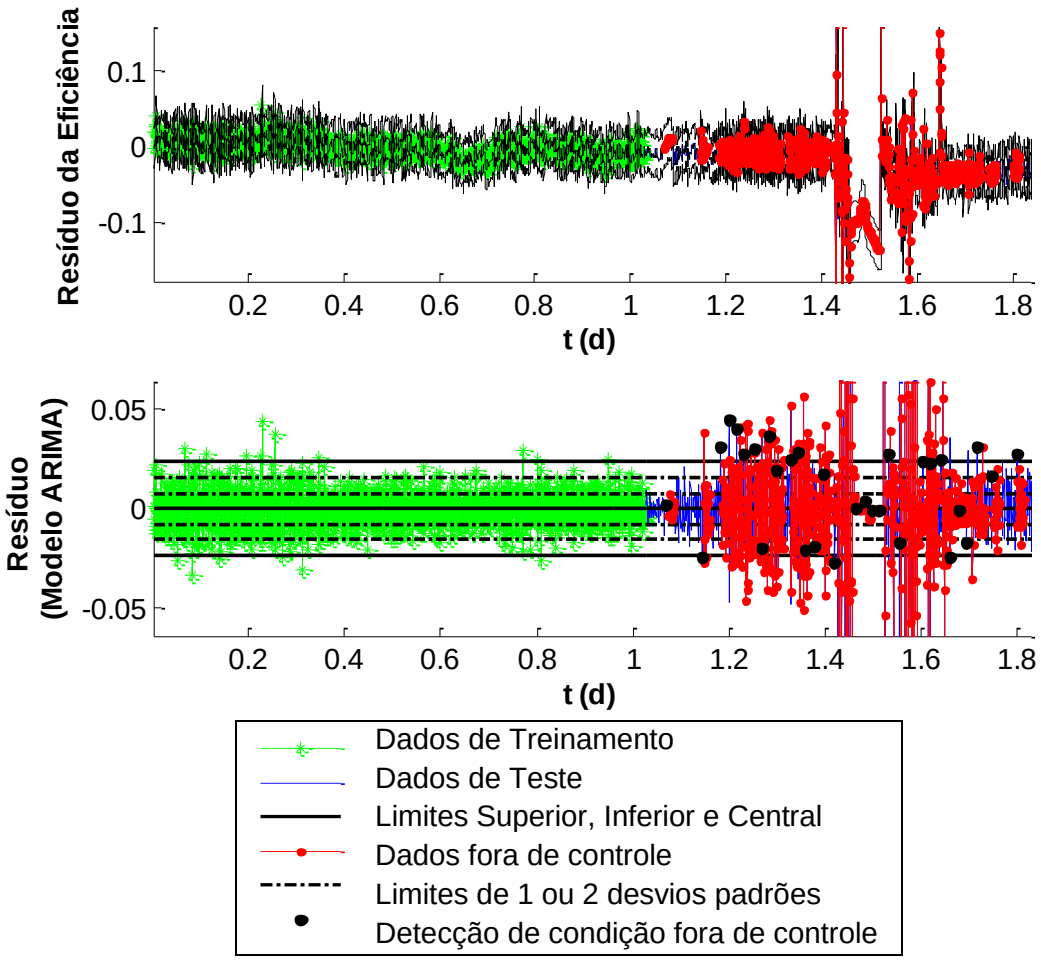

Figura 46: Monitoramento por EWMA de Linha Central Móvel para os Resíduos da Eficiência de Compressão.

4.6.2.5. Integração de CEP com o Controle Automático de Processos

A aplicação do Controle Estatístico de Processos sobre o desvio da variável controlada com o *setpoint* pode resultar em detecções rápidas de causas especiais de variabilidade. Assim, se for possível a remoção destas causas, considerável redução na variabilidade das observações pode ser obtida (MONTGOMERY, RUNGER, *et al.*, 1994).

Desta forma, avaliou-se a aplicação de cartas de controle sobre o desvio entre a pressão de sucção e o seu *setpoint* dos dados de simulação. Considerou-se a separação dos dados no tempo de 36000s de simulação para a região de treinamento e de teste.

A separação dos estados sob controle (Figura 47-a) utilizou o desvio relativo entre intervalos de média com os parâmetros: $L = 20$; $N_{t_{conf}} = 10$; $\alpha_F = 0{,}0001$ e $LIM_{MÉDIA} = 1{,}4$. Como o valor do desvio entre a pressão de sucção medida e seu setpoint é próximo de zero, a relação de comparação não utilizou a divisão pelo intervalo predecessor. A etapa de determinação dos estados sob controle equivalentes indica que os três estados identificados correspondem ao mesmo ponto operacional (média e variância compatíveis).

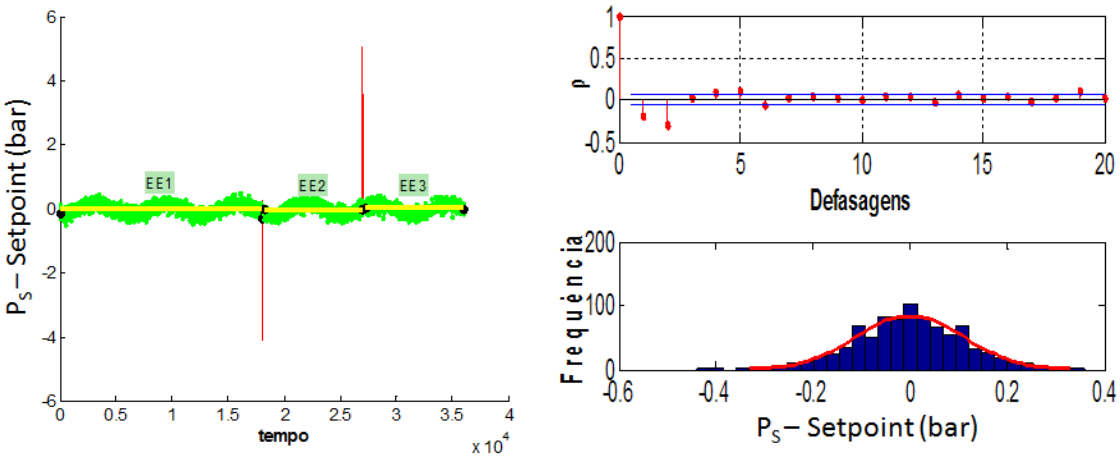

(a) (b)

Figura 47: (a) Separação dos Intervalos Estáveis; (b) Verificação gráfica dos resíduos IMA(1,1)

Aplicou-se novamente o modelo IMA(1,1) para a obtenção dos resíduos para o monitoramento. A Figura 48 ilustra o procedimento considerando o estado sob controle identificado de número 3 como dados de treinamento e os dados sucessores correspondem aos dados de teste. Para a comparação do estado momentâneo com a base de estados sob controle usou-se 50 pontos.

É possível notar que nos tempos de 36000 e 40550s o procedimento identificou condição fora de controle sem referenciais históricos. Esses eventos correspondem a uma perturbação no processo que foi estabilizada pelo sistema de controle. Entretanto devido à dinâmica para a correção da perturbação o método não identificou estado sob controle equivalente, mas após este período os dados voltaram a indicar situação sob controle.

Nas detecções de anormalidade dos tempos 45050s e 49410s houve uma mudança de *setpoint* da variável controlada. Novamente o procedimento não identificou estado sob controle de referência histórica devido à dinâmica para a estabilização no novo *setpoint*. Após a estabilização, o modelo voltou a descrever adequadamente o processo de forma que as observações situaram-se dentro dos limites do EWMA de linha central móvel.

Durante os intervalos 54150 a 58900 e 63060 a 67810 segundos simulou-se aumento da variabilidade nas medições do sensor e falha no atuador (pela anulação da saída de controle), respectivamente. Nessas situações a metodologia não identificou intervalos sob controle compatíveis durante todo o período de perturbação, evidenciando uma falha no processo.

As detecções de pontos fora de controle em 37120, 38360, 43010, 46450, 67810 e 68610 segundos retornaram estados sob controle compatíveis. A detecção em 67810s corresponde à determinação de uma operação de intervalo estável conhecido após uma possível falha no processo. Os demais eventos correspondem a falsos alarmes, visto que as medições sucessoras voltaram a situação sob controle (indicado pelo procedimento ao determinar o estado sob controle compatível).

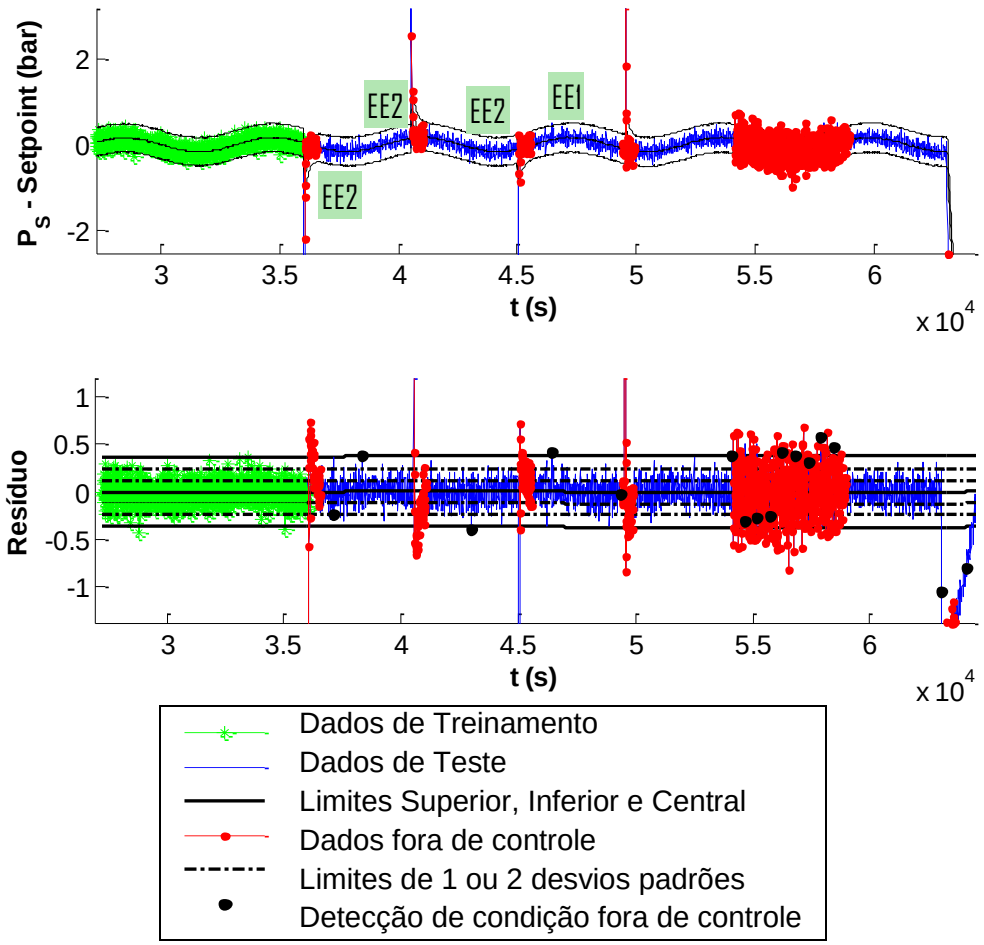

Figura 48: Monitoramento por EWMA de Linha Central Móvel para o desvio da variável controlada e seu *setpoint* (dados de simulação)o)

5. CONCLUSÕES

O presente trabalho considerou a implementação de técnicas de controle estatístico de processos em processos industriais contínuos. Desta forma, o primeiro passo foi estudar as características desses processos e compreender as adaptações necessárias para a introdução dos conceitos de CEP nestes ambientes.

O trabalho também abordou metodologias para permitir a atualização automática dos parâmetros de monitoramento de acordo com pontos operacionais relevantes. Para isso, foi desenvolvida uma metodologia para a segregação de intervalos estáveis de operação a partir da análise da série histórica de medições.

O método de identificação de estados sob controle mostrou-se eficiente para o propósito. Entretanto, devido às particularidades dos processos que podem considerar como situação normal de operação variabilidades na média das variáveis de diferentes magnitudes, é necessário o ajustes de parâmetros do procedimento.

Foram apresentados alguns cenários da aplicação dos gráficos de controle em variáveis de processos contínuos. Mostrou-se que a aplicação desta técnica aos dados originais é inadequada, visto que as hipóteses não são respeitadas e, consequentemente, as regras de sensibilidade comuns ao CEP não poderão ser aplicadas.

A aplicação de modelos de séries temporais corresponde a uma estratégia adequada para permitir a utilização dos conceitos básicos do CEP. Os resíduos obtidos pela previsão de um instante adiante possui autocorrelação reduzida, assim a identificação de situações anormais no processo pode ser realizada pelas regras de sensibilidade usuais do CEP.

Foi considerada a situação de processos industriais com mais de um estado operacional. Neste contexto, a integração entre o monitoramento em tempo real com os pontos operacionais identificados pode fornecer maior eficiência de detecção de falhas do que limites fixos pré-estabelecidos. Quando considerado o monitoramento por limites de controle fixos (gráfico de Shewhart convencional) esta integração atua com uma forma de limites de alarme dinâmicos. Por outro lado, nas estratégias baseadas em modelos de séries temporais, a integração possui a função de atualização dos parâmetros do modelo de série temporal, de forma a manter a sua representatividade ao processo estabilizado.

Existem alguns pontos que devem ser aprimorados, por exemplo, na situação de mudança intencional de estado operacional por alterações nos *setpoints* de variáveis controladas. Esta ação ocasiona variabilidade em variáveis do processo até

que ocorra sua estabilização em um novo patamar. Esta variabilidade não é esperada pelos modelos de série temporal, assim há a indicação de condição fora de controle. No procedimento considerado, é necessária a estabilização da variável para a confirmação que a variabilidade não representa uma possível falha no processo. Esta questão pode ser uma sugestão de trabalho futuro, por exemplo, estudando a integração entre a série temporal da variável manipulada com a série da variável controlada.

Outro ponto importante é em relação às regras de sensibilidade para a definição de pontos fora de controle pelo gráfico de Shewhart. Essas regras surgiram para a identificação de pequenas mudanças na média ou na variabilidade de um processo de montagem de peças. Nestes ambientes, qualquer causa especial de variabilidade deve ser corrigida a fim de aumentar a qualidade dos produtos de montagem. Por outro lado, nas indústrias de processos contínuos uma das principais atribuições do monitoramento é a segurança, assim não se tem a mesma necessidade de identificar pequenas causas de variabilidade. Logo, as regras de sensibilidade não necessitam ser tão rígidas. Um estudo para adequar as regras de sensibilidade à indústria de processos contínuos, considerando a segurança de processos como principal questão, poderia trazer benefícios à detecção de falhas.

BIBLIOGRAFIA

ALLEN, T. T. Introduction to Engineering Statistics and Six Sigma. [S.l.]: Springer, 2006.

ALVES, C. L. Uma aplicação da Técnica de Análise de Camadas de Proteção (LOPA) na avaliação de risco de incêncios nas rotas de cabos de desligamento de um reator nuclear. UFRJ COPPE/ Engenharia Nuclear. Rio de Janeiro. 2007.

ALWAN, L. C.; ROBERTS, H. V. Time-series modeling for statistical process control. Journal of Business & Economics Statistics, 1988.

ANDERSSON, M. A Matlab Tool for Rapid Process Identification and PID Design. Department of Automatic Control Lund Institute of Technology. [S.l.]. 2000.

ANDRADE, D. C. Fatores Condicionantes do Crescimento Econômico de Longo Prazo na China: Aspectos Teóricos e Investigação Empírica. Universidade Federal de Uberlândia. Uberlândia, p. 60-70. 2006.

ARAUJO, N. G. A. D. Aplicação de Gráficos de Controle para Monitoramento Estatístico da Turbidez da Água Potável. Universidade do Estado de Santa Catarina. Joinville, p. 55 a 60. 2010.

BALESTRASSI, P. P. Identificação de Padrões em Gráficos de Controel Estatístico de Processos, em Tempo Real, Utilizando Séries Tempórais e Redes Neurais Artificiais. UFSC. Florianópolis. 2000.

BASSEVILLE, M.; NIKIFOROV, I. V. Detection of Abrupt Changes: Theory and Application. [S.l.]: Prentice-Hall, Inc., 2006.

BISGAARD, S.; KULAHCI, M. Time Series Analysis and Forecasting by Example. [S.l.]: Wiley, 2011.

BOTROS, K. Transient Phenomena in Compressor. Journal of Engineering for Gas Turbines and Power, v. Volume 116, p. pp. 133-142, Janeiro 1994.

BOX, G. E. P.; JENKINS, G. M. Times Series Analysis: Forecasting and Control. 1. ed. San Francisco: Holden-Day, 1970.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. Time Series Analysis: Forecasting and Control. [S.l.]: [s.n.], 1994.

BOX, G. E. P.; LUCENO, A. Statistical Control by Monitoring and Feedback Adjustment. New York: John Wiley & Sons.

BOX, G.; KRAMER, T. Statistical Process Control and Automatic Process Control Discussion. Center of Quality and Productivity Improvement; University of Wisconsin-Madison. [S.l.]. 1990.

BROCKWELL, P. J.; DAVIS, R. A. Time Series: Theory and Methods. 2. ed. [S.l.]: Springer, 1991.

CAMPOS, M. C. M. M. D.; TEIXEIRA, H. C. G. Controles Típicos de Equipamentos e Processos Industriais. 1. ed. [S.l.]: Edgar Blucher, 2006.

CANABARRO, L. R. Inferência Dinâmica em Colunas de Destilação para uma Unidade de Processamento de Gás Natural. Universidade Federal do Rio de Janeiro. Rio de Janeiro, p. 65 a 72. 2011.

CAUMO, L. Aplicação e Cálculo da derivada de Sinais de Processos Industriais. Dissertação de Mestrado. Programa de Pós-Graduação em Engenharia, Universidade Federal do Rio Grande do Sul. Porto Alegre, RS. 2006.

GILBERT, K. C.; KIRBY, K.; HILD, C. R. Charting Autocorrelated Data: Guidelines for Practitioners. Quality Engineering, 1997.

GUJARATI, D. Basic Econometrics. 4. ed. [S.l.]: The McGraw−Hill Companies, 2004.

HOLLIFIELD, B. R.; HABIBI, E. Alarm Management: A Comprehensive Guide. 2. ed. [S.l.]: ISA, 2011.

HOULDING, S. W. Pratical geostatistics. Springer Verlag, New York, 2000.

AUTOMIND INC., A. Melhorando a Confiabilidade e a Segurança das Plantas Industriais através da Eficácia das Operações. Disponivel em: <www.isasp.org.br/>. Acesso em: fevereiro 2013.

ISERMANN, R. Fault-Diagnosis Systems. [S.l.]: Springer, 2006.

JIANG, T.; CHEN, B.; HE, X.; STUART, P.. Application of steady-state detection method based on wavelet transform. Computers and Chemical Engineering, 2003.

JIANG, W.; KHAN, J.; DOUGAL, R. A. Dynamic centrifugal compressor model for system simulation. Journal of Power Sources, 2005.

JIANG, W.; TSUI, K.-L.; WOODALL, W. H. A New SPC Monitoring Method: The ARMA Chart. American Society for Quality, 2000. 399-410.

KORZENOWSKI, A. L. Premissas e Suposições para contrução de gráficos de controle um framework para verificação. Universidade Federal do Rio Grande do Sul. Porto Alegre. 2009.

LPS/COPPE/UFRJ; CENPES. Relatório 08.2011/01. Programa de Engenharia Elétrica - Projeto Cenpes - Petrobras. Rio de Janeiro. 2011.

MACDONALD, D. Practical Hazops, Trips and Alarms. [S.l.]: Elsevier, 2004.

MACGREGOR, J. F. A Different View of the Funnel Experiment. Journal of Quality Technology , v. 22, p. 255-259, 1990.

MAHADEVA, L.; ROBINSON, P. Unit Root Testing to Help Model Building. Bank of England. London. 2004.

MEJIA, R. I G.; DUARTE, M. B.; TRIERWEILER, J. O. Contribuição para o Ajuste Automático dos Parâmetros de Métodos de Identificação de Estado Estacionários. Congresso Brasileiro de Automática, Bonito, MS, 12 a 16 outubro 2010.

MEJIA, R. I G.; DUARTE, M. B.; TRIERWEILER, J. O. Novo Método para a Identificação de Estado Estacionário Baseada na Estimativa da Autocorrelação Local. Congresso Brasileiro de Automática, 2010.

MEJIA, G. I. R.; DUARTE, M. B.; TRIERWEILER, J. O. Avaliação do Desempenho de Métodos de Identificação de Estado Estacionário. XVIII Congresso Brasileiro de Automática, 2010.

MINGOTI, S. A.; FIDELIS, M. T. Aplicando geoestatística no controle estatístico de processos. Produto & Produção, v. 5, 2001. 55-70.

MINGOTI, S. A.; YASSUKAWA, F. R. S. Uma comparação de gráficos de controle para a média de processos autocorrelacionados. Revista Eletrônica Sistemas & Gestão, 2008.

MIYOSHI, S. Monitoramento e detecção de falhas off-line em um sistema de compressão real baseado em modelo híbrido fenomenológico e cartas de controle estatísticas univariáveis. Relatório Técnico/UFRJ. Rio de Janeiro. 2011.

MIYOSHI, S. C.; ZYNGIER, D.; SOUZA, M. B. Jr; , SECCHI, A. R.; TEIXEIRA, A. F.; CAMPOS, M. C. M. M.; LIMA, E. L. Hybrid Monitoring of Offshore Compression Systems. IFAC Workshop on Automatic Control in Offshore Oil and Gas Production, 2012.

MONTGOMERY, D. C. Introduction to Statistical Quality Control. [S.l.]: Wiley, 2009.

MONTGOMERY, D. C.; RUNGER, G. C.; MESSINA, W. S.; KEATS, J. B. Integrating Statistical Process Control and Engineering Process Control. Jornal of Quality Technology, v. 26, Abril 1994.

MONTGOMERY, D. C.; KEATS, J. B. Integrating Statistical Process Control and Engeneering Process Control. Journal of Quality Technology, v. 26, Abril 1994. ISSN 2.

MONTGOMERY, D. C.; MASTRANGELO, C. M. Some statistical process control methods for autocorrelated data. Journal of Quality Technology, 1991. 179-204.

MOREIRA, F. D. J. Jr. Proposta de um Método para o Controle Estatístico de Processo para Observações Autocorrelacionadas. Dissertação de Mestrado/Programa de Pós-Graduação em Engenharia de Produção/ UFRGS. Porto Alegre. 2005.

MOURA, N. R. D. Simulação Fluidodinâmica Computacional de Desempenho de um Impelidor de um Compressor Centrífugo. Dissertação de Mestrado/Programa de Pós-Graduação de Engenharia Mecânica/UFRJ/COPPE. Rio de Janeiro. 2008.

PCHARA, G. R.; BARRERA, P. R.; KIRST, R. W. Gerenciamento de Desvios em Sistemas Instrumentados de Segurança. ABRAMAN. [S.l.]. 2010.

PINTO, J. C.; SCHWAAB, M. Análise de Dados Experimentais I: Fundamentos de Estatística e Estimação de Parâmetros. 1. ed. [S.l.]: e-paper, 2007.

PSARAKIS, S.; PAPALEONIDA, G. E. A. SPC Procedures for Monitoring Autocorrelated Processes. Quality Technology & Quantitative Management Vol. 4, 2007. 501-540.

ROBERTS, S. W. Control Chart Tests Based on Geometric Moving Averages. Technometrics, v. 43, p. 97 a 102, 1959.

RODRIGUES, P. S. B. Compressores Industriais. [S.l.]: EDC, 1991.

RUNGER, G. C.; WILLEMAIN, T. R. Batch Means Control Charts for Autocorrelated Data. IIE, 1996.

SAMOHYL, R. W. Controle Estatístico de Qualidade. São Paulo: Elsevier Campus, 2009.

SANTOS, S. R. D. Tratamento da Água: Monitoramento das Características de Qualidade da Água Potável. Dissertação de Mestrado, Pós-Graduação em Métodos Numéricos em Engenharia/UFPR. Curitiba. 2007.

STEPHANOPOULOS, G. Chemical Process Control An Introduction to Theory and Practice. New Jersey: Advisor Yeditors, 1984.

TINTNER, G. Econometrics. New York: John Wiley & Sons, 1965.

TOLOI, C. M.; C.; MORETTIN, P. A. Previsão de Séries Temporais. São Paulo: Atual, 1985.

VANBRACKLE, L. N.; REYNOLDS, M. R. J. EWMA and CUSUM Control Charts in the Presence of Correlation. Communications in Statistics-Simulation and Computation, 1997.

VAZ, C. A. Jr. Detecção e Diagnóstico de Falhas com Base em Dados Históricos de Processo: Aplicação em Dutovias. Tese de Doutorado/UFRJ. Rio de Janeiro. 2010.

VENKATASUBRAMANIAN, V.; RENGASWAMY, R.; YIN, K.; KAVURI, S. N. A review of process fault detection and diagnosis Part I: Quantitative model-based methods. Computer & Chemical Engineering, 2002. ISSN 27, 2003a. 293-311.

WARDELL, D. G.; MOSKOWITZ, H.; PLANTE, R. D. Control charts in the presence of data autocorrelation. Management Science, 1992. 1084-1105.

WESTERN ELECTRIC CO. INC. Statistical Quality Control Handbook. New York. 1958.

WHEELER, D. J. Advanced Topics in Statistical Process Control. [S.l.]: SPC Press, 1994.

WIEL, S. A.; VANDER; T., WILLIAM T.; FALTIN, F. W.; DOGANAKSOY, N. Algorithmic Statistical Process Control: Concepts and an Application. American

Statistical Association and the American Society of Quality Control, v. 34, 1992. ISSN 2.

WOODALL, W. H. Controversies and Contradictions in Statistical Process Control. Journal of Quality Technology, Minneapolis, Minnesota, v. 32, p. 341-350, Outubro 2000. ISSN 4.

YOUNG, T. M.; WINISTOFER, P. M. The effects of autocorrelation on real-time statistical process control with solutions for forest products manufactures. Forest Products Society, 2001.

ZHANG, N. F. A Statistical Control Chart for Stationary Process Data. American Society for Quality, 1998. 24-38.