

UNIVERSIDADE FEDERAL DE MINAS GERAIS  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**UM ALGORITMO DE DETECÇÃO DE FALHAS  
EM SISTEMAS MULTIVARIADOS**

ALEXANDRE AMANTÉA CAMPOS

Belo Horizonte, janeiro de 2011

UNIVERSIDADE FEDERAL DE MINAS GERAIS  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

# **UM ALGORITMO DE DETECÇÃO DE FALHAS EM SISTEMAS MULTIVARIADOS**

ALEXANDRE AMANTÉA CAMPOS

Dissertação de Mestrado submetida à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, como um dos requisitos necessários à obtenção do Grau de Mestre em Engenharia Elétrica.

Orientador: Prof. Benjamim Rodrigues de Menezes

Co-orientador: Prof. Walmir Matos Caminhas

Belo Horizonte, 17 de janeiro de 2011

## **RESUMO**

Este trabalho apresenta uma contribuição no desenvolvimento de metodologias para projetos de sistemas de detecção de falhas em plantas multivariadas. Foram empregadas técnicas de controle estatístico da qualidade em conjunto com redução de variáveis. O método permite a manipulação adequada de variáveis conjuntas e redução do número de variáveis com a menor perda de informação possível. Os resultados foram avaliados por intermédio de um simulador de falhas em um sistema de acionamento com motor de corrente contínua. As principais contribuições deste trabalho são: Métodos eficazes de projeto utilizando cartas de controle; Arquiteturas eficientes para aplicação de redução de variáveis e redução do modelo da planta.

## **ABSTRACT**

This paper presents a new methodology for system design and fault detection in multivariate plants, statistical quality control and reduction of variables techniques were employed. The technique allows the proper handling of joint variables and reducing the number of variables with the least possible loss of information. The results were evaluated through a faults simulator of a DC drive system. The most important techniques developed in this work are: Effective methods of control chart project; new architectures for efficient implementation of variable reduction, optimizing the plant model.

## **AGRADECIMENTOS**

Criar um trabalho de dissertação como este não é das tarefas mais fáceis que já me propus a fazer. É necessário muito conhecimento, maturidade e perseverança, qualidades que pude ver manifestas em toda a equipe de pesquisa do PPGEE. Agradeço a este pessoal pela ajuda e companheirismo, e de forma especial aos professores Benjamim Rodrigues de Menezes e Walmir Matos Caminhas que com seu trabalho e empenho contribuíram de forma determinativa para conclusão deste projeto.

Gostaria de expressar minha sincera gratidão ao senhor Paulo Roberto Fagundes Azevedo que junto à instituição do Banco Rural S/A. ofereceram total apoio ao autor deste projeto. Da mesma forma agradeço à FAPEMIG e ao CNPq.

Agradeço também, de forma especial, à minha família e amigos pelo apoio incondicional em todos os momentos.

## SUMÁRIO

<b>1</b>	<b>Introdução .....</b>	<b>1</b>
1.1	Considerações Gerais .....	1
1.2	Proposta de Trabalho .....	2
1.3	Organização do Trabalho .....	4
<b>2</b>	<b>Revisão Bibliográfica .....</b>	<b>6</b>
2.1	CEP: Controle Estatístico de Processo .....	7
2.1.1	Cartas de controle .....	9
2.1.2	T <sup>2</sup> de Hotelling.....	13
2.1.3	MMEP - Média móvel ponderada .....	19
2.2	Princípio de Pareto .....	26
2.3	Reduções de Variáveis.....	29
2.3.1	Análise das Componentes Principais .....	30
2.4	Conclusões.....	34
<b>3</b>	<b>Metodologia proposta .....</b>	<b>36</b>
3.1	Trabalhando em ambientes multivariados .....	37
3.1.1	Análise Conjunta das Variáveis .....	40
3.1.2	Diminuindo a complexidade .....	43
3.2	Simulador da uma Máquina CC .....	44
3.2.1	Formalismo matemático .....	45
3.2.2	Metodologia prática de simulação .....	48
3.3	Estudo sobre as cartas de controle.....	52
3.3.1	Os diversos tipos de falha .....	53
3.3.2	Simulação das Falhas .....	55
3.3.3	Comparação entre as cartas.....	58

3.3.4	Projeto das cartas de controle .....	60
3.3.5	Analisando o MMEP .....	62
3.4	Conclusões.....	63
<b>4</b>	<b>Experimento de detecção de falhas .....</b>	<b>64</b>
4.1	Projeto do sistema de detecção de falhas.....	65
4.1.1	Redução de variáveis .....	65
4.1.2	Escolha da carta de controle .....	66
4.1.3	O método de detecção de falhas .....	66
4.2	Metodologia Proposta .....	68
4.2.1	Obtenção da massa de dados para teste.....	70
4.2.2	Modelo matemático.....	70
4.2.3	Critérios de prova .....	71
4.3	Caso 1: Redução para uma só variável .....	72
4.4	Caso 2: Utilização da carta multivariada .....	78
4.5	Análise Geral dos Resultados Obtidos .....	82
<b>5</b>	<b>Conclusão .....</b>	<b>84</b>
<b>6</b>	<b>Referências bibliográficas .....</b>	<b>85</b>

## LISTA DE FIGURAS

Figura 1 Descrição do processo de detecção de falhas utilizando resíduos, redução de variáveis e gráficos de controle.....	4
Figura 2 Gráfico de controle de um sistema que se encontra sob controle estatístico .....	10
Figura 3 Gráfico de controle de um sistema que se encontra fora de controle estatístico.....	11
Figura 4 Demonstração dos efeitos do cálculo dos limites de controle LSC1 e LSC2. ....	13
Figura 5 Curva gaussiana demonstrando os limites calculados.....	15
Figura 6 Curva gaussiana bivariada - representação multivariada. ....	18
Figura 7 Gráfico de controle X-barra na presença de pequenas falhas. ....	20
Figura 8 Gráfico de controle MMEP na presença de pequenas falhas. ....	20
Figura 9 Gráfico de controle x-barra na presença de ruído. ....	21
Figura 10 Gráfico de controle MMEP na presença de ruído.....	21
Figura 11 Gráfico MMEP com lambda 0.3 (curva pontilhada superior), 0.1 e 0.001. ....	23
Figura 12 Gráfico de Pareto com porcentagens acumuladas. ....	28
Figura 13 Gráfico de Pareto com distribuição do problema. ....	28
Figura 14 Gráfico de Pareto com a regra 80/20. ....	29
Figura 15 Uma reta somada ao ruído gaussiano branco para estudo da metodologia do PCA.....	33
Figura 16 Autovetores projetados sobre os dados processados. ....	34
Figura 17 Processo de detecção de falhas. ....	37



Figura 18 Representação de um sistema multivariado operando sem falhas, mas gera um alarme falso se tratado inadequadamente. ....	38
Figura 19 Representação de um sistema multivariado operando sem falhas, mas não gera falha já que suas variáveis são tratadas conjuntamente. ....	39
Figura 20 Representação de um sistema multivariado operando com falha conjunta detectada adequadamente. ....	39
Figura 21 Representação de um sistema multivariado operando com falha simples detectada adequadamente. ....	40
Figura 22 Elipse de controle para duas variáveis independentes .....	41
Figura 23 Elipse de controle para duas variáveis dependentes.....	42
Figura 24 Diagrama em bloco do modelo construído da MCC.....	44
Figura 25 Dados de uma simulação do motor de corrente contínua sem falhas. ....	49
Figura 26 Dados de uma simulação do motor de corrente contínua com desconexão do conversor do campo.....	49
Figura 27 Dados de uma simulação do motor de corrente contínua com desconexão do conversor da armadura. ....	49
Figura 28 Dados de uma simulação do motor de corrente contínua com falha no sensor de corrente de armadura.....	49
Figura 29 Dados de uma simulação do motor de corrente contínua com curto-circuito do conversor do campo. ....	50
Figura 30 Fluxograma do processo de detecção de falhas. ....	51
Figura 31 Processo de decisão para análise do resíduo. ....	52
Figura 32 Representação de uma falha abrupta de baixa amplitude por um degrau unitário. ....	54
Figura 33 Representação de uma falha abrupta de grande amplitude por um degrau de peso três.....	54
Figura 34 Representação de uma falha abrupta por uma rampa. ....	55

Figura 35 Representação de ruído por um impulso.....	55
Figura 36 Resultado gráfico X-barra quando testado para os vários tipos de falhas.....	56
Figura 37 Resultado gráfico CUSUM quando testado para os vários tipos de falhas.....	57
Figura 38 Resultado gráfico MMEP quando testado para os vários tipos de falhas. ....	57
Figura 39 Escolha das cartas de controle para o projeto do sistema de detecção de falhas. ....	61
Figura 40 Ajuste dos parâmetros do MMEP, representação de uma carta MMEP com lambda igual a 0.1 .....	62
Figura 41 Ajuste dos parâmetros do MMEP, representação de uma carta MMEP com lambda igual a 0.01.....	62
Figura 42 Sistema de detecção de falhas .....	64
Figura 43 Descrição do processo de detecção de falhas e das ferramentas utilizadas. ....	67
Figura 44 Redução total de variáveis.....	69
Figura 45 Utilizando cartas multivariadas.....	69
Figura 46 Resultado das componentes principais do PCA representadas em um gráfico de Pareto. ....	70
Figura 47 Caso 1 - Redução para uma variável tratada pela a carta de controle simples. ....	72
Figura 48 Pareto das componentes principais .....	73
Figura 49 Resultado do tratamento do caso 1 para falhas abruptas. ....	74
Figura 50 Resultado do tratamento do caso 1 para falhas de baixa magnitude. ....	75
Figura 51 Resultado do tratamento do caso 1 para falhas de baixa magnitude utilizando o gráfico X-barra. ....	76
Figura 52 Resultado do tratamento do caso 1 para falhas incipientes.....	76

Figura 53 Resultado do tratamento do caso 1 para falhas com picos de ruído. ....	77
Figura 54 Resultado do tratamento do caso 1 para falhas com picos de ruído utilizando o gráfico de controle CUSUM. ....	78
Figura 55 Resultado do tratamento do caso 2 para falhas abruptas. ....	79
Figura 56 Resultado do tratamento do caso 2 para falhas de baixa magnitude. ....	80
Figura 57 Resultado do tratamento do caso 2 para falhas incipientes.....	81
Figura 58 Resultado do tratamento do caso 2 para falhas com picos de ruído. ....	81
Figura 59 Caso 1:Redução total de variáveis.....	82
Figura 60 Caso2: Utilizando cartas de controle. ....	83

## LISTA DE TABELAS

Tabela 1 Comprimento médio de seqüência para vários esquemas de controle MMEP.....	24
Tabela 2 Dados para demonstração do gráfico de Pareto .....	27
Tabela 3 Normalização dos dados segundo Pareto .....	27
Tabela 4 Cálculo das freqüências e freqüências acumuladas .....	27
Tabela 5 Resultado do desempenho das cartas de controle quando aplicada uma falha abrupta de grande amplitude.....	58
Tabela 6 Resultado do desempenho das cartas de controle quando aplicada uma falha abrupta de pequena amplitude.....	59
Tabela 7 Resultado do desempenho das cartas de controle quando aplicada uma falha incipiente .....	59
Tabela 8 Resultado do desempenho das cartas de controle quando submetida a ambientes ruidoso .....	60
Tabela 9 Escolha de cartas de controle segundo suas propriedades para utilização em detecção de falhas.....	60
Tabela 10 Resultado do tratamento do caso 1 para falhas abruptas. ....	74
Tabela 11 Resultado do tratamento do caso 1 para falhas de baixa magnitude. ....	75
Tabela 12 Resultado do tratamento do caso 1 para falhas de baixa magnitude utilizando o gráfico X-barra. ....	75
Tabela 13 Resultado do tratamento do caso 1 para falhas incipientes.....	76
Tabela 14 Resultado do tratamento do caso 1 para falhas com picos de ruído. ....	77

Tabela 15 Resultado do tratamento do caso 2 para falhas abruptas. ....	79
Tabela 16 Resultado do tratamento do caso 2 para falhas de baixa magnitude. ....	80
Tabela 17 Resultado do tratamento do caso 2 para falhas incipientes.....	80
Tabela 18 Resultado do tratamento do caso 2 para falhas com picos de ruído. ....	81
Tabela 19 Caso 1 - Robustez a ruído .....	82
Tabela 20 Caso 2 – Resultado numérico. ....	83

# NOMENCLATURAS

CEP	Controle estatístico de processos
CUSUM	<i>Cumulative Sum</i>
LC	Linha central
LIC	Limite inferior de controle
LSC	Limite superior de controle
MMEP	Médias móveis exponencialmente ponderadas
PCA	<i>Principal Components Analysis</i>
Bm	Coefficiente de atrito viscoso
ea	Força contra-eleto-motriz da armadura
ia	Corrente do circuito de armadura
ifd	Corrente do circuito de campo
Jm	Momento de inércia
La	Indutância do circuito de armadura
Lafd	Indutância mútua
Lfd	Indutância do circuito de campo
ra	Resistência do circuito de armadura
rfd	Resistência do circuito de campo
Tem	Conjugado eletromagnético
TL	Conjugado mecânico exigido pela carga
Va	Tensão do circuito de armadura
Vfd	Tensão do circuito de campo
Wr	Velocidade mecânica de rotação
cov	Covariância
p	Variância
R()	Rampa
RFB	Ruído gaussiano branco
svd	<i>Singular value decomposition</i>
u	Média
U()	Degrau unitário

# **1 INTRODUÇÃO**

## **1.1 Considerações Gerais**

A qualidade dos produtos e serviços usados por nossa sociedade tornou-se o principal fator de decisão do consumidor em muitas, se não na maioria, das formas modernas de negociações. Independentemente de o consumidor ser um indivíduo, uma corporação, um programa militar de defesa ou uma loja de varejo, é provável que ele dê a mesma importância à qualidade do produto que ao custo e aos prazos. Conseqüentemente, a melhoria da qualidade tornou-se uma das principais preocupações de muitas corporações (Montgomery, 2004).

Outro fator importante é a possibilidade de melhorar o aproveitamento do processo e então diminuir seus custos. O estudo aprofundado do processo permite determinar com maior eficiência a dosagem de matéria prima necessária e diminuir a probabilidade de produzir peças fora dos padrões de qualidade adotada.

A detecção de falhas diminui custos, aumenta a produtividade, promove segurança e estabelece um maior controle e visibilidade das operações nas plantas industriais. Dada sua importância, esta técnica fomenta a produção de trabalhos científicos já há alguns anos (Venkatasubramanian *et al.*, 2003, 2003a, 2003b). Esta metodologia pressupõe a construção de modelos que devem predizer o comportamento adequado das plantas. A divergência entre as simulações destes modelos e as amostras colhidas de forma *online* do processo físico determina o resíduo. Este resultado é utilizado para identificar anomalias, gerar alertas de falhas e tratá-las (Venkatasubramanian *et al.*, 2003a, 2003b, 2003c).

Os sistemas multivariados criam a necessidade de manipular um conjunto de  $n$  variáveis simultaneamente. Neste caso, normalmente, as variáveis são dependentes entre si. Por isso os métodos de detecção de falhas devem analisar os resíduos conjuntamente (Macgregor e Kourti, 1995).

## **1.2 Proposta de Trabalho**

Os conceitos e práticas que constituem o processo de detecção de falhas estão bem definidos na literatura científica, alguns trabalhos citados na referência bibliográfica constituem excelentes fontes de informação sobre o assunto (Venkatasubramanian, *et al.*, 2003a, 2003b, 2003c). A evolução dos trabalhos de pesquisas nesta área é eminente, estudos recentes demonstram metodologias capazes de realizar o que é conhecido por detecção de novidades através do emprego de ferramentas da matemática estatística (Lemos, 2007).

Seguindo a linha de procedimentos estatísticos, o conceito de CEP (Controle estatístico de processamento) fornece um poderoso conjunto de métodos matemáticos com características bastante eficientes e de grande empregabilidade no processo de detecção de falhas em sistemas dinâmicos. Seguindo estes preceitos aparecem outros trabalhos empregando o CEP para resolver o problema da detecção de novidades (Lemos, 2007).

Este documento inspira-se nos bons resultados obtidos em (Lemos, 2007) quando oferece uma metodologia para tratar a detecção de falhas em sistemas dinâmicos. Neste caso, aquela proposta será estendida de forma a contemplar ambientes multivariados.

Este trabalho apresenta uma metodologia de detecção de falhas dimensionada para sistemas multivariados. Ela é embasada nos conceitos de controle estatístico de processos (Montgomery, 2004). As



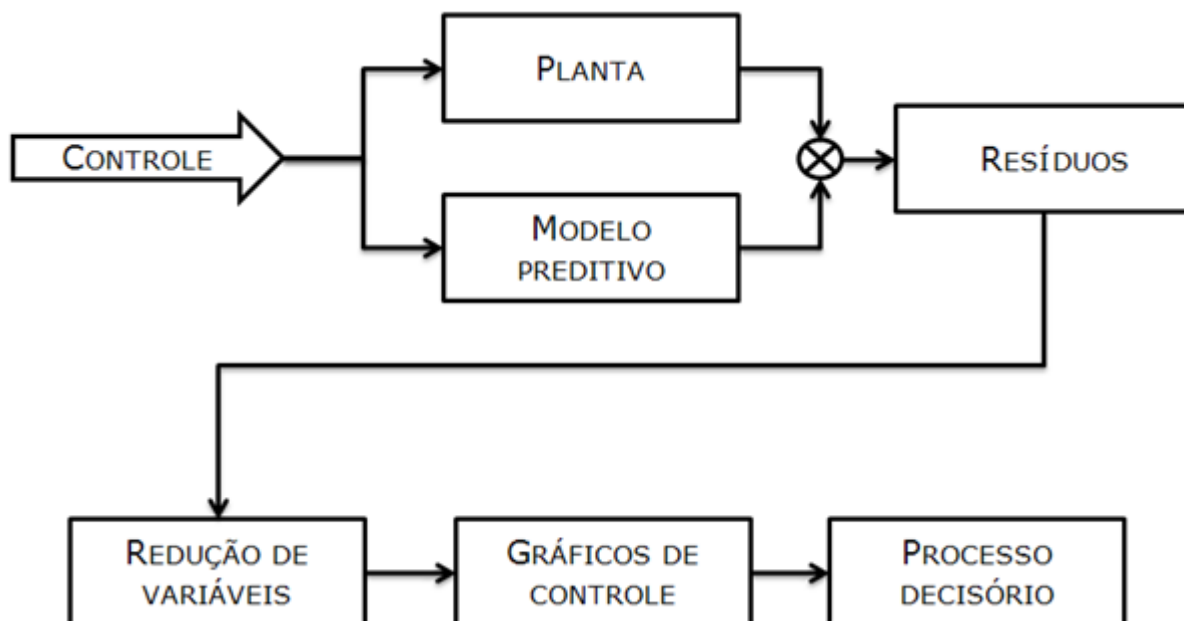
cartas de controle do CEP são excelentes ferramentas para sinalizar as condições de operação da planta.

No trabalho serão empregadas técnicas de controle estatístico da qualidade e redução de variáveis. O método permite a manipulação adequada de variáveis conjuntas e redução do número de variáveis com a menor perda de informação possível. De forma complementar, a decomposição em componentes principais - PCA (Liu e Chen, 2009) é empregada na redução de variáveis sem perda significativa de informações.

A descrição do procedimento sugerido é relativamente simples, a diferença entre os dados amostrados da planta e o modelo preditivo (resíduo) passa pelo processo de redução de variáveis (PCA) e em seguida pelo gráfico de controle para então ser processado pelo algoritmo de decisão onde o estado de funcionamento do sistema é julgado, Figura 1.

O procedimento é validado utilizando um simulador de acionamento de máquina de corrente contínua (Caminhas, 1997) que gera amostras da corrente e da velocidade do motor. A ferramenta também é usada para simular falhas. Os resultados são estabelecidos segundo critérios estatísticos: falso positivo, falso negativo e tempo necessário para detectar a falha. No contexto de detecção de falhas, os dois primeiros termos devem ser referenciados como alarme falso e falha ocorrida e não detectada, respectivamente.

Como contribuição deste trabalho, em Setembro de 2010 o artigo Controle Estatístico de Processo Aplicado à Detecção Online de Falhas em Sistemas Multivariados (Amantéa, A. Campos, 2010) foi publicado no XVIII Congresso Brasileiro de Automática CBA.



*Figura 1 Descrição do processo de detecção de falhas utilizando resíduos, redução de variáveis e gráficos de controle.*

### **1.3 Organização do Trabalho**

O primeiro capítulo dedica-se a formalizar uma pequena introdução sobre o assunto. Ele está dividido em três partes que abordam algumas considerações gerais, a proposta do trabalho e a sua prática de organização.

O segundo capítulo vem abordar os conceitos que formam a base para construção deste trabalho. Sua organização foi apresentada em três pontos: Primeiramente são apontados os aspectos principais do controle estatístico de processo, depois os princípios de Pareto e finalmente disserta sobre a idéia de redução de variáveis.

A metodologia proposta é discutida no terceiro capítulo que faz uma reflexão sobre os aspectos principais que envolvem o reconhecimento de ambientes multivariados onde se destacam a necessidade de manipulação conjunta de dados e redução de variáveis. O discurso continua salientando pontos cruciais no que diz respeito à

utilização de cartas de controle neste tipo de aplicação. Este capítulo descreve também os preceitos utilizados para validação dos resultados obtidos.

O capítulo quatro descreve em detalhes os ensaios propostos a fim de testar o sistema de detecção de falhas. Nesta ocasião a metodologia de projeto aplicada é discutida passo a passo (redução de variáveis, escolha das cartas de controle, método de detecção de falhas). Também é esclarecida a metodologia proposta (obtenção da massa de dados de treinamento e validação, modelo matemático, critérios de prova).

Finalmente os resultados são discutidos em dois casos separadamente:

- Caso 1-Redução para uma só variável e
- Caso 2-Utilização de cartas de controle multivariadas.

Cada um destes casos foi testado e os resultados obtidos discutidos no último capítulo que apresenta a conclusão deste trabalho.

## 2 REVISÃO BIBLIOGRÁFICA

Nesta seção serão apresentados os conceitos e as ferramentas estatísticas aplicadas neste trabalho. O item 2.1 discute o controle estatístico de processos, uma ferramenta há tempos estudada e empregada pelos conceitos de engenharia da qualidade. Atualmente vem ganhando importância junto ao estudo dos processos de detecção de anomalias funcionais em sistemas dinâmicos. O CEP disponibiliza facilidades para interatuar em ambientes multivariados além de prover dispositivos com acentuada capacidade de rejeição ao ruído.

Em seqüência, duas das principais ferramentas do CEP serão apresentadas. O item 2.1.1 discute as cartas de controle. Este método é utilizado para criar dispositivos de caráter gráfico ou numérico capazes de reconhecer padrões dos sinais apresentados a ele. Desta forma o sistema se torna apto a monitorar dados a fim de detectar e alertar possíveis desvios no comportamento destas informações. Estas propriedades podem ser utilizadas em sistemas de detecção de falhas. As cartas de controle simples são descritas na seção 2.1.1. Nas seções 2.1.2 e 2.1.3 as cartas de controle  $T^2$  de Hotelling e Carta de médias móveis ponderada são apresentadas, respectivamente. Os dois últimos métodos dão suporte a sistemas multivariados.

O princípio de Pareto, descrito no item 2.2, é uma ferramenta inteligente apta a modelar e organizar de forma sistêmica as relações de causa e efeito de um determinado problema de interesse. Seguindo seus critérios é possível formar uma base teórica (fundamentada em termos determinísticos), bastante oportuna quando é necessário haver tomada de decisões a respeito da relevância de diferentes características mensuráveis dentro de contexto global estudado, ou seja, um sistema multivariado.

Em geral os ambientes multivariados denotam dois problemas clássicos. Na grande maioria dos sistemas estas características

ou variáveis são dependentes entre si. Essa dependência significa que uma única causa pode gerar efeito em diversas variáveis conjuntamente. Este fato pode vir a fazer com que as ferramentas estatísticas promovam resultados inconclusivos, chegando a inviabilizar o uso destes métodos ou fazer com que fiquem muito complexos. O processamento *online* de sistemas exige que o método de análise tenha baixa complexidade computacional. Este fenômeno está diretamente relacionado às características de qualidade destes mecanismos, por exemplo, ao tempo necessário para que o algoritmo de decisão seja capaz de gerar uma resposta indicativa de falha.

Outro assunto bastante relevante, e que ainda concerne ao fato da complexidade dos algoritmos mencionada logo acima, é a relação entre o custo computacional e a quantidade de variáveis que devem ser observadas simultaneamente. Assim, o aumento do processamento e de sua morosidade varia de forma exponencial com relação ao crescimento das características estudadas. Os itens 2.3 e 2.3.1 desta seção exploram uma ferramenta com aplicações realmente interessantes neste contexto. A redução de variáveis através do método PCA (Análise das componentes principais) combinada com os princípios de Pareto consegue diminuir de forma controlada a quantidade de variáveis necessárias para obter o resultado esperado. Além disso, este método cria variáveis que estatisticamente não são classificadas como conjuntas. Desta forma as ferramentas estatísticas se tornam adequadas para trabalhar com eficácia no meio multivariado.

## **2.1 CEP: Controle Estatístico de Processo**

O processo industrial deve permanecer dentro de padrões ótimos de funcionamento para garantir as características de qualidade

necessárias para se obter um bom produto final, e possivelmente minimizar os custos do procedimento. Os mecanismos responsáveis pelos procedimentos da fabricação assim como todo o controle que envolve esta produção devem manter-se estáveis, ou seja, as características que gerenciam o desempenho final do processo devem ser replicáveis. Em outras palavras, as plantas que compõem sistemas como este podem ser compreendidas por intermédio da observação de suas características.

O procedimento mais comum para obtenção destas características é o processo conhecido como amostragem temporal, discreta no tempo e não muito raramente, discreta em amplitude. Este método consiste em capturar valores de cada característica desejada em determinados instantes de tempo formando um conjunto de dados que descrevem o comportamento daquela variável.

Admitindo um processo estável e replicável, é perfeitamente possível que através da análise do sistema em perfeito funcionamento seja estabelecido um padrão de comportamento aceitável para essas variáveis. Desta forma, lançando mão de medidas estatísticas (particularmente tem-se média, desvio padrão, variância) este conceito será estabelecido de forma sistêmica por intermédio de ferramentas do controle estatístico de processos. Mais precisamente, o processo deve ser capaz de operar com pequena variabilidade em torno das dimensões alvo ou nominais das características de qualidade do produto (Montgomery, 2004).

Quaisquer detecções de mudanças no funcionamento da planta tornam-se possível através da análise continuada (*online*) das variáveis do processo, comparando-as com os padrões ótimos de comportamento já estabelecido. Este é o objetivo principal do controle estatístico de processos. Cada vez que uma mudança importante pode ser observada em um sistema, o conjunto de ferramentas do CEP estabelece um mecanismo para alarmar de forma a chamar atenção para possíveis

falhas no processo (Isermann, 1984). Essas falhas podem ser mecânica, desgaste, defeitos gerais, falhas em sensores, etc.

O controle estatístico de processos é uma metodologia bastante interessante se seu objetivo for inspecionar as variáveis do processo quanto às características mencionadas acima. Neste capítulo serão examinadas as características de funcionamento dos gráficos de controle.

### **2.1.1 Cartas de controle**

Qualquer processo, mesmo que em seu funcionamento ótimo, ainda apresenta certa variação característica daquele processo. Este fato também é conhecido por ruído aos olhos da engenharia que geralmente idealiza-o como uma fonte de sinal aleatório com espectro de frequência contínuo e distribuição gaussiana de suas amplitudes (conhecido como ruído branco). De qualquer forma, pode-se dizer que o processo está sob controle estatístico se, e somente se, estas variações forem de natureza aleatória e estiverem contidos entre limites pré-especificados (limites de controle).

Os gráficos de controle constituem um método para monitorar as variáveis de um processo e determinar se há desvios substanciais em seus valores, o que em sua nomenclatura caracteriza um processo fora do controle estatístico. Com conhecimento prévio do processo, às vezes é possível determinar a causa das variações apontadas pela ferramenta e aplicar ações corretivas sobre o sistema, a fim de eliminar a causa e restaurar o funcionamento normal do sistema.

Em linhas gerais, o gráfico de controle, Figura 2, consiste em pontos (unidades amostrais das variáveis de controle) desenhados em um eixo cartesiano de duas dimensões, onde o eixo das ordenadas representa o tempo em sua unidade e nas abscissas são representadas a média ou variação das amostras. Existem outras duas linhas que cortam o

eixo das abscissas perpendicularmente, elas marcam os limites superiores e inferiores das amostras sob controle, ou seja, determina os valores máximos e mínimos permitidos para os dados observados de forma a considerar o sistema em funcionamento ideal. Qualquer amostra que ultrapasse estes valores deve ser considerada um alarme de mau funcionamento do sistema controlado (Lowry e Montgomery 1994).

A Figura 2 ilustra um gráfico de controle, onde a linha de cima é o limite superior de controle (LSC) enquanto a de baixo é o limite inferior de controle. Para este gráfico, diz-se que o processo está sobre controle estatístico já que nenhuma amostra ultrapassou quaisquer uns desses limites.

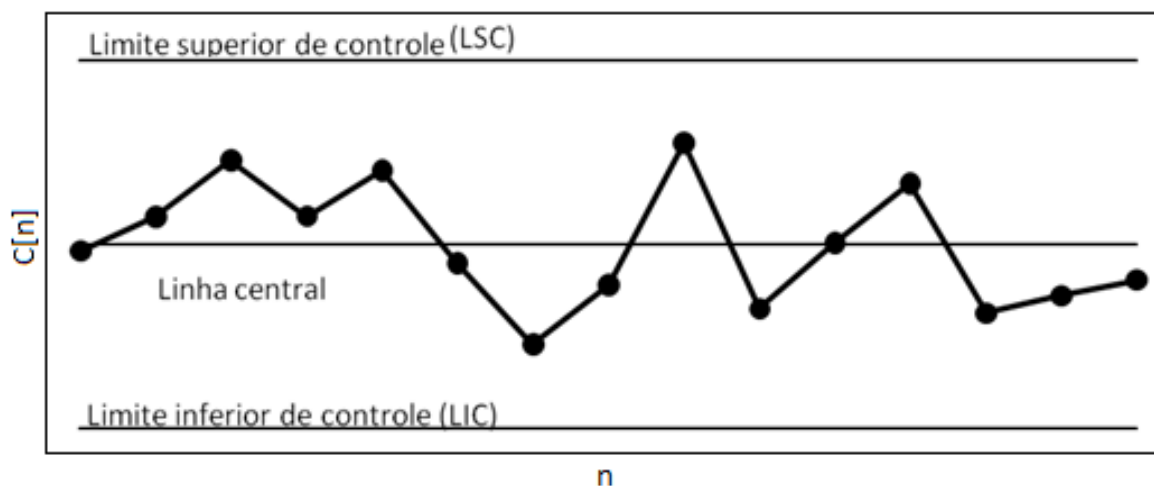


Figura 2 Gráfico de controle de um sistema que se encontra sob controle estatístico

Para as figuras Figura 2, Figura 3 e Figura 4, a variável  $n$  no eixo das abscissas contém um número seqüencial que representa o tempo amostrado com um período de amostragem  $T$  de forma que  $t = nT$ . Nas ordenas a variável  $C[n]$  representa o sinal de controle da qualidade gerado pelas cartas de controle. A escala dos valores de  $C[n]$  depende da escala do sinal analisado e também do tipo de carta de controle utilizado.

Por outro lado, a Figura 3 ilustra um sistema fora de controle estatístico. O fato pode ser claramente observado pelo alarme



provocado depois que a décima terceira amostra ultrapassa a linha de limite superior.

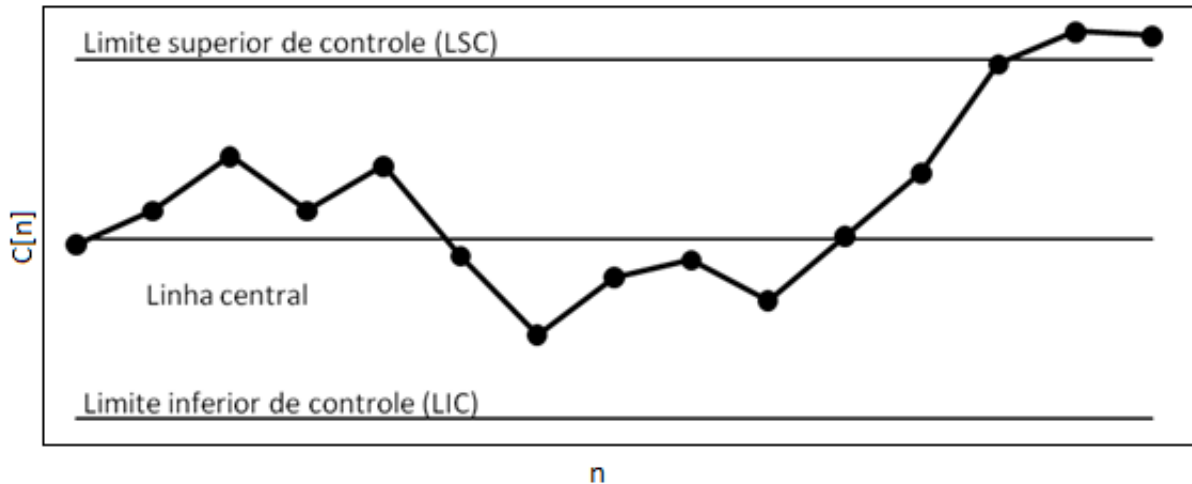


Figura 3 Gráfico de controle de um sistema que se encontra fora de controle estatístico.

A discussão do projeto destes gráficos é bastante particular para cada método escolhido. No entanto, existem quatro passos fundamentais da metodologia de construção destas ferramentas gráficas que são tomadas como base para o estudo da criação de todos os gráficos de controle.

São eles:

1. Definição das variáveis a serem monitoradas;
2. Tomar amostras do processo sobre controle estatístico;
3. Calcular os limites (LSC, LC e LIC);
4. Testar os limites obtidos.

Qualquer processo multivariado possui uma infinidade de características passíveis de monitoramento. O primeiro passo consiste em definir quais serão transformadas em variáveis para observação. Às vezes são escolhidas as variáveis mais simples ou de menor custo de medição ou ainda, se houver conhecimento profundo do processo, escolhem-se as variáveis mais pertinentes às falhas mais eminentes. Ferramentas de redução de variáveis também podem ser empregadas a fim de aperfeiçoar

esta escolha. Em seguida é necessário observar o processo em funcionamento sem falhas a fim de tomar amostras das variáveis escolhidas. Essas amostras contêm informações estatísticas do comportamento do processo e servirão de base para calcular os limites do gráfico de controle.

O cálculo desses limites é dividido em duas fases: fase um e fase dois, também conhecida como análise retrospectiva. Na primeira fase tomam-se as variáveis colhidas no passo dois e calculam-se os limites. Este é o passo três. Depois os limites são reajustados e as variáveis voltam a ser submetidas a eles em forma de um teste para verificar os limites apurados. Este é o quarto passo.

O cálculo destes limites é bastante importante, envolve conhecimento estatístico e do processo. Quaisquer erros nestes levantamentos acarretarão falhas no processo de detecção de anomalias e o gráfico não responderá conforme esperado. Seguem algumas delas:

- Lentidão no processo de detecção de falhas;
- Falso positivo;
- Falso negativo.

Se o cálculo dos limites estiver muito reduzido, isso é próximo de mais da linha central, isso fatalmente acarretará falsos positivos, ou seja, o gráfico causará alarmes em situações de normalidade de operação do processo. Por outro lado, limites muito afastados da linha central podem induzir a falsos positivos quando as amostras ainda estão dentro dos limites, neste caso não existe qualquer alarme e o sistema apresentará falhas.

Estes limites muito afastados também podem contribuir para um mau funcionamento do gráfico, pois podem atrasar a emissão do alarme para falhas incipientes. Observando a Figura 4 é possível ver o efeito do cálculo dos limites de controle, onde são colocados dois níveis diferentes de limite superior (LSC1 e LSC2). Por exemplo, o limite superior LSC2 soa o alarme de falha na décima segunda amostra, enquanto o LSC1

soa o alarme na décima terceira amostra indicando o atraso de uma amostra para detectar a falha. Em outro caso, apesar de ser mais rápido, o LSC2 acusou um falso alarme na terceira amostra. Da mesma forma, o limite inferior poderia acusar um falso positivo, ou seja, não acionar alarme para uma possível falha na sétima amostra.




Figura 4 Demonstração dos efeitos do cálculo dos limites de controle LSC1 e LSC2.

### 2.1.2 $T^2$ de Hotelling

Essa ferramenta se propõe a monitorar o sinal desejado através de suas características estatísticas, seja ela a média, variância ou amplitude das amostras coletadas do processo. Ela deriva dos gráficos X barra e R ou S (Montgomery, 2004).

Em termos de construção destes gráficos, médias, variâncias ou amplitudes, os três apresentam embasamento teórico estatístico bastante similar. Portanto, segue a demonstração do gráfico X barra que se dedica a manipular as amostras "A" discriminando-as por suas médias (Chen et al., 2003) .

Partindo do princípio de que são estabelecidos previamente a média e o desvio padrão esperados, para cada grupo de amostras a serem testadas, tem-se:

$$x = x_1, x_2, x_3, \dots, x_n \quad (1)$$

Onde  $x$  é um vetor coluna que representa as amostras de um determinado sinal que se deseja controlar. Suas características estatísticas de média e variância são respectivamente definidas pelas equações (2) e (3). Nestas equações,  $\sigma$  representa o desvio padrão da variável  $X$  e pode ser obtido através da equação (4).

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2)$$

$$\sigma_{\bar{x}} = \frac{1}{\sqrt{n-1}} \sigma \quad (3)$$

$$\sigma = \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (4)$$

Logo, se este conjunto de  $n$  amostras se comporta conforme previsto pelas suas propriedades de média e variância, a equação (5) estabelece um padrão de comportamento que define o sinal estudado do ponto de vista estatístico.

$$\bar{x} - \sigma_{\bar{x}} \leq x_n \leq \bar{x} + \sigma_{\bar{x}} \quad (5)$$

Para que este modelo seja válido durante o processo de detecção de falhas, um fator de probabilidade deve ser incorporado de tal forma que  $(1 - \alpha)$  determine a possibilidade de qualquer  $X_n$  cair entre

estes limites. Essa lei de probabilidade é calculada admitindo-se a distribuição normal das amostras, conforme Figura 4.

Por fim, segue a formulação geral para definição dos limites de controle para o gráfico. A equação (6) estabelece o intervalo de confiança de aproximação da média conforme equação (7) já que  $Z_{\alpha/2}$  representa a abscissa em uma curva normal, Figura 5, de forma que a probabilidade de uma amostra ser superior a  $Z_{\alpha/2}$  é definida por  $\frac{\alpha}{2}$ , equação (8). É bastante comum o emprego do valor  $Z_{\alpha/2} = \frac{Z_{\alpha}}{2} = 3$  conhecido por limite três sigma, o que estabelece de forma simplificada os valores de  $p$  e  $\frac{\alpha}{2}$  encontrados nas equações (6), (7) e (8).

$$\mu - Z_{\alpha/2}\sigma_{\bar{x}} \leq X_n \leq \mu + Z_{\alpha/2}\sigma_{\bar{x}} \quad (6)$$

$$p = 100(1 - \alpha) \quad (7)$$

$$p\{z \geq Z_{\alpha/2}\} = \frac{\alpha}{2} \quad (8)$$

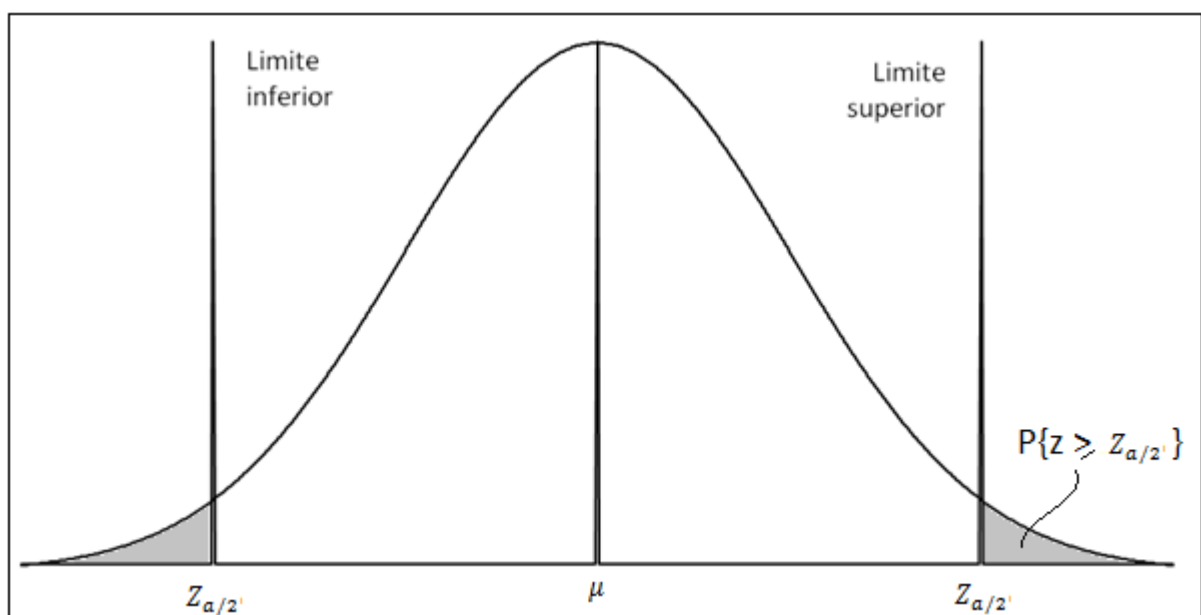


Figura 5 Curva gaussiana demonstrando os limites calculados.

Nas aplicações em que não é possível determinar os valores da média e da variância esperada, é necessária a utilização de estimadores para levantar estes dados. Toma-se então um conjunto de  $m$  amostras do sistema em funcionamento sem falhas, a fim de aplicar os estimadores.

O melhor estimador para  $\bar{x}$  é a própria média, equação (9).

$$\bar{\bar{x}} = \frac{1}{m} \sum_{n=1}^m \bar{x}_n \quad (9)$$

É conhecida a relação da amplitude relativa, equação (10), cuja média é  $d_1$  definida em função do tamanho da amostra, equação (11), onde  $R$  é a amplitude da amostra, ou seja, a diferença entre o maior e o menor valor amostrado.

$$W = \frac{R}{g} \quad (10)$$

$$\hat{\sigma} = \frac{\bar{R}}{d_2} \quad (11)$$

Por fim, o gráfico deve conter três linhas por entre as quais as amostras são desenhadas: A linha central (LC) riscada na altura de  $\bar{\bar{x}}$ , um limite superior LSC e um limite inferior LSI, conforme segue:

$$LSC = \bar{\bar{x}} + \frac{3}{d_2 \sqrt{n}} \bar{R} \quad (12)$$

$$LC = \bar{\bar{x}} \quad (13)$$

$$LIC = \bar{\bar{x}} - \frac{3}{d_2\sqrt{n}}\bar{R} \quad (14)$$

Este método pode ser modificado com intuito de transformar  $\bar{\bar{x}}$  em um vetor de  $p$  variáveis a fim de criar uma ferramenta capaz de lidar em ambientes multivariados. Essa formulação é conhecida como gráfico de controle  $T^2$  de Hotelling.

A fim de saber qual a probabilidade de que as amostras multivariadas estejam sobre controle estatístico é empregada uma ferramenta que combine as informações de média e variância de forma conjunta a todas as dimensões de cada amostra. A equação escolhida por Hotelling é conhecida por Distribuição Normal Multivariada.

A Figura 6 ilustra uma Distribuição Normal Multivariada de segunda ordem (normal bivariada) que será usada como exemplo nesta demonstração, equações (15) e (16).

$$f(x) = \frac{1}{\sqrt{(2\pi)^p |\Sigma|}} e^{-\frac{(x-\mu)' \Sigma^{-1} (x-\mu)}{2}} \quad (15)$$

$$x = \begin{bmatrix} \bar{x}_1 \\ \bar{x}_2 \\ \vdots \\ \bar{x}_p \end{bmatrix} \quad (16)$$

$$x_0^2 = n(x - \mu)' S^{-1} (x - \mu) \quad (17)$$




Figura 6 Curva gaussiana bivariada - representação multivariada.

E a expressão estatística, equação (17), é usada para criar o gráfico de controle  $T^2$  de Hotelling. Ou seja, as amostras são submetidas a essa equação e o resultado é desenhado no gráfico de controle junto com os limites estabelecidos.

O gráfico de controle  $T^2$  de Hotelling é construído de forma que o limite inferior é sempre zero, já que a expressão estatística vista na equação anterior é quadrática. As equações (18) e (19) definem os limites de controle para a primeira e segunda fase de projeto respectivamente, onde  $p$  representa o número de características de controle do sistema multivariado,  $m$  o tamanho da amostragem,  $b$  é a distribuição beta com a probabilidade  $\alpha$  e  $F$  a distribuição F com a probabilidade  $\alpha$ . Além disso, a equação (20) refere-se a uma aproximação da equação (19) normalmente utilizada quando as amostras preliminares são grandes o suficiente, por exemplo:  $m > 100$  amostras.

$$LSC_1 = \frac{(m - 1)^2}{m1} \beta_{\alpha, \frac{p}{2}, \frac{m-p-1}{2}} \quad (18)$$



$$LSC_2 = \frac{p(m+1)(m-1)}{m^2 - mp} F_{\alpha, p, m-p} \quad (19)$$

$$\widetilde{LSC}_2 = \frac{p(m-1)}{m-p} F_{\alpha, p, m-p} \quad (20)$$

### 2.1.3 MMEP - Média móvel ponderada

Esta ferramenta se dedica à construção de gráficos para analisar o comportamento de um sinal observado em função da média ou variância relacionando as amostras atuais com as do passado, isto é, este processo leva em conta a dinâmica das mudanças observadas. Todas as amostras recolhidas são acumuladas e ponderadas exponencialmente de forma que as mais recentes tenham peso maior.

O método anterior também se dedica a verificar as mesmas características do sistema, porém se preocupa com cada amostra individualmente. Essa ferramenta garante a eficiência do processo mesmo na presença de pequenas mudanças já que um erro, mesmo que pequeno é acumulado durante o tempo amostral. Desta forma tem-se um efeito de amplificação das pequenas falhas.

Na Figura 7 o sistema demonstra algum sinal de anomalia a partir da sétima amostra. Por inspeção, as próximas amostras demonstram uma tendência positiva, ou seja, estão acima da linha central e perderam o comportamento aleatório esperado. Contudo, nenhum alarme foi gerado quando utilizada a metodologia x barra, que ocorreu devido à insensibilidade que este gráfico apresenta quanto às alterações de pequena magnitude.

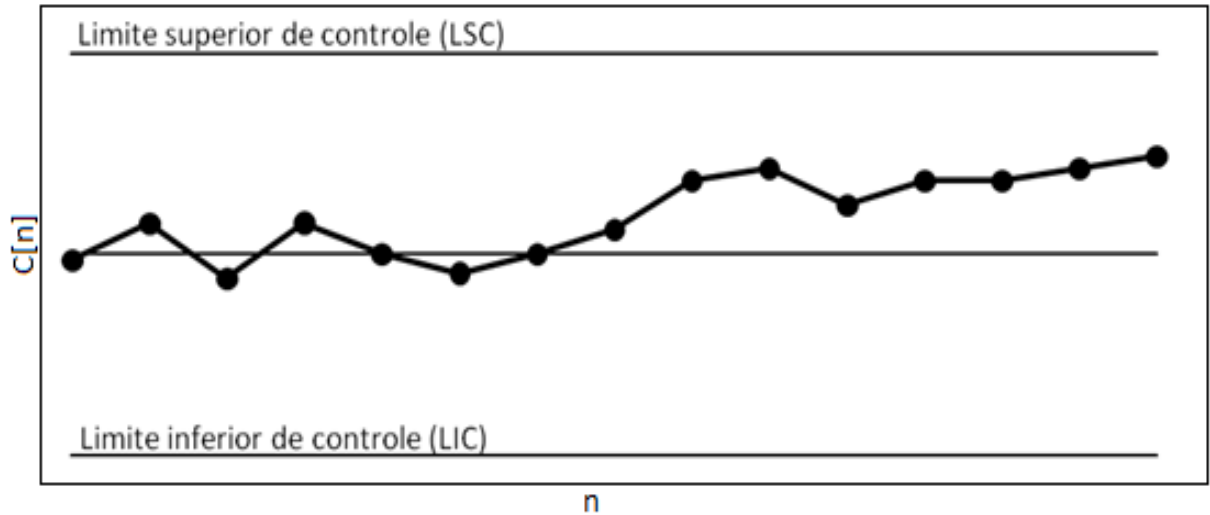


Figura 7 Gráfico de controle X-barra na presença de pequenas falhas.

Na Figura 8, os mesmos dados foram computados, porém com utilização do gráfico de controle de médias móveis exponencialmente ponderadas. Esta ferramenta se mostra mais eficaz para este caso, e gera alarme por volta da décima amostra. Observe que este gráfico não é insensível a pequenas magnitudes, mas provoca um atraso de três tempos amostrais para gerar o alarme.




Figura 8 Gráfico de controle MMEP na presença de pequenas falhas.

Para as figuras Figura 7, Figura 8, Figura 9, Figura 10 e Figura 11, no eixo das abscissas a variável  $n$  que representa o tempo amostral. Nas ordenas a variável  $C[n]$  representa o sinal de controle da qualidade gerado pela carta de controle aplicada. A escala dos valores de

$C[n]$  depende da escala do sinal analisado e também do tipo de carta de controle utilizado.




Figura 9 Gráfico de controle  $x$ -barra na presença de ruído.




Figura 10 Gráfico de controle MMEP na presença de ruído.

Por outro lado, muitas vezes aparecem amostras isoladas com características de falha, ou seja, fora dos limites de controle. Uma vez que são isoladas, e se todas as outras amostras ao redor demonstram ter comportamento adequado, este ponto causaria um provável alarme falso. Mais uma vez a análise conjunta dos dados pode amenizar este efeito de forma considerável. Veja o exemplo ilustrado pelas Figura 9 e Figura 10.

O décimo segundo ponto que aparece fora dos limites de controle na Figura 9 é considerado falha, e, portanto gera alarme quando observado o gráfico  $x$  barra. Inspeccionando os outros pontos é fácil

perceber que o sistema está funcionando sem falhas. A conclusão mais óbvia é que existe algum problema com esta amostra em questão.

De fato, o deslocamento desta amostra pode ter sido provocado por falha nos sensores ou ruído de alguma fonte externa. A Figura 10 mostra o comportamento do gráfico MMEP diante desta situação. Este tipo de gráfico se mostra robusto a este problema.

Vale apenas ressaltar que de forma intermediária nas ferramentas  $T^2$  e MMEP existe a idéia do gráfico de controle de soma cumulativa, (CUSUM). Este método também se propõe a acumular as amostras com a diferença que não há qualquer forma de ponderação entre as amostras mais atuais e as mais antigas, ou seja, todas as amostras têm o mesmo peso. Como será demonstrado ao longo do texto, o MMEP possui variáveis de controle que o CUSUM não tem. Em suas equações existem alguns ajustes cuja escolha dos valores pode alterar a dinâmica do funcionamento do gráfico. Segue um exemplo para demonstrar este efeito.

É fácil perceber que a alteração da variável *lambda* afeta diretamente a forma com que o gráfico trata os dados. A discussão sobre este parâmetro será detalhada mais adiante, mas é possível perceber por análise da Figura 11 que os valores maiores de *lambda* aceleram a detecção da falha. Veja que para *lambda* igual a 0.3, o alarme aconteceu já na nona amostra enquanto que para *lambda* igual a 0.001 isso ocorreu da décima segunda amostra.

É claro que valores muito elevados de *lambda* são excelentes para detectar falhas rapidamente, e promove excelente desempenho na presença de pequenas falhas, mas deixa o gráfico menos robusto a presença de ruído ou interferências.




Figura 11 Gráfico MMEP com lambda 0.3 (curva pontilhada superior), 0.1 e 0.001.

Em linhas gerais, essa dinâmica de comportamento gira em torno de dois pontos principais: a velocidade de detecção de uma anomalia no sinal observado e a rejeição de ruído intrínseco ao sistema. A escolha dos parâmetros de funcionamento do MMEP deve ser feita em função de uma decisão de compromisso entre esses dois fatores.

A equação (21) descreve uma formula para o cálculo do gráfico de médias móveis exponencialmente ponderadas enquanto a equação (22) sua forma recursiva. Nestas equações,  $x$  representa um vetor que contém as amostras de interesse,  $Z$  é a característica de controle da qualidade calculada pelo gráfico de controle e  $\lambda$  é uma constante que controla a dinâmica do funcionamento da carta MMEP.

$$Z_i = \lambda \sum_{j=0}^{i-1} (1 - \lambda)^j x_{i-j} + (1 - \lambda)^i z_0 \quad (21)$$

$$Z_i = \lambda x_i + (1 - \lambda) Z_{i-1} \quad (22)$$

O parâmetro lambda que aparece na equação acima deve ser calculado como resultado do planejamento do gráfico de controle. Este parâmetro deve estar contido no intervalo de zero até um, e quanto mais próximo de zero estiver, menor a capacidade de detectar pequenas mudanças, e menor a velocidade de resposta aos sinais do sistema. No entanto, quanto menor o valor escolhido para este parâmetro, maior será a robustez ao ruído apresentada pelo gráfico projetado.

Os valores que compreende o intervalo  $0.005 \leq \lambda \leq 0.25$  se mostram eficientes e funcionam bem na prática. Os valores  $\lambda = 0.05$ ,  $\lambda = 0.10$  e  $\lambda = 0.20$  são as escolhas mais populares (Montgomery, 2004).

Estes parâmetros também podem ser determinados com o auxílio de gráficos ou tabelas. O valor ótimo deve ser encontrado em função de um desempenho do CMS desejado e da amplitude média das amostras sobre controle e fora de controle (Montgomery, 2004). Veja tabela abaixo:

*Tabela 1 Comprimento médio de seqüência para vários esquemas de controle MMEP*

Mudança na média ( $\times \sigma$ )	L=	3.054	2.998	2.962	2.814	2.615
	$\lambda=$	0.400	0.250	0.200	0.100	0.050
0.00		500.0	500.0	500.0	500.0	500.0
0.25		224.0	170.0	150.0	106.0	084.1
0.50		071.2	048.2	041.8	031.3	028.8
0.75		028.4	020.1	018.2	015.9	016.4
1.00		014.3	011.1	010.5	010.3	011.4
1.50		005.9	005.5	005.5	006.1	007.1
2.00		003.5	003.6	003.7	004.4	005.2
2.50		002.5	002.7	002.9	003.4	004.2
3.00		002.0	002.3	002.4	002.9	003.5
4.00		001.4	001.7	001.9	002.2	002.7

*(Retirado do livro Introdução ao controle Estatístico de Douglas C. Montgomery)*

Os limites de controle para o gráfico MMEP são dados pelas equações (23) e (24) onde  $\mu_0$  representa a média amostral esperada,  $\sigma$  o desvio padrão da amostra, L a amplitude da margem de confiança adotada e  $\lambda$  o parâmetro de controle do gráfico MMEP.

$$LSC = \mu_0 + L\sigma \sqrt{\frac{\lambda}{2-\lambda} [1 - (1-\lambda)^{2i}]} \quad (23)$$

$$LIC = \mu_0 - L\sigma \sqrt{\frac{\lambda}{2-\lambda} [1 - (1-\lambda)^{2i}]} \quad (24)$$

Estes limites variam com a evolução das amostras de forma regida pelo parâmetro  $i$ . Essa variação exponencial se estabiliza com o passar do tempo de tal maneira que a curva descrita pelas equações (23) e (24) podem ser simplificadas e representadas pelas retas, equações (25) e (26).

$$LSC = \mu_0 + L\sigma \sqrt{\frac{\lambda}{2-\lambda}} \quad (25)$$

$$LIC = \mu_0 - L\sigma \sqrt{\frac{\lambda}{2-\lambda}} \quad (26)$$

Para completar o projeto deste gráfico ainda falta o cálculo do parâmetro  $L$  que aparece nas equações dos limites. Este parâmetro é comumente definido como  $L = 3$  conforme os limites três sigma usuais. Para obter o controle de processos multivariados foram desenvolvidas novas equações (Lowry e Montgomery, 1994).

$$Z_i = \lambda x_i + (1-\lambda)Z_{i-1} \quad (27)$$

$$T_i^2 = Z_i' \Sigma_{Z_i}^{-1} Z_i \quad (28)$$

Onde a variável  $X_i$  é um vetor coluna com o conjunto de sinais de cada amostra e sigma, equação (29), representa a matriz de covariância destes mesmos sinais.

$$\Sigma_{zi} = \frac{\lambda}{2 - \lambda} [1 - (1 - \lambda)^{2i}] \Sigma \quad (29)$$

## 2.2 Princípio de Pareto

O diagrama de Pareto é uma ferramenta estatística largamente utilizada para solução de problemas de engenharia da qualidade. Consiste em uma metodologia capaz de elencar um ranque de tarefas de forma a especificar qual a relevância de cada uma para a solução do problema proposto. Este método tem como premissa a regra **80/20**, ou seja, ao fazer vinte por cento do trabalho já se obtém aproximadamente oitenta por cento dos benefícios do trabalho concluído. Esta visão deu a Pareto a idéia de desenvolver um recurso gráfico para estabelecer esta relação, o que é chamado de diagrama de Pareto.

No ponto de vista da qualidade, esta idéia pode ser estendida para causas de perdas que devem ser eliminadas, ou seja, procurar uma relação clara de ação versus benefício de forma a priorizar as ações que resultem de forma mais rápida e eficaz no objetivo estudado. Para um exemplo, imaginem um almoxarifado escolar onde ha necessidade de comprar novos materiais cuja lista de itens faltantes está organizada na Tabela 2. Segue um exemplo passo a passo para criar um diagrama de Pareto para esta situação:

1. Montar uma lista identificando todas as causas do problema pesquisado e determinar a freqüência com que cada uma delas aparece no problema;



*Tabela 2 Dados para demonstração do gráfico de Pareto*

<b>Material</b>	<b>Necessidade mensal</b>
Falta lápis	245
Falta caneta	502
Falta borracha	54
Falta apontador	28
Falta régua	30
Falta grampo	229

2. Organizar estes itens por ordem decrescente de frequência, a causa mais importante (de maior frequência) deve aparecer no topo da lista;

*Tabela 3 Normalização dos dados segundo Pareto*

<b>Material</b>	<b>Necessidade mensal</b>
Falta caneta	502
Falta lápis	245
Falta grampo	229
Falta borracha	54
Falta régua	30
Falta apontador	28

3. Adicionar mais duas colunas nesta tabela calculando agora a porcentagem acumulada:

*Tabela 4 Cálculo das frequências e frequências acumuladas*

<b>Material</b>	<b>Necessidade mensal</b>	<b>Percentual</b>	<b>Percentual acumulado</b>
Falta caneta	502	46.14	046.14
Falta lápis	245	22.52	068.66
Faltam grampos	229	21.05	089.71
Falta borracha	54	04.96	094.67
Falta régua	30	02.76	097.43
Falta apontador	28	02.57	100.00

- Desenhar em um plano cartesiano as causas no eixo X e as porcentagens acumuladas no eixo Y, e junte os pontos com uma linha para obter uma curva;




Figura 12 Gráfico de Pareto com porcentagens acumuladas.

- No mesmo gráfico acrescente barras determinando as causas no eixo x, no eixo y às frequências simples de cada causa;

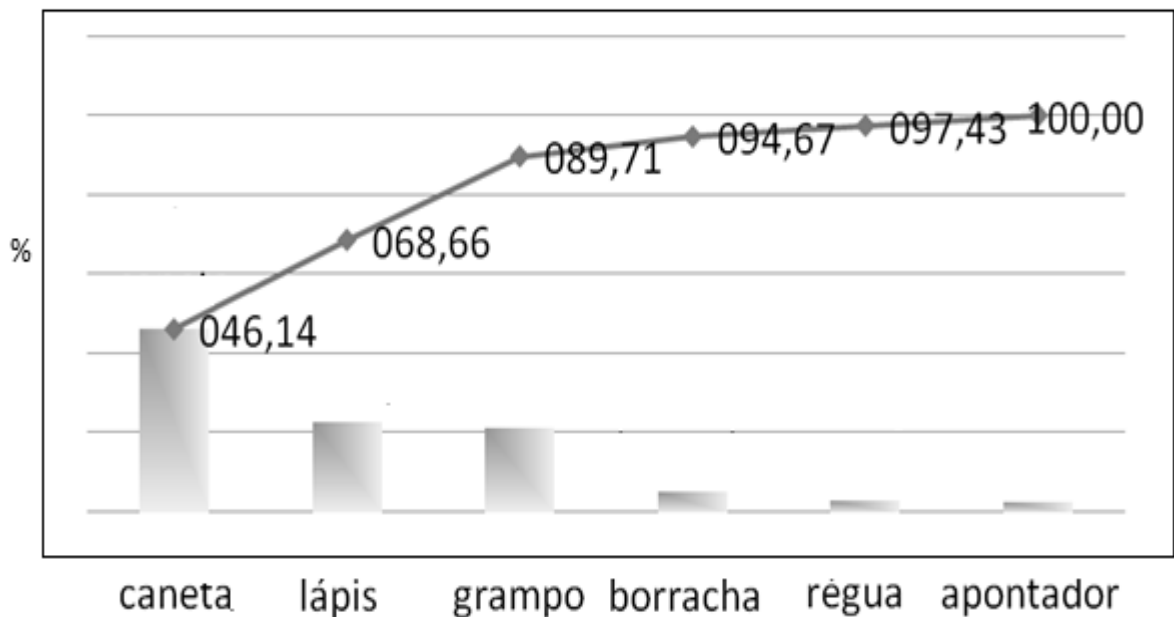


Figura 13 Gráfico de Pareto com distribuição do problema.

6. Desenhe ainda uma linha paralela ao eixo y e de forma a interceptar a curva proposta no segundo passo onde ela alcança o valor de oitenta por cento. (Segundo o principio de Pareto, esta linha separa as causas mais importes a sua esquerda).

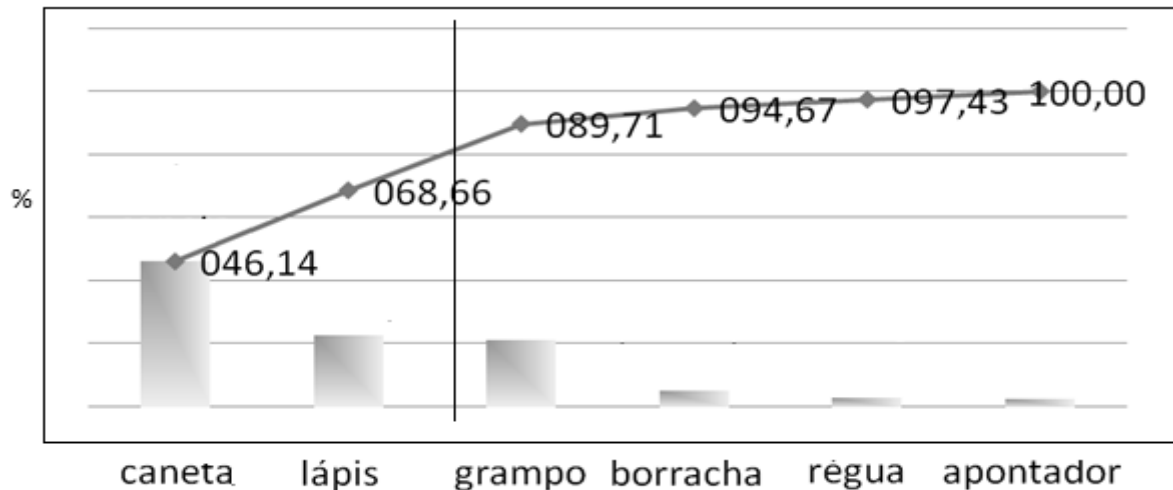


Figura 14 Gráfico de Pareto com a regra 80/20.

É fácil observar que são poucas as causas que realmente importam para avaliar as situações em questão. O Pareto determina um número, vinte por cento, que pode ser empregado em grande parte das situações encontradas no dia a dia. Esta ferramenta é uma formulação estatística bastante simples e capaz de estabelecer estas relações.

### 2.3 Reduções de Variáveis

Se não forem todos os sistemas, a grande maioria deles tem caráter multivariado. Muitas características (variáveis) diferentes entram em cena na complexidade de seus funcionamentos. Isso é verdade, mas também é possível reduzir a complexidade destes sistemas reduzindo as variáveis observadas e obtendo um modelo aproximado.

Se há interesse em estudar parte do processo, essa redução de variáveis não vai gerar erro no modelo. Para isso basta encontrar as variáveis que estão mais relacionadas ao fato estudado e desprezar as outras menos importantes.

Nesta parte do texto serão descritas ferramentas para estes propósitos. A análise das componentes principais é capaz de nos mostrar quais as principais variáveis do processo atribuindo um peso para cada uma delas. Não raramente este processo aponta componentes de relevância quase insignificante para a análise proposta.

Vale à pena lembrar que o PCA analisa somente as variáveis de saída do processo, sem se preocupar com a correlação entre os dados de saída e os de entrada, que atuam no sistema.

### **2.3.1 Análise das Componentes Principais**

A análise das componentes principais é uma ferramenta estatística para processos multivariados que analisa a quantidade de informação das variáveis em termos de sua variância. Existem outras terminológicas para este mesmo princípio: Transformada de Karhunen-Loève (KLT), transformada de Hotelling ou decomposição ortogonal própria (POD) (Shlens, 2009).

Este método é bastante aplicado no ramo de qualidade e também de engenharia. Quando há a necessidade de estudar um sistema pouco conhecido (caixa preta), a forma mais comum de inferir seu comportamento é estabelecer uma relação entre suas características observáveis. No entanto, pouco se sabe sobre como estas características influenciam realmente o sistema, ou seja: Quais destas características são redundantes? Quais as que melhor explicam o funcionamento do sistema? Existe alguma que não faz parte do mecanismo estudado?

A análise proposta pelo PCA vem nos prover estas respostas. De maneira geral, cada característica é atribuída a um eixo do plano cartesiano e passa a ser chamada de variável. O processo de análise consiste em fazer uma rotação dos eixos cartesianos de tal forma que no espaço do PCA as componentes podem ser elencadas segundo sua importância para descrição do processo em estudo (Lui e Chen, 2009).

No espaço do PCA, as variáveis do sistema passam a ser conhecidas por componentes principais. Desta forma, a primeira componente principal carrega a maior parte da informação dos dados e, portanto, é a de maior importância para explicação do sistema. As demais componentes carregam o restante da variação com grau de importância cada vez menor (Shlens, 2009).

Este resultado é de suma importância quando o sistema é definido multivariado. Considerando o fato de que nem todas as componentes principais têm a mesma importância, algumas delas podem ser desprezadas segundo algum critério de relevância (comumente usado o critério de Pareto) sem perda significativa na descrição do processo.

A possibilidade de redução de variáveis é foco principal da aplicação do PCA já que diminui a complexidade do problema e ainda elimina as variáveis redundantes ou que contribuem pouco para a definição do problema. Também é interessante lembrar que o conjunto de componentes principais é descorrelacionado, o que possibilita a aplicação de outras técnicas estatísticas, como por exemplo, os gráficos do controle estatístico de processos (Shlens, 2009).

Segue o método de cálculo do PCA passo a passo:

1. Organizar os dados em uma matriz  $Q$  onde cada coluna deve ser preenchida com uma das variáveis observadas;
2. Subtrair a média e normalizar quanto à variância. Em alguns casos as variáveis podem ser derivadas de diferentes unidades de medida ou

apresentar assimetria em relação à média. Este procedimento torna os dados adimensionais, com média nula e variância unitária;

$$x_{ij} = \frac{1}{\sqrt{n}} \frac{(q_{ij} - \bar{q}_j)}{S_j} \quad (30)$$

Onde a matriz  $X$  corresponde a  $Q$  modificada,  $n$  é o tamanho da amostra e  $S$  é o desvio padrão de cada variável  $j$ . Vale à pena lembrar que os valores de  $n$  e  $S$  devem ser armazenados caso haja a necessidade de recuperar os dados após o processamento.

3. Calcular a matriz de correlação  $R$ ;

$$R = \begin{bmatrix} cov(x_1, x_1) & cov(x_1, x_2) & \dots & cov(x_1, x_n) \\ cov(x_2, x_1) & cov(x_2, x_2) & & cov(x_2, x_n) \\ \vdots & & \ddots & \\ cov(x_n, x_1) & cov(x_n, x_2) & & cov(x_n, x_n) \end{bmatrix} \quad (31)$$

$$cov(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n - 1} \quad (32)$$

4. Estabelecer os autovalores e autovetores da matriz  $R$  de covariância;

$$[r, s, q] = svd(R) \quad (33)$$

Onde  $s$  é a matriz que contém os valores singulares em sua diagonal principal, e a matriz  $r$  apresenta em suas colunas os autovetores da matriz  $R$  (Chen, 1999).

Para demonstrar melhor os efeitos da transformação para o espaço de componentes principais segue um exemplo. A Figura 15 ilustra

o conjunto de dados contendo mil pontos gerados pela sobreposição de ruído gaussiano branco a uma equação de reta, que utilizado neste estudo.




Figura 15 Uma reta somada ao ruído gaussiano branco para estudo da metodologia do PCA.

Conforme descrito nos passos citados acima, os autovalores calculados formam uma base para definir o grau de importância de cada componente criada no espaço PCA. Os valores obtidos são:

$$L = \begin{bmatrix} 1.9845 \\ 0.0155 \end{bmatrix} \quad (34)$$

Para discutir este resultado uma boa escolha seria a utilização da ferramenta desenvolvida por Pareto (2.2.2). No entanto, neste caso, a primeira componente é muito maior do que a segunda e por isso estudos mais detalhados podem ser dispensados.

Os autovetores formam uma matriz de rotação capaz de descrever os dados transformados para o espaço PCA. Desta forma eles apontam as direções das componentes principais, conforme representado na Figura 16:




Figura 16 Autovetores projetados sobre os dados processados.

Se o objetivo for utilizar o PCA para conseguir redução de variáveis, em geral trabalha-se com os dados no espaço do PCA manipulando apenas as variáveis de interesse, depois recupera os dados originais. As equações para este fim estão descritas abaixo:

$$X = xr' \quad (35)$$

$$x = Xr'^{-1} \quad (36)$$

## 2.4 Conclusões

Este capítulo discute as ferramentas que serão utilizadas com intuito de suprir as necessidades de manipular sistemas dinâmicos com comportamento multivariado. De forma geral, esta situação obriga os projetistas a lidar com duas particularidades bem definidas. Uma vez escolhida uma abordagem estatística para tratar o problema, é inevitável que apareça a necessidade de criar mecanismos capazes de processar



todas as características do sistema de forma correlacionada. Por outro lado, o número de variáveis relacionadas a um determinado evento na maioria das vezes se mostra bastante expressivo o que exige o emprego de mecanismos de redução de variáveis.

A fim de resolver o problema da redução de variáveis será proposto um procedimento que combina a técnica do PCA com as idéias de Pareto. Este capítulo apresentou a modelagem matemática necessária para realizar esta solução. Da mesma forma, foram apresentadas as técnicas  $T^2$  *Hoteling* e as cartas MMEPM uma vez que podem tratar de forma eficiente a análise conjunta de variáveis.

A complexidade computacional dos processamentos propostos neste capítulo é baixa o suficiente para criar procedimentos que vão funcionar de forma *online* conforme é exigido na proposta deste estudo. Ademais, quaisquer umas dessas formulações podem ser manipuladas utilizando o sistema *Matlb* ou qualquer outra linguagem computacional.

### **3 METODOLOGIA PROPOSTA**

Este capítulo expõe os conceitos e métodos propostos pelo trabalho a fim de alcançar bons resultados para detectar falhas em ambientes multivariados. Conforme salientado na introdução, o processamento de dados multivariados requer alguns cuidados adicionais quanto à necessidade de avaliação conjunta dos dados. A seção 3.1 apresenta um estudo sobre ambientes multivariados ressaltando os principais pontos a serem observados por sistemas que vão manipular informações desta natureza. Com este mesmo intuito, algumas ferramentas serão apresentadas de forma conceitual e aplicadas ao projeto de detecção de falhas. Assim, será apresentada a forma com que será tratada a análise de variáveis conjuntas e a redução de variáveis como forma de diminuir a complexidade computacional dos sistemas criados (Hines et al., 2006).

A fim de definir um modelo teórico para testar os processos e ferramentas empregados neste projeto a seção 0 discute um simulador de máquina de corrente contínua que será o responsável por representar um ambiente multivariado criando amostras que descrevem seu funcionamento. Essas amostras podem ser obtidas para o sistema em perfeito funcionamento ou podem também representar falhas conhecidas nas situações de funcionamento.

O processamento estatístico através do CEP disponibiliza uma grande quantidade de ferramentas aptas a analisar os sinais de interesse. A seção 3.3 propõe estudos para entender as particularidades de cada um desses métodos a fim de obter uma norma técnica capaz de decidir pela melhor opção de acordo com as características do ambiente em que vão ser aplicados (Bersimis et al., 2007).

### 3.1 Trabalhando em ambientes multivariados

Em sistemas de controle de uma planta industrial, ou de quaisquer outros processos, é bem provável que haja a necessidade de reconhecer, controlar e observar vários de seus atributos e, se for de interesse, entender e atuar em seu funcionamento. É dentro deste contexto que aparece o conceito de sistemas multivariados, onde para cada atributo a ser estudado, uma variável é criada construindo um modelo complexo que engloba todas as suas características de uma só vez. De maneira geral, as diversas variáveis que compõem tal modelo não são independentes entre si.

Com o objetivo de idealizar um mecanismo para acompanhar o funcionamento destes sistemas é comum trabalhar em dois problemas principais: Encontrar um modelo capaz de reproduzir a dinâmica do sistema; e depois, criar um mecanismo de análise do resíduo (erro) gerado pela comparação da planta e do modelo. A Figura 17 ilustra um modelo geral que será discutido com mais detalhes ao longo do trabalho.

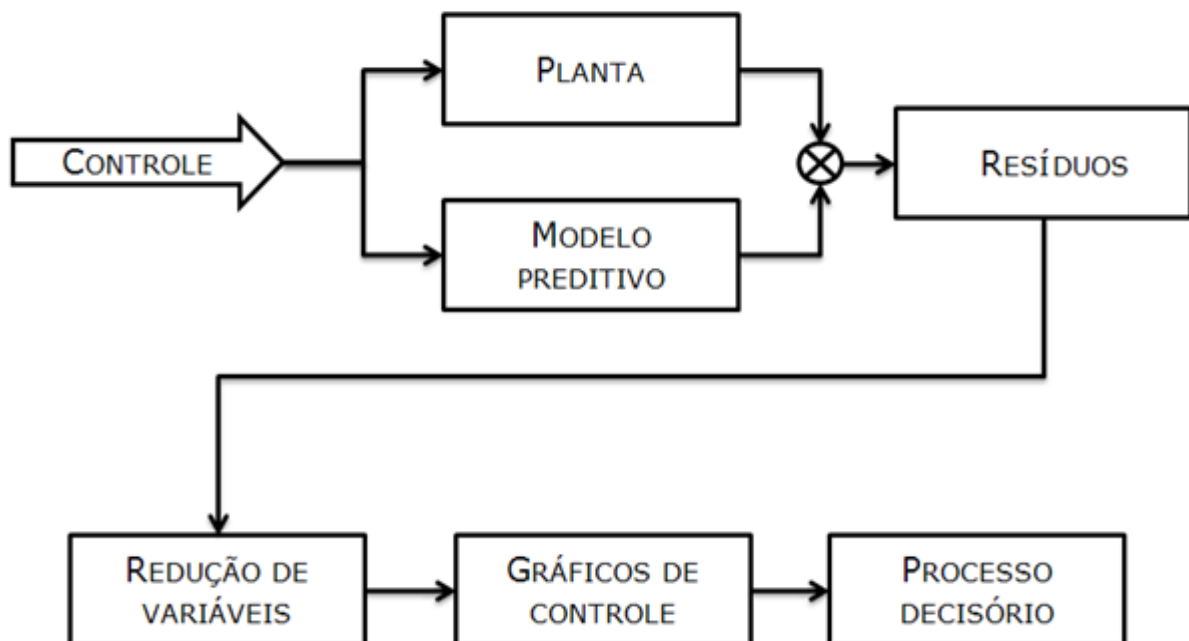


Figura 17 Processo de detecção de falhas.

Os modelos conhecidos na literatura estão aptos a manipular sistemas com este perfil (Aguirre, 2007). A ver, as representações em espaço de estados, os modelos auto-regressivos, as soluções em inteligência computacional, entre outros tantos. De qualquer maneira, a preocupação é maior com a análise gráfica e/ou lógica das variáveis de interesse, o que de fato constitui o foco desta dissertação. Portanto, a proposta para este trabalho gira em torno da discussão de ferramentas capazes de fazer análises conjuntas das variáveis produzidas por aqueles modelos. Sendo assim, se relacionam com os quadros de redução de variáveis e gráficos de controle da Figura 17.

As figuras Figura 18, Figura 19, Figura 20 e Figura 21 ilustram com mais detalhes o problema de reconhecimento de falhas em sistemas multivariados. Nessas figuras os traços sólidos representam os limites calculados por ferramentas de análise não especializadas em ambientes multivariados, ou seja, são definidos limites manipulando cada variável isoladamente.

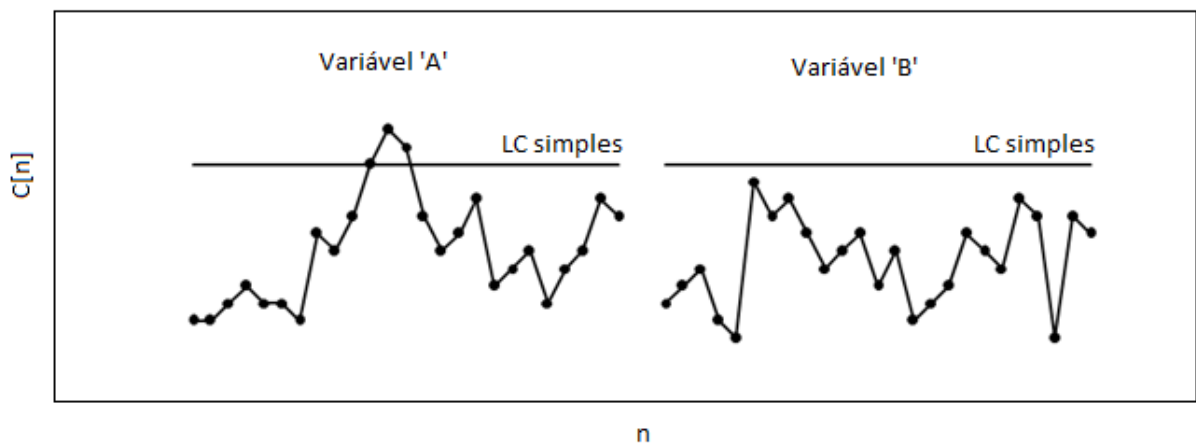


Figura 18 Representação de um sistema multivariado operando sem falhas, mas gera um alarme falso se tratado inadequadamente.

Por outro lado as figuras Figura 18 e Figura 19 contam com traços pontilhados que foram determinados pela análise conjunta entre as variáveis 'A' e 'B'.

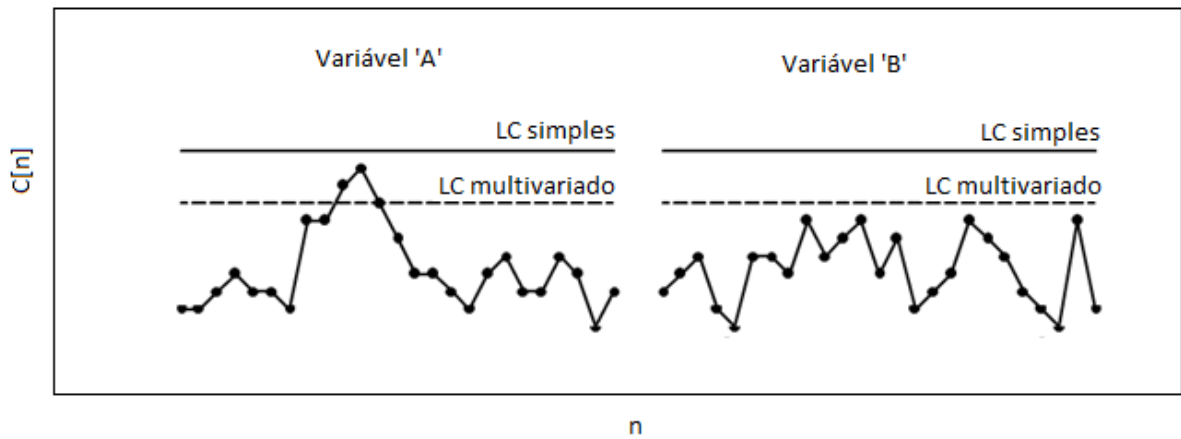


Figura 19 Representação de um sistema multivariado operando sem falhas, mas não gera falha já que suas variáveis são tratadas conjuntamente.

Note que na Figura 18, a variável 'A' ultrapassou a linha pontilhada, ou seja, segunda a concepção anterior deveria soar um alarme. Este não é o caso, as ferramentas multivariadas determinam a condição para detecção de novidade somente se ambas as variáveis atingem a linha pontilhada (Figura 20), ou se uma das variáveis passa do limite estabelecido pela linha cheia (Figura 21).




Figura 20 Representação de um sistema multivariado operando com falha conjunta detectada adequadamente.




Figura 21 Representação de um sistema multivariado operando com falha simples detectada adequadamente.

### 3.1.1 Análise Conjunta das Variáveis

Possivelmente, a ferramenta mais utilizada e mais citada na literatura é conhecida pela sigla CEP, que significa controle estatístico de processo. Essa ferramenta se propõe a analisar a qualidade da operação de um processo através de dados amostrados do sistema que sejam pertinentes à característica que se deseja controlar. No caso de detecção de falhas, essa informação é colhida por sensores instalados nos sistemas de interesse das plantas industriais.

As cartas de controle estabelecem uma metodologia para classificar estes sinais, e para definir, em seus critérios, se está sob controle ou não. O que se traduz em operação normal (o sistema esta sob controle estatístico) ou falha (o sistema esta fora de controle estatístico).

Falando de forma genérica, essas ferramentas se baseiam na média e variância das variáveis do processo as quais há interesse em controlar. Estabelecem um modelo para coleta das amostras, métodos para determinar os intervalos de confiança, e ferramentas para análise gráfica do funcionamento do sistema. A seguir são citadas algumas ferramentas estatísticas bastante conhecidas:

- XR e XS – gráficos de controle de médias;
- CUSUM – gráficos de controle de soma cumulativa;

- MMEP – gráficos de controle de média móvel;
- $T^2$  – gráficos de controle  $T^2$  de *Hotelling*;
- MMEPM – gráfico de controle de média móvel multivariado.

Para entender um pouco melhor o processo de análise conjunta de variáveis foi gerado um conjunto de dados com distribuição conjunta e com um ponto de falha, Figura 22 e Figura 23.




Figura 22 Elipse de controle para duas variáveis independentes

Na primeira figura, utilizou-se uma carta de controle convencional, na outra uma carta de controle multivariada. A parte

interna das elipses desenhadas nestas figuras representa os pontos considerados sob controle estatístico. Note que o método multivariado foi capaz de identificar um ponto fora de controle, Figura 23.




Figura 23 Elipse de controle para duas variáveis dependentes

A elipse mostra que quanto maior for o deslocamento com relação à média de qualquer das variáveis, maior a probabilidade de soar o alarme de falha. De qualquer forma, se ambas as variáveis crescem



juntas uma anomalia será detectada mesmo para valores inferiores aos que disparariam alarmes se uma só tivesse alterado seus atributos.

### **3.1.2 Diminuindo a complexidade**

Alguns sistemas podem apresentar inúmeras variáveis de saída para serem analisadas. Este quadro tornaria qualquer dessas técnicas bastante complicada e com alto custo computacional. É por este motivo que técnicas capazes de reduzir o número de variáveis a serem estudadas são bem vindas. As ferramentas mais conhecidas são:

PLS – Mínimos quadrados parciais;

PCA – Decomposição em componentes principais.

O método dos mínimos quadrados parciais atua diretamente no modelo, estimando uma estrutura reduzida em termos de regressores, mas que ainda é capaz de explicar a dinâmica do sistema com alto grau de fidelidade. A decomposição em componentes principais projeta as variáveis nos eixos que explicam a maior parte da variância das variáveis, onde se torna possível elencar as variáveis mais importantes para o processo.

Qualquer redução de variáveis implica em perda de informação do sistema e em possível redução de ordem do seu modelo. Por outro lado torna o modelo menos complexo. Esta relação de custo e benefício deve ser bem observada. O problema da escolha das variáveis para descarte não é trivial e deverá ser discutido a fundo neste trabalho, pois ela depende o desempenho de todo o processo.

### 3.2 Simulador da uma Máquina CC

Para dar seqüência a este trabalho, e a fim de obter uma metodologia para testar cada algoritmo apresentado, é necessário a obtenção de uma massa de dados conhecidos e submetê-la ao sistema. Neste primeiro momento, a utilização de uma fonte de dados conhecida e controlável é mais interessante se há interesse em verificar o funcionamento dos códigos.

Com este propósito, esta seção apresenta um algoritmo que funciona como um simulador de uma máquina de corrente contínua (Caminhas, 1997). Este mecanismo é utilizado largamente em ambientes industriais e também é clara a sua natureza multivariada além de ser um dispositivo não linear, o que tornam os testes mais realistas.

Essa ferramenta representará um sistema dinâmico não linear e de funcionamento conhecido, ou seja, serão gerados dados suficientemente complexos para excitar os algoritmos propostos. Além disso, este simulador não gera somente dados do sistema em funcionamento normal como também é capaz de apresentar falhas de acordo com as necessidades de teste. Com este mecanismo será criada uma massa de dados com informações suficientes para treinar os algoritmos detectores de falhas com dados que contenha informação do funcionamento normal da máquina e depois testar estes mesmos algoritmos com dados que contenha informações de falhas. Segue a Figura 24 com o esquema de uma máquina de corrente contínua conforme modelada.




Figura 24 Diagrama em bloco do modelo construído da MCC

Onde as entradas são representas pelas variáveis:

- $\mathbf{V}_{fd}$  Tensão do circuito de campo;
- $\mathbf{V}_a$  Tensão do circuito de armadura.

E as saídas:

- $\mathbf{i}_{fd}$  Corrente do circuito de campo;
- $\mathbf{i}_a$  Corrente do circuito de armadura;
- $\mathbf{\Omega}_r$  Velocidade mecânica de rotação.

### 3.2.1 Formalismo matemático

A equação geral para este modelo fica:

$$\begin{bmatrix} x_1(k+1) \\ x_2(k+1) \\ x_3(k+1) \end{bmatrix} = \begin{bmatrix} k_{aa}a_1 & k_{aa}a_1(k) & 0 \\ 0 & k_{af}a_3 & 0 \\ a_4(k) & 0 & a_5 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix} \quad (37)$$

$$+ \begin{bmatrix} b_1 & 0 \\ 0 & b_2 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} k_{aa}\bar{k}_{cca}V_a(k) \\ k_{af}\bar{k}_{ccfd}V_{fd}(k) \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ d_1 \end{bmatrix} [T_L(k)]$$

$$\begin{bmatrix} y_1(k) \\ y_2(k) \\ y_3(k) \end{bmatrix} = \begin{bmatrix} \bar{k}_{ia} & 0 & 0 \\ 0 & \bar{k}_{ifd} & 0 \\ 0 & 0 & \bar{k}_{Wr} \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix} \quad (38)$$

Onde para realizar estas equações será necessário o levantamento dos parâmetros do motor:

- $\mathbf{r}_a$  Resistência do circuito de armadura;
- $\mathbf{r}_{fd}$  Resistência do circuito de campo;

- $L_a$  Indutância do circuito de armadura;
- $L_{fd}$  Indutância do circuito de campo;
- $L_{afd}$  Indutância mútua;
- $e_a$  Força contra-eleto-motriz da armadura;
- $T_{em}$  Conjugado eletromagnético;
- $T_L$  Conjugado mecânico exigido pela carga;
- $B_m$  Coeficiente de atrito viscoso;
- $J_m$  Momento de inércia.

Então se calcula os coeficientes:

$$a_1 = e^{\frac{r_a h}{L_a}} \quad (39)$$

$$a_2 = \frac{1}{r_{fd}L_a - r_aL_{fd}} [L_{afd}L_{fd}(a_3 - a_1)x_3(k) - (r_aL_{fd}a_1 - r_{fd}L_a a_3)] \quad (40)$$

$$a_3 = e^{\frac{r_{fd} h}{L_{fd}}} \quad (41)$$

$$a_4 = e^{\frac{(1-a_5)}{B_m} x_2(k)} \quad (42)$$

$$a_5 = e^{-\frac{B_m h}{J_m}} \quad (43)$$

$$b_1 = \frac{1 - a_1}{r_a} \quad (44)$$

$$b_2 = \frac{1 - a_3}{r_{fd}} \quad (45)$$

$$d_1 = \frac{1 - a_5}{B_m} \quad (46)$$

Para que possa ser simulado o efeito das falhas, os parâmetros do motor devem ser alterados antes de calcular as equações acima. Seguem as alterações necessárias:

$$r_a^f = K_{RaCa} K_{RaFv} r_a \quad (47)$$

$$L_a^f = K_{LaCa} K_{LaFv} L_a \quad (48)$$

$$r_{fd}^f = K_{RfdCfd} K_{RfdFv} r_{fd} \quad (49)$$

$$L_{fd}^f = K_{LfdCfd} K_{LfdFv} L_{fd} \quad (50)$$

$$B_m^f = K_{fl} B_m \quad (51)$$

As falhas nos atuadores são representadas por parâmetros:

- **k<sub>aa</sub>**            {0,1}            Desconexão do conversor da armadura;
- **k<sub>afd</sub>**            {0,1}            Desconexão do conversor do campo;
- **k<sub>cca</sub>**            {0,1}            Curto-circuito do conversor da armadura;
- **k<sub>ccfd</sub>**           {0,1}            Curto-circuito do conversor do campo.

As falhas nos componentes da planta:

- $k_{RaCa}$  [0,1] Curto-circuito na bobina de armadura ( $r_a$ );
- $k_{LaCa}$  [0,1] Curto-circuito na bobina de armadura ( $L_a$ );
- $k_{RfdCfd}$  [0,1] Curto-circuito na bobina de campo ( $r_{fd}$ );
- $k_{LfdCfd}$  [0,1] Curto-circuito na bobina de campo ( $L_{fd}$ ).

Quanto as falhas no sistema de ventilação:

- $k_{RaFd}$  [1,∞) Variação de  $r_a$  para falha de ventilação;
- $k_{RfdFv}$  [1,∞) Variação de  $r_{fd}$  para falha de ventilação;
- $k_{fl}$  [1,∞) Variação de  $B_m$  para falha de lubrificação.

Finalmente, as falhas de instrumentação:

- $k_{ia}$  {0,1} falha no sensor de corrente de armadura;
- $k_{ifd}$  {0,1} falha no sensor de corrente de campo;
- $k_{wr}$  {0,1} falha no sensor de velocidade.

### 3.2.2 Metodologia prática de simulação

O algoritmo para gerar os dados de teste processa o simulador de máquina de corrente contínua um total de duas mil vezes (épocas) com mil pontos cada. Entre estas épocas foram simuladas as falhas de desconexão do conversor do campo, desconexão do conversor da armadura, falha no sensor de corrente de armadura e curto-circuito no conversor do campo. Em todos os sinais foi adicionado ruído aleatório com distribuição gaussiana.




Figura 25 Dados de uma simulação do motor de corrente contínua sem falhas.




Figura 26 Dados de uma simulação do motor de corrente contínua com desconexão do conversor do campo.




Figura 27 Dados de uma simulação do motor de corrente contínua com desconexão do conversor da armadura.




Figura 28 Dados de uma simulação do motor de corrente contínua com falha no sensor de corrente de armadura.


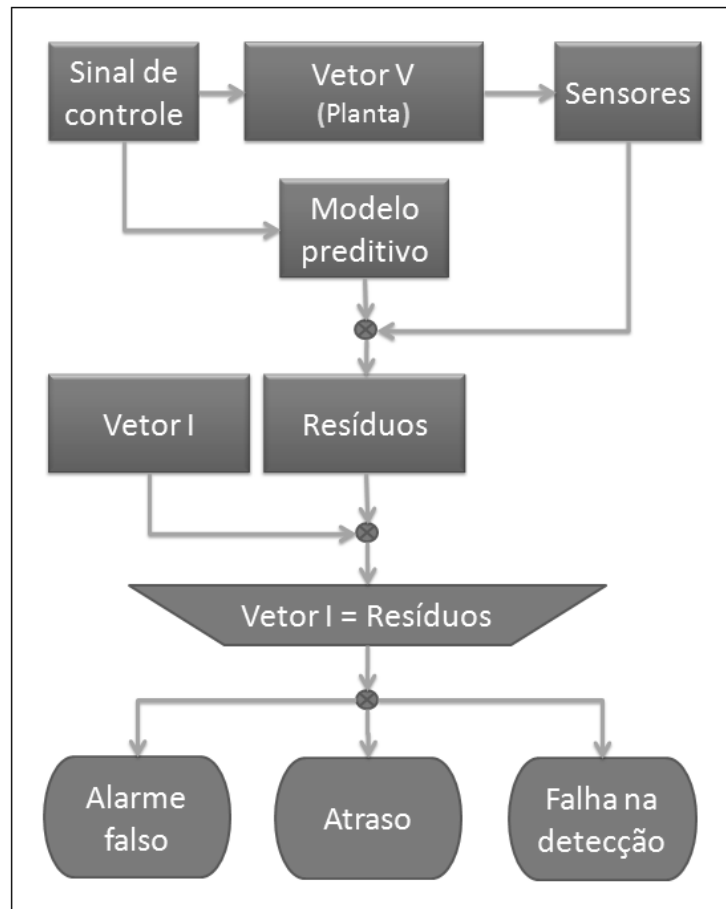


Figura 29 Dados de uma simulação do motor de corrente contínua com curto-circuito do conversor do campo.

Desta forma a seguinte prática foi adotada, construir um vetor de teste  $\mathbf{V}$  contendo amostras de trechos de pontos simulando o funcionamento da máquina sem defeitos e outros simulando um ou mais defeitos. Um segundo vetor,  $\mathbf{I}$ , contendo um código para cada ponto do vetor  $\mathbf{V}$  de forma a especificar que tipo de simulação originou cada valor de  $\mathbf{V}$ . Ou seja, indica se o ponto representa a máquina em funcionamento normal ou se há simulação de quaisquer falhas durante aquela amostragem.

Estes dois vetores serão apresentados ao algoritmo de detecção de falhas. O vetor  $\mathbf{V}$  simula o funcionamento de uma planta real a ser monitorada enquanto uma nova simulação do modelo prediz o comportamento esperado desta planta. A diferença entre estes resultados gera o resíduo que é comparado com o vetor  $\mathbf{I}$  para testar os resultados obtidos através do sistema de detecção de falhas, desta forma será calculada a eficiência do processo, Figura 30.





*Figura 30 Fluxograma do processo de detecção de falhas.*

O tratamento do resíduo, (isto é, a decisão que deve ser tomada ao avaliar o sinal gerado pelo modelo preditivo e o sinal amostrado na planta) também influencia de forma determinante o desempenho do processo de detecção de falhas como um todo. A Figura 31 demonstra o procedimento adotado neste projeto.

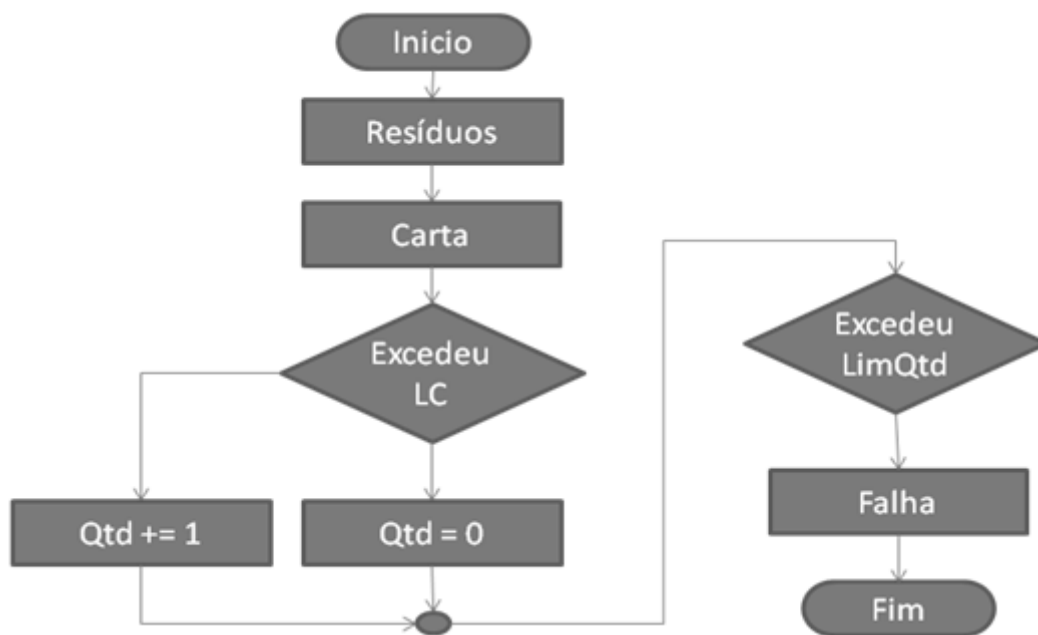


Figura 31 Processo de decisão para análise do resíduo.

Com o intuito de evitar a detecção prematura de uma falha, a variável Qtd foi adicionada, assim estabeleceu-se um limite mínimo de pontos encontrados fora de controle estatístico antes que o sistema seja considerado em operação com falhas.

### 3.3 Estudo sobre as cartas de controle

Se há interesse em reconhecer toda e qualquer novidade no funcionamento de um determinado sistema é imprescindível lembrar que nem todas as falhas têm o mesmo comportamento e nem sempre apresentam a mesma dinâmica. Algumas classes de falhas importantes são: Falhas abruptas, incipientes, de pequena e grande amplitude.

As chamadas falhas abruptas se caracterizam por aparecerem repentinamente, ou seja, promove variação das características estatísticas do resíduo em um intervalo muito menor do que o tempo amostral. Em contraposição aparecem as falhas incipientes

que se caracterizam por modificarem paulatinamente, ou seja, de forma não abrupta o resíduo.

Os processos também costumam influenciar na amplitude da falha. As diversas falhas provocadas por um sistema podem criar situações onde os resíduos modifiquem sua média ou variância com intensidades diferentes.

Qualquer uma destas características influencia no comportamento dos gráficos de controle. Portanto para conseguir um bom desempenho dessas ferramentas, a dinâmica da falha deve ser levada em conta no projeto.

O objetivo deste capítulo é testar as cartas de controle contra cada tipo de falha para conhecer o comportamento dos gráficos diante de cada tipo de evento. Esses dados irão auxiliar na escolha correta da ferramenta a ser utilizada.

### **3.3.1 Os diversos tipos de falha**

Para se tornar possível o estudo dos diversos tipos de falhas, alguns modelos para a simulação das possíveis dinâmicas encontradas em sistemas reais serão estabelecidos. As excitações impulso, degrau e rampa serão base para a abstração dos modelos. Junto a elas aparecerá a figura do ruído branco e gaussiano aditivo para proporcionar teste quanto à robustez ao ruído de cada gráfico estatístico. Seguem as quatro entidades estabelecidas:

- Um degrau para simular falhas abruptas, este com pequena amplitude, Figura 32

$$y[n] = U[n - n_p] + RBG[n] \quad (52)$$

- Um degrau para simular falhas abruptas, com grande amplitude, Figura 33

$$y[n] = 3U[n - n_p] + RBG[n] \quad (53)$$

- Uma rampa para simular falhas incipientes, Figura 34

$$y[n] = U_{-1}[n - n_p] + RBG[n] \quad (54)$$

- Um impulso para simular transientes, Figura 35

$$y[n] = 4\delta[n - n_p] + RBG[n] \quad (55)$$

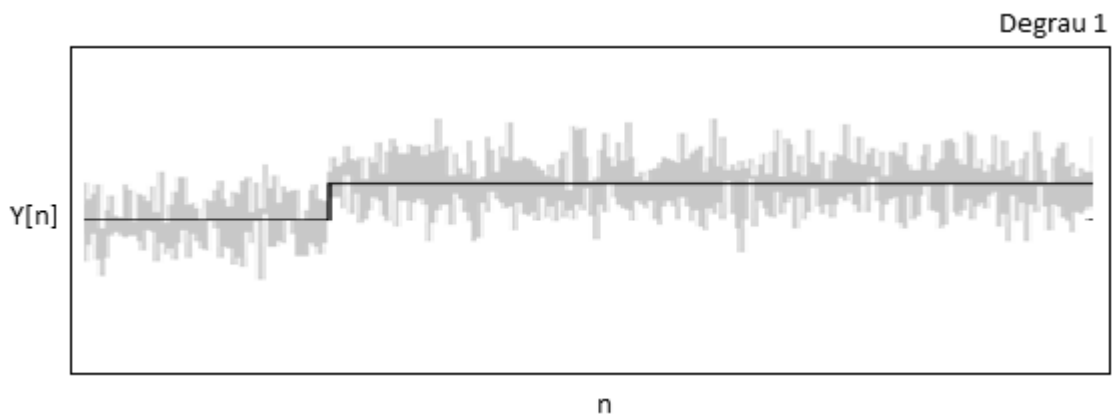


Figura 32 Representação de uma falha abrupta de baixa amplitude por um degrau unitário.




Figura 33 Representação de uma falha abrupta de grande amplitude por um degrau de peso três.




Figura 34 Representação de uma falha abrupta por uma rampa.




Figura 35 Representação de ruído por um impulso.

### 3.3.2 Simulação das Falhas

Cada uma das amostras de dados criadas no item 3.3.1 (falha de baixa amplitude, falha de alta amplitude, falha incipiente e falha com grande quantidade de ruído) foram submetidas ao processamento das cartas de controle X barra, CUSUM e MMEP. O desempenho dos métodos será medido segundo os critérios:

1. Quantidade de pontos com falso negativo;
2. Quantidade de pontos com falso positivo;
3. Tempo de detecção da falha.

Além disso, uma falha será sinalizada somente depois de detectados três pontos em seqüência fora dos limites de controle estabelecidos pelos gráficos. Os resultados para o gráfico de controle X barra estão descritos na Figura 36, para o gráfico CUSUM estão na Figura 37 e para o gráfico MMEP na Figura 38.

### Gáfico X barra

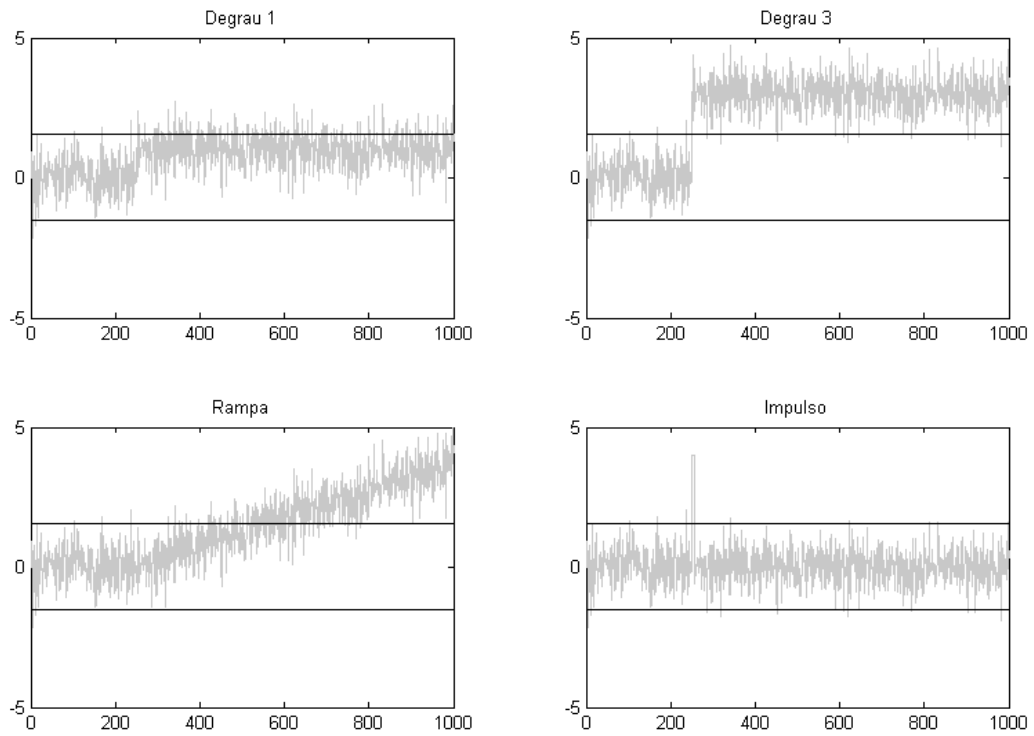


Figura 36 Resultado gráfico X-barra quando testado para os vários tipos de falhas.

### Gráfico CUSUM

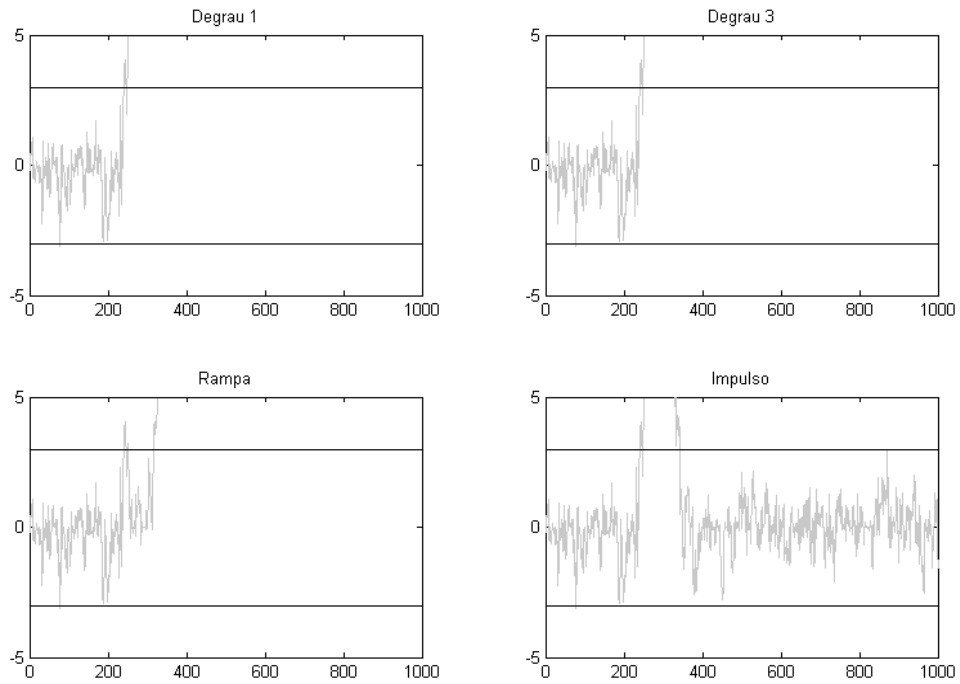


Figura 37 Resultado gráfico CUSUM quando testado para os vários tipos de falhas.

### Gráfico MMEP

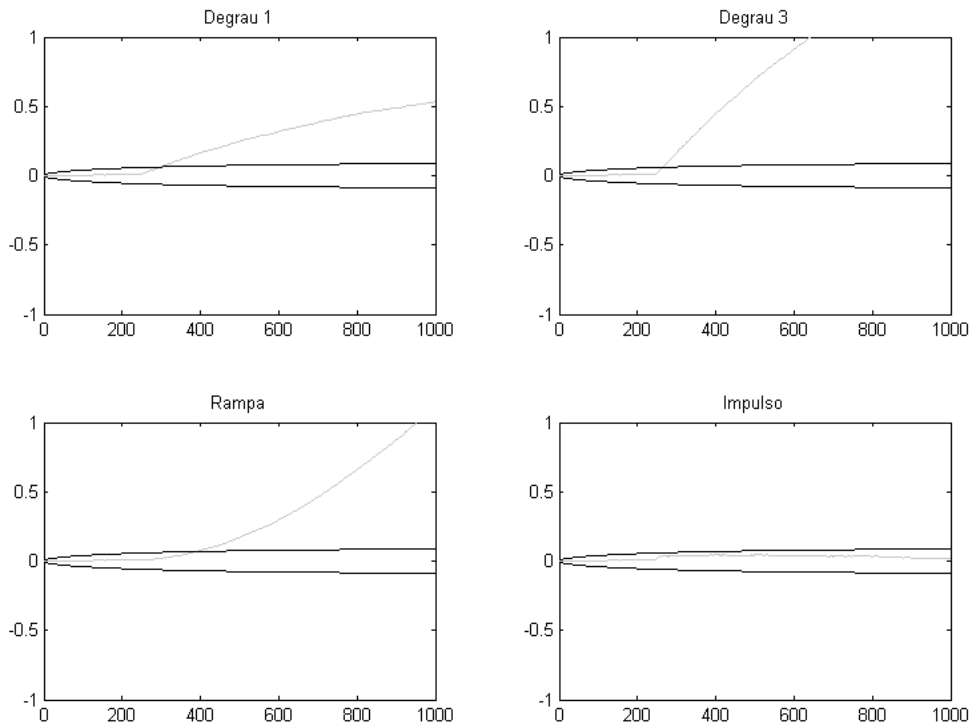


Figura 38 Resultado gráfico MMEP quando testado para os vários tipos de falhas.

### 3.3.3 Comparação entre as cartas

Esta seção se dedica a discutir os resultados obtidos nos itens anteriores. Serão feitas comparações entre o desempenho dos gráficos estudados, seguindo os critérios testados, segundo cada tipo de falha simulada.

As tabelas Tabela 5, Tabela 6,

Tabela 7 e

Tabela 8 são compostas pelos resultados estatísticos dos testes realizados. Os dois primeiros itens, falso negativo e falso positivo, são dados em termos percentuais de forma a analisar a frequência destes itens com relação ao total de épocas testadas. Cada vez que uma falha foi detectada com sucesso era computado o tempo decorrido entre a aplicação da falha e a sinalização pelo sistema de forma que a média desses valores é representada pelo terceiro item destas tabelas, tempo de detecção.

#### Falha abrupta de grande amplitude

*Tabela 5 Resultado do desempenho das cartas de controle quando aplicada uma falha abrupta de grande amplitude*

	X barra	CUSUM	MMEP
Falso positivo	0.6	0.6	0
Falso negativo	1.2	0	1.5
Tempo de detecção	0	2	17

Para este tipo de falha, o gráfico X barra se mostra bastante eficiente se a necessidade maior for velocidade de detecção de falhas. A escolha do CUSUM melhora um pouco o erro chamado de falso negativo, mas implicaria em considerável aumento do custo computacional. O método MMEP demonstra bom desempenho quanto aos quesitos falso positivo e falso negativo, no entanto quanto ao tempo de detecção se mostra bastante inferior.



## Falha de pequena amplitude

*Tabela 6 Resultado do desempenho das cartas de controle quando aplicada uma falha abrupta de pequena amplitude*

	X barra	CUSUM	MMEP
Falso positivo	0.5	0.6	0
Falso negativo	61.9	0	5
Tempo de detecção	263	2	52

Neste caso o gráfico X barra se mostra ineficiente. Uma boa escolha é o gráfico CUSUM.

## Falha incipiente

*Tabela 7 Resultado do desempenho das cartas de controle quando aplicada uma falha incipiente*

	X barra	CUSUM	MMEP
Falso positivo	0.5	0.6	0
Falso negativo	30.1	6.7	13.7
Tempo de detecção	263	70	139

Para falhas incipientes o gráfico x barra e MMEP se mostram muito ineficientes por causa do atraso gerado na detecção da falha. A melhor opção para este caso parece ser o CUSUM. No entanto, será visto adiante que é possível alterar as propriedades do MMEP para fazer com que fique mais rápido, e provavelmente será uma melhor escolha devido à simplicidade de sua execução.

## Resposta a ruídos

Tabela 8 Resultado do desempenho das cartas de controle quando submetida a ambientes ruidoso

	X barra	CUSUM	MMEP
Falso positivo	2.1	0.6	0
Falso negativo	0.2	0	0
Tempo de detecção	0	2	-

É bastante claro ao analisar o quadro que o método mais robusto ao ruído é o gráfico MMEP. Este gráfico não gerou alarme algum, enquanto o X barra e CUSUM geram alarme quase imediatamente ao aparecimento do ruído.

### 3.3.4 Projeto das cartas de controle

O gráfico X-Barra não é capaz de identificar falhas pequenas com clareza. O CUSUM gera maior atraso bem mais expressivo no caso de falhas de grande amplitude. O MMEP é bastante eficiente na presença de ruído. Tendo em vista tais conclusões é possível estabelecer uma metodologia para escolha da melhor carta segundo o seu desempenho, Tabela 9.

Tabela 9 Escolha de cartas de controle segundo suas propriedades para utilização em detecção de falhas.

Tipo de falha	X-barra	CUSUM	MMEP
Grande amplitude	X		
Pequena amplitude		X	
Incipiente		X	X
Com muito ruído			X

A classificação das cartas quanto a sua eficiência é uma abordagem até então não discutida na literatura. Esta nova metodologia garante uma forma determinística e segura para a aplicação das cartas de controle. As cartas MMEP contam com vários parâmetros de ajuste (Morettin, 2006). Essa idéia pode ser usada a fim de criar métodos para projetá-las com máxima eficiência.

Seguindo as conclusões estabelecidas neste capítulo, a Figura 39 ilustra o procedimento adotado na escolha das cartas de controle estatístico utilizada em cada situação de teste.




Figura 39 Escolha das cartas de controle para o projeto do sistema de detecção de falhas.

A Figura 39 apresenta três colunas: A primeira contém uma lista descrevendo as situações de teste encontradas nas simulações. A segunda coluna determina o tipo de carta de controle a ser utilizada em caso de redução total de variáveis. A última coluna aponta as cartas de controle utilizadas sempre que houver necessidade de manipular duas ou mais variáveis.

Assim, a análise de falhas abruptas será realizada por intermédio de cartas x-barra com PCA. A carta CUSUM será utilizada em conjunto com PCA no tratamento de falhas de baixa amplitude e a carta MMEP será empregada para detectar falhas incipientes ou com presença de ruído sempre que houver redução total de variáveis. A carta de controle MMMEP será utilizada em quase toda abordagem em que tratarmos diretamente o sistema de forma multivariada com exceção de falhas abruptas onde será empregada a carta de controle  $T^2$ .

### 3.3.5 Analisando o MMEP

Conforme foi adiantado no item anterior, os gráficos MMEP podem ter seu comportamento modificado conforme as características do tipo de falha a ser identificada. A Figura 40 ilustra o desempenho desta ferramenta quando se ajusta os parâmetros  $L$  para 3 e  $\lambda$  para 0.1. A Figura 41 o parâmetro  $L$  é definido 7 e  $\lambda$  0.01.

Na Figura 40 a primeira falha foi detectada por volta da amostra 300, na Figura 41 estava na amostra 400. O segundo conjunto de amostras contém um erro amostral que não deveria ser considerado uma falha, o resultado demonstrado na Figura 41 foi capaz de rejeitar este sinal. Fica fácil compreender que quando o parâmetro  $\lambda$  fica maior, o gráfico é mais rápido para detectar falhas, porém fica mais suscetível ao ruído.

#### MMEP - Rápido




Figura 40 Ajuste dos parâmetros do MMEP, representação de uma carta MMEP com  $\lambda$  igual a 0.1

#### MMEP - Robusto ao ruído




Figura 41 Ajuste dos parâmetros do MMEP, representação de uma carta MMEP com  $\lambda$  igual a 0.01

### 3.4 Conclusões

A metodologia proposta neste capítulo pode ser compreendida melhor se for dividida em três pontos de estudo: Projeto, processamento e validação. Desta forma, o texto discutiu as considerações necessárias para um bom projeto de sistemas de detecção de falhas, apresentou o formalismo matemático necessário para processar os dados de um sistema dinâmico com características multivariadas e finalmente propôs um modelo para testar e validar os procedimentos discutidos.

Segundo este princípio, se torna claro que a escolha da carta de controle estatístico ideal está intimamente ligada às características dinâmicas do comportamento das falhas de interesse. Ou seja, as cartas de controle baseadas na simples observação das características do sistema são as mais eficientes em relação ao tempo necessário para detecção da falha, porém não se aplicam com excelência quando há necessidade de tratar sinais ruidosos ou nos quais as falhas provocam alterações pequenas. Estes são os casos em que o uso das cartas MMEPM se mostra mais vantajoso.

O capítulo também promoveu discussões sobre como os dispositivos do CEP deveriam ser aplicados aos sinais colhidos do sistema a ser controlado. Estabeleceu os procedimentos exigidos para programar os conceitos das cartas de controle. Apresentou subsídios para entender a união entre os processos de redução de variáveis e decisão estatística.

Finalmente disserta sobre a estratégia de teste e validação dos princípios citados acima. Com este fim, foi proposto um modelo capaz de simular o funcionamento real de uma máquina de corrente contínua. Este mesmo procedimento também é capaz de gerar dados simulando este equipamento com falhas.

Este capítulo reúne todo o conhecimento necessário para criar uma metodologia de detecção de falhas em sistemas multivariados.

## 4 EXPERIMENTO DE DETECÇÃO DE FALHAS

Um sistema de detecção de falhas, em linhas gerais, deve reconhecer toda e qualquer situação de funcionamento anormal por intermédio do monitoramento da planta de interesse. Com este fim coletam-se informações provenientes de sensores espalhados pelo sistema monitorado que caracterizam o estado de funcionamento da planta em um intervalo de tempo inversamente proporcional à frequência de amostragem destes sinais (Oppenheim *et al.*, 1999). Por outro lado, um modelo matemático da planta deve agir paralelamente prevendo a situação normal esperada num dado momento. Os dois resultados são combinados de forma que sua diferença indique a possibilidade de alguma anomalia. Este diagnóstico é definido dentro da metodologia de detecção de falhas com o termo falta (Venkatasubramanian *et al.*, 2003) porém neste trabalho foi usado o termo falha com o mesmo propósito.

A Figura 42 ilustra através de um diagrama em blocos a formação básica utilizada neste trabalho para realizar a detecção de falhas.

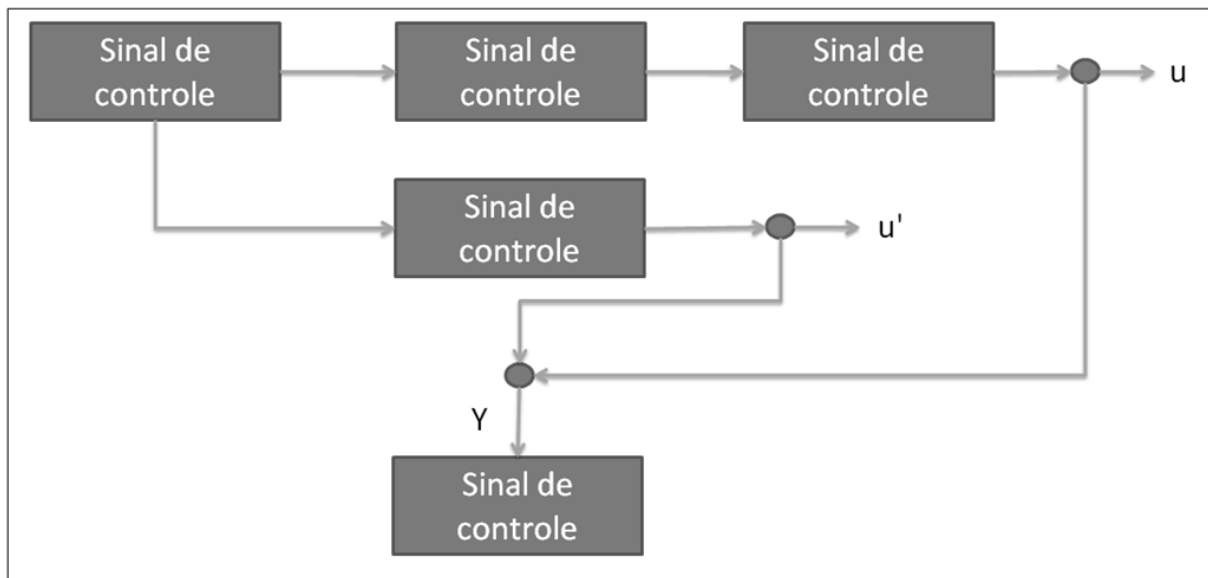


Figura 42 Sistema de detecção de falhas

Neste contexto,  $u$  é um vetor que contém o conjunto de variáveis do sistema multivariado provido pelos sensores,  $u'$  é um vetor que representa as mesmas variáveis, porém calculadas pelo modelo

matemático da planta, e finalmente, y corresponde ao vetor de resíduos. Todos os vetores possuem o mesmo número de elementos que é igual ao número de variáveis monitoradas. Neste trabalho foram adotadas as cartas de controle para manipular o vetor de resíduos. A definição de falha é compreendida com na metodologia proposta pelo CEP, ou seja, é o mesmo que detectar uma ou mais variáveis fora de controle estatístico (Montgomery, 2004).

#### **4.1 Projeto do sistema de detecção de falhas**

Esta seção se dedica a conceituar este trabalho no que diz respeito aos pontos discutidos para criação de um projeto de sistema de detecção de falhas. Os tópicos estão divididos em: Redução de variáveis; Tipos de falhas e escolha da carta de controle; Metodologia de detecção de falhas. Essas idéias podem ser organizadas de forma mais genérica em dois pontos principais:

1. A escolha adequada do número de variáveis de trabalho;
2. A importância da utilização de uma carta de controle adequada, baseando-se no tipo de falha.

##### **4.1.1 Redução de variáveis**

Em qualquer processo multivariado é muito comum se deparar com casos em que aparecem inúmeras características e nem sempre todas são bem conhecidas. O fato é que em grande parte delas geralmente se mostram redundantes ou poucos efeitos para análise do processo como um todo. Na revisão bibliográfica foram descritas as idéias de Pareto que criam parâmetros para lidar com este tipo de problema. Ele nos diz que aproximadamente oitenta por cento de todo o problema encontra solução em apenas vinte por cento das causas. Traduzindo para o contexto das variáveis: *Com aproximadamente vinte por cento das variáveis seria possível explicar oitenta por cento da informação contida no conjunto de todas as variáveis.*

De qualquer forma é necessário o procedimento de redução de variáveis, primeiro para reduzir a complexidade do projeto final e

depois porque o excesso de variáveis torna o processo menos sensível às falhas. As ferramentas de Pareto serão utilizadas para calcular exatamente qual é a quantidade de informação que está sendo desprezada ao proceder desta maneira. O ideal é trabalhar com um número de variável bastante reduzido, ao contrário, os pesos de cada variável fica bastante diluído entre elas dificultando a detecção de alguma mudança no processo (Montgomery, 2004).

#### **4.1.2 Escolha da carta de controle**

No item 3.3 foi feita uma discussão a fim demonstrar o desempenho das cartas de controle quando se deparam com diferentes tipos de falha, ou seja, falha abrupta de baixa ou alta intensidade, falha incipiente e também robustez na presença de ruído. Atente para o fato de que cada tipo de carta demonstra resultados excelentes para alguns tipos de falhas e ao mesmo tempo, resultados indesejáveis para outros.

É recomendável um estudo prévio das falhas a serem analisadas a fim de organizar as falhas possíveis dentro de grupos que as caracterizem pela sua dinâmica, ou seja, o tipo de falha correspondente. Desta forma é possível aumentar a confiança na detecção das falhas aplicando o sinal do resíduo em cartas de diferentes tipos.

#### **4.1.3 O método de detecção de falhas**

A Figura 43 descreve de forma geral o processo de detecção de falha proposto neste trabalho.



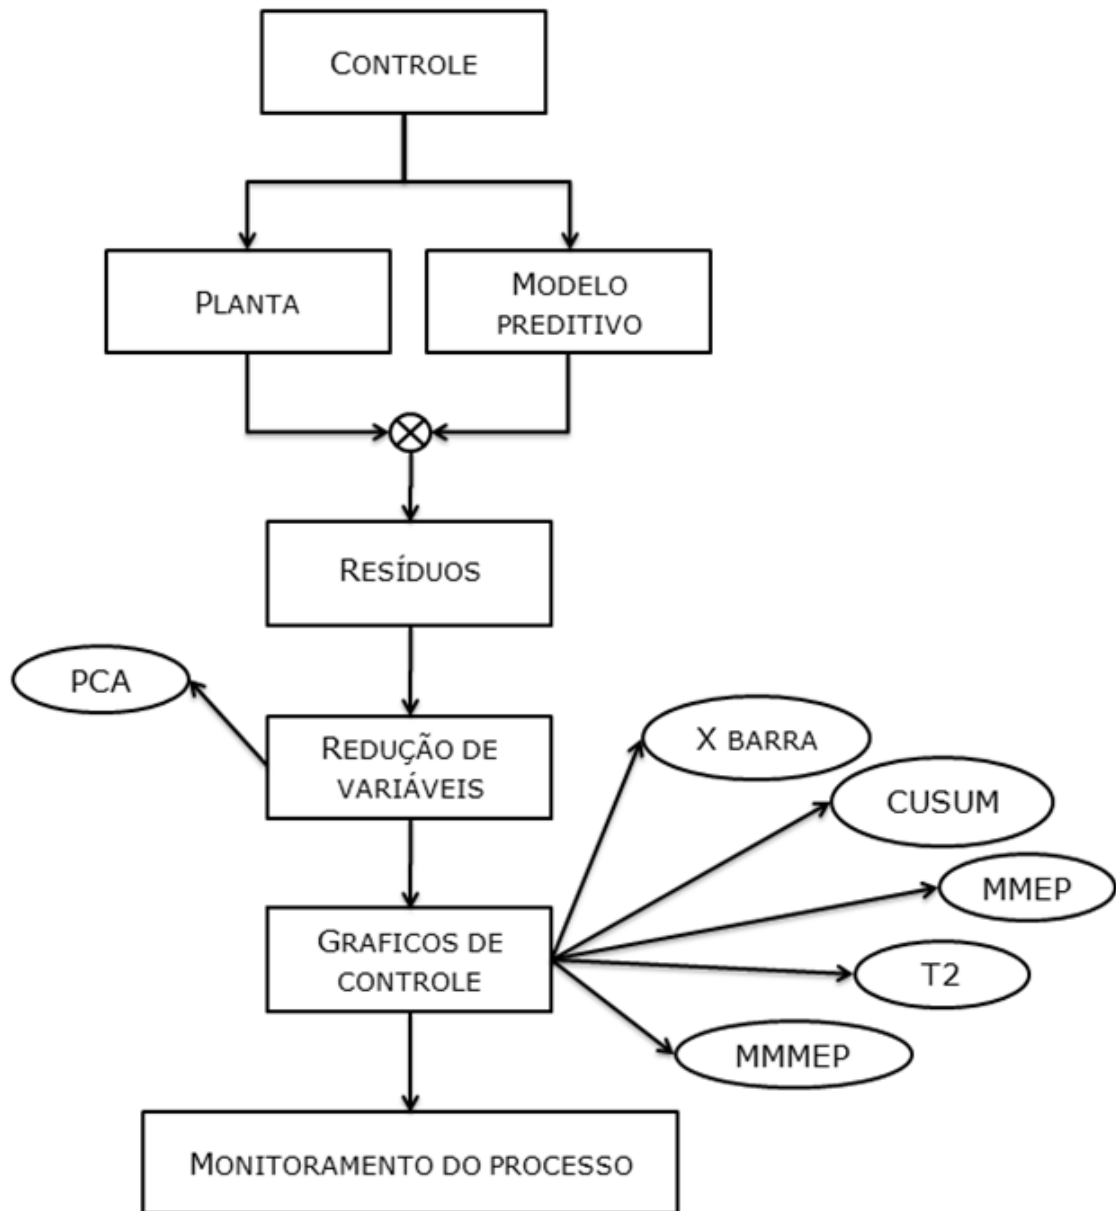


Figura 43 Descrição do processo de detecção de falhas e das ferramentas utilizadas.

Os próximos itens se encarregarão da discussão desta proposta para solução do problema de detecção de falhas. Este algoritmo será testado em três casos diferentes. O primeiro caso estuda a aplicação deste algoritmo nos dados simulados pelo processo descrito no capítulo 3. Ao sinal gerado pelo simulador de máquina de corrente contínua é aplicada a redução de variáveis de forma a restar apenas uma variável que servirá de excitação para as cartas de controle de uma só variável (X barra, CUSUM, MMEP).

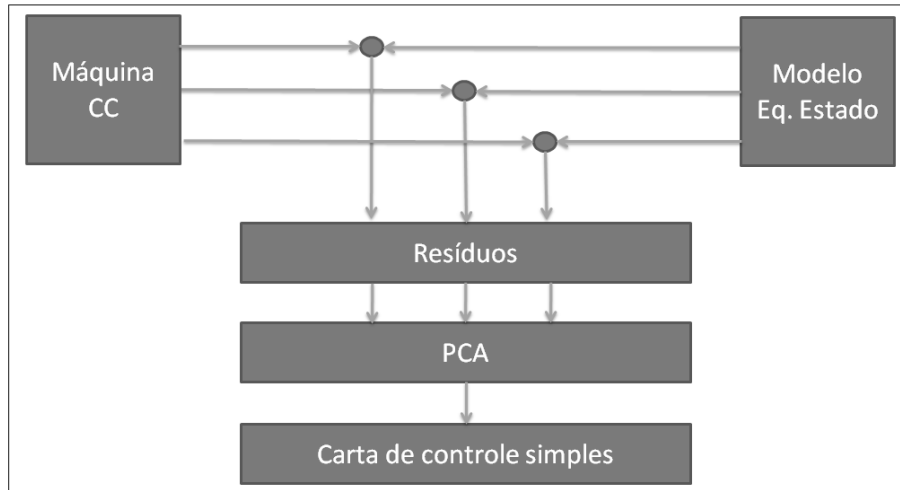
Depois, no segundo caso, serão aplicadas as três saídas do simulador diretamente nas cartas de controle multivariadas ( $T^2$  e MMEP) sem nenhuma redução de variáveis. Isso é possível pelo fato de que existem poucas variáveis neste processo. Para ambos os casos discutidos, falhas de todos os tipos serão geradas e aplicadas às cartas adequadas.

Os processos de cada caso serão avaliados segundo os mesmos critérios: Quantidade de falso positivo, quantidade de falso negativo, tempo de atraso para detecção da falha e custo de processamento.

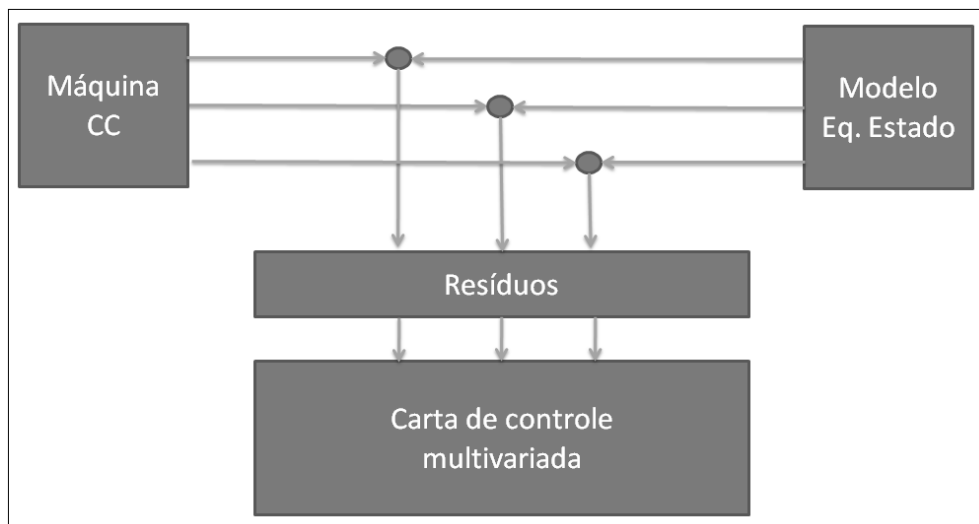
## **4.2 Metodologia Proposta**

Os sistemas multivariados ao serem tratados pela metodologia de detecção de falhas geram um vetor de resíduos que pode conter variáveis correlacionadas entre si. Esta metodologia propõe resolver este problema combinando a aplicação de cartas de controle e redução de variáveis. Foram propostos dois casos de estudo para monitorar o funcionamento de uma máquina de corrente contínua com três variáveis de interesse: No primeiro caso, a redução total de variáveis foi empregada com o propósito de utilizar uma carta de controle simples, isso foi possível no experimento proposto já que a redução para uma única variável ainda conservava mais de oitenta por cento da informação total (Figura 44); O segundo caso utiliza as cartas de controle multivariadas conectadas diretamente ao resíduo (Figura 45).

É interessante observar que para estudo posterior, é possível considerar a simplificação do caso apresentado na Figura 44 modificando a disposição do PCA. Desta forma, se a redução de variáveis for aplicada antes da dedução dos resíduos, as variáveis da máquina de corrente contínua serão reduzidas de forma que o modelo matemático também pode ser reduzido.



*Figura 44 Redução total de variáveis*



*Figura 45 Utilizando cartas multivariadas*

Essa modificação implica em redução do custo computacional no cálculo dos resíduos bem como no processamento do modelo. Outro ganho notável se dá no cálculo do PCA já que a forma apresentada anteriormente submete a ferramenta a uma série de zeros muito grande (i.e. espera-se que o resíduo seja zero a maior parte do tempo, pois indica bom funcionamento da planta). Este fato causa dificuldades para calcular as matrizes de covariância exigidas pelo método, gerando instabilidade no processo.

### 4.2.1 Obtenção da massa de dados para teste

O simulador de máquina de corrente contínua foi usado para gerar dados com falha a fim de realizar testes. Quatro tipos de falhas foram gerados: A primeira falha simula a desconexão do conversor do campo de forma abrupta de grande amplitude; A segunda simula um curto circuito na bobina de armadura de forma abrupta com baixa amplitude; A próxima, um curto circuito na bobina de campo de forma incipiente; Finalmente a desconexão do conversor da armadura com muitos picos de ruído. Para cada simulação foram geradas mil amostras, as falhas foram aplicadas a partir da amostra número quinhentos. Estes quatro resultados foram aplicados aos dois casos descritos na seção anterior e detalhados na Figura 44 e Figura 45.

Quando aplicada a redução total de variáveis de saída da planta é possível ver que grande parte da informação é transferida para a primeira componente principal, veja o gráfico da Figura 46.




Figura 46 Resultado das componentes principais do PCA representadas em um gráfico de Pareto.

### 4.2.2 Modelo matemático

No segundo caso, aplicando as cartas de controle multivariadas sem redução de variáveis e para a falha abrupta de grande amplitude foi aplicada a carta  $T^2$ . Se  $x$  for um vetor coluna contendo as saídas da planta,  $u$  a média desses valores e  $S$  a sua variância, a análise estatística  $T^2$  é dada pela função:

$$x_0^2 = n(x - \mu)'S^{-1}(x - \mu) \quad (56)$$

As demais falhas são tratadas com o gráfico MMMEP. Se  $x$  for um vetor coluna contendo as saídas da planta e  $\lambda$  um fator entre determinado entre  $0 < \lambda < 1$  a estatística  $Z$  é determinada pela equação:

$$Z_i = \lambda x_i + (1 - \lambda)Z_{i-1} \quad (57)$$

Para cada um destes testes foram geradas trezentas realizações com mil amostras cada uma. Para cada realização deve ser gerada uma quantidade aleatória de amostras com falhas do tipo exigido pelo teste realizado.

#### 4.2.3 Critérios de prova

Para os experimentos dos modelos descritos nas Figura 44 e Figura 45 foram submetidos à massa de dados definida no item anterior. Esta seqüência de amostras foi gerada em intervalos regulares de quinhentos pontos intercalando intervalos contendo dados normais e outros intervalos com simulação de uma ou mais falhas. Além disso, foram definidos dados que contêm informações sobre cada um destes intervalos, tais como, posição de início e término, amostras normais ou simulando falhas, tipo de falha simulada. Os resultados obtidos foram avaliados segundo três critérios:

- **Falha não detectada:** Neste item foi contabilizado o número de vezes em que o sistema classificou como normal um trecho da massa de dados criada com intenção de simular uma falha de um tipo qualquer. Este valor numérico foi representado em percentual com relação ao número total de testes efetuados.
- **Alarme falso:** Desta vez foi calculado o número de vezes que o sistema sinalizou falha em um evento previsto como normal na amostra. Este valor numérico foi representado em percentual com relação ao número total de testes efetuados.
- **Tempo de resposta:** Este indicador computa o espaço de tempo que se passou entre o momento em que a massa de dados prevê uma falha e o disparo do alarme por parte do sistema de detecção

de falhas. Este valor é expresso em quantidade de amostras, ou seja, se relacionado com o tempo de amostragem é possível estabelecer o tempo decorrido. Além disso, o valor final foi definido como sendo a média aritmética de cada atraso mensurado durante o teste.

### 4.3 Caso 1: Redução para uma só variável

O modelo de simulação da máquina de corrente contínua será usado para testar este caso. O primeiro passo é criar um código para simular o processo e depois gerar algumas falhas de tipo diferentes para serem aplicadas às cartas de controle. Quatro tipos de falhas foram gerados:

1. Falha abrupta
2. Falha de pequena magnitude
3. Falha incipiente
4. Falha abrupta e picos de ruído

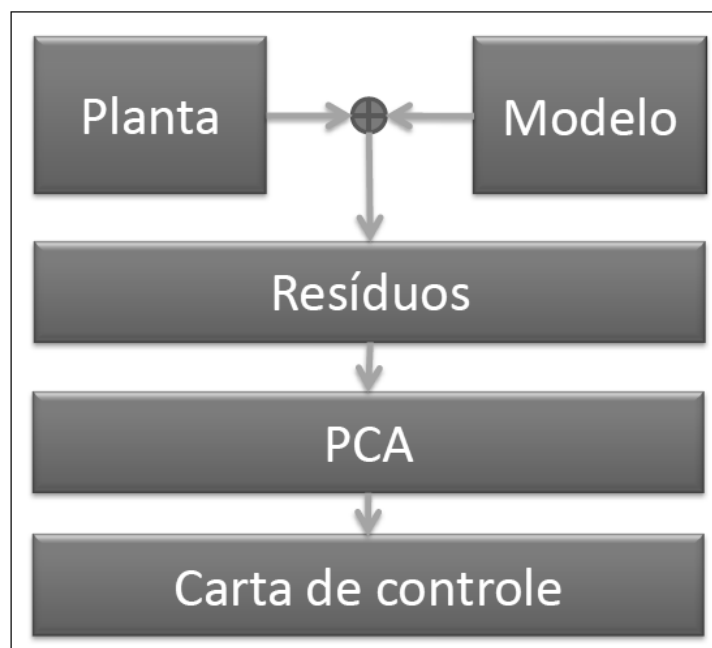


Figura 47 Caso 1 - Redução para uma variável tratada pela a carta de controle simples.

O passo seguinte é fazer a redução de variáveis e verificar a viabilidade de utilizar uma só componente principal. O algoritmo utilizado foi o PCA e a Figura 48 mostra o resultado desta análise conforme definições de Pareto.




Figura 48 Pareto das componentes principais

É fácil verificar que a primeira componente principal corresponde a aproximadamente sessenta e cinco por cento de toda a informação. Este fato é encorajador para prosseguir com o teste utilizando apenas uma componente. Na seqüência será aplicado o PCA em todos os sinais gerados, e depois são escolhidas as cartas adequadas para tratar cada tipo de falha.

### **Tratamento da falha abrupta**

O tratamento da falha abrupta é executado com maior desempenho quando utilizando a carta X barra conforme visto em itens anteriores. O resultado estatístico está na

Tabela 10, o gráfico é mostrado na Figura 49.



Tabela 10 Resultado do tratamento do caso 1 para falhas abruptas.

Teste	Resultado
Falso positivo	0,00 %
Falso negativo	0,20%
Tempo de latência	4 pontos




Figura 49 Resultado do tratamento do caso 1 para falhas abruptas.

### Tratamento da falha de baixa magnitude

Neste caso deve ser empregado o gráfico CUSUM como já foi alertado foi alertado anteriormente. O resultado estatístico está na

Tabela 11, o gráfico é mostrado na Figura 44 Redução total de variáveis.

Tabela 11 Resultado do tratamento do caso 1 para falhas de baixa magnitude.

Teste	Resultado
Falso positivo	0,40 %
Falso negativo	3,30%
Tempo de latência	35 pontos




Figura 50 Resultado do tratamento do caso 1 para falhas de baixa magnitude.

A título de investigação é possível observar na Figura 51 que este tipo de falha não seria captada por um gráfico X barra. Veja também o resultado estatístico deste experimento na Tabela 12.

Tabela 12 Resultado do tratamento do caso 1 para falhas de baixa magnitude utilizando o gráfico X-barra.

Teste	Resultado
Falso positivo	0,40 %
Falso negativo	3,30%
Tempo de latência	35 pontos




Figura 51 Resultado do tratamento do caso 1 para falhas de baixa magnitude utilizando o gráfico X-barra.

### Tratamento de falhas incipiente

Este tipo de falha também deve ser tratado com auxílio de cartas de controle CUSUM. Na Tabela 13 está apresentado o resultado estatístico e na Figura 52 pode-se acompanhar graficamente o resultado.

Tabela 13 Resultado do tratamento do caso 1 para falhas incipientes.

Teste	Resultado
Falso positivo	0,40 %
Falso negativo	3,30%
Tempo de latência	35 pontos




Figura 52 Resultado do tratamento do caso 1 para falhas incipientes.

## Tratamento de falhas abruptas com pico de ruídos

Da mesma forma já foi descrito a melhor maneira de lidar com este tipo de falha. A carta de controle MMEP será utilizada neste caso. O resultado gráfico está na Figura 53 e a Tabela 14 demonstra o resultado estatístico.

Tabela 14 Resultado do tratamento do caso 1 para falhas com picos de ruído.

Teste	Resultado
Falso positivo	0,00 %
Falso negativo	3,30%
Tempo de latência	35 pontos




Figura 53 Resultado do tratamento do caso 1 para falhas com picos de ruído.

Observe na Figura 54 o que aconteceria se esta mesma falha fosse aplicada a uma carta de controle CUSUM, esta carta detecta a falha real com precisão, mas gera muitos pontos de alarme falso por causa dos picos de ruído.




Figura 54 Resultado do tratamento do caso 1 para falhas com picos de ruído utilizando o gráfico de controle CUSUM.

#### 4.4 Caso 2: Utilização da carta multivariada

Continuando o estudo com o simulador de máquina de corrente contínua, este caso propõe estudar as cartas de controle modificadas para operar em processos multivariados. É visto que este simulador conta com três variáveis de saída, então, será aplicada todas as três nas cartas de controle multivariadas de acordo com o tipo de falha simulado. Note que serão utilizadas as mesmas amostras do caso um, ou seja, o sinal de entrada será aquele descrito anteriormente.

##### Tratamento da falha abrupta

A fim de tratar falhas do tipo abruptas será utilizada a  $T^2$  de Hotelling que é a adaptação da carta x barra já conhecida como a mais adequada para tratar este tipo de caso. A Tabela 15 representa os resultados estatísticos obtidos a Figura 55 ilustra o resultado graficamente.

Tabela 15 Resultado do tratamento do caso 2 para falhas abruptas.

Teste	Resultado
Falso positivo	0,10 %
Falso negativo	3,50%
Tempo de latência	37 pontos




Figura 55 Resultado do tratamento do caso 2 para falhas abruptas.

Os demais tipos de falhas são tratados com a carta de controle MMMEP. Nota que para o caso de falha com ruído, o  $\lambda$  é definido 0.01 e as outras falhas são tratadas com  $\lambda$  igual a 0.1 para ficarem mais rápidas já que não precisam filtrar ruído.

### Tratamento de falha de baixa magnitude

Os resultados podem ser acompanhados na Tabela 16 e na Figura 56.

Tabela 16 Resultado do tratamento do caso 2 para falhas de baixa magnitude.

<b>Teste</b>	<b>Resultado</b>
<b>Falso positivo</b>	0,10 %
<b>Falso negativo</b>	3,50%
<b>Tempo de latência</b>	37 pontos




Figura 56 Resultado do tratamento do caso 2 para falhas de baixa magnitude.

### Tratamento de falha incipiente

Tabela 17 Resultado do tratamento do caso 2 para falhas incipientes.

<b>Teste</b>	<b>Resultado</b>
<b>Falso positivo</b>	0,10 %
<b>Falso negativo</b>	3,50%
<b>Tempo de latência</b>	36 pontos






Figura 57 Resultado do tratamento do caso 2 para falhas incipientes.

### Tratamento de falha com picos de ruído

Tabela 18 Resultado do tratamento do caso 2 para falhas com picos de ruído.

Teste	Resultado
Falso positivo	0,00 %
Falso negativo	0,60%
Tempo de latência	8 pontos




Figura 58 Resultado do tratamento do caso 2 para falhas com picos de ruído.

## 4.5 Análise Geral dos Resultados Obtidos

A Figura 59 mostra um resumo dos resultados gráficos do algoritmo que executou o primeiro caso e a Tabela 19 discute os resultados numéricos. A Figura 60 e a Tabela 20 demonstram os respectivos resultados para o segundo caso.

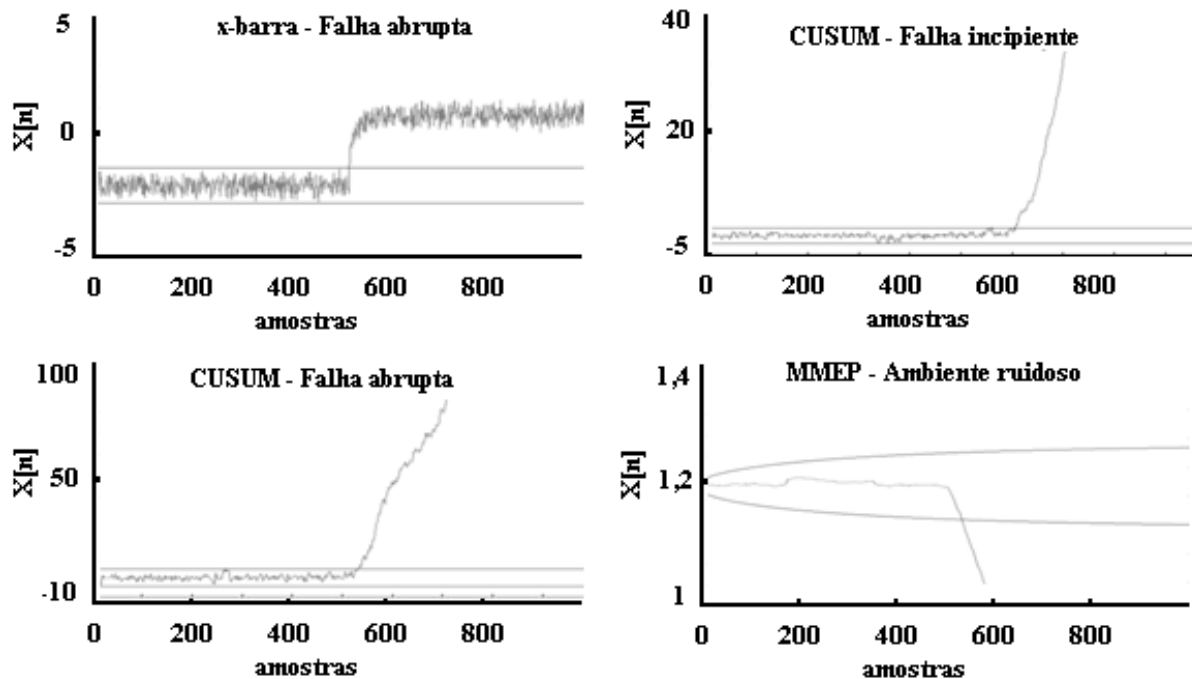


Figura 59 Caso 1: Redução total de variáveis.

Tabela 19 Caso 1 - Robustez a ruído

<b>Tipo de falha</b>	<b>Alarme falso</b>	<b>Falha na detecção</b>	<b>Atraso</b>
Grande amplitude	0,0%	0,2%	4
Pequena amplitude	0,4%	3,3%	35
Incipiente	0,2%	10,3%	109
Picos de ruído	0,0%	3,3%	35

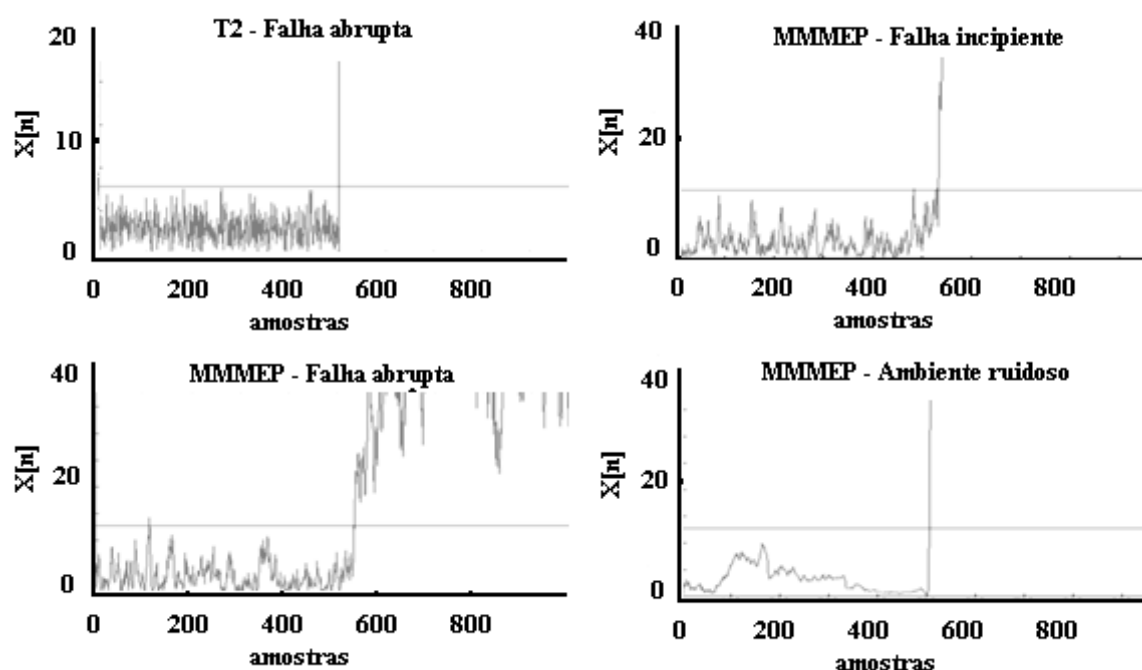


Figura 60 Caso2: Utilizando cartas de controle.

Tabela 20 Caso 2 – Resultado numérico.

<b>Tipo de falha</b>	<b>Falso positivo</b>	<b>Falso negativo</b>	<b>Tempo</b>
Grande amplitude	0,1%	3,5%	37
Pequena amplitude	0,1%	3,5%	37
Incipiente	0,1%	3,3%	36
Picos de ruído	0,0%	0,6%	8

Os resultados demonstrados na Tabela 19 são em linhas gerais bastante parecidos com os vistos na Tabela 20. Os mesmos dados foram aplicados nos dois casos, desta forma estas tabelas podem ser usadas como comparador de desempenho entre eles. Notam-se diferenças significativas quando analisado o tempo e as falhas na detecção, não existindo método privilegiado, ou seja, a melhor escolha continua dependendo do tipo de falha.

## 5 CONCLUSÃO

A abordagem de detecção de falhas é um sistema diferente quando se trata de ambientes multivariados. Ela utiliza-se de técnicas difundidas há bastante tempo na literatura; controle estatístico da qualidade, controle estatístico de processos que são normalmente utilizadas no controle de qualidade da produção aplicado à parte administrativa da indústria.

Os resultados obtidos através da simulação da máquina de corrente contínua demonstram que a abordagem é interessante. Nenhuma das falhas testadas deixou de ser detectada. O tempo de detecção também se mostra bastante eficiente se a taxa de amostragem for elevada o suficiente. Nenhuma falha deixou de ser detectada e as taxas de alarme falso e não detecções de falhas ocorridas se mostraram bastante reduzidas, inferiores a 0,1%, ou seja, foi obtido um resultado geral de sucesso. Este resultado, quando comparado com outros trabalhos realizados com as mesmas condições (utilizando o modelo da máquina de corrente contínua para simular as falhas e validar o modelo) se mostra promissor. As contribuições inovadoras deste trabalho são de suma importância quando se trata de projetos com cartas de controle, criando métodos bem definidos do ponto de vista da engenharia para criar sistemas de detecção de falhas com máxima eficiência.

Destaca-se também como resultado parcial deste trabalho a publicação aceita e apresentado no Congresso Brasileiro de Automática - CBA 2010 (Controle Estatístico de processos aplicado a detecção online de falhas em sistemas multivariados), que apresenta os resultados obtidos neste estudo.

## 6 REFERÊNCIAS BIBLIOGRÁFICAS

- Amantéa, A. C., Menezes, B. R., & Caminhas, W. M. (2010). Controle estatístico de processo aplicado à detecção online de falhas em sistemas multivariados . *CBA* .
- Bersimis, Sotiris, Psarakis, Stelios, Panaretos, & John. (2007, December 19). Multivariate Statistical Process Control Charts: An Overview. *Quality and Reliability Engineering Internacioanl* , 517-543.
- Caminhas, W. M., & Takahashi, R. H. (2001). Dynamic System Failure Detection and Diagnosis Employing Sliding Mode Observers and Fuzzy Neural Networks. . *9th IFSA World Congress e NAFIPS International Conference* , v. 1. p. 304-309.
- Caminhas, W. M., & Tavares, M. F. (1997). Estratégias de detecção e diagnóstico de falhas em sistemas dinâmicos. . *Universidade Estadual de Campinas., Faculdade de engenharia elétrica e de computação., Departamento de engenharia de sistema.* .
- Chen, C.-T. (1999). *Linear System Theory and Design*. New York: Oxford University Press.
- Chen, Q., Kruger, U., M. Meronk, & Leung, A. Y. (28 de August de 2003). Synthesis of T2 and Q statistics for process monitoring. *Control Engineering Practice* , 745-755.
- Hines, W. W., Montgomery, D. C., Goldsman, D. M., & Borror, C. M. (2006). *Probabilidade e Estatística na Engenharia* (quarta ed.). Rio de Janeiro, RJ, Brasil: LTC - Livros Técnico e Científicos Editora S. A.
- Isermann, R. (1984). Process fault-detection based on modeling and estimation methods – a survey.
- Lemos, A. P., Palhares, r. M., Menezes, B. R., Bomfim, C. H., & Caminhas, W. M. (2009, June 30). A Novelty Detection Approach for Condition Monitoring - A Case Study Applied to Monitoring a FCC Unit's Fractionator. *Elsevier* , 1-34.
- Liu, J., & Chen, D.-S. (03 de February de 2009). Fault Detection and Identification Using Modified Bayesian Classification on PCA Subspace. *I&EC Research Industrial & Engineering Chemistry Research* .
- Lowry, C. A., & Montgomery, D. C. (February de 1994). A review of multivariate control charts. *IIE Transactions* , 800-810.

MacGregor, J. F., & Kourti, T. (1995). Statistical Process Control of Multivariate Processes. *Control Engeneering Practice* , Vol.3, No3, 403-414.

Montgomery, D. C. (2004). *Introdução ao Controle Estatístico da Qualidade* (quarta ed.). Rio de Janerio, RJ, Brasil: LTC - Livros Técnicos e Científicos Editora S. A.

Oppenheim, A. V., Schafer, R. W., & Buck, J. R. (1999). *Discrete-Time Signal Processing* (second ed.). New Jersey: Prentice-Hall.

Pedro A. Morettin, C. M. (2006). *Análise e Séries Temporais* (segunda ed.). São Paulo, SP, Brasil: Editora Edgard Plucher LTDA.

Shlens, J. (April de 2009). A Tutorial on Principal Component Analysis. *Center for Neuyral Science, New Your University* .

Venkatasubramanian, V., & Rengaswamy, R. (22 de Abril de 2002). A review of process fault detection and diagnosis Part I: Quantitative model-based methods.

Venkatasubramanian, V., Rengaswamy, R., & Kavuri, S. N. (22 de Abril de 2002). A review of process fault detection and diagnosis Part II: Qualitative models and search strategies.

Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. N., & Yin, K. (22 de Abril de 2002). A review of process fault detection and diagnosis Part III: Process history based methods.