

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PRODUÇÃO**

**MDMAIC
UM ROADMAP SEIS SIGMA MULTIVARIADO**

Rogério Santana Peruchi

Itajubá, fevereiro de 2014

Tese de Doutorado	ROGÉRIO SANTANA PERUCHI	2014
--------------------------	--------------------------------	-------------

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM

ENGENHARIA DE PRODUÇÃO

Rogério Santana Peruchi

MDMAIC

UM ROADMAP SEIS SIGMA MULTIVARIADO

Tese submetida ao Programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para obtenção do título de *Doutor em Ciências em Engenharia de Produção*.

Área de Concentração: Engenharia de Produção

Orientadores: Prof. Anderson Paulo de Paiva, Dr.
Prof. Pedro Paulo Balestrassi, Dr.

Itajubá, fevereiro de 2014

Ficha catalográfica elaborada pela Biblioteca Mauá –
Bibliotecária Margareth Ribeiro- CRB_6/1700

P471m

Peruchi, Rogério Santana

MDMAIC: um roadmap seis sigma multivariado / Rogério
Santana Peruchi. -- Itajubá, (MG) : [s.n.], 2014.
170 p. : il.

Orientador: Prof. Dr. Anderson Paulo de Paiva.

Coorientador: Prof. Dr. Pedro Paulo Balestrassi.

Tese (Doutorado) – Universidade Federal de Itajubá.

1. Análise de Componentes Principais (PCA). 2. Análise de
Sistema de Medição (MSA). 3. Cartas de controle. 4. Índices
de Capabilidade de Processo (PCI). 5. Modelagem e otimizac_ão.
I. Paiva, A. P., orient. II. Balestrassi, P.P., coorient. III.
Universidade Federal de Itajubá. IV. Título.

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM

ENGENHARIA DE PRODUÇÃO

Rogério Santana Peruchi

MDMAIC

UM ROADMAP SEIS SIGMA MULTIVARIADO

Tese aprovada por banca examinadora em 28 de fevereiro de 2014, conferindo ao autor o título de *Doutor em Ciências em Engenharia de Produção*.

Banca examinadora:

Prof. Dr. Anderson Paulo de Paiva (Orientador)

Prof. Dr. Pedro Paulo Balestrassi (Orientador)

Prof. Dr. Eduardo Gomes Salgado (UNIFAL)

Prof. Dr. Fabricio José Pontes (EMBRAER)

Prof. Dr. Emerson José de Paiva (UNIFEI)

Prof. Dr. José Henrique de Freitas Gomes (UNIFEI)

Prof. Dr. Rafael Coradi Leme (UNIFEI)

Itajubá, fevereiro de 2014

DEDICATÓRIA

*A todos os amigos que me incentivaram,
em especial aos meus pais, Antônio
Genésio Peruchi e Célia Aparecida de
Santana Peruchi, à minha irmã Solange
Santana Peruchi e à minha namorada
Andreza da Silva.*

AGRADECIMENTOS

A DEUS por todas as dádivas, oportunidades e pessoas que coloca em meu caminho.

À minha família pela educação e incentivo nos momentos mais difíceis.

À minha namorada por me ouvir, incentivar e confiar no meu trabalho.

Aos meus orientadores, Dr. Anderson Paulo de Paiva e Dr. Pedro Paulo Balestrassi, pela amizade, incentivo, competência e motivação constante.

Aos professores Dr. Carlos Eduardo Sanches da Silva, Dr. João Batista Turrioni, Dr. João Roberto Ferreira, Dr. José Henrique de Freitas Gomes e Dr. Rapinder Sawhney pelas diversas contribuições desta tese.

Ao coordenador do Programa de Pós-Graduação em Engenharia de Produção Dr. Rafael Coradi Leme.

A todos os professores que disponibilizaram seu tempo e dividiram seus conhecimentos.

Aos amigos do grupo de pesquisa Gabriela, Jhon Jairo, Julian, Leonardo, Luiz Gustavo e esposa Neli, Patricia, Paulo Campos, Paulo Rotela, Paulo Maia, Pedro Papandrea, Rafael Miranda, Tabata, Tarcisio e todos os que estiveram comigo nesta jornada.

Aos meus parentes, em especial ao Bruno, tia Fátima, Marcel, Michele, tio Moacir e tia Silma, pela paciência em tantas vezes que o tempo me faltava.

Aos amigos de longa data Emerson, Enzo, Flávio, Lucas, Luiz Gustavo e Vitor, que torceram por mim e compreenderam minha ausência e por sempre me apoiarem.

Aos amigos do Tennessee Bill, Diogo, Enrique, Gagan, Junior e Gisele, Lavanya, Luciana e Gary, Luis e Roberta, Moraes, Neo, Seyed Ahmad, Vahid, Yasser e todos que me apoiaram durante meio estágio de doutorado nos Estados Unidos.

A equipe do laboratório de automação da manufatura da Unifei, em especial ao Veríssimo por ser sempre tão prestativo.

Agradeço a FAPEMIG, CNPq e, principalmente, CAPES pelo apoio e incentivo à pesquisa brasileira.

Enfim, a todos que sempre através de um gesto e palavra amiga, mesmo sem perceberem, deram-me forças a chegar até aqui.

EPÍGRAFE

“Toda verdade passa por três estágios. Primeiro, ela é ridicularizada. Segundo, ela é violentamente rejeitada. Terceiro, ela é aceita como auto evidente.”
Arthur Schopenhauer

RESUMO

Esta tese explora a aplicação de projetos Seis Sigma para solução de problemas multivariados em processos de manufatura. O principal objetivo desta pesquisa consiste em propor o *roadmap* MDMAIC (multivariado – definir, medir, analisar, melhorar (*improve*), controlar), baseado em análise de componentes principais para definir, medir, analisar, melhorar e controlar processos com múltiplas respostas correlacionadas. As principais contribuições deste trabalho não se resumem apenas ao *roadmap*, mas também em novos métodos para análise de sistema de medição, análise de capacidade de processo, modelagem e otimização de múltiplas respostas e projeto econômico de cartas de controle. A abordagem que viabilizou a integração das técnicas e ferramentas multivariadas ao MDMAIC consiste em analisar escores ponderados de componentes principais para grupos de variáveis, as quais devem ser separadas de acordo com seus objetivos de otimização. O *roadmap* proposto e os métodos específicos de cada etapa foram testados e validados através de dados simulados, dados da literatura e dados obtidos em laboratório para o processo de soldagem com arame tubular para o revestimento de chapas de aço carbono ABNT 1020 com aço inoxidável ABNT 316L.

Palavras-chave: análise de componentes principais (PCA), análise de sistema de medição (MSA), cartas de controle, DMAIC, índices de capacidade de processo (PCI), modelagem e otimização.

ABSTRACT

This dissertation explores the implementation of Six Sigma projects for problem-solving of multivariate manufacturing processes. This research aims to propose the MDMAIC (multivariate – define, measure, analyze, improve, control) roadmap, based on principal component analysis (PCA), in order to define, measure, analyze, improve and control processes with multiple correlated responses. The major contributions of this work are not limited only to the roadmap, but also new methods for measurement system analysis, process capability analysis, modeling and optimization of multiple responses and economic design of control charts. Weighted scores of principal components for group of variables (separated according to their optimization objective) was the approach applied to integrate multivariate tools and techniques into MDMAIC. Besides the proposed roadmap, new methods have been tested and validated by using simulated data, literature data and data from the cladding process of depositing ABNT 316L stainless steel onto ABNT 1020 carbon steel plates using flux-cored arc welding (FCAW).

Key-words: control charts, DMAIC, measurement system analysis (MSA), modeling and optimization, principal component analysis (PCA), process capability indexes (PCI).

LISTA DE FIGURAS

Figura 2.1 – (a) Foco do Seis Sigma e (b) Desvio de $1,5\sigma$ em longo prazo.....	27
Figura 2.2 – (a) Rotação imposta nos eixos das variáveis originais e (b) Novo eixo z_1 representando uma regressão linear ortogonal	37
Figura 2.3 – Interpretação geométrica da PCA	38
Figura 2.4 – Matriz da qualidade.....	40
Figura 2.5 – Relação entre satisfação do cliente e nível de desempenho do produto	41
Figura 2.6 – Diagrama de árvore (necessidades do cliente).....	42
Figura 2.7 – Diagrama de árvore (Ys do projeto).....	42
Figura 2.8 – Gráfico de Pareto para priorização dos Ys.....	44
Figura 2.9 – Diagrama de causa e efeito da variabilidade de um sistema de medição.....	51
Figura 2.10 – Componentes da variância combinada de um sistema de medição.....	52
Figura 2.11 – Processo de medição consistente	52
Figura 2.12 – Estabilidade de um processo de medição.....	53
Figura 2.13 – Biais de um processo de medição	54
Figura 2.14 – Linearidade de um processo de medição	54
Figura 2.15 – Representação gráfica de repetitividade e reprodutividade	55
Figura 2.16 – Relacionamentos entre bias e repetitividade.....	55
Figura 2.17 – Critérios de aceitação do sistema de medição.....	56
Figura 2.18 – Desvantagens do método de somas ponderadas.....	77
Figura 2.19 – Comparação entre NBI e método de somas ponderadas.....	78
Figura 2.20 – Método de interseção normal à fronteira - NBI	79
Figura 3.1 – Roadmap MDMAIC baseado em PCA.....	93
Figura 3.2 – Ilustração que caracteriza possíveis processos multivariados.....	96
Figura 3.3 – Diagrama de causa e efeito orientado a DOE	107
Figura 3.4 – Procedimento para otimização multivariada pelo método NBI-WPC	109
Figura 3.5 – Ilustração das ponderações do método de otimização proposto	110
Figura 3.6 – Elementos da otimização por NBI	111
Figura 4.1 – Princípio de operação da soldagem de revestimento	116
Figura 4.2 – Exemplos de camadas de revestimento depositadas a partir de processos de soldagem.....	116

Figura 4.3 – Perfil geométrico desejado do cordão de solda: a) Soldagem convencional; b) Soldagem de revestimento.....	117
Figura 4.4 – <i>Project charter</i>	118
Figura 4.5 – Diagrama de árvore das necessidades do cliente	119
Figura 4.6 – HOQ para o processo de soldagem de revestimento.....	120
Figura 4.7 – Gráfico de Pareto para priorização dos Ys.....	120
Figura 4.8 – Gráfico de Pareto com os pesos dos Ys selecionados.....	121
Figura 4.9 – Características geométricas do cordão de solda de revestimento	122
Figura 4.10 – Procedimento para medição da geometria do cordão de solda	123
Figura 4.11 – Cordões de solda selecionados para o estudo de GR&R	124
Figura 4.12 – Análise de estabilidade e capacidade para o grupo maximizar, WPC_{max}	126
Figura 4.13 – Análise de estabilidade e capacidade para o grupo minimizar, WPC_{min}	126
Figura 4.14 – Diagrama de causa e efeito para o DOE	129
Figura 4.15 – Gráfico de Pareto para o vetor WPC_{max}	131
Figura 4.16 – Gráfico de Pareto para o vetor WPC_{min}	131
Figura 4.17 – Gráfico de contorno e de superfície de resposta para WPC_{max}	134
Figura 4.18 – Gráfico de contorno e de superfície de resposta para WPC_{min}	134
Figura 4.19 – Fronteira de Pareto equiespaçadas para os vetores WPC_{max} (WPCa) e WPC_{min} (WPCb).....	135
Figura 4.20 – Análise de estabilidade e capacidade para grupo de variáveis com objetivo de maximização.....	136
Figura 4.21 – Análise de estabilidade e capacidade para grupo de variáveis com objetivo de minimização.....	137
Figura 4.22 – Análise de sensibilidade do projeto econômico das cartas de controle WPC_{max} e WPC_{min}	139

LISTA DE TABELAS

Tabela 2.1 – Benefícios do Seis Sigma no setor de manufatura	28
Tabela 2.2 – Roadmap DMAIC genérico.....	31
Tabela 2.3 – Definições para as correlações da matriz de QFD.....	43
Tabela 3.1 – Resumo dos métodos univariados, multivariados e propostos associados a cada passo do MDMAIC	94
Tabela 4.1 – Respostas analisadas nas pesquisas anteriores abordando a soldagem MIG/MAG ¹ ou com arame tubular ² para o revestimento de aços carbono com aços inoxidáveis.....	119
Tabela 4.2 – Composição química (%) do metal base e metal de adição.....	123
Tabela 4.3 – Estrutura de correlação entre os Ys	124
Tabela 4.4 – Análise de componentes principais para os Ys.....	125
Tabela 4.5 – Alvos e limites de especificação para os Ys, PCs e WPCs.....	127
Tabela 4.6 – Objetivo de desempenho para o processo multivariado	128
Tabela 4.7 – Parâmetros estudados nas pesquisas anteriores abordando a soldagem MIG/MAG ¹ ou com arame tubular ² para o revestimento de aços carbono com aços inoxidáveis.....	128
Tabela 4.8 – Parâmetros fixos do processo de soldagem de revestimento.....	129
Tabela 4.9 – Parâmetros variáveis e níveis de trabalho.....	130
Tabela 4.10 – Comparação entre os modelos completos (MC) e reduzidos (MR)	132
Tabela 4.11 – Análise de componentes principais para as respostas ponderadas	133
Tabela 4.12 – Parâmetros ótimos da soldagem com arame tubular para as operações de revestimento de aço carbono ABNT 1020 com aço inoxidável ABNT 316L considerando pesos diferentes entre as respostas	136
Tabela 4.13 – Alvos e limites de especificação para os Ys, PCs e WPCs na condição otimizada	137
Tabela 4.14 – Comparação do processo melhorado com o baseline	138
Tabela 4.15 – Dados para o projeto econômico das cartas de controle.....	138
Tabela 4.16 – Resultados ótimos da análise de sensibilidade para distintos tamanhos de subgrupo	139

LISTA DE ABREVIATURAS E SÍMBOLOS

Letras Latinas

D	Diluição do processo de soldagem
d	Metade da largura do intervalo de especificação Resíduos padronizados em modelos de regressão
E	Matriz de autovetores
e	Autovetor Resíduos em modelos de regressão
f	Função objetivo
g	Função restrição
h	Elementos da diagonal principal da matriz X
I	Corrente
k	Fator de cobertura
L	Função de mínimos quadrados Função Lagrangeana
M	Média do intervalo de especificação
N	Tamanho da amostra Distância bico contato peça
o	Número de operadores
P	Penetração do cordão de solda, <i>P-value</i>
p	Número de peças
q	Número de Ys (ou características da qualidade)
R	Amplitude Reforço do cordão de solda
R	Matriz de correlação amostral
r	Número de réplicas
s	Desvio-padrão amostral
S	Matriz de variância-covariância amostral
T	Alvo Tensão
U	Incerteza expandida

x	Variável de controle
X	Matriz de variáveis de controle
\bar{X}	Média amostral
w	Ponderação em funções objetivo
W	Largura do cordão de solda
Y	Variável de resposta

Letras gregas

α	Nível de significância
β	Coefficiente da equação de regressão
ε	Erro do modelo de regressão
μ	Média populacional
Σ	Matriz variância-covariância populacional
	Nível sigma multivariado
λ	Autovalor
	Multiplicador de Lagrange
ρ	Correlação populacional
	Raio da região experimental
σ	Desvio-padrão populacional
σ^2	Variância populacional
ζ	Alvo para componente principal
η	Rendimento do processo de soldagem

Siglas

%R&R	Percentual de variação de repetitividade e reprodutividade
ABNT	Associação Brasileira de Normas Técnicas
AIAG	<i>Automotive Industry Action Group</i>
ANOVA	Análise de Variância
AHP	<i>Analytic Hierarchy Process</i> (análise hierárquica de processo)
AP	Área de Penetração
AR	Área de Reforço

AT	Área Total
BB	<i>Black Belt</i>
CCD	<i>Central Composite Design</i> (arranjo composto central)
C_p	Índice de capacidade de processo
C_{pm}	Índice de capacidade de processo
C_{pmk}	Índice de capacidade de processo
C_{pk}	Índice de capacidade de processo
CQI	<i>Continuous Quality Improvement</i> (melhoria contínua da qualidade)
CTQ	<i>Critical-To-Quality</i> (característica crítica da qualidade)
DEA	<i>Data Envelopment Analysis</i> (análise envoltória de dados)
DMAIC	Definir (<i>Define</i>), Medir (<i>Measure</i>), Analisar (<i>Analyze</i>), Melhorar (<i>Improve</i>) e Controlar (<i>Control</i>).
DOE	<i>Design of Experiments</i> (projeto de experimentos)
DPMO	Defeitos por milhão de oportunidades
DPU	Defeitos por unidade
EPC	<i>Engineering Process Control</i> (controle de processos de engenharia)
FCAW	<i>Flux Cored Arc Welding</i> (soldagem a arco elétrico com arames tubulares)
GB	<i>Green Belt</i>
GR&R	<i>Gage Repeatability and Reproducibility</i> (repetitividade e reprodutividade do sistema de medição)
GUM	<i>Guide to the Expression of Uncertainty in Measurement</i> (guia para expressão de incerteza em medição)
HOQ	<i>House of Quality</i> (casa da qualidade)
ICP	Índices de Capacidade de Processo
ICPM	Índice de Capacidade de Processo Multivariado
IWLS	<i>Iterative Weighted Least Squares</i> (mínimos quadrados ponderados iterativos)
LCL	<i>Lower Control Limit</i> (limite inferior de controle)
LOF	<i>Lack-of-fit</i> (falta de ajuste)
LSL	<i>Lower Specification Limit</i> (limite inferior de especificação)
LTB	<i>Larger-the-better</i> (quanto maior melhor)
MANOVA	<i>Multivariate Analysis of Variance</i> (análise multivariada de variância)
MBB	<i>Master Black Belts</i>
MC	Modelo de regressão completo

MC _p	Índice multivariado de capacidade de processo (WANG e CHEN, 1998)
MDMAIC	Multivariado (<i>Multivariate</i>): Definir (<i>Define</i>), Medir (<i>Measure</i>), Analisar (<i>Analyze</i>), Melhorar (<i>Improve</i>) e Controlar (<i>Control</i>)
MMSE	<i>Multivariate Mean Square Error</i> (Erro quadrático médio multivariado – EQMM)
MR	<i>Moving Range</i> (média móvel) Modelo de regressão reduzido
MS	<i>Mean Square</i> (média quadrática)
MSA	<i>Measurement System Analysis</i> (análise do sistema de medição)
MSE	<i>Mean Square Error</i> (erro quadrático médio – EQM)
MSO	<i>Mean Square for Operator</i> (média quadrática para o fator operador)
MSP	<i>Mean Square for Part-to-part</i> (média quadrática para o fator peça-a-peça)
MSPO	<i>Mean Square for Part*Operator</i> (média quadrática para a interação peça*operador)
MWAC _p	Índice multivariado de capacidade de processo (proposto)
MWC _p	Índice multivariado de capacidade de processo (WANG, 2005)
MXC _p	Índice multivariado de capacidade de processo (PERAKIS e XEKALAKI, 2012)
ndc	Número de categorias distintas
NBI	<i>Normal Boundary Intersection</i> (interceção normal à fronteira)
NTB	<i>Nominal-the-best</i> (nominal é melhor)
OEE	<i>Overall Equipment Effectiveness</i> (efetividade global de equipamento)
OLS	<i>Ordinary Least Squares</i> (mínimos quadrados ordinários)
P/T	Taxa de precisão à tolerância
PC	<i>Principal Component</i> (componente principal)
PCA	<i>Principal Component Analysis</i> (análise de componentes principais)
PCR	<i>Principal Component Regression</i> (regressão por componentes principais)
PDCA	Planejar (<i>Plan</i>), Fazer (<i>Do</i>), Checar (<i>Check</i>), Agir (<i>Act</i>)
PLS	<i>Partial Least Squares</i> (mínimos quadrados parciais)
POBREP	<i>Process-oriented Basis Representation</i> (representação com base orientada a processo)
PPM	Peças por milhão
QD	Desdobramento da Qualidade

QFD	<i>Quality Function Deployment</i> (desdobramento da função qualidade)
RMM	Regressão múltipla multivariada
RPD	<i>Robust Parameter Design</i> (projeto de parâmetro robusto)
R&R	<i>Repeatability and Reproducibility</i> (repetitividade e reprodutividade)
RSM	<i>Response Surface Methodology</i> (metodologia de superfície de resposta)
SCM	<i>Supply Chain Management</i> (gestão da cadeia de suprimentos)
SIPOC	<i>Suppliers-Inputs-Process-Outputs-Customers</i> (fornecedor – entradas – processo – saídas – clientes)
SM	Sistema de Medição
SNR	<i>Signal-to-Noise Ratio</i> (relação sinal-ruído)
SS	<i>Sum of Squares</i> (soma de quadrados)
SPC	<i>Statistical Process Control</i> (controle estatístico de processo - CEP)
STB	<i>Smaller-the-better</i> (quanto menor melhor)
TD	Taxa de deposição do processo de soldagem
TF	Taxa de fusão do processo de soldagem
TQC	<i>Total Quality Control</i> (controle de qualidade total)
TPM	<i>Total Productive Maintenance</i> (manutenção produtiva total)
TQM	<i>Total Quality Management</i> (gestão da qualidade total)
u_c	Incerteza combinada
UCL	<i>Upper Control Limit</i> (limite superior de controle)
USL	<i>Upper Specification Limit</i> (limite superior de especificação)
V_a	Velocidade de alimentação do arame
VOC	<i>Voice of Customer</i> (voz do cliente)
V_s	Velocidade de soldagem
VSM	<i>Value Stream Map</i> (mapeamento da cadeia de valor)
WMMSE	<i>Weighted Multivariate Mean Square Error</i> (erro quadrático médio multivariado ponderado – EQMM _p)
WPC	<i>Weighted Principal Components</i> (componentes principais ponderados – CPP)

SUMÁRIO

1. INTRODUÇÃO	19
1.1 Tema	19
1.2 Problema de pesquisa.....	21
1.3 Objetivos	21
1.4 Contribuições	22
1.5 Limitações.....	23
1.6 Metodologia de pesquisa	23
1.7 Estrutura da tese.....	24
2. REVISÃO DA LITERATURA	26
2.1 Considerações iniciais.....	26
2.2 Seis Sigma.....	26
2.2.1 Roadmap DMAIC	29
2.2.2 Análise crítica sobre o <i>roadmap</i> genérico.....	32
2.2.3 Caso univariado.....	33
2.2.4 Caso multivariado	33
2.3 Análise de componentes principais.....	34
2.3.1 Abordagem algébrica	35
2.3.2 Abordagem geométrica	37
2.3.3 Seleção de componentes principais.....	38
2.3.4 Matriz de correlação e matriz de variância-covariância.....	39
2.4 Desdobramento da função qualidade – QFD.....	39
2.4.1 Tradução da voz do cliente – VOC	40
2.4.2 Obtenção de Ys a partir das necessidades do cliente	42
2.4.3 Correlação entre Ys e as necessidades do cliente	42
2.4.4 Priorização dos Ys.....	43
2.4.5 Avaliação da correlação entre Ys.....	44
2.4.6 Caso univariado.....	46
2.4.7 Caso multivariado	47
2.5 Análise multivariada de sistemas de medição	48
2.5.1 Incerteza de medição.....	50
2.5.2 Consistência	52

2.5.3	Estabilidade	52
2.5.4	Capabilidade.....	53
2.5.5	Caso univariado.....	57
2.5.6	Caso multivariado	60
2.6	Análise multivariada de capacidade de processo	62
2.6.1	Caso univariado.....	63
2.6.2	Caso multivariado	63
2.7	Modelagem de múltiplas respostas	66
2.7.1	Mínimos quadrados ordinários – OLS	66
2.7.2	Coeficiente de determinação	67
2.7.3	Análise residual	68
2.7.4	Diagnóstico de observações influentes	69
2.7.5	Teste para falta de ajuste	69
2.7.6	Caso univariado.....	71
2.7.7	Caso multivariado	71
2.8	Otimização de múltiplas respostas.....	73
2.8.1	Caso univariado.....	74
2.8.2	Caso multi-objetivo	75
2.8.3	Caso multivariado	80
2.9	Cartas de controle multivariadas.....	84
2.9.1	Caso univariado.....	85
2.9.2	Caso multivariado	87
2.9.3	Projeto econômico de cartas de controle.....	90
2.10	Considerações finais	92
3.	MDMAIC: UM ROADMAP MULTIVARIADO	93
3.1	Considerações iniciais.....	93
3.2	Etapa “Definir”	96
3.2.1	D1: identificar e mapear processo relevante	96
3.2.2	D2: <i>Project charter</i>	96
3.3	Etapa “Medir”	97
3.3.1	M1: selecionar Ys.....	97
3.3.2	M2: validar sistema de medição.....	98
3.3.3	M3: avaliar capacidade do processo atual e definir objetivos	101
3.4	Etapa “Analisar”	105

3.4.1	A1: Identificar potenciais Xs.....	105
3.4.2	A2: selecionar poucos vitais Xs	106
3.5	Etapa “Melhorar”	107
3.5.1	I1: quantificar relacionamento dos Xs com os Ys e PCs	108
3.5.2	I2: otimização do processo pelas WPCs	109
3.5.3	I3: conduzir teste piloto para as ações de melhoria.....	111
3.6	Etapa “Controlar”	111
3.6.1	C1: determinar capacidade do processo melhorado	111
3.6.2	C2: implementar planos de controle.....	111
3.7	Considerações finais	113
4.	APLICAÇÃO DO ROADMAP MULTIVARIADO	115
4.1	Considerações iniciais.....	115
4.2	D1: identificar e mapear processo relevante.....	115
4.3	D2: Project charter	117
4.4	M1: selecionar Ys	118
4.5	M2: validar sistema de medição	122
4.6	M3: avaliar capacidade do processo e definir objetivos.....	125
4.7	A1: identificar potenciais Xs	128
4.8	A2: selecionar poucos vitais fatores de influência.....	130
4.9	I1: quantificar relacionamento dos Xs com os Ys e PCs.....	131
4.10	I2: Otimização do processo pelas PCs.....	133
4.11	I3: conduzir teste piloto para as ações de melhoria	135
4.12	C1: determinar capacidade do processo melhorado	136
4.13	C2: implementar planos de controle	138
4.14	Considerações finais	140
5.	CONCLUSÃO	143
5.1	Conclusões gerais	143
5.2	Sugestões para trabalhos futuros.....	144
	REFERÊNCIAS BIBLIOGRÁFICAS	146
	ANEXO A – Dados experimentais.....	158
	ANEXO B – Dados simulados.....	162
	ANEXO C – Superfícies de resposta	166
	ANEXO D – Cartas de controle.....	168

1. INTRODUÇÃO

1.1 Tema

Seis Sigma é definido por Linderman *et al.* (2003) como um método organizado e sistemático para a melhoria do processo estratégico e desenvolvimento de novos produtos e serviços, que se baseia em métodos estatísticos e científicos para fazer reduções drásticas nas taxas de defeitos definidos pelo cliente.

Pesquisas científicas, tal como Schroeder *et al.* (2008) e Zu *et al.* (2008), têm tentado determinar quais elementos fazem o Seis Sigma ser efetivo. Além do foco nas métricas (índices de validação do sistema de medição, índices de capacidade de processo, etc.), o procedimento de melhoria estruturado do Seis Sigma é visto como uma contribuição efetiva e inovadora para gestão da qualidade. Este procedimento de melhoria é geralmente conhecido sobre o acrônimo DMAIC – Definir, Medir, Analisar, Melhorar (do inglês, *Improve*) e Controlar (DE MAST e LOKKERBOL, 2012).

DMAIC em termos funcionais é similar ao seu predecessor em solução de problemas de manufatura, PDCA – Planejar, Fazer (do inglês, *Do*), Checar, Agir e o método de Sete Passos de Juran e Gryna (BALAKRISHNAN *et al.*, 1995). Na teoria de rotinas organizacionais, DMAIC é uma meta-rotina: uma rotina para estabelecer mudanças ou para projetar novas rotinas (SCHROEDER *et al.*, 2008). Originalmente descrito como um método para redução de variação, DMAIC é aplicado em prática como uma abordagem genérica de melhoria e solução de problemas (DE KONING e DE MAST, 2006; MCADAM e LAFFERTY, 2004). É o instrumento usado na implementação de Seis Sigma como uma metodologia de melhoria de processo (CHAKRAVORTY, 2009).

Seis Sigma e seu método DMAIC emergiram e se desenvolveram na prática. Foi construído sob noções do campo de engenharia da qualidade, incorporando ideias de controle estatístico da qualidade e gestão da qualidade total. Sua ampla adoção na prática tem garantido uma análise científica crítica de processos (DE MAST e LOKKERBOL, 2012).

O método DMAIC está, como todo método de solução de problemas, sujeito ao *trade-off* poder/generalidade, o qual tem primeiro resultado na evolução em direção a uma maior generalização (além de manufatura e redução de variação) e, ultimamente, para considerável quantidade de adaptações a domínios específicos. De Mast e Lokkerbol (2012) concluíram que o método DMAIC é aplicável para uma ampla gama de problemas bem-estruturados e

semiestruturados. O DMAIC, em especial o DMAIC adaptado para domínios específicos, serve como rotina para organizar problemas, com objetivo de transformá-los em bem-estruturados. No entanto, DMAIC parece não se ajustar a solução de problemas mal estruturados, nos quais dinâmica humana, percepções subjetivas e valores pessoais são aspectos importantes. Métodos de estruturação de problemas com objetivo de explorar e reconciliar múltiplos pontos de vista subjetivos, tal como descrito por Mingers e Rosenhead (2004), são, provavelmente, melhor ajustados a estes tipos de problemas.

Observa-se na literatura que diversas pesquisas têm aplicado o *roadmap* DMAIC como método para solução de problemas de manufatura (ANTONY *et al.*, 2012; BARRY *et al.*, 2012; BILGEN e SEM, 2012; CHEN e TSOU, 2003; GIJO *et al.*, 2011; KAIJA *et al.*, 2010; KUMAR *et al.*, 2007; KUMARAVADIVEL e NATARAJAN, 2013; LEE e WEI, 2010; LI *et al.*, 2008; LI e AL-REFAIE, 2008; LO *et al.*, 2009; SAHOO *et al.*, 2008; TONG *et al.*, 2004; TSOU e CHEN, 2005; VINODH *et al.*, 2014) e serviços (AAKRE; VALLEY; O’CONNOR., 2010; CHAN, 2004; FRINGS e GRANT, 2005; FURTERER e ELSHENNAWY, 2005; KUMI e MORROW, 2006). Todavia, levando em consideração que, geralmente, os processos industriais apresentam múltiplas respostas (TANCO *et al.*, 2009), pouco tem sido publicado sobre a utilização de uma abordagem multivariada para solução de problemas de manufatura através do *roadmap* estruturado DMAIC.

Um trabalho que, particularmente, merece ser mencionado é o de Chang *et al.* (2012), o qual descreve a aplicação de um projeto Seis Sigma, usando DMAIC, para integração de controle estatístico de processo (*statistical process control* – SPC) a existentes práticas de controle de processos de engenharia (*Engineering process control* – EPC). Na fase de análise do *roadmap*, os autores usaram carta de controle multivariada, T^2 de Hotelling, para avaliar seis características da qualidade em um processo de cura de mangueiras de alta pressão. No entanto, um projeto Seis Sigma, de fato, não se restringe apenas a SPC.

Fundamentando-se no trabalho de De Mast e Lokkerbol (2012), os quais afirmaram que um *roadmap* DMAIC para domínios específicos é mais poderoso na solução destes problemas em particular, esta tese pretende propor um *roadmap* DMAIC multivariado, o MDMAIC (*Multivariate: Define, Measure, Analyze, Improve, Control*). Através da técnica estatística multivariada de análise de componentes principais (*Principal Component Analysis* – PCA) será demonstrado como integrar todas as etapas do Seis Sigma à otimização de processos de caráter multivariado (múltiplas respostas correlacionadas), considerando não apenas SPC, mas também outras técnicas como desdobramento da função qualidade (*Quality Function*

Deployment – QFD), análise de sistema de medição (*Measurement System Analysis – MSA*), projeto de experimentos (*Design of Experiments – DOE*) e otimização.

Para validação do método proposto nesta pesquisa serão utilizados dados da literatura, dados reais obtidos em laboratório e dados simulados. Os dados da literatura referem-se ao trabalho de Gomes *et al.* (2013) que propuseram um método de otimização multivariado com ponderação, chamado *Weighted Multivariate Mean Square Error* (WMMSE). O planejamento experimental, para avaliação do sistema de medição, consiste em 8 peças selecionadas do arranjo CCD (*Central Composite Design*) com 3 operadores executando as medições para os parâmetros geométricos do cordão de solda. Índices multivariados de capacidade de processo foram estimados para determinar o *baseline* e objetivos do projeto. A modelagem e otimização deste processo multivariado seguirá o procedimento do método proposto nesta tese. Finalmente, os experimentos simulados de confirmação foram avaliados para comparar com a estabilidade e capacidade inicial do processo.

1.2 Problema de pesquisa

Quanto mais complexas forem as necessidades dos clientes e consumidores, mais características da qualidade serão necessárias para atingir tal expectativa. Este perfil de exigência dos clientes atuais pode conferir aos processos de manufatura o caráter multivariado (PAIVA, 2006). Considerando processos multivariados de manufatura, o problema de pesquisa desta tese resume-se em como criar um método estruturado para resolver problemas multivariados, nos quais o analista possui controle sobre os parâmetros do processo e deseja-se otimizar múltiplas respostas correlacionadas.

1.3 Objetivos

O objetivo principal desta tese é: **propor um *roadmap* (MDMAIC: *Multivariate – Define, Measure, Analyze, Improve, Control*), baseado em escores de componentes principais sobre *clusters* de respostas com mesmo objetivo de otimização, para solução de problemas específicos, os quais envolvam múltiplas respostas correlacionadas.**

Em decorrência do objetivo principal desta pesquisa, alguns objetivos secundários podem ser destacados:

- Propor novos índices multivariados para avaliação de sistemas de medição;
- Propor novos índices de capacidade, incluindo uma proposta de cálculo de nível sigma para processos multivariados;

- Propor um método multivariado de otimização por interseção normal à fronteira que pondera as múltiplas respostas usando uma matriz QFD;
- Controlar processos multivariados através do projeto econômico de cartas de controle para os escores ponderados de componentes principais;
- Aplicar o MDMAIC no processo soldagem com arame tubular para o revestimento de chapas de aço carbono ABNT 1020 com aço inoxidável ABNT 316L.

1.4 Contribuições

O ineditismo desta pesquisa resume-se na elaboração de um *roadmap* capaz de orientar analistas na condução de projetos Seis Sigma para resolver problemas de múltiplas respostas. Alguns pesquisadores (Paiva *et al.*, 2007; 2009; 2010; 2012; Gomes *et al.*, 2013) têm aplicado métodos baseados em PCA sobre o conjunto de dados para reduzir a dimensionalidade e viabilizar a solução do problema. No entanto, o desenvolvimento desta tese tem demonstrado algumas dificuldades, principalmente, ao converter os limites de especificação das variáveis originais em escores de componentes principais. Executar PCA para todo conjunto de dados, quando há presença de correlações positivas e negativas, pode gerar autovetores positivos e negativos. Por conseguinte, os limites de especificação em termos de escore de componente principal são estimados ineficientemente ao aplicar a combinação linear dos autovetores com as especificações das variáveis originais.

Tendo em vista que muitos dos processos industriais são de caráter multivariado e levando em consideração a discussão acima, esta tese pretende integrar de forma eficiente técnicas estatísticas multivariadas a uma estrutura organizada para condução de projetos de melhoria. Em decorrência do aporte de conhecimento gerado no desenvolvimento desta tese, contribuições serão endereçadas aos seguintes tópicos:

- Novo *roadmap* MDMAIC que integra técnicas estatísticas multivariadas à condução de projetos Seis Sigma;
- Novo método multivariado para avaliar e classificar sistemas de medição;
- Novos índices multivariados de capacidade de processo;
- Novo método de otimização multivariado que pondera os Ys através das importâncias relativas obtidas por matriz QFD;
- Nova proposta de projeto econômico de cartas de controle de Shewhart para escores ponderados de componentes principais sobre grupos de variáveis.

A abordagem utilizada nesta tese gerou a seguinte publicação

PERUCHI, R.S.; BALESTRASSI, P.P.; PAIVA, A.P.; FERREIRA, J.R.; CARMELOSSI, M.S. A new multivariate gage R&R method for correlated characteristics. *International Journal of Production Economics*, v.144, p.301-3015, 2013.

a qual representa a primeira contribuição já validada, referente ao tópico **Novo método multivariado para avaliar e classificar sistemas de medição**.

1.5 Limitações

O conjunto de conceitos exigidos em projetos Seis Sigma é de fato muito abrangente. Assim como Tang *et al.* (2007) destacaram, é óbvio que o Seis Sigma possui limitações e não pode ser solução universal para qualquer organização e/ou qualquer situação. Além disso, De Mast e Lokkerbol (2012) destacaram que o *roadmap* DMAIC é mais poderoso na solução de problemas bem-estruturados de domínios específicos. Por conseguinte, limitações quanto ao tipo de variáveis, processos e técnicas estatísticas multivariadas foram impostas para viabilizar a conclusão desta pesquisa. Para aplicar o *roadmap* proposto, assume-se que:

- Variáveis dependentes e independentes são contínuas;
- Analista possui total controle sobre as variáveis de entrada do processo;
- Os escores obtidos por PCA devem se aproximar de uma distribuição normal;
- A técnica estatística multivariada usada para reduzir dimensionalidade do problema restringe-se à PCA;
- Foco do *roadmap* está na aplicação das ferramentas quantitativas do *roadmap* Seis Sigma para otimizar processos (exceção ao QFD que é qualitativo). Destaque para análise de sistemas de medição, índices de capacidade de processo, modelagem e otimização de múltiplas respostas correlacionadas e cartas de controle por PCA.

De acordo com as considerações destacadas acima, determina-se que o *roadmap* proposto é mais adequado para solução de problemas multivariados de manufatura, nos quais se deseja usar uma abordagem quantitativa sobre variáveis contínuas. Neste caso, o analista está interessado em determinar a configuração dos parâmetros de entrada que otimizam as múltiplas respostas que representam o processo multivariado.

1.6 Metodologia de pesquisa

Esta pesquisa caracteriza-se por ser de natureza aplicada devido ao seu interesse prático, isto é, que os resultados sejam aplicados ou utilizados imediatamente na solução de problemas

que ocorrem na realidade. Quanto aos seus objetivos, a pesquisa pode ser classificada como normativa. Neste caso, primariamente, tem-se interesse no desenvolvimento de políticas, estratégias e ações para aperfeiçoar os resultados disponíveis na literatura existente, para encontrar uma solução ótima para novas definições de problemas ou para comparar várias estratégias relativas a um problema específico (BERTRAND e FRANSOO, 2002). Esta pesquisa possui uma Abordagem Quantitativa, pois considera que opiniões e informações podem ser traduzidas em números e analisadas estatisticamente.

O método para condução da pesquisa será o experimental, pois segundo Bryman (2004), a pesquisa experimental:

- Permite ao investigador estabelecer fortes relações de causalidade; ou seja, um experimento permite a identificação de uma função de transferência do tipo $Y=f(x)$;
- Apresenta uma maior facilidade no estabelecimento de relações de causa e efeito;
- É dotada de validade interna, ou seja, a capacidade de se concluir que as variáveis independentes realmente afetam a variável dependente;
- Quando se utiliza a técnica experimental é necessário que se tenha controle das variáveis de estudo, para que seja possível alterá-las segundo as necessidades do estudo. No entanto, preocupando-se em não ameaçar a validade externa da pesquisa em questão.

A técnica para a coleta de dados baseou-se principalmente na observação estruturada ou sistemática. Esta técnica realiza-se em condições controladas, para responder a propósitos preestabelecidos. Todavia, as normas não devem ser padronizadas nem rígidas, pois tanto as situações quanto os objetos e objetivos da investigação podem ser muito diferentes. Nela, o observador sabe o que procura e o que carece de importância em determinada situação; deve ser objetivo, reconhecer possíveis erros e eliminar sua influência sobre o que vê ou recolhe. A coleta de dados do tipo contínuo deve ser executada através de um instrumento de medição, o qual deverá ser validado quanto à sua adequação para o processo de fabricação em análise. Os dados devem ser coletados de forma aleatória, caso contrário, o procedimento de coleta de dados pode reproduzir valores tendenciosos.

1.7 Estrutura da tese

Esta tese está estruturada em cinco capítulos. O primeiro apresentou a contextualização desta pesquisa, apontou os objetivos a serem alcançados, assim como o método de pesquisa adotado. Os próximos capítulos estão organizados da seguinte forma:

- O capítulo dois, inicialmente, apresentará uma visão geral sobre Seis Sigma, com enfoque sobre o *roadmap* DMAIC, e a técnica estatística multivariada, análise de componentes principais. Ainda neste capítulo, serão detalhadas as principais técnicas e ferramentas do *roadmap* DMAIC, focando principalmente nos casos multivariados;
- O capítulo três detalhará o *roadmap* MDMAIC proposto, assim como as contribuições pontuais relacionadas ao desenvolvimento de cada técnica e ferramenta;
- O capítulo quatro mostrará a aplicação do MDMAIC e contribuições propostas sobre o processo de soldagem com arame tubular para o revestimento de chapas de aço carbono ABNT 1020 com aço inoxidável ABNT 316L;
- Por fim, o capítulo cinco encerra a tese, apresentando as conclusões e sugestões para pesquisas futuras.

2. REVISÃO DA LITERATURA

2.1 Considerações iniciais

Conforme determinado na seção 1.7, este capítulo apresentará a fundamentação teórica para elaboração desta tese. Na seção 2.2, uma visão geral sobre Seis Sigma será apresentada, tais como, origem, definições, exemplos de empresas que adotaram o Seis Sigma, sistema *Belt* e particularidades do projeto. Em seguida, discute-se acerca dos *roadmaps* DMAIC (Definir, Medir, Analisar, Melhorar – *Improve*, Controlar) disponíveis na literatura, assim como a utilização de técnicas univariadas e multivariadas em projetos Seis Sigma. A seção 2.3 demonstrará a técnica estatística multivariada, PCA (*Principal Component Analysis*), que foi utilizada como técnica intermediária para obtenção dos resultados do projeto Seis Sigma. Na seção 2.4, o QFD (*Quality Function Deployment*) como técnica para traduzir a voz do cliente em características de projeto será discutido. A seção 2.5, destacará a importância de se analisar o sistema de medição como pré-requisito para a continuidade do projeto. Já a seção 2.6, tem o objetivo de mostrar como avaliar o desempenho de um processo multivariado através de índices de capacidade. As seções 2.7 e 2.8 demonstrarão como viabilizar a modelagem e otimização de um processo multivariado através da técnica PCA. Por fim, a seção 2.9 apresentará as principais cartas de controle multivariadas construídas através de PCA.

2.2 Seis Sigma

Bill Smith, um engenheiro da Motorola, desenvolveu o programa Seis Sigma como uma forma de atender às necessidades de melhoria da qualidade e redução de defeitos em seus produtos. Bob Galvin, CEO da Motorola, ficou impressionado com os resultados de sucesso desta metodologia e decidiu aplicar o Seis Sigma com foco nos processos de manufatura. Entre 1987 e 1994 foi alcançada uma redução de 94% dos defeitos em semicondutores (MONTGOMERY e WOODAL, 2008). Empresas como a Allied Signal, IBM e General Electric adotaram o Seis Sigma como requisito corporativo para as operações estratégicas e táticas para produzir resultados de alto nível, melhorar processos de trabalho, ampliar as competências dos trabalhadores e mudança cultural (ABOELMAGED, 2010).

Linderman *et al.* (2003) trataram da necessidade de uma definição comum para Seis Sigma. Os autores propuseram que Seis Sigma é um método organizado e sistemático, para a melhoria do processo estratégico e desenvolvimento de novos produtos e serviços, que se

baseia em métodos estatísticos e científicos para fazer reduções drásticas nas taxas de defeitos definidos pelo cliente. Adicionalmente a esta definição, Brady e Allen (2006), destacaram dois princípios, retorno financeiro dos projetos e formação de não estatísticos no uso profissional das ferramentas com um mínimo de teoria. Em uma publicação mais recente, Schroeder *et al.* (2008) atualizaram a definição de Linderman *et al.* (2003), ao declarar que Seis Sigma é uma estrutura meso-paralela organizada para reduzir variação em processos organizacionais usando especialistas em melhoria, um método estruturado e métricas de desempenho com o objetivo de alcançar objetivos estratégicos.

Kwak e Anbari (2006) ao diferenciar Seis Sigma de outras iniciativas, resumiram esta metodologia da seguinte forma:

$$\begin{aligned} \text{Seis Sigma} = & \text{TQM} + \text{maior foco no cliente} + \text{gestão de projetos} & (2.1) \\ & + \text{ferramentas adicionais de análise de dados} + \text{retorno financeiro} \end{aligned}$$

Segundo Montgomery e Woodall (2008), um fator determinante no sucesso desta metodologia consiste no seu foco em reduzir a variação de características críticas do produto sobre um alvo especificado, em nível no qual a ocorrência de uma falha ou defeito seja praticamente improvável. A Figura 2.1a ilustra esta informação, onde 1 sigma determina uma taxa de defeito de 317.300 em 1 milhão e o nível 6 sigma com apenas 0,002 defeitos em 1 milhão. Todavia, nenhum processo ou sistema é eternamente estável e, mesmo nas melhores condições, perturbações deverão ocorrer. Por este motivo, espera-se um desvio teórico de 1,5 sigma do desempenho do processo, o que resulta no nível sigma 3,4 defeitos em 1 milhão (Figura 2.1b).

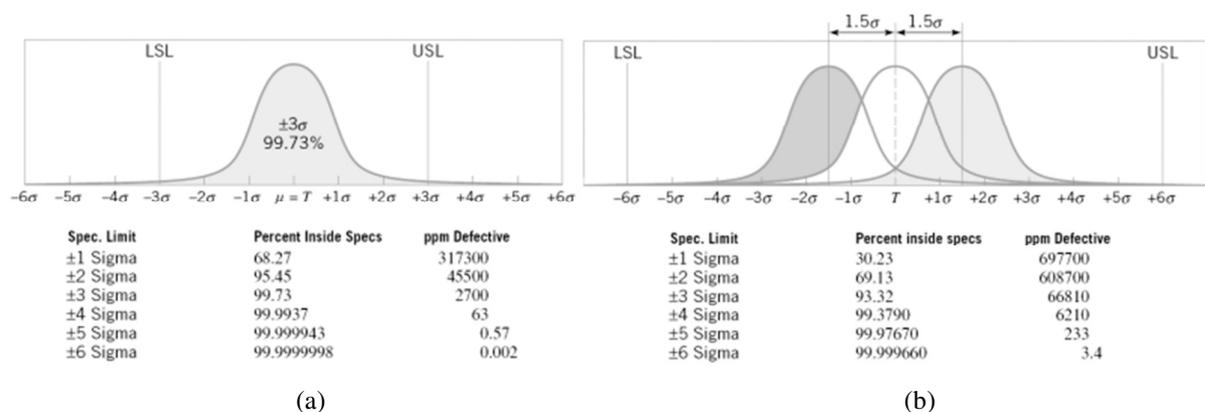


Figura 2.1 – (a) Foco do Seis Sigma e (b) Desvio de 1,5 σ em longo prazo
Fonte: Montgomery e Woodall (2008)

Kumar *et al.* (2008) e Kwak e Anbari (2006), revisando as pesquisas sobre Seis Sigma, destacaram os principais resultados tangíveis, obtidos no setor de manufatura. Tabela 2.1 resume as organizações, projetos, benefícios, melhorias e *savings* apresentados pelos autores.

Tabela 2.1 – Benefícios do Seis Sigma no setor de manufatura

Organização/ projeto	Métrica/ medida	Savings (em dólares)
Motorola 1992	Níveis de defeitos no processo	Redução em 150 vezes
Raytheon/ sistema de integração de aeronaves	Tempo de inspeção da manutenção (em dias)	Redução em 88%
GE/ empreendimento de aluguel <i>railcar</i>	Tempo de reparo	Redução de 62%
Allied Signal (Honeywell)/ planta de laminação em <i>South Carolina</i>	Capacidade/ tempo de ciclo/ estoque/ entrega no prazo	Acima de 50%/ até 50%/ até 50%/ aumento em 100%
Allied Signal (Honeywell)/ pastilha de freio Bendix IQ	Tempo de ciclo de entrega de pedido	Reduzido de 18 para 8 meses
Hughes aircraft's missile systems group/ operações de soldagem	Qualidade/ produtividade	Melhorou 1000%/ melhorou 50%
Continental Teves/ montagem de eixo e freio	Taxa de falhas	Redução acima de 50%
Borg Warner Turbo Systems	Financeiro	\$1,5 milhões anualmente desde 2002
GE	Financeiro	\$2 bilhões em 1999
Motorola (1999)	Financeiro	\$15 bilhões em 11 anos
Dow chemical/ projeto de entrega de trilhos	Financeiro	Savings de \$2,45 milhões em despesas de capital
DuPont/ planta de Yerkes em New York (2000)	Financeiro	Savings acima de \$25 milhões
Telefônica de España (2001)	Financeiro	Savings e aumento na receita de 30 milhões de euros em 10 meses
Texas instruments	Financeiro	\$600 milhões
Johnson and Johnson	Financeiro	\$500 milhões
Honeywell	Financeiro	\$1,2 bilhão
Ford/ defeitos de superfícies em painéis externos	Financeiro	\$500.000

Fonte: Kumar *et al.* (2008) e Kwak e Anbari (2006).

O Seis Sigma utiliza uma variedade de especialistas em melhoria para alcançar suas metas, frequentemente referidos como Black Belts (BBs), Master Black Belts (MBBs), Green Belts (GBs) e Champions. BBs trabalham *full-time* na condução de projetos de melhoria e geralmente recebem 4 semanas de treinamento. MBBs recebem mais treinamento e muitas vezes servem como instrutores e consultores internos. GBs trabalham *part-time*, recebem menos treinamento (2 semanas) e auxiliam os BBs nos projetos de melhoria. Finalmente, o Champion é quem identifica os projetos importantes estrategicamente para as equipes de melhoria e fornece recursos para a condução do projeto. O Champion recebe apenas uma orientação sobre Seis Sigma ao invés de um treinamento detalhado. Como pode ser visto, a intensidade e o treinamento diferenciado é uma parte importante da abordagem Seis Sigma (ABOELMAGED, 2010; LINDERMAN *et al.*, 2003; SCHROEDER *et al.*, 2008).

De acordo com Montgomery e Woodall (2008), os projetos Seis Sigma, geralmente, têm duração de 4-6 meses e são selecionados de acordo com o potencial impacto nos negócios. Melhoria da qualidade e do negócio via projetos tiveram sua origem com Joseph Juran, que sempre estimulou a abordagem projeto-a-projeto para melhorar a qualidade (JURAN, 1988). O impacto do projeto deve ser avaliado, pelo departamento financeiro da empresa, em termos de seus benefícios financeiros para o negócio. Obviamente, projetos com grandes potenciais de impacto são mais desejáveis. Esta integração dos sistemas financeiros é uma prática padrão do Seis Sigma e deve ser parte do projeto DMAIC.

2.2.1 Roadmap DMAIC

Thahjono *et al.* (2010), revisando a literatura sobre Seis Sigma, afirmaram que há diversas variações para o DMAIC tais como: P-DMAIC (*Project-DMAIC*), E-DMAIC (*Enterprise-DMAIC*) e DMAICR (*DMAIC Report*). Os autores destacam que a diferença consiste nos números e tipos de fases do projeto, mas as ferramentas utilizadas são basicamente as mesmas. Todavia, o autor desta tese, ao conduzir a revisão da literatura sobre os *roadmaps* propostos nos periódicos mais renomados (aqueles indexados na base de dados da *Web of Science*), identificou que há algumas particularidades, principalmente, em relação à aplicação específica e serão destacadas a seguir. Assim como Tang *et al.* (2007) destacaram, é óbvio que o Seis Sigma possui limitações e não pode ser solução para qualquer organização e/ou em qualquer situação. As ferramentas utilizadas e estrutura das fases do projeto podem mudar de acordo com a natureza do problema a ser resolvido.

Como parte da estrutura curricular de programas de pós-graduação, o departamento de engenharia de produção da *Arizona State University* (MONTGOMERY *et al.*, 2005) e o departamento de estatística da *Virginia Tech* (ANDERSON-COOK *et al.*, 2005) apresentaram matrizes curriculares de treinamento para auxiliar estudantes a ingressar na carreira industrial. Ambos os trabalhos apresentam seus *roadmaps* DMAIC propostos com as ferramentas abordadas em cada tópico para condução dos projetos. De acordo com os autores, o *feedback* dos estudantes e *project sponsors* foi bastante positivo, tanto em termos de resultado de projeto quanto em relação ao aporte de conhecimento reportado pelos estudantes.

Tang *et al.* (2007) exploraram a possibilidade de melhorar a utilidade e efetividade do Seis Sigma, em ambientes operacionais e de negócios. Os autores propuseram um *roadmap* para treinamento de *Black Belts* que integra técnicas de pesquisa operacional e gestão. Uma matriz que relaciona ferramentas do treinamento com entregas (cumprimento de etapas) do

projeto é apresentada para explicar o relacionamento próximo entre objetivos do treinamento e os resultados do projeto.

Tanco *et al.* (2009) desenvolveram um *roadmap* DMAIC para facilitar a implementação do DOE em empresas. Os autores apresentaram uma metodologia do ponto de vista da engenharia, sem ignorar a fundamentação estatística da técnica. O *roadmap* desenvolvido é especialmente útil para pessoas não familiarizadas com as ferramentas e também para consultores que pretendem explicar DOE de forma sistemática. As ferramentas e atividades a serem realizadas são explicadas em cada fase do *roadmap* DMAIC, além de um caso prático que ilustra a aplicação das ferramentas.

Yeh *et al.* (2007) propuseram um modelo *fuzzy* modificado para avaliar o desempenho de SCM (*Supply Chain Management*). O modelo proposto, estruturado de acordo com um *roadmap* DMAIC, foi comparado com o original através da aplicação em duas empresas mecânicas em Taiwan.

Kumar *et al.* (2006) integraram as ferramentas Lean (mapa do fluxo de valor – VSM, 5S e TPM – *total productive maintenance*) ao DMAIC para propor um *roadmap* Lean Seis Sigma, capaz de reduzir variabilidade e eliminar atividades que não agregam valor nas organizações. A implantação da estrutura proposta mostrou melhorias consideráveis em métricas importantes (DPU – defeitos por unidade, índice de capacidade de processo, OEE – *overall equipment effectiveness*, média, desvio-padrão e rendimento do processo avaliado), além de retorno financeiro substancial para a organização. Os autores, no entanto, reiteram que o *roadmap* proposto precisa ser avaliado em diferentes cenários para estabelecer sua validade. Em outra contribuição para Lean Seis Sigma, Chen e Lyu (2009) propuseram um *roadmap* DMAIC com objetivo de melhorar a qualidade na manufatura de painéis sensíveis ao toque. Apesar dos autores concluírem que Lean Seis Sigma pode resolver problemas de *mix* de produção que afetam a qualidade e, conseqüentemente, otimiza a produção, nenhuma ferramenta Lean foi abordada pelos autores para resolver tal problema. Os autores afirmam ainda que o estudo aplicado ao processo de manufatura de painéis sensíveis ao toque pode ser estendido a diversos outros exemplos da indústria.

No contexto de sistemas de saúde (*healthcare systems*), Feng e Antony (2010) incorporaram DEA (*data envelopment analysis*) em um *roadmap* DMAIC para integrar a utilidade do Seis Sigma à efetividade da implementação de DEA em avaliar e melhorar a eficiência de serviços de saúde. Os autores afirmam que a estrutura proposta permite avaliar o desempenho de organizações ou indivíduos mais efetivamente. Para a aplicação estudada, os autores concluíram que a abordagem proposta conduzirá à otimização da receita e

planejamento dos recursos em longo prazo. Sellers *et al.* (2013) desenvolveram um *roadmap* DMAIC sustentável para ensinar médicos, em estágio de residência cirúrgica, a teoria e condução de projetos de melhoria da qualidade. Durante os primeiros três anos do programa, sete projetos foram desenvolvidos e 57% completaram todas as etapas do DMAIC. Projetos iniciais envolveram questões de eficiência clínica, enquanto que os mais recentes focaram em questões de cuidados clínicos. Os autores concluíram que a estrutura proposta fornece um modelo de sucesso para outros programas cirúrgicos introduzirem projetos similares centrados na iniciativa de projetos de melhoria conduzidos por residentes.

Com objetivo de avaliar a cientificidade e reconstruir racionalmente o *roadmap* DMAIC, alguns autores (DE KONING e DE MAST, 2005; DE MAST *et al.*, 2000; DE MAST, 2003) têm estudado diversos *roadmaps* disponíveis na literatura, tais como: Breyfogle (1999), Hahn *et al.* (1999), Hahn *et al.* (2000), Harry (1997), Pande *et al.* (2000) e Rasis *et al.* (2002). O trabalho desses autores resultou em um *roadmap* genérico (DE KONING e DE MAST, 2006) apresentado na Tabela 2.2.

Tabela 2.2 – Roadmap DMAIC genérico

Passos	Descrição	Foco
D1	Identificar e mapear processo relevante	
D2	Identificar <i>stakeholder</i>	
D3	Determinar e priorizar necessidades e requisitos dos clientes	
D4	Fazer um <i>business case</i> para o projeto	
M1	Selecionar um ou mais Ys	Ys
M2	Determinar definição operacional para Ys	Ys
M3	Validar sistema de medição dos Ys	Ys
M4	Avaliar a capacidade do processo atual	Ys
M5	Definir objetivos	Ys
A1	Identificar potenciais fatores de influência	Xs
A2	Selecionar os poucos vitais fatores de influência	Xs
I1	Quantificar o relacionamento entre Xs e Ys	Xs e Ys
I2	Definir ações para modificar o processo ou configuração dos fatores influentes de modo que os Ys sejam otimizados	Xs e Ys
I3	Conduzir teste piloto das ações de melhoria	Xs e Ys
C1	Determinar nova capacidade do processo	Ys
C2	Implementar plano de controle	Xs

Fonte: De Koning e De Mast, 2006.

A etapa definir de um projeto Seis Sigma/DMAIC consiste basicamente em selecionar o problema a ser resolvido, avaliar seu impacto no consumidor e potenciais benefícios que o projeto pode proporcionar. A etapa seguinte de medição tem objetivo de traduzir o problema para uma forma mensurável e, em seguida, medir a situação atual. A etapa analisar identifica os fatores de influência e causas que determinam o comportamento dos Ys. Na etapa de

melhoria o objetivo é definir e implementar ajustes ao processo para melhorar o desempenho dos Ys. Por fim, a etapa controlar ajusta o gerenciamento do processo e sistema de controle para que as melhorias alcançadas sejam mantidas (DE KONING e DE MAST, 2006; PERUCHI *et al.*, 2012f; 2012g).

2.2.2 Análise crítica sobre o *roadmap* genérico

Em um estudo recente, De Mast e Lokkerbol (2012) criticamente compararam o método DMAIC, em De Koning e De Mast (2006), com teorias científicas sobre solução de problemas. Um ponto forte destacado pelos autores acerca deste método compreende eficazes técnicas estatísticas para tomadas de decisões baseadas em fatos e verificação empírica de ideias, além de um *roadmap* bem elaborado para estruturar e resolver problemas. O problema desta pesquisa se enquadra adequadamente aos aspectos destacados por De Mast e Lokkerbol (2012), os quais determinam que o método DMAIC é aplicável para resolver problemas do tipo:

- i. empíricos, sendo eles semiestruturado ou bem estruturado;
- ii. problemas que requerem definição, diagnóstico e projeto de melhorias;
- iii. apesar de ser genérico, o método DMAIC pode ser alterado para satisfazer mais adequadamente a solução de problemas de domínios mais específicos.

Ao analisar o item (iii) mencionado acima, os autores afirmaram que a desvantagem do *roadmap* genérico é que métodos específicos para solução de problemas de um mesmo domínio podem ser mais efetivos ao guiar o analista nas particularidades do problema e de uma forma mais operacional.

Levando em consideração a pesquisa de De Mast e Lokkerbol (2012), além de analisar os *roadmaps* disponíveis na literatura (ver Seção anterior), esta tese apresenta uma contribuição original denominada “MDMAIC: um *roadmap* Seis Sigma multivariado”. De acordo com Tanco *et al.* (2009), processos industriais geralmente apresentam múltiplas respostas. Como destacado por diversos pesquisadores (Box *et al.*, 1973; Chiao e Hamada, 2001; Paiva *et al.*, 2009; Wu, 2004; Yuan *et al.*, 2008), a análise individual de cada resposta pode levar a um ótimo conflitante, visto que o nível dos fatores que melhora uma resposta pode degradar outra. A presença de correlação pode também causar a instabilidade do modelo e imprecisão nos coeficientes de regressão. Em modelagem e otimização, as equações de regressão não representam adequadamente uma função objetivo sem considerar a estrutura de variância-covariância entre as múltiplas respostas (BOX *et al.*, 1973; WU, 2004; YUAN *et al.*, 2008).

Esta tese abrange um escopo mais amplo que vai além da modelagem e otimização de múltiplas respostas. Visa-se propor um *roadmap* DMAIC baseado em PCA para solução de problemas de manufatura com processos multivariados. Portanto, será integrada uma abordagem multivariada das principais ferramentas estatísticas (MSA, SPC e DOE) de um projeto Seis Sigma ao *roadmap* estruturado DMAIC.

2.2.3 Caso univariado

Diversas pesquisas têm aplicado o *roadmap* DMAIC como método estruturado para solução de problemas de manufatura e serviços. Os principais exemplos de publicações sobre solução de problemas de manufatura incluem: fundição (BILGEN e SEM, 2012; KUMAR *et al.*, 2007; KUMARAVADIVEL e NATARAJAN, 2013), montagem de interruptores (VINODH *et al.*, 2014), produção de placas de circuito impresso (LEE e WEI, 2010; LI *et al.*, 2008; TONG *et al.*, 2004), forjamento radial (SAHOO *et al.*, 2008), suspensão de automóveis (CHEN e TSOU, 2003), injeção de plásticos (LO *et al.*, 2009), montagem de assento de automóveis (TSOU E CHEN, 2005), prototipagem rápida (KAIJA *et al.*, 2010), montagem de bomba de injeção de combustível em automóveis (ANTONY *et al.*, 2012; GIJO *et al.*, 2011), farmacêutico (BARRY *et al.*, 2012) e moveleiro (LI e AL-REFAIE, 2008). Já no setor de serviços incluem: hospital (AAKRE; VALLEY; O'CONNOR, 2010; CHAN, 2004; FRINGS e GRANT, 2005), governamental (FURTERER e ELSHENNAWY, 2005) e biblioteca (KUMI e MORROW, 2006).

Além dos trabalhos citados acima e aqueles citados, detalhadamente, na seção 2.2.1, o leitor pode conferir o livro “*World class application of Six Sigma: real world examples of success*”, escrito pelos pesquisadores Antony *et al.* (2006). Encontram-se neste livro, 6 exemplos detalhados de aplicações de projetos Seis Sigma no setor de manufatura, além de 5 no setor de serviços e 2 em ambientes transacionais.

2.2.4 Caso multivariado

A aplicação de técnicas estatísticas multivariadas em um *roadmap* DMAIC Seis Sigma não é uma ideia completamente inédita. Chang *et al.* (2012) descreveram a aplicação de um projeto Seis Sigma, usando DMAIC, para integração de SPC a existentes práticas de controle de processos de engenharia (EPC). Na fase de análise do *roadmap*, os autores usaram carta de controle multivariada, T^2 de Hotelling, para avaliar seis características da qualidade em um processo de cura de mangueiras de alta pressão. Foi decidido separar as variáveis em dois grupos (variáveis de aquecimento e de resfriamento) para o monitoramento do processo

através de duas cartas de controle multivariadas. Os pesquisadores sugerem que o procedimento SPC, baseado no DMAIC, pode ser empregado mais amplamente em outras aplicações sobre SPC/EPC.

No entanto, um projeto Seis Sigma não se restringe particularmente a SPC. Esta tese demonstrará como integrar todas as etapas do Seis Sigma para otimização de processos de caráter multivariado, considerando não apenas SPC, mas também outras técnicas como QFD, MSA, DOE e otimização. A técnica estatística multivariada que fundamenta o desenvolvimento desta tese é PCA. A próxima seção apresentará maiores detalhes a respeito da técnica multivariada que serve como processo intermediário para aplicação das técnicas e ferramentas do Seis Sigma.

2.3 Análise de componentes principais

PCA é uma técnica estatística multivariada criada por Hotelling (1933) e que se dedica à explicação da estrutura de variância-covariância existente em um conjunto de dados, utilizando-se combinações lineares das variáveis originais. Segundo Johnson e Wichern (2007) e Rencher (2002), seus objetivos principais são: (1) a redução de dimensionalidade, e (2) a interpretação de dados.

Embora q componentes sejam necessários para se reproduzir a variabilidade total de um sistema de interesse, geralmente, a maior parte desta variabilidade pode ser representada por um número $k < q$ de componentes principais. Isto quer dizer que existe quase tanta informação em k componentes principais que nas q variáveis originais. A ideia geral da PCA é, portanto, que k componentes principais podem substituir, sem perda considerável de informação, as q variáveis originais. O conjunto original de dados, consistindo de n posições (de observações) das q variáveis, é reduzido para um conjunto posterior também formado por n posições (de escores) de k componentes principais.

De acordo com Rencher (2002), a PCA geralmente revela relacionamentos que não seriam previamente identificados com o conjunto original, o que resulta em uma interpretação mais abrangente do fenômeno. Segundo Johnson e Wichern (2007), a análise de componentes principais (PCA) serve como um passo intermediário na análise dos dados.

2.3.1 Abordagem algébrica

Análise de componentes principais é uma das ferramentas aplicadas mais amplamente usadas para resumir os padrões comuns de variação entre variáveis. É algebricamente uma combinação linear ℓ de q variáveis aleatórias Y_1, Y_2, \dots, Y_q . As coordenadas dos eixos têm agora as variáveis Y_1, Y_2, \dots, Y_q e representam a direção de máximo. As componentes principais são não correlacionadas e dependem somente da matriz de covariância Σ (ou da matriz de correlação ρ) das variáveis Y_1, Y_2, \dots, Y_q e seu desenvolvimento não requer a suposição de normalidade multivariada.

As informações necessárias para obtenção dos escores do primeiro componente principal (PC_1), segundo a definição de Johnson e Wichern (2007), vem da combinação linear que maximizar a variância, de acordo com a Eq. (2.2).

$$\begin{aligned} \text{Maximizar : } & \text{Var}[\mathbf{e}'_1 \mathbf{Y}] \\ \text{Subjeito a : } & \mathbf{e}'_1 \mathbf{e}_1 = 1 \end{aligned} \quad (2.2)$$

No problema de otimização acima, o produto das variáveis de decisão são limitadas ao comprimento unitário, para eliminar indeterminação da solução, visto que \mathbf{e}_1 pode ser multiplicado por qualquer escalar. Para obter os escores do segundo componente principal (PC_2), o problema (2.2) é alterado, de acordo com a Eq. (2.3), para garantir a ortogonalidade entre PC_1 e PC_2 .

$$\begin{aligned} \text{Maximizar : } & \text{Var}[\mathbf{e}'_2 \mathbf{Y}] \\ \text{Subjeito a : } & \mathbf{e}'_2 \mathbf{e}_2 = 1 \\ & \text{Cov}[\mathbf{e}'_1 \mathbf{Y}, \mathbf{e}'_2 \mathbf{Y}] = 0 \end{aligned} \quad (2.3)$$

Desta forma geral, o i -ésimo componente principal será a solução para a combinação linear $\mathbf{e}'_i \mathbf{Y}$ que maximiza:

$$\begin{aligned} \text{Maximizar : } & \text{Var}[\mathbf{e}'_i \mathbf{Y}] \\ \text{Subjeito a : } & \mathbf{e}'_i \mathbf{e}_i = 1 \\ & \text{Cov}[\mathbf{e}'_i \mathbf{Y}, \mathbf{e}'_k \mathbf{Y}] = 0 \quad \text{para } k < i \end{aligned} \quad (2.4)$$

O resultado do problema de otimização lexicográfica descrito acima determina como solução da função objetivo os autovalores e, a solução ótima das variáveis de decisão, os autovetores de cada componente principal. De posse dos pares de autovalores e autovetores de cada componente principal, $(\lambda_1, \mathbf{e}_1), (\lambda_2, \mathbf{e}_2), \dots, (\lambda_q, \mathbf{e}_q)$ onde $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_q \geq 0$, os escores de componentes principais podem ser calculados através da combinação linear abaixo:

$$\mathbf{PC}_i = \mathbf{e}'_i \mathbf{Y} = \mathbf{e}_{1i} \mathbf{Y}_1 + \mathbf{e}_{2i} \mathbf{Y}_2 + \dots + \mathbf{e}_{qi} \mathbf{Y}_q \quad i = 1, 2, \dots, q \quad (2.5)$$

assim como o percentual de explicação da i -ésima componente principal usando

$$\%PC_i = \frac{\lambda_i}{\sum_{j=1}^q \lambda_j} \quad i = 1, 2, \dots, q \quad (2.6)$$

As componentes principais podem também ser obtidas pelas variáveis padronizadas

$$\begin{aligned} Z_1 &= \frac{(Y_1 - \mu_1)}{\sqrt{\sigma_{11}}} \\ Z_2 &= \frac{(Y_2 - \mu_2)}{\sqrt{\sigma_{22}}} \\ &\vdots \\ Z_q &= \frac{(Y_q - \mu_q)}{\sqrt{\sigma_{qq}}} \end{aligned} \quad (2.7)$$

Em notação matricial,

$$\mathbf{Z} = (\mathbf{V}^{1/2})^{-1} (\mathbf{Y} - \boldsymbol{\mu}) \quad (2.8)$$

onde $\mathbf{V}^{1/2}$ é a matriz diagonal de desvio-padrão. Claramente, $E(\mathbf{Z}) = \mathbf{0}$ e $Cov(\mathbf{Z}) = (\mathbf{V}^{1/2})^{-1} \boldsymbol{\Sigma} (\mathbf{V}^{1/2})^{-1} = \boldsymbol{\rho}$. Os escores de componentes principais de \mathbf{Z} podem ser obtidos dos autovetores da matriz de correlação $\boldsymbol{\rho}$ de \mathbf{Y} . Todos os prévios resultados aplicam-se, com algumas simplificações, já que a variância de cada Z_i é a unidade. A notação será a mesma para PC_i referindo-se a i -ésima componente principal e $(\lambda_i, \mathbf{e}_i)$ para os pares de autovalor-autovetor

da matriz ρ ou Σ . No entanto, $(\lambda_i, \mathbf{e}_i)$ derivado de Σ é, em geral, não exatamente o mesmo que derivado de ρ .

2.3.2 Abordagem geométrica

As componentes principais são inicialmente obtidas pela rotação dos eixos com objetivo de alinhar com a variação natural do sistema, no qual as novas variáveis tornam-se não correlacionadas e refletem a direção de máxima variância. A Figura 2.2 ilustra a rotação imposta no eixo composto pelas variáveis originais (y_1 e y_2) para obtenção dos componentes principais (z_1 e z_2) através de um exemplo de Rencher (2002). Note que a linha formada pelo eixo maior lembra uma linha de regressão. Esta é uma linha que ajusta os pontos de tal forma que a distância perpendicular dos pontos para a linha é minimizada, ao invés de simplesmente minimizar a distância vertical.

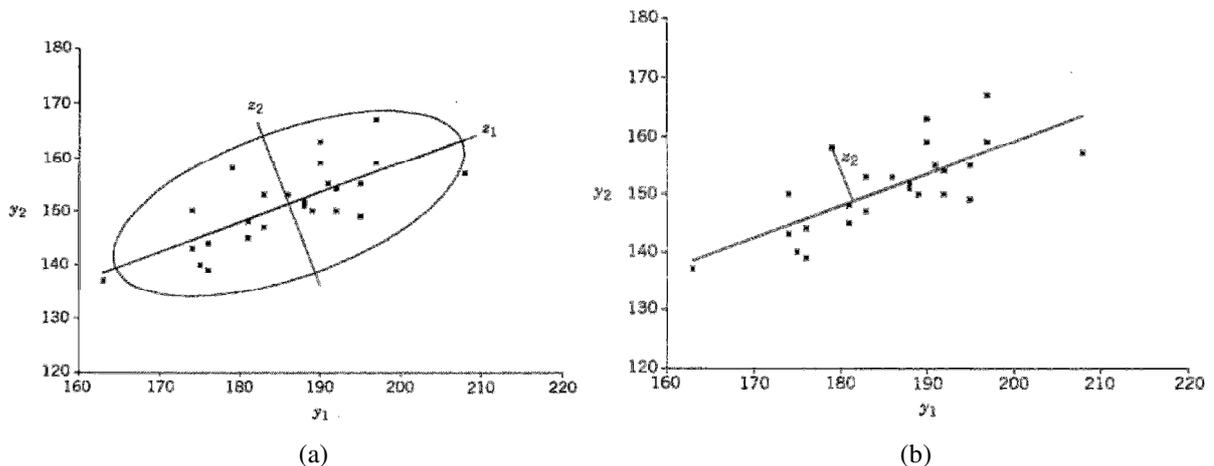


Figura 2.2 – (a) Rotação imposta nos eixos das variáveis originais e (b) Novo eixo z_1 representando uma regressão linear ortogonal
Fonte: Rencher (2002)

Conforme descrevem Gabrielsson *et al.* (2003), a PCA corresponde a um ajuste por mínimos quadrados de uma linha reta ($N=1$) ou um plano/hiperplano N -dimensional para os dados em um espaço K -dimensional de componentes principais. No caso apresentado pela Figura 2.3 (JOHNSON e WICHERN, 2007), os dados são centrados na média e três variáveis originais são descritas por apenas dois componentes principais. As variáveis originais são projetadas no plano matemático descrito pelos componentes, e o valor do escore em cada componente é obtido através da determinação das distâncias entre a origem e as variáveis originais projetadas. Os autovetores, também chamados de “Carregamentos”, representam os coeficientes da direção do plano ajustado.

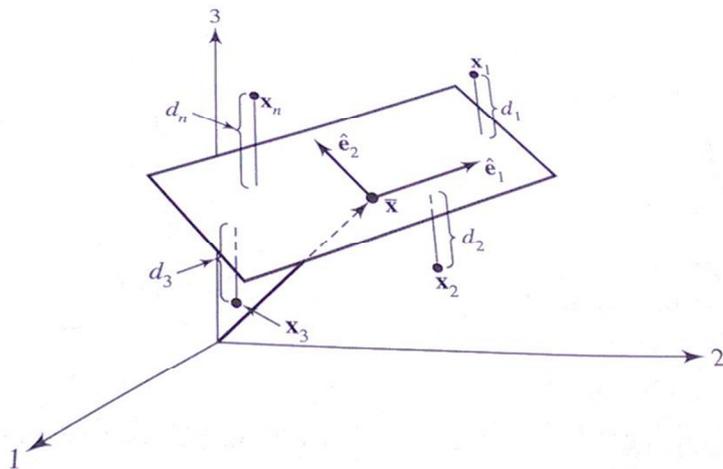


Figura 2.3 – Interpretação geométrica da PCA
 Fonte: Johnson e Wichern (2007)

2.3.3 Seleção de componentes principais

Em qualquer aplicação, uma decisão deve ser tomada em relação a quantas componentes principais devem ser retidas para efetivamente representar os dados originais. Rencher (2002) propôs algumas orientações que são explicadas a seguir:

- Reter componentes suficientemente capazes de explicar um percentual específico da variância original dos dados, por exemplo, 80%.
- Reter as componentes em que os autovalores são maiores que a média de autovalores, $\sum_{i=1}^p \lambda_i / q$. Para a matriz de correlação, esta média é 1.
- Usar o gráfico *scree*, que mostra λ_i versus i , e procura diferenciar os “grandes” autovalores dos “pequenos” autovalores.
- Testar a significância dos autovalores “maiores”.

Johnson e Wichern (2007) afirmam que não há um método definitivo para definir quantas componentes reter na análise. No entanto, alguns elementos que devem ser levados em consideração são a quantidade de variância explicada, tamanho dos autovalores e interpretação das componentes principais do assunto discutido. Os autores também determinam que o gráfico *scree* é um método visual bastante útil. Além disso, os autores orientam para reter as componentes principais que são capazes de explicar uma proporção de pelo menos $1/q$ da variância total.

2.3.4 Matriz de correlação e matriz de variância-covariância

Nota-se que as componentes principais geradas pela matriz **R** não são compatíveis com as obtidas pela matriz **S**. Em casos que a variância entre as variáveis originais apresentarem discrepância significativa, a matriz **R** pode apresentar resultados melhores. Por exemplo, se uma variável apresentar variância muito maior que as outras do conjunto original de dados, esta variável dominará a primeira componente principal (JOHNSON e WICHERN, 2007; RENCHER, 2002).

2.4 Desdobramento da função qualidade – QFD

O método QFD (*Quality Function Deployment*) surgiu no contexto do controle da qualidade total (TQC) com o objetivo comum de gerar satisfação aos *stakeholders*. Este método foi formulado pelos professores Akao e Mizuno no final da década de 60 e, desde então, vários elementos conceituais e metodológicos foram acrescentados pelo próprio Akao e outros autores (CHENG e MELO FILHO, 2007). A aplicação do método originou-se do uso do diagrama de causa-efeito para definição dos pontos de controle na produção.

O QFD é um método conhecido e utilizado nos Estados Unidos e na Europa onde, em termos de conteúdo, é restrito ao Desdobramento da Qualidade – QD. Ao passo que, no Japão, apresenta um sentido mais amplo, ligado ao sistema de garantia da qualidade durante o desenvolvimento do produto. O QD visa desdobrar a qualidade, utilizando a lógica da causa e efeito, de forma estruturada, hierarquizada e priorizada (CHENG e MELO FILHO, 2007).

Nesta tese, o método QFD será aplicado de forma restrita conferindo, principalmente, o desdobramento da qualidade. O procedimento para traduzir a voz do cliente em características técnicas de projetos segue os seguintes passos:

- 1) Tradução da voz do cliente – VOC;
- 2) Obtenção de Ys a partir das necessidades do cliente;
- 3) Correlação entre Ys e as necessidades do cliente;
- 4) Priorização dos Ys;
- 5) Correlações entre os Ys obtidos empiricamente.

Estes passos serão detalhados nas seções seguintes. A matriz da qualidade, apresentada na Figura 2.4, é a ferramenta utilizada para organizar e dispor, em informações de projeto, os dados obtidos do procedimento de tradução da voz do cliente.

Nota-se que o próprio QFD é multivariado, visto que múltiplas necessidades do cliente são desdobradas em múltiplas características técnicas de projeto. Simplesmente priorizar estas

características em uma única, crítica ao cliente ou CTQ (*critical-to-quality*), não é a estratégia mais eficiente. A otimização de uma característica pode influenciar o desempenho de outra, principalmente quando estas características apresentam objetivos conflitantes, neste caso, afetando negativamente. Por este motivo, nesta tese não será adotado a denominação CTQ para a característica crítica do projeto. O QFD nesta tese não priorizará as características técnicas em apenas um CTQ, determinará múltiplos Ys correlacionados.

Customer Requirements	Technical Requirements	Customer Importance	Y1	Y2	Y3	Y4	Y5	Planning Matrix						
								Our Product	Competitor A's Product	Competitor B's Product	Planned Rating	Improvement Factor	Sales Point	Overall Weighting
Necessidade 1	3	Strong	Weak	Weak	Medium	Weak	3	3	3	3	1,0	1,0	3,0	23%
Necessidade 2	1	Weak	Medium	Weak	Strong	None	3	3	3	3	1,0	1,0	1,0	8%
Necessidade 3	5	Strong	Medium	Medium	None	Weak	3	3	3	3	1,0	1,0	5,0	38%
Necessidade 4	4	None	Strong	Medium	Medium	Medium	3	3	3	3	1,0	1,0	4,0	31%
Technical Priorities			73,0	57,0	31,0	30,0	20,0	211,0			Total			13,0
Percentage of Total			35%	27%	15%	14%	9%							
Benchmarking	Our Product													
	Competitor A's Product													
	Competitor B's Product													
Design Targets														

Figura 2.4 – Matriz da qualidade
Fonte: próprio autor

2.4.1 Tradução da voz do cliente – VOC

Antes de discutir como captar a voz do cliente é importante conhecer a relação que existe entre nível de satisfação do cliente e nível de desempenho do produto. O Prof. Noriaki Kano e colaboradores identificaram a relação entre esses dois pontos de vista, no modelo apresentado na Figura 2.5 (KANO *et al.*, 1984). Este modelo é útil para a classificação dos diversos itens de qualidade do produto conforme percebido pelos clientes. De acordo com Cheng e Melo Filho (2007) e Pyzdek (2001), estes itens classificam-se como:

- Qualidade básica (ou obrigatória): são itens de qualidade considerados óbvios, quando o desempenho é suficiente, porém sua insuficiência causa insatisfação;
- Qualidade esperada (ou desejada): são itens de qualidade que trazem maior satisfação aos clientes, a medida que aumenta o nível de desempenho do produto. Sua ausência causa insatisfação;

- Qualidade atrativa: são itens de qualidade que, mesmo com desempenho insuficiente, são aceitos com resignação pelos clientes. Porém, sua suficiência causa grande satisfação.

É um fato comprovado que a avaliação em relação aos itens de qualidade apresenta um fenômeno de obsolência, passando de (CHENG e MELO FILHO, 2007):

Qualidade atrativa → Qualidade esperada → Qualidade básica

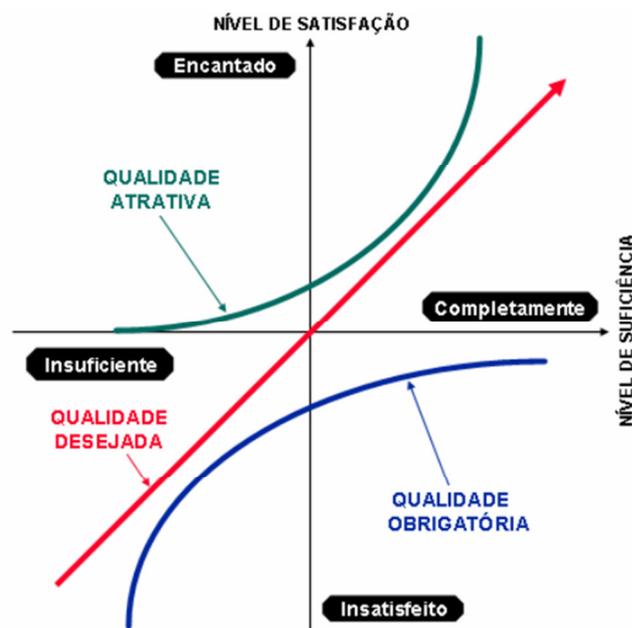


Figura 2.5 – Relação entre satisfação do cliente e nível de desempenho do produto
Fonte: adaptado de Kano *et al.* (1984)

Percebe-se que é importante criar novas qualidades atrativas e otimizar as qualidades existentes para garantir a preferência dos clientes. As necessidades do cliente são obtidas através de uma representação organizada e detalhada das verdadeiras exigências do cliente, na linguagem da equipe do projeto. Essas exigências são resumidas de forma sistemática, desdobradas do nível abstrato para o concreto, do resumido para o detalhado. Um diagrama de árvore, Figura 2.6, pode ser utilizado para desdobrar a necessidade do cliente do nível primário para subníveis detalhados e concretos. Além disso, o analista pode ilustrar no diagrama de árvore o grau de importância associado a cada necessidade do cliente. Essas necessidades devem ser escritas na matriz da qualidade da Figura 2.4.

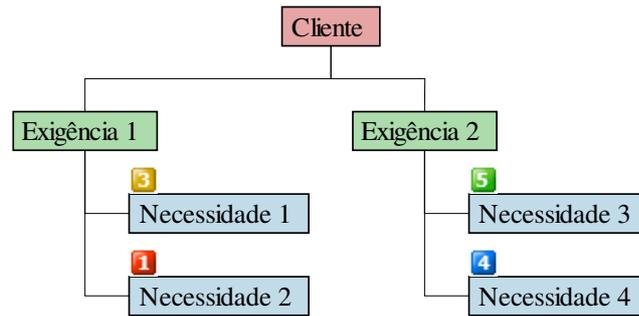


Figura 2.6 – Diagrama de árvore (necessidades do cliente)
Fonte: próprio autor

2.4.2 Obtenção de Ys a partir das necessidades do cliente

A voz do cliente deve ser transformada em características da qualidade mensuráveis. Estas características permitem avaliar no produto o atendimento às exigências do cliente. As características Ys são selecionadas questionando-se quais delas medem tecnicamente cada necessidade do cliente. O relacionamento entre as características Ys e as necessidades do cliente pode ser expresso graficamente através da árvore da qualidade da Figura 2.7. As características Ys identificadas devem ser escritas na matriz da qualidade da Figura 2.4.

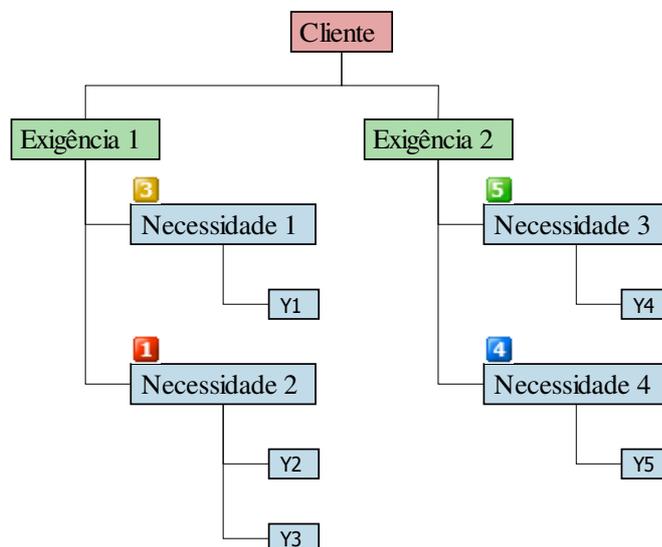


Figura 2.7 – Diagrama de árvore (Ys do projeto)
Fonte: próprio autor

2.4.3 Correlação entre Ys e as necessidades do cliente

O processo de estabelecimento da correlação do QFD possui dois objetivos:

- Correlacionar as necessidades do cliente com as características técnicas Ys;
- Viabilizar a priorização dos Ys através de uma relação de causa-efeito, considerando os pesos atribuídos às necessidades do cliente.

A Tabela 2.3 sugere algumas formas de representação da intensidade das correlações (CHENG e MELO FILHO, 2007). Nesta tese, será usada a escala de valores sugeridos (9,3,1,0), os quais devem ser escritos na matriz da qualidade da Figura 2.4.

Tabela 2.3 – Definições para as correlações da matriz de QFD

Correlação	Cor	Símbolo	Valores sugeridos		
Forte	Vermelho	⊖	9	5	4
Média	Verde	Δ	3	3	2
Fraca	Azul	○	1	1	1
Inexistente		Vazio	-	-	-

Fonte: Cheng e Melo Filho (2007).

2.4.4 Priorização dos Ys

A utilização de matrizes QFD nesta tese possui principal objetivo de priorizar os Ys que são considerados mais importantes ao cliente. As importâncias relativas obtidas das matrizes QFD são utilizadas nos passos seguintes do *roadmap* MDMAIC.

A matriz da qualidade realiza a conversão do peso relativo das necessidades dos clientes para as características técnicas Ys. Nesta conversão, a importância atribuída pelo cliente a cada necessidade é transferida às características da qualidade Ys, determinando as prioridades para o projeto Seis Sigma. Assumindo q características técnicas e n requisitos de necessidades dos clientes, os pesos absolutos de cada Y no projeto podem ser definidos como:

$$PaY_j = \sum_{i=1}^n PrN_i X_{ij} \quad (2.9)$$

onde, PrN_i é o peso relativo das necessidades e X_{ij} são as correlações entre Y_j e N_i . Os pesos relativos das características da qualidade Ys são calculados usando:

$$PrY_j = \frac{PaY_j}{\sum PaY} \quad (2.10)$$

Adicionalmente, pode-se construir um gráfico de Pareto com os pesos relativos obtidos para os Y_s . A Figura 2.8 mostra o gráfico de Pareto construído para a matriz da qualidade da Figura 2.4. Quando houver quantidade relativamente alta de Y_s no projeto, pode-se selecionar, através de um gráfico de Pareto, apenas aqueles Y_s que representarem uma percentagem estipulada pelo tomador de decisão, por exemplo, 80%. Na Figura 2.8, Y_1 - Y_3 representam 76,3%, o tomador de decisão pode considerar esta percentagem satisfatória, ou incluir Y_4 para garantir um percentual acima de 80%.

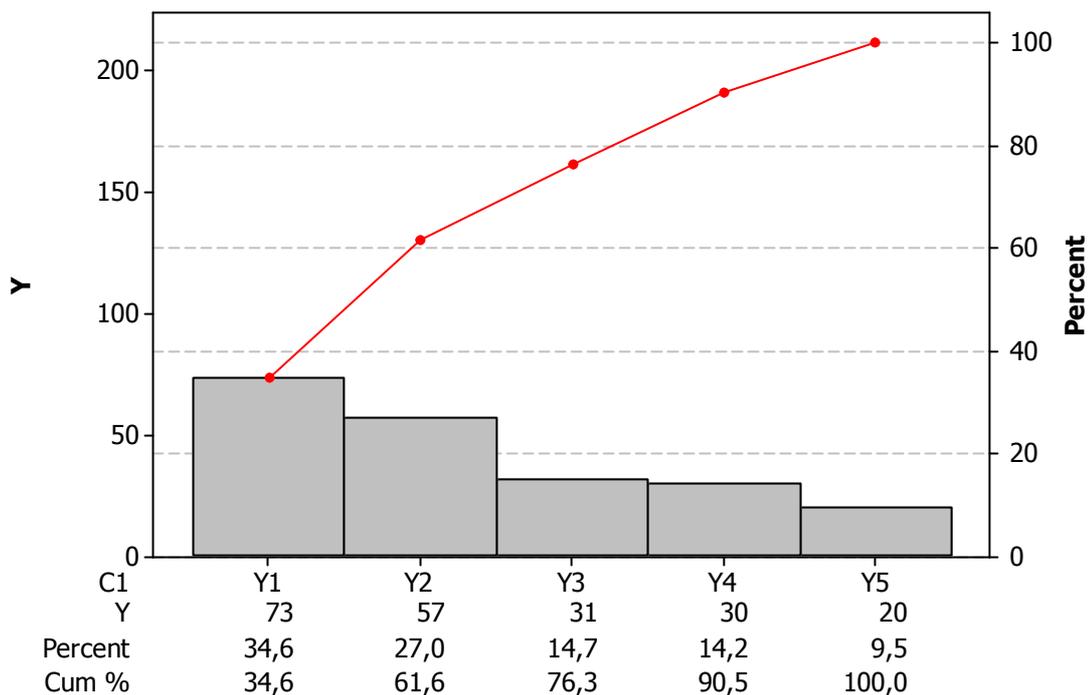


Figura 2.8 – Gráfico de Pareto para priorização dos Y_s
Fonte: próprio autor

2.4.5 Avaliação da correlação entre Y_s

As correlações entre os Y_s , que poderiam ser representadas no telhado da casa da qualidade da Figura 2.4, serão avaliadas empiricamente no decorrer desta tese, preferencialmente, antes de executar PCA. Neste caso, considere y um vetor de q variáveis medidas em uma unidade amostral. Se houver n indivíduos na amostra, os n vetores observados serão denotados por y_1, y_2, \dots, y_n . Todos n vetores observados y_1, y_2, \dots, y_n podem ser transpostos por vetores linha e listados em uma matriz de dados Y como segue:

A correlação amostral entre as j -ésimas e k -ésimas variáveis é definida como:

$$r_{jk} = \frac{s_{jk}}{\sqrt{s_{jj}s_{kk}}} \quad (2.15)$$

A matriz de correlação amostral é análoga à matriz de covariância:

$$\mathbf{R} = [r_{jk}] = \begin{bmatrix} 1 & r_{12} & \cdots & r_{1q} \\ r_{21} & 1 & \cdots & r_{2q} \\ \vdots & \vdots & \ddots & \vdots \\ r_{q1} & r_{q2} & \cdots & 1 \end{bmatrix} \quad (2.16)$$

A segunda linha, por exemplo, contém a correlação da Y_2 com as outras Y s (incluindo a correlação da Y_2 com ela mesma, que é 1). É claro que a matriz \mathbf{R} é simétrica, logo $r_{jk} = r_{kj}$.

A matriz de correlação populacional análoga a Eq. (2.16) é definida como:

$$\boldsymbol{\rho} = [\rho_{jk}] = \begin{bmatrix} 1 & \rho_{12} & \cdots & \rho_{1q} \\ \rho_{21} & 1 & \cdots & \rho_{2q} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{q1} & \rho_{q2} & \cdots & 1 \end{bmatrix} \quad (2.17)$$

2.4.6 Caso univariado

Apesar de QFD ser amplamente conhecido como uma técnica para seleção e priorização das características críticas da qualidade em projetos, poucos trabalhos, dentre os citados na seção 2.2 tem citado o QFD (ANDERSON-COOK *et al.*, 2005; TANG *et al.*, 2007). Além disso, não apresentam a aplicação desta técnica dentro do *roadmap* DMAIC.

Outra constatação deste autor é que pouco tem sido publicado sobre a integração do QFD como estratégia de seleção e priorização de Y s em otimização multi-objetivo por experimentos planejados. Neste contexto, Kazemzadeh *et al.* (2008) é um trabalho que merece destaque. Estes autores desenvolveram um método de otimização de múltiplas superfícies de respostas, usando *goal programming* e considerando ponderação das respostas através das importâncias relativas obtidas por uma matriz QFD. Os autores defendem que a nova abordagem é mais adequada, pois considera os tomadores de decisão tradicionais como fabricante e experimentalista, além das opiniões dos clientes e gestores.

Ainda neste contexto, mas usando uma abordagem distinta, Yang *et al.* (2003) propuseram o método de otimização baseado em QFD com objetivo de incluir a preferência

do cliente no *trade-off* de múltiplos objetivos. O procedimento de duas fases, inicialmente, determina os valores ótimos dos Ys, através do método NBI – *Normal Boundary Intersection* (DAS e DENNIS, 1998), que podem maximizar o nível geral de satisfação do cliente. A satisfação do cliente é representada por suas necessidades, que por sua vez, são definidas em função dos Ys obtidos pelas importâncias relativas da HOQ (*House of Quality*). Em seguida, as variáveis de projeto, Xs, são obtidas por *goal programming* com objetivo de atender aos níveis alvo dos Ys. Adicionalmente, os autores avaliaram a robustez da solução obtida, variando-se os pesos relativos atribuídos às necessidades do cliente. Estas alterações foram aplicadas, sistematicamente, através de projetos de Taguchi para se analisar, posteriormente, o impacto nos Ys.

Outros trabalhos que modelam as necessidades do cliente em função das características da qualidade são apresentados a seguir. Dawson e Askin (1999) propuseram uma programação matemática não-linear para determinar as especificações ótimas de engenharia, durante o processo de desenvolvimento de produtos. O modelo, que pode ser obtido por mínimos quadrados ordinários usando arranjos do tipo fatorial, composto central, composto reduzido e *D-optimal*, considerou a voz do cliente, custos de produção e restrições de tempo de desenvolvimento. A abordagem computacionalmente viável para problemas de tamanho real superou uma abordagem heurística estudada pelos autores. Moskowitz e Kim (1997) desenvolveram um protótipo de sistema para tomada de decisão (*QFD Optimizer*), baseado em abordagem integrada de formulação e solução de uma programação matemática. Segundo estes autores, o sistema auxilia a equipe de projeto a construir a HOQ, entender e analisar inter-relacionamentos das necessidades do cliente e obter ótimos valores alvo para as características técnicas do projeto.

2.4.7 Caso multivariado

O uso combinado de técnicas estatísticas multivariadas e QFD tem sido pouco explorado na literatura. Com objetivo de modelar necessidades do cliente em função das características do produto, Kang *et al.* (2007) integraram HOQ e análise estatística multivariada (análise fatorial e análise de *cluster*), no processo de desenvolvimento de produtos. A análise dos resultados compara os métodos de Taguchi e de Análise Conjunta pela utilidade e relação sinal-ruído. Os autores concluem que empresas interessadas em maior participação de mercado, devem utilizar a abordagem baseada em Análise Conjunta para aumentar aceitação do produto. Porém, se o objetivo é manter a atual participação de mercado, o método de Taguchi deve ser empregado para aumentar a robustez do produto.

Como destacado na seção anterior, pouco tem sido publicado sobre a integração do QFD como estratégia de seleção e priorização de Ys em otimização multi-objetivo por experimentos planejados. Kazemzadeh *et al.* (2008) é, dentro da bibliografia pesquisada, a única referência que tem empregado esta integração “*QFD+DOE+otimização*”. Nesta tese, será proposto um método multivariado de otimização que pondera os Ys através das importâncias relativas extraídas de uma matriz QFD.

2.5 Análise multivariada de sistemas de medição

Os esforços em projetos de melhoria da qualidade são frequentemente direcionados para a produção com zero defeito através da redução da variabilidade. Se um produto é classificado como não conforme, geralmente, entende-se que a variabilidade é atribuída ao processo, logo ações de melhoria são implementadas para melhorar a capacidade do processo. Infelizmente, pode ser que os esforços não necessariamente resultem em capacidade do processo melhorada, pois é possível que o processo já seja capaz o bastante, no entanto, o erro de medição é ainda inaceitável quando comparado à variabilidade do processo. Portanto, é importante investigar tanto a variabilidade de um processo de medição quanto à variabilidade do processo de manufatura antes de tomar ações para melhorias futuras (PERUCHI, 2011; PERUCHI *et al.*, 2012d).

Em manufatura, um sistema de medição nem sempre produz a dimensão exata de uma peça, mas ela fornece medições que são desviadas do valor verdadeiro por algum erro. Em qualquer atividade envolvendo medições, uma parte da variabilidade observada será devido ao próprio produto/processo, σ_p^2 , enquanto que o restante será devido ao erro de medição ou variabilidade do sistema de medição, σ_{SM}^2 (AIAG, 2010; AL-REFAIE e BATA, 2010; COSTA *et al.*, 2005; LI e AL-REFAIE, 2008; MAJESKE, 2008; SENOL, 2004; WANG e CHIEN, 2010; WANG e YANG, 2007; WOODALL e BORROR, 2008).

O estudo usado para medir as componentes de variação em análise do sistema de medição (MSA) é chamado de Estudo de Repetitividade e Reprodutividade do Instrumento de Medição (*Gage Repeatability and Reproducibility – GR&R*), o qual pretende determinar se a variabilidade do sistema de medição é relativamente menor que a variabilidade do processo monitorado (PERUCHI *et al.*, 2013b; 2013c). Repetitividade é a variação nas medições obtidas com um instrumento de medição quando usado diversas vezes por um avaliador que mede a mesma característica em uma mesma peça. Reprodutividade é tipicamente definida como a variação na média das medições feitas por diferentes avaliadores usando o mesmo

instrumento de medição para medir a mesma característica em uma mesma peça (AIAG, 2010; AL-REFAIE e BATA, 2010; BURDICK *et al.*, 2003; ERDMANN *et al.*, 2010; KAIJA *et al.*, 2010; HE *et al.*, 2011; MAJESKE, 2008; WANG e CHIEN, 2010).

Há na literatura alguns exemplos de estudos GR&R aplicados durante a condução de projetos Seis Sigma. Dejaegher *et al.* (2006) usaram a metodologia Seis Sigma para medir, analisar e melhorar a capacidade de um método requerido para testar e confirmar a qualidade de um ingrediente ativo farmacêutico. Isto foi feito usando múltiplos estudos GR&R para analisar a capacidade do método de medição e em seguida foi utilizado planejamento de experimentos para melhorar este método.

Kaija *et al.* (2010) usaram algumas ferramentas Seis Sigma para avaliar um processo de impressão de uma camada dielétrica com uma impressora de jato de tinta. Inicialmente foi conduzido um estudo GR&R para avaliar qual a proporção de variação é causada pelo sistema de medição e pela variação do processo. Em seguida, planejamento e análise de experimentos foram conduzidos para identificar os parâmetros com os efeitos mais significativos para as respostas camada isolante e rugosidade da camada dielétrica.

Johnson *et al.* (2006) apresentaram uma aplicação do DMAIC para o experimento “*paper helicopter*”, disponível em Box (1992). Na etapa Medir, daquele projeto Seis Sigma para *Black Belts*, os autores usaram um estudo GR&R, através do método ANOVA (*analysis of variance*), para avaliar o sistema que mede o tempo de descida dos helicópteros de papel. A componente de variação devido ao sistema de medição foi de apenas 2,24%, logo, os autores concluíram que o sistema de medição era aceitável para a condução do projeto.

Li e Al-Refaie (2008) utilizaram o método DMAIC do Seis Sigma para aumentar a capacidade do sistema de medição de uma indústria madeireira. O sistema de medição avaliado por um estudo GR&R foi considerado inaceitável. Para melhorar o sistema de medição foi implementado treinamento dos operadores, seleção adequada do dispositivo de medição e o método de medição foi também melhorado. Em um segundo estudo GR&R, os autores concluíram que a variância do dispositivo de medição foi reduzida em 39.38% e o índice ndc (número de categorias distintas) foi melhorado com um aumento de 168.84%.

Os trabalhos citados acima usaram uma abordagem univariada, durante a etapa Medir dos projetos, para a avaliação do sistema de medição. A seção 2.5.5.1 detalhará como obter os componentes de variação em um estudo GR&R univariado e a seção 2.5.6.1 para um estudo GR&R multivariado por PCA.

2.5.1 Incerteza de medição

Incerteza de medição é um termo que é usado internacionalmente para descrever a qualidade de um valor medido. Enquanto este termo tem tradicionalmente sido reservado para as medições de alta precisão executadas em laboratórios de metrologia, muitos clientes e padrões de sistemas de qualidade requerem que a incerteza de medição seja conhecida e consistente com a capacidade de medição requerida de qualquer inspeção e equipamentos de testes e medições.

Em essência, incerteza é o valor atribuído para um resultado medido que descreve, dentro de um nível definido de confiança, a amplitude esperada para conter o resultado de medição verdadeiro. Incerteza de medição é normalmente referenciada como uma distribuição bilateral. Incerteza é uma expressão quantificada da confiabilidade da medição. Uma simples expressão deste conceito é:

$$\text{Medição Verdadeira} = \text{Medição Observada} \pm U \quad (2.18)$$

U é o termo para “incerteza expandida” do mensurando e resultado medido. Incerteza expandida é o erro padrão combinado (u_c , aleatório e sistemático) no processo de medição multiplicado por um fator de cobertura (k) que representa a área da distribuição normal para um nível desejado de confiança. O manual GUM (1995) determina que um fator de cobertura de 95% de confiança é suficiente para reportar a incerteza. Neste caso, é interpretado $k = 2$.

$$U = ku_c \quad (2.19)$$

O erro padrão combinado (u_c) inclui todas as componentes significantes de variação em um processo de medição. A Figura 2.9 mostra um diagrama de causa e efeito de algumas das potenciais fontes de variação. A componente de erro mais significativa pode ser quantificada por $\sigma_{desempenho}^2$ (AIAG, 2010). Outras fontes significantes de erro podem existir baseadas na aplicação da medição. Uma declaração de incerteza deve incluir um escopo adequado que identifique todos os erros significantes e permita que a medição seja replicada. Uma simples expressão pode ser quantificada como:

$$u_c^2 = \sigma_{desempenho}^2 + \sigma_{outro}^2 \quad (2.20)$$

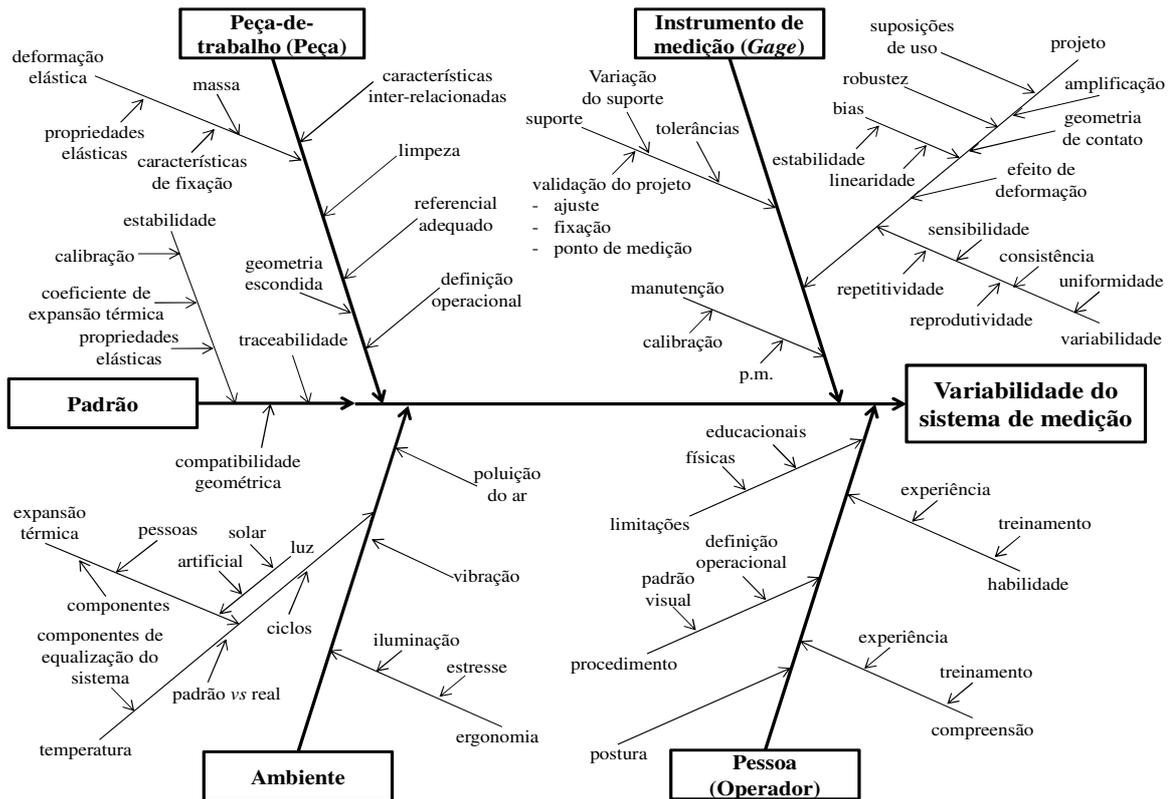


Figura 2.9 – Diagrama de causa e efeito da variabilidade de um sistema de medição
Adaptado de AIAG (2010)

Em muitos casos, a estimativa da incerteza de medição usará métodos de MSA e GR&R para quantificar os erros padrão significativos (AIAG, 2010). MSA distingue-se de incerteza pelo fato de focar em entender o processo de medição, determinando a quantidade de erro no processo e avalia a adequação do sistema de medição para o controle do produto ou processo. MSA fornece entendimento e melhoria (redução da variação). Incerteza é a amplitude de valores medidos, definidos por um intervalo de confiança, associado com um resultado medido e espera-se incluir o valor verdadeiro da medição. De uma forma geral, a variância combinada (aleatório e sistemático) pode ser composta pelos termos de variação, a longo e curto prazo, conforme Figura 2.10.

Da mesma forma que em desempenho de processo, o desempenho do sistema de medição é a rede de efeitos de todas as fontes determináveis e significantes de variação ao longo do tempo. O $\sigma_{desempenho}^2$ quantifica a atribuição de erros combinados de medição (aleatório e sistemático) e pode ser expresso como:

$$\sigma_{desempenho}^2 = \sigma_{capabilidade}^2 + \sigma_{estabilidade}^2 + \sigma_{consistência}^2 \quad (2.21)$$

Uma estimativa do desempenho de medição é uma expressão de erros esperados para determinadas condições, escopo e amplitude do sistema de medição. A capacidade representa os termos de erro (repetitividade, reprodutividade, *bias* e linearidade) de curto prazo de um sistema de medição.

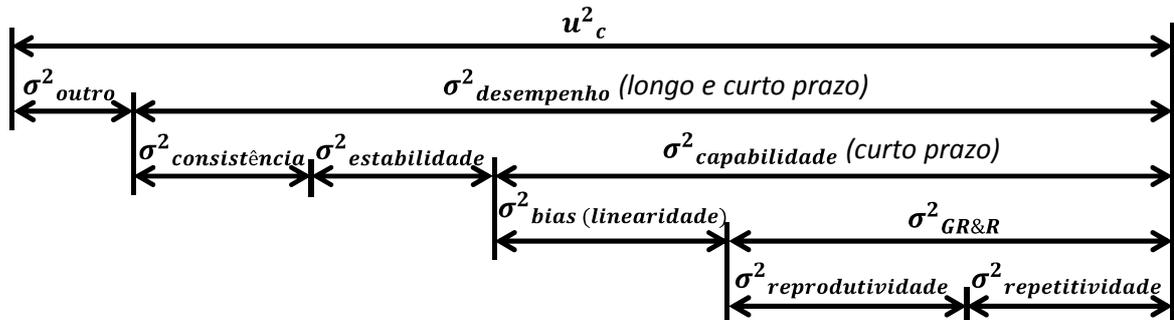


Figura 2.10 – Componentes da variância combinada de um sistema de medição
Fonte: Peruchi (2011)

2.5.2 Consistência

Consistência é a diferença na variação das medições realizadas ao longo do tempo, ou seja, a repetitividade ao longo do tempo. Um processo de medição consistente deve estar sob controle em relação a sua dispersão (Figura 2.11).

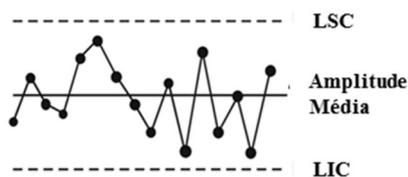


Figura 2.11 – Processo de medição consistente
Adaptado de AIAG (2010)

2.5.3 Estabilidade

Estabilidade é a variação total nas medições obtidas com um sistema de medição em uma mesma peça ao medir uma única característica ao longo de um extenso período de tempo. Pode ser considerada a mudança no *bias* ao longo do tempo. Um processo de medição estável deve estar sob controle em relação ao seu valor de referência (Figura 2.12).

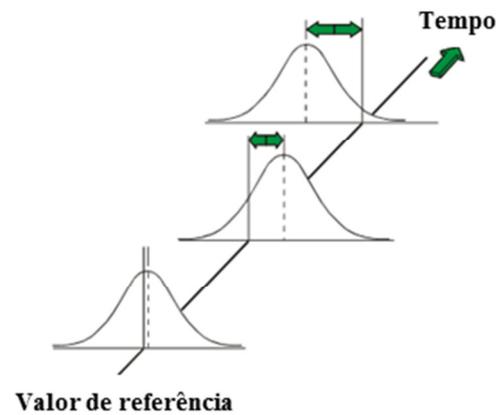


Figura 2.12 – Estabilidade de um processo de medição
Adaptado de AIAG (2010)

2.5.4 Capabilidade

AIAG (2010) define capabilidade como estimativa da variação combinada de erros de medição (aleatório e sistemático) baseada em uma avaliação de curto prazo. Uma estimativa de capabilidade de medição é uma expressão do erro esperado para definidas condições, escopo e amplitude do sistema de medição. A $\sigma_{capabilidade}^2$ pode ser expressa como:

$$\sigma_{capabilidade}^2 = \sigma_{bias (linearidade)}^2 + \sigma_{GR\&R}^2 \quad (2.22)$$

Existem dois pontos essenciais para entender e aplicar corretamente a capabilidade do sistema de medição. Primeiro, uma estimativa de capabilidade é sempre associada com um escopo de medição definido – condições, amplitude e tempo. Segundo, a consistência e uniformidade (erros de repetitividade), de curto prazo, ao longo da amplitude das medições são incluídas na estimativa de capabilidade.

2.5.4.1 Bias e Linearidade

Bias é frequentemente referenciado como exatidão. Devido ao fato de que o termo “exatidão” na literatura tem diversos significados, usar um termo alternativo a “*bias*” não é recomendado. *Bias* é a diferença entre o valor verdadeiro (valor de referência) e a média observada das medições de uma mesma característica em uma mesma peça (Figura 2.13). Para Attivissimo *et al.* (2011), *bias* é a medida de erro sistemático do sistema de medição.



Figura 2.13 – Bias de um processo de medição
Adaptado de AIAG (2010)

A diferença de *bias* ao longo de toda amplitude de operações (medições) esperadas do equipamento é chamada de linearidade. Pode ser interpretada como a mudança de *bias* em relação à amostra avaliada (Figura 2.14).

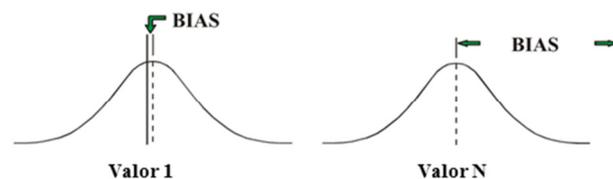


Figura 2.14 – Linearidade de um processo de medição
Adaptado de AIAG (2010)

2.5.4.2 Repetitividade e Reprodutividade

Grande parte dos trabalhos publicados na literatura definem repetitividade como a variação nas medições obtidas com um instrumento de medição quando usado diversas vezes por um avaliador que mede a mesma característica em uma mesma peça (AL-REFAIE e BATA, 2010; AWAD *et al.*, 2009; BURDICK *et al.*, 2003; MAJESKE, 2008; WU *et al.*, 2009). Além disso, segundo AIAG (2010), a repetitividade é comumente referenciada como a variação do equipamento de medição. De fato, repetitividade é a variação de causa comum (erro aleatório) das sucessivas réplicas medidas sob definidas condições de medição. Uma boa definição para repetitividade é variação “dentro do sistema” quando condições de medição são fixadas e definidas – peça, operador, instrumento, método, condições ambientais, etc.

Já a reprodutividade é tipicamente definida como a variação na média das medições feitas entre diferentes avaliadores usando o mesmo instrumento de medição para medir a mesma característica em uma mesma peça (ERDMANN *et al.*, 2010; KNOWLES *et al.*, 2003; POLINI e TURCHETTA, 2004; SENOL, 2004; VAN DEN HEUVEL e TRIP, 2002; WANG e CHIEN, 2010). No entanto, esta afirmação não é verdadeira para processos de medição em sistemas automatizados, nos quais o operador não é uma fonte significativa de variação. Por

esta razão, AIAG (2010) define reprodutividade como a variação média “entre sistemas” ou entre condições de medição – instrumentos, laboratórios, condições ambientais e, principalmente, operadores. A Figura 2.15 representa graficamente as fontes de variação devido à repetitividade e reprodutividade de um sistema de medição.

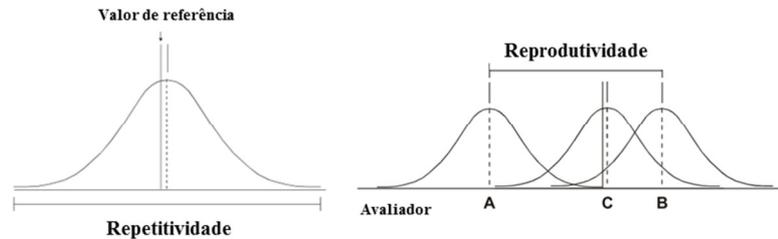


Figura 2.15 – Representação gráfica de repetitividade e reprodutividade
Adaptado de AIAG (2010)

Pode existir algum equívoco conceitual ao se tratar de *bias* e repetitividade. Se um instrumento de medição é certificado por uma agência independente como “exato”, ou se o instrumento é assegurado ter “alta precisão” pelo vendedor, pode-se concluir de forma incorreta que todas as leituras vão determinar valores muito próximos ao real. Isto não é apenas conceitualmente incorreto como também pode conduzir a decisões mal tomadas sobre o produto e o processo. É importante perceber que:

- *Bias* e repetitividade são independentes um do outro (veja Figura 2.16);
- Controlar uma destas fontes de erro não garante o controle da outra. Conseqüentemente, programas de controle do sistema de medição devem quantificar e rastrear todas as fontes relevantes de variação.

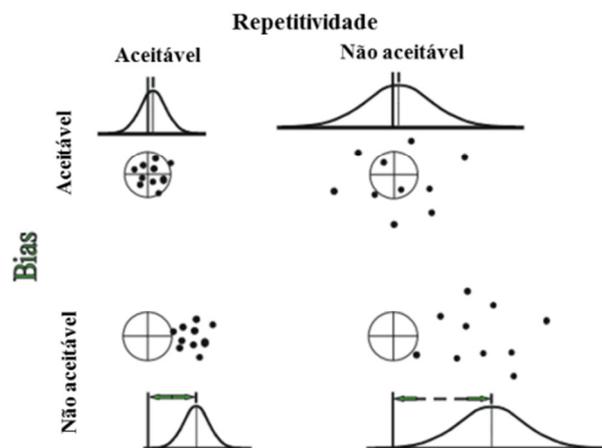


Figura 2.16 – Relacionamentos entre bias e repetitividade
Adaptado de AIAG (2010)

De acordo com Al-Refaie e Bata (2010), Shiau (2000) e Wang e Chien (2010) o estudo usado para medir as componentes de variação de uma análise do sistema de medição é chamado de estudo *Gage Repeatability and Reproducibility* (GR&R), o qual pretende determinar se a variabilidade do sistema de medição é relativamente menor que a variabilidade do processo monitorado.

Para situações de “controle de produto” em que o resultado da medição resulta na decisão para produtos conformes e não conformes, através de inspeção 100% ou amostragem, a especificação da tolerância deve ser considerada. Neste caso, teremos um GR&R direcionado para avaliar a tolerância especificada para o produto, logo, não deverá cobrir toda a amplitude do processo.

Para situações de “controle de processo” em que o resultado da medição resulta em decisões a respeito de “estabilidade de processo, entendimento da variação natural do processo” (ou seja, *SPC*, monitoramento de processo, capacidade e melhoria de processo), a viabilidade de amostras para toda a amplitude de operação torna-se muito importante. Neste caso, teremos um GR&R direcionado para avaliar a adequação do sistema de medição para o controle do processo. Portanto, quando o propósito de um sistema de medição é analisar um processo, as diretrizes gerais para aceitação do sistema de medição estão apresentadas na Figura 2.17 (AIAG, 2010; AL-REFAIE e BATA, 2010; DE MAST e WIERINGEN, 2004; DEJAEGHER *et al.*, 2006; HE *et al.*, 2011; LI e AL-REFAIE, 2008; MAJESKE, 2008; MONTGOMERY, 2005; PERUCHI *et al.*, 2013a; 2014; WANG e CHIEN, 2010; WHITE e BORROR, 2011; WOODALL e BORROR, 2008).

	GR&R	Decisão	Comentário
	$\%R\&R > 30\%$	Inaceitável	Esforços devem ser direcionados para melhorar o sistema de medição
	$10\% < \%R\&R < 30\%$	Marginal	Pode ser aceitável dependendo da aplicação, custo do instrumento de medição, custo de retrabalho ou reparo. Deve ser aprovado pelo cliente.
	$\%R\&R < 10\%$	Aceitável	Recomendado especialmente quando se tenta classificar peças ou quando é requisitado um controle mais rigoroso de processo.

Figura 2.17 – Critérios de aceitação do sistema de medição

Uma estatística adicional de variabilidade do sistema de medição é o número de categorias distintas (*ndc*). Esta estatística indica o número de categorias em que o processo de

medição pode ser dividido. Este valor deve ser maior ou igual a 5 (AIAG, 2010; AL-REFAIE e BATA, 2010; LI e AL-REFAIE, 2008; MAJESKE, 2008; MONTGOMERY, 2005; WANG e CHIEN, 2010; WHITE e BORROR, 2011; WOODALL e BORROR, 2008). Os equacionamentos utilizados para obtenção destes índices de avaliação do sistema de medição serão apresentados nas seções 2.5.5.1 (univariado, ANOVA), 2.5.6.1 (multivariado, PCA) e 3.3.2 (multivariado proposto, *weighted principal components* – WPC).

2.5.5 Caso univariado

Segundo Wang e Chien (2010) e Peruchi *et al.* (2014), dois métodos comumente usados em estudos GR&R univariado são: (1) Análise de Variância (ANOVA); e (2) Gráfico Xbar e R. De acordo com AIAG (2010), o método ANOVA é mais recomendado que o método de Média e Amplitude, pois possui vantagens tais como:

- Estima as variâncias mais precisamente;
- Extrai mais informações dos dados experimentais (através do efeito da interação entre peça e operador).

Na literatura, há uma considerável quantidade de trabalhos que usaram o método GR&R univariado ANOVA para avaliar um sistema de medição. Al-Refaie e Bata (2010) propuseram um procedimento para avaliar o sistema de medição e a capacidade do processo usando um estudo GR&R com quatro medidas de qualidade. Os índices taxa de precisão à tolerância (P/T), relação sinal ruído (SNR), taxa de discriminação (DR) e índices de capacidade (C_p e C_{pk}) foram os critérios de aceitação e rejeição empregados para avaliar o sistema de medição e a capacidade do processo.

Costa *et al.* (2005) trataram da concepção e implementação de um sistema de medição que permite avaliar a ondulação superficial do papel de forma quantitativa, objetiva e sistemática. O processo de concepção do sistema de medição foi apresentado considerando todas as suas etapas, desde a seleção e avaliação do dispositivo de medição, usando um estudo GR&R, até a geração e validação do modelo estatístico de medição.

Lyu e Chen (2008) desenvolveram um procedimento, baseado em um modelo linear generalizado, para avaliar a repetitividade e reprodutividade de um sistema de medição para dados do tipo atributo. Para calcular a repetitividade de um sistema, o procedimento integra o método iterativo mínimos quadrados ponderados (IWLS) e análise de desvio.

Senol (2004) usou planejamento de experimentos para acrescentar ao modelo de avaliação do sistema de medição o fator laboratório. Tal estudo concluiu que as condições

ambientais e atmosféricas, muitas vezes desprezadas em estudos GR&R, podem representar uma contribuição significativa para a variabilidade da medição.

Shiau (2000) usou um modelo matemático de custo de perda de medição para avaliar um dispositivo de medição e também melhorar sua utilização na linha de produção. Foi sugerido o conceito de limite de proteção para reduzir o custo da perda de medição *online* quando não há um dispositivo de melhor desempenho disponível.

A próxima seção detalhará como obter os componentes de variação em um estudo GR&R univariado, assim como os índices de aceitação do sistema de medição. Neste caso, utiliza-se análise de variância para identificar os fatores significativos de variação, em seguida estimam-se as componentes de variação do estudo e, por fim, estimam-se os índices de aceitação do sistema de medição.

2.5.5.1 Método ANOVA aplicado em GR&R

Um modelo geral ANOVA em análise de sistema de medição é representado por

$$Y = X + E \quad (2.23)$$

onde Y é o valor medido de uma peça selecionada aleatoriamente de um processo de manufatura, X é o valor verdadeiro e E é o erro devido ao sistema de medição. Os termos X e E são variáveis aleatórias normais independentes com média μ_p e μ_{sm} além de variâncias σ_p^2 e σ_{sm}^2 , respectivamente. A média μ_{sm} é referente ao *bias* do sistema de medição. Tipicamente, se for assumido $\mu_{sm} = 0$, também se conclui que $\mu_y = \mu_p$. Caso esta suposição seja violada, apenas a estimativa de μ_p será afetada, logo as estimativas das variâncias não serão sensíveis a problemas desta ordem (PERUCHI *et al.*, 2014). Visto que as variâncias são de maior interesse em estudos GR&R, o modelo ANOVA anterior, agora com p peças, o operadores e r réplicas pode ser expandido para (AL-REFAIE e BATA, 2010; AWAD *et al.*, 2009; BURDICK *et al.*, 2003; DELDOSSI e ZAPPA, 2011; ERDMANN *et al.*, 2010; GONG *et al.*, 2005):

$$y = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk} \begin{cases} i = 1, 2, \dots, p \\ j = 1, 2, \dots, o \\ k = 1, 2, \dots, r \end{cases} \quad (2.24)$$

onde y é a variável resposta medida, μ é a média dos valores medidos e $\alpha_i \sim N(0, \sigma_\alpha)$, $\beta_j \sim N(0, \sigma_\beta)$, $\alpha\beta_{ij} \sim N(0, \sigma_{\alpha\beta})$ e $\varepsilon_{ijk} \sim N(0, \sigma_\varepsilon)$ são variáveis aleatórias estatisticamente independentes para peça, operador, interação e o termo de erro, respectivamente. As variâncias do modelo acima podem ser traduzidas em notação GR&R para (PERUCHI *et al.*, 2012c; 2012e):

$$\begin{aligned} \sigma_p^2 &= \sigma_\alpha^2, & \sigma_{\text{repetitividade}}^2 &= \sigma_\varepsilon^2, & \sigma_{\text{reprodutividade}}^2 &= \sigma_\beta^2 + \sigma_{\alpha\beta}^2 \\ \sigma_{sm}^2 &= \sigma_{\text{repetitividade}}^2 + \sigma_{\text{reprodutividade}}^2, & \sigma_T^2 &= \sigma_p^2 + \sigma_{sm}^2 \end{aligned} \quad (2.25)$$

Mais detalhes de como calcular os componentes de variação na Eq. (2.25) usando ANOVA podem ser encontrados em AIAG (2010), Burdick *et al.* (2003,2005), Majeske (2008) e Wang e Chien (2010).

Dois índices comuns em estudos de GR&R serão usados para determinar a aceitação do sistema de medição. Recomenda-se avaliar o sistema de medição dimensionando o desvio-padrão do sistema de medição com o desvio-padrão total do processo observado. A estatística, denominada porcentagem R&R, é definida como (AIAG, 2010; AL-REFAIE e BATA, 2010; DE MAST e WIERINGEN, 2004; DEJAEGHER *et al.*, 2006; LI e AL-REFAIE, 2008; MONTGOMERY, 2005; WHITE e BORROR, 2011; WOODALL e BORROR, 2008):

$$\%R \& R = \frac{\sigma_{sm}}{\sigma_t} \quad (2.26)$$

O número de categorias distintas (*ndc* ou índice sinal-ruído, SNR) é uma estatística adicional para dimensionar a variabilidade do sistema de medição e pode ser definida como (AIAG, 2010; AL-REFAIE e BATA, 2010; LI e AL-REFAIE, 2008; MONTGOMERY, 2005; WHITE e BORROR, 2011; WOODALL e BORROR, 2008):

$$ndc = \sqrt{2} \frac{\sigma_p}{\sigma_{sm}} \quad (2.27)$$

Os critérios de aceitação do sistema de medição já foram descritos na seção anterior.

2.5.6 Caso multivariado

No caso em que se deseja avaliar um sistema de medição que mede múltiplas variáveis, utilização de métodos univariados pode não ser satisfatória. Nestes casos, as características geralmente apresentam uma estrutura de correlação que deve ser considerada na análise, logo, devem ser utilizados métodos multivariados para análise deste sistema de medição. Para estudos GR&R multivariado existem poucas pesquisas já realizadas até o momento na literatura (WANG e CHIEN, 2010; PERUCHI *et al.*, 2014).

Flyn *et al.* (2009) usaram análise de regressão para avaliar a capacidade de dois sistemas de medição que são equivalentes funcionalmente e diferentes tecnologicamente para um teste de aceitação de uma unidade de teste. Visto que os critérios “passa/não passa” de uma unidade de teste são inapropriados para as medições de precisão como repetitividade e reprodutividade, os autores propuseram uma metodologia, que utiliza MANOVA e PCA, para examinar se há diferença significativa entre os sistemas de medição.

He *et al.* (2011) propuseram uma abordagem *online* de MSA multivariada para detectar falhas em instrumentos de teste em um sistema de testes *multisite*. Os dados multivariados foram transformados usando análise de componentes principais, em seguida, os valores das componentes principais de cada instrumento de teste foi comparado com os limites de controle obtidos através da análise das componentes principais de todos os instrumentos de teste.

Majeske (2008) usou o método de MANOVA para estimar a matriz variância-covariância para estudos GR&R com um fator, dois fatores e três fatores significativos. Tal trabalho demonstra como ajustar um modelo MANOVA e estimar critérios multivariados (P/T_m , $\%R\&R_m$ e SNR_m) para avaliar o sistema de medição usando dados de um estudo GR&R de um painel automotivo de aço laminado.

Wang e Chien (2010) usaram o método *Process-oriented basis representation* (POBREP) para avaliar um processo de medição com dados multivariados. Os resultados mostraram que o método POBREP supera outros métodos como PCA e o método univariado, pois o POBREP é capaz de identificar causas específicas de problemas de produção e mapeá-los em uma matriz base.

Wang e Yang (2007) apresentaram um estudo GR&R com múltiplas características usando o método PCA. Dois índices compostos, precisão à tolerância e porcentagem de variação do sistema de medição em relação à variação total do processo, foram usados para

avaliar a adequação do sistema de medição. O estudo de caso mostrou que o método PCA foi melhor que o método univariado para estimação dos índices.

A próxima seção apresentará como obter os componentes de variação em um estudo GR&R multivariado, assim como os índices de aceitação do sistema de medição usando o método PCA.

2.5.6.1 Método PCA aplicado em GR&R

Segundo Wang e Chien (2010), para tratar com múltiplas características da qualidade em um estudo GR&R, PCA é um método alternativo ao método MANOVA proposto por Majeske (2008). PCA é uma das ferramentas aplicadas mais amplamente usadas para resumir os padrões comuns de variação entre variáveis. Além disso, esta técnica estatística também é capaz de reter informações significativas nos primeiros eixos das PCs, visto que a variação associada ao erro experimental, erro de medição, erro de arredondamento é resumido nos últimos eixos das PCs (PAIVA, 2006; PAIVA *et al.*, 2007; PERUCHI *et al.*, 2013a). PCA é, algebricamente, uma combinação linear ℓ de q variáveis aleatórias Y_1, Y_2, \dots, Y_q . Geometricamente, essas combinações representam um novo sistema de coordenadas obtidas durante a rotação de um sistema original (JOHNSON e WICHERN, 2007; MUKHERJEE e RAY, 2008; PAIVA *et al.*, 2009; PERUCHI *et al.*, 2013a). As coordenadas dos eixos têm agora as variáveis Y_1, Y_2, \dots, Y_q e representam a direção de máximo. As componentes principais são não correlacionadas e dependem somente da matriz de covariância Σ (ou da matriz de correlação R) das variáveis Y_1, Y_2, \dots, Y_q e seu desenvolvimento não requer a suposição de normalidade multivariada. O i -ésimo componente principal é obtido pela Eq. (2.4) e os escores de componente principal pela Eq. (2.5).

Considerando Z a matriz de dados padronizados e E a matriz de autovetores do conjunto multivariado, cada escore da componente principal pode então ser obtido com (JOHNSON e WICHERN, 2007):

$$PC_{score} = Z^T E = \begin{bmatrix} \left(\frac{y_{11} - \bar{y}_1}{\sqrt{s_{11}}} \right) & \left(\frac{y_{12} - \bar{y}_2}{\sqrt{s_{22}}} \right) & \dots & \left(\frac{y_{1q} - \bar{y}_q}{\sqrt{s_{qq}}} \right) \\ \left(\frac{y_{21} - \bar{y}_1}{\sqrt{s_{11}}} \right) & \left(\frac{y_{22} - \bar{y}_2}{\sqrt{s_{22}}} \right) & \dots & \left(\frac{y_{2q} - \bar{y}_q}{\sqrt{s_{qq}}} \right) \\ \vdots & \vdots & \ddots & \vdots \\ \left(\frac{y_{n1} - \bar{y}_1}{\sqrt{s_{11}}} \right) & \left(\frac{y_{n2} - \bar{y}_2}{\sqrt{s_{22}}} \right) & \dots & \left(\frac{y_{nq} - \bar{y}_q}{\sqrt{s_{qq}}} \right) \end{bmatrix}^T \times \begin{bmatrix} e_{11} & e_{12} & \dots & e_{1q} \\ e_{21} & e_{22} & \dots & e_{2q} \\ \vdots & \vdots & \ddots & \vdots \\ e_{q1} & e_{q2} & \dots & e_{qq} \end{bmatrix} \quad (2.28)$$

Um modelo completo de estudo GR&R multivariado, usando PCA, com q características da qualidade, p peças, o operadores e r réplicas é representado pela Eq. (2.29). Este modelo é similar ao modelo univariado, no entanto, as respostas originais são substituídas pelos escores de uma componente principal (PERUCHI *et al.*, 2012a; 2013a).

$$PC_q = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk} \begin{cases} i = 1, 2, \dots, p \\ j = 1, 2, \dots, o \\ k = 1, 2, \dots, r \end{cases} \quad (2.29)$$

onde PC_q é a componente usada como resposta do modelo, μ é uma constante, $\alpha_i \sim N(0, \sigma_\alpha)$, $\beta_j \sim N(0, \sigma_\beta)$, $\alpha\beta_{ij} \sim N(0, \sigma_{\alpha\beta})$ e $\varepsilon_{ijk} \sim N(0, \sigma_\varepsilon)$ são variáveis aleatórias estatisticamente independentes para peça, operador, interação e o termo de erro, respectivamente. Os cálculos para estimar as componentes de variação do estudo GR&R e os índices multivariados de aceitação do sistema de medição, usando PCA, são realizados da mesma forma que no método univariado ANOVA. No entanto, os resultados destes equacionamentos aplicados aos escores das componentes principais representam a avaliação simultânea das q características do processo (PERUCHI *et al.*, 2012b). Wang e Chien (2010) determinaram que os critérios de aceitação do sistema de medição são os mesmos descritos na seção 2.5.4.2.

2.6 Análise multivariada de capacidade de processo

Os índices de capacidade de processo (ICP), C_p , C_{pk} , C_{pm} e C_{pmk} foram projetados para avaliar casos os quais a característica da qualidade é univariada. No entanto, é um fato incontestado que, frequentemente, há mais de uma característica da qualidade resultante de processos (SCAGLIARINI, 2011). Neste cenário, a qualidade é medida pelo nível conjunto de diversas características da qualidade correlacionadas e, logo, análise de capacidade deve ser baseada em técnicas estatísticas multivariadas; veja, por exemplo, o livro de Kotz e Lovelace (1998) e a revisão de Kotz e Johnson (2002).

Definições alternativas de índice de capacidade de processos multivariados (ICPM), baseados em diversas abordagens distintas, têm sido propostas na literatura. Em geral, ICPM são construídos em uma das seguintes formas: usando a relação de volume da região de tolerância com o volume da região do processo – veja, por exemplo, Taam *et al.* (1993) e Pearn *et al.* (2007) e suas referências; usando a proporção de itens não conformes – veja Chen (1994) e Chen *et al.* (2003); ou através de PCA.

Esta tese focará na avaliação multivariada da capacidade de processo através da técnica multivariada PCA.

2.6.1 Caso univariado

ICP são medidas da habilidade de um processo de manufatura produzir itens que atendam aos limites de especificação. Como regra, ICPs comparam a variabilidade natural de um processo estável e a variabilidade permitida deste processo. Alguns dos ICPs comumente usados são os seguintes (MONTGOMERY, 2005; PERAKIS e XEKALAKI, 2012; SCAGLIARINI, 2011; WANG, 2005; WANG e CHEN, 1998; WANG e DU, 2000):

$$C_p = \frac{USL - LSL}{6\sigma} \quad (2.30)$$

$$C_{pk} = \min\left\{\frac{USL - \mu}{3\sigma}, \frac{\mu - LSL}{3\sigma}\right\} = \frac{d - |\mu - M|}{3\sigma} \quad (2.31)$$

$$C_{pm} = \frac{USL - LSL}{6\sqrt{\sigma^2 + (\mu - T)^2}} \quad (2.32)$$

$$C_{pmk} = \frac{d - |\mu - M|}{3\sqrt{\sigma^2 + (\mu - T)^2}} \quad (2.33)$$

onde USL e LSL são os limites superior e inferior de especificação respectivamente, T é o valor alvo, μ é a média do processo, σ é o desvio-padrão do processo, $M = (USL + LSL)/2$ é o ponto médio do intervalo de especificação e $d = (USL - LSL)/2$ é a metade da largura do intervalo de especificação.

2.6.2 Caso multivariado

Considerando que $\mathbf{Y}' = (Y_1, Y_2, \dots, Y_m)$ representa o vetor das q características de interesse com vetor de médias $\boldsymbol{\mu}$ e matriz variância-covariância $\boldsymbol{\Sigma}$ positiva definida. Assume-se que os dados do processo multivariado são tomados de uma distribuição normal multivariada.

Denotando os valores do q -vetor dos limites inferiores de especificação, limites superiores de especificação e valores alvos como segue:

$$\mathbf{LSL}' = (LSL_1, LSL_2, \dots, LSL_q) \quad (2.34)$$

$$\mathbf{USL}' = (USL_1, USL_2, \dots, USL_q) \quad (2.35)$$

$$\mathbf{T}' = (T_1, T_2, \dots, T_q) \quad (2.36)$$

Wang e Chen (1998) propuseram um procedimento para a construção dos índices de capacidade multivariado usando PCA. Esta técnica usa a decomposição espectral da matriz variância-covariância Σ :

$$\Sigma = \mathbf{E}\mathbf{D}\mathbf{E}' \quad (2.37)$$

onde $\mathbf{E} = (\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_q)$ é a matriz de autovetores de Σ com colunas \mathbf{e}_i ($i = 1, 2, \dots, q$), e $\mathbf{D} = \mathbf{E}'\Sigma\mathbf{E} = \text{diag}(\lambda_1, \dots, \lambda_q)$ é a matriz diagonal dos autovalores. As especificações de engenharia da i -ésima componente principal (PC_i) e o valor alvo são:

$$LSL_{PC_i} = \mathbf{e}_i' \mathbf{LSL} \quad USL_{PC_i} = \mathbf{e}_i' \mathbf{USL} \quad T_{PC_i} = \mathbf{e}_i' \mathbf{T} \quad (2.38)$$

Wang e Chen (1998) propuseram avaliar a capacidade multivariada considerando um subconjunto v ($v \leq q$) de componentes principais. Eles definiram os ICPMs MC_p , MC_{pk} , MC_{pm} e MC_{pmk} usando os ICP univariados dos componentes principais. O índice de capacidade MC_p para o processo multivariado definido por Wang e Chen (1998) é

$$MC_p = \left(\prod_{i=1}^v C_{p,PC_i} \right)^{1/v} \quad (2.39)$$

Onde

$$C_{p;PC_i} = \frac{USL_{PC_i} - LSL_{PC_i}}{6\sigma_{PC_i}} \quad (2.40)$$

é a medida univariada de capacidade para a i -ésima componente principal, $\sigma_{PC_i} = \sqrt{\lambda_i}$ e v denota o número de componentes principais usados para avaliar a capacidade. Similarmente, eles definiram MC_{pk} , MC_{pm} e MC_{pmk} substituindo $C_{p;PC_i}$ por $C_{pk;PC_i}$, $C_{pm;PC_i}$, $C_{pmk;PC_i}$, respectivamente, para $i = 1, 2, \dots, v$.

Esta definição de índice de capacidade tem uma deficiência que todas as componentes principais são igualmente ponderadas. No entanto, é amplamente conhecido que as primeiras componentes principais serão mais relevantes que as últimas. Com objetivo de superar este problema, Wang (2005) propôs o uso da média geométrica ponderada. Os pesos neste caso são os autovalores λ_i de cada componente principal. O índice é:

$$MWC_p = \left(\prod_{i=1}^v C_{p;PC_i}^{\lambda_i} \right)^{1/\sum_{i=1}^v \lambda_i} \quad (2.41)$$

O autor propôs definições similares para MWC_{pk} , MWC_{pm} e MWC_{pmk} .

Neste mesmo cenário, Perakis e Xekalaki (2012) sugeriram uma série de novos índices que permitem diferenças potenciais na porção de variância explicada pelos componentes principais em questão. Consideração é tomada destas diferenças atribuindo pesos distintos para os índices univariados correspondentes às componentes principais empregadas, em particular em proporção ao percentual de variância explicada por elas, como determinado pelos seus respectivos autovalores. Perakis e Xekalaki (2012) especificamente propuseram o seguinte índice:

$$MXC_p = \frac{\sum_{i=1}^v \lambda_i C_{p;PC_i}}{\sum_{i=1}^v \lambda_i} \quad (2.42)$$

e ofereceram similares definições de MXC_{pk} , MXC_{pm} e MXC_{pmk} .

Recentemente, outros trabalhos em ICPMs baseados em componentes principais têm sido produzidos por Gonzáles e Sánches (2009) e por Shinde e Khadse (2009).

2.7 Modelagem de múltiplas respostas

2.7.1 Mínimos quadrados ordinários – OLS

O método dos mínimos quadrados ordinários (do inglês *ordinary least squares* – OLS) é o algoritmo tipicamente usado para estimar os coeficientes de um modelo de regressão linear múltipla, arranjos fatoriais completos, arranjos fracionados e arranjos de superfícies de resposta (MONTGOMERY, 2005; PAIVA, 2006). Um modelo de regressão linear múltipla é representado pela Eq. (2.43) abaixo:

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \varepsilon \quad (2.43)$$

O método OLS escolhe os β s (coeficientes dos regressores) na Eq. (2.43) de tal forma que os quadrados dos erros, ε , sejam minimizados. A função de mínimos quadrados é:

$$L = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij} \right)^2 \quad (2.44)$$

A função L a ser minimizada em relação à $\beta_0, \beta_1, \dots, \beta_k$. O estimador de mínimos quadrados deve satisfazer

$$\left. \frac{\partial L}{\partial \beta_0} \right|_{\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k} = -2 \sum_{i=1}^n \left(y_i - \hat{\beta}_0 - \sum_{j=1}^k \hat{\beta}_j x_{ij} \right) = 0 \quad (2.45)$$

$$\left. \frac{\partial L}{\partial \beta_j} \right|_{\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k} = -2 \sum_{i=1}^n \left(y_i - \hat{\beta}_0 - \sum_{j=1}^k \hat{\beta}_j x_{ij} \right) x_{ij} = 0 \quad (2.46)$$

As equações normais de mínimos quadrados acima são simplificadas através de notação matricial por (MONTGOMERY, 2005):

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (2.47)$$

Deseja-se encontrar o vetor dos estimadores de mínimos quadrados que minimizam:

$$L = \sum_{i=1}^n \varepsilon_i^2 = \boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \quad (2.48)$$

Reescrevendo L, temos:

$$\begin{aligned} L &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ &= \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \\ &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'\mathbf{X}'\mathbf{y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \end{aligned} \quad (2.49)$$

onde $\boldsymbol{\beta}'\mathbf{X}'\mathbf{y}$ e sua transposta, $(\boldsymbol{\beta}'\mathbf{X}'\mathbf{y})' = \mathbf{y}'\mathbf{X}\boldsymbol{\beta}$ são escalares, logo, o estimador de mínimos quadrados deve satisfazer:

$$\left. \frac{\partial L}{\partial \boldsymbol{\beta}_j} \right|_{\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k} = -2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = 0 \quad (2.50)$$

Por simplificação, temos os coeficientes da regressão estimados pelo algoritmo de mínimos quadrados pela equação matricial abaixo:

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \quad (2.51)$$

2.7.2 Coeficiente de determinação

A medida mais comum de adequação de um modelo é o coeficiente de determinação (R^2). Este termo representa o percentual de variação na resposta que é explicada pelo modelo estimado. Associado a este coeficiente, encontra-se o R^2 ajustado – $R^2(\text{adj.})$, que considera o fato de que R^2 tende a superestimar a quantidade atual de variação contabilizada para a população. Também é fato que a inclusão de muitos termos no modelo de regressão aumenta substancialmente o valor de R^2 . Se o modelo recebeu fatores adicionais desnecessários,

haverá um incremento em R^2 , sem haver, necessariamente, melhoria de informação na resposta. É por este motivo que o valor de R^2 ajustado é mais apropriado para se comparar modelos com diferentes quantidades de termos (PAIVA, 2006).

O valor de R^2 pode ser calculado aplicando-se a Eq. (2.52) abaixo:

$$R^2 = \frac{SS_R}{SS_T} = 1 - \frac{SS_E}{SS_T} \quad (2.52)$$

O coeficiente de determinação ajustado $R^2(\text{adj.})$ é uma modificação que considera o número q de variáveis do modelo. Observando-se a Eq. (2.53), nota-se que o valor ajustado decresce à medida que q aumenta.

$$R^2(\text{adj.}) = 1 - \left(\frac{n-1}{n-q} \right) (1 - R^2) \quad (2.53)$$

2.7.3 Análise residual

Os resíduos de um modelo de regressão desenvolvem um importante papel no julgamento da sua adequação. Considerando-se alguns aspectos peculiares, o conjunto de resíduos deve ter distribuição normal com média zero e variância σ^2 , não devem ser autocorrelacionados e não deve ser correlacionados com as variáveis preditoras. Devem ter padrão aleatório, não tendencioso e devem preferencialmente assumir a forma padronizada segundo a Eq. (2.54) (MONTGOMERY, 2005; MONTGOMERY *et al.*, 2004).

$$d_i = \frac{e_i}{\sqrt{MS_e}} = \frac{e_i}{\sqrt{\hat{\sigma}^2}} \quad (2.54)$$

A padronização dos resíduos cria um escalonamento para o desvio-padrão, o que torna sua interpretação mais fácil. Outra forma de escalonamento é a de Student, dada pela Eq. (2.55) a seguir:

$$d_i = \frac{e_i}{\sqrt{\hat{\sigma}^2(1-h_{ii})}} \quad (2.55)$$

h_{ii} representa o i -ésimo elemento da diagonal de uma matriz chapéu $\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$.

2.7.4 Diagnóstico de observações influentes

Algumas observações experimentais podem exercer uma influência desproporcional no modelo de regressão ajustado. Consequentemente, os parâmetros estimados podem depender mais de um subconjunto influente que das observações não influentes do conjunto de dados. Se estes pontos influentes são valores “ruins”, eles devem ser eliminados. A disposição dos pontos no espaço de x é importante em determinar as propriedades do modelo. A matriz $\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ é muito útil em identificar observações influentes. Os elementos h_{ij} de \mathbf{H} podem ser interpretados como quantidade de influência (*leverage*) exercida por y_j em \hat{y}_i . Visto que $\sum_{i=1}^n h_{ii} = \text{rank}(\mathbf{H}) = \text{rank}(\mathbf{X}) = q$, o tamanho médio dos elementos da diagonal da matriz \mathbf{H} é q/n . Uma orientação sugerida por Montgomery (2005) consiste em avaliar se o elemento da diagonal h_{ii} é maior que $2q/n$, a observação i é considerada influente. No caso particular dos resíduos padronizados, esta observação influente será maior que $|2|$.

2.7.5 Teste para falta de ajuste

A adição de pontos centrais (os quais representam as réplicas experimentais) aos arranjos proporciona a obtenção de uma estimativa do erro experimental. De acordo com Montgomery (2005), este artifício permite que a soma de quadrados residual (SS_{ϵ}) seja discriminada em dois componentes: (a) a soma de quadrados devido ao erro puro (SS_{pe}) e (b), a soma de quadrados devido à falta de ajuste do modelo escolhido (SS_{lof} – lof, do inglês *Lack of Fit*). Assim, escreve-se:

$$SS_{\epsilon} = SS_{pe} + SS_{lof} \quad (2.56)$$

Por suposição, admitindo-se que existam n_i observações de uma dada resposta de interesse no i -ésimo nível dos regressores x_i , $i = 1, 2, \dots, mq$. Considere-se que y_{ij} denote a j -ésima observação de uma resposta no nível x_i , $i = 1, 2, \dots, m$ e $j = 1, 2, \dots, n_i$. Como existe um total de observações $n = \sum_{i=1}^m n_i$, então, o ij -ésimo resíduo será:

$$y_{ij} - \hat{y}_i = (y_{ij} - \bar{y}_i) + (\bar{y}_i - \hat{y}_i) \quad (2.57)$$

Onde \bar{y}_i é a média da n_i observações no nível x_i . Elevando-se ao quadrado ambos os lados da Eq. (2.57) e somando-se cada i e j , se obtém:

$$\underbrace{\sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \hat{y}_i)^2}_{SS_r} = \underbrace{\sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_i)^2}_{SS_{pe}} + \underbrace{\sum_{i=1}^m (\bar{y}_i - \hat{y}_i)^2}_{SS_{lof}} \quad (2.58)$$

O lado esquerdo da Eq. (2.58) é a soma de quadrados residual (SS_r). Os dois termos do lado direito são respectivamente, o erro puro (SS_{pe}) e a falta de ajuste do modelo (SS_{lof}). Pode-se notar que SS_{pe} é obtido computando-se a correta soma de quadrados das observações repetidas em cada nível da variável independente (fator), em operações repetidas para cada um dos m níveis de x . Se a suposição de variância constante for satisfeita SS_{pe} representa um modelo independente de medição do erro puro, porque apenas a variabilidade das repostas em nível dos fatores é utilizada para calculá-lo. Uma vez que existem $n_i - 1$ graus de liberdade associados ao erro puro em cada nível, o número total de graus de liberdade para o termo de erro puro é igual a $n - m$. Como se nota, SS_{lof} é uma soma quadrática ponderada dos desvios encontrados entre a resposta média \bar{y}_i em um dado nível da variável independente e o correspondente valor ajustado \hat{y}_i . O valor ajustado \hat{y}_i é a estimativa fornecida pelo modelo de regressão escolhido para os valores das variáveis independentes em uma dada observação. Se o valor ajustado possuir um valor numérico muito próximo ao valor das médias das repostas \bar{y}_i , então, há um forte indício que o modelo de regressão escolhido é o mais correto. Caso contrário, haverá a necessidade de se estudar outro modelo que apresente um melhor ajuste dos dados observados. Há $m - q$ graus de liberdade associados à SS_{lof} porque existem m níveis de x e q graus de liberdade perdidos em função dos q parâmetros que devem ser estimados pelo modelo.

A estatística de teste para a falta de ajuste pode ser escrita na forma:

$$F_0 = \frac{SS_{lof} / (m - q)}{SS_{pe} / (n - m)} = \frac{MS_{lof}}{MS_{pe}} \quad (2.59)$$

Quando a estatística de F_0 assumir valores menores que o nível de significância escolhido, então, haverá evidência suficiente para se aceitar a hipótese nula de que a diferença

entre o valor ajustado e a média observada é nula. Logo, não haverá falta de ajuste na estimativa proporcionada pelo modelo escolhido.

2.7.6 Caso univariado

Uma potencial preocupação no uso de arranjos fatoriais completos de dois níveis está na suposição de linearidade nos efeitos dos fatores. É evidente que linearidade perfeita é desnecessária e o arranjo 2^k funcionará razoavelmente bem mesmo quando a suposição de linearidade for apenas próxima da realidade. Um modelo linear com k fatores é representado pela Eq. (2.43) (MYERS *et al.*, 2009). De fato, quando termos de interação são adicionados aos efeitos principais ou modelo de primeira ordem, o modelo passa a representar alguma curvatura na modelagem da resposta de interesse. Esta curvatura, evidentemente, resulta da torção no plano induzida pelos termos de interação $\beta_{ij}x_i x_j$ na Eq. (2.60).

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i < j} \beta_{ij} x_i x_j + \varepsilon = b_0 + \nabla f(x)^T \quad (2.60)$$

Haverá situações onde a curvatura na função da resposta não será adequadamente modelada apenas pela Eq. (2.60). Em tais casos, um modelo lógico a ser considerado é:

$$\begin{aligned} y &= \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i < j} \beta_{ij} x_i x_j + \varepsilon \\ &= b_0 + \nabla f(x)^T + \frac{1}{2} x^T [\nabla^2 f(x)] x \end{aligned} \quad (2.61)$$

onde β_{ii} representa os efeitos quadráticos ou puramente de segunda ordem. A Eq. (2.61) é chamada de modelo de superfície de resposta de segunda ordem.

2.7.7 Caso multivariado

A existência de correlações entre as várias respostas de um conjunto exerce uma forte influência sobre as funções de transferência utilizadas. Como o modelo matemático é extremamente importante para a determinação do ponto de ótimo, a negligência da estrutura de correlação pode conduzir a pontos de ótimo inapropriados, fruto de uma inadequação do

método dos mínimos quadrados ordinários (BRATCHELL, 1989; KHURI e CONLON, 1981).

Ao longo dos últimos anos, vários pesquisadores têm se preocupado em tratar adequadamente este tipo de problema, considerando as estruturas de correlação entre as respostas anteriormente à construção dos modelos dos processos. Muitos destes têm utilizado a abordagem baseada na Análise de Componentes Principais (FUNG e KANG, 2005; LIAO, 2006; PAIVA *et al.*, 2007; PAIVA *et al.*, 2009).

Diversas dificuldades podem surgir quando se trabalha com respostas multivariadas. Independentemente do modelo, a negligência da correlação pode conduzir a interpretações equivocadas do problema multi-objetivo. A questão fundamental é se ajustar os modelos multivariados desprezando a dependência entre os erros, ou a dependência linear entre os valores esperados e as respostas, ou a dependência linear entre os dados originais, que podem ocorrer. Quando estas dependências ocorrem, o correto seria modelar as funções usando RMM (regressão múltipla multivariada) (RENCHEER, 2002), PLS (*Partial Least Squares*) ou PCR (Regressão por Componentes Principais). Nestas três proposições, porém, pressupõe-se que exista correlação entre as variáveis do conjunto de entrada e os dados de saída. No caso dos arranjos de superfície de resposta, entretanto, o conjunto de entrada é projetado para ter valores independentes, o que elimina a possibilidade de multicolinearidade dos modelos de regressão (MONTGOMERY, 2001). Como forma de se contornar o problema de correlação existente apenas no conjunto de saída, uma estratégia híbrida baseada na PCA pode ser empregada (BOX *et al.*, 1973). Além de eliminar o problema da correlação nos coeficientes dos regressores, a PCA reduz a dimensão do problema multi-objetivo. Nesta abordagem, os dados multivariados são fatorizados em um número de variáveis independentes, trocando as variáveis de resposta pelo escore do componente principal a partir da decomposição espectral da matriz de variância-covariância ou correlação das variáveis originais. Aplicando-se o algoritmo OLS às combinações experimentais do CCD (*Central Composite Design*), tendo os escores como resposta, criam-se as funções objetivo independentes. Para forçar a solução do problema para o interior da região experimental, um modelo de programação não-linear é gerado em termos de componentes principais, podendo ser representado pelo sistema de Equações (2.62) proposto por Bratchell (1989).

$$PC_i = b_0 + \nabla f(x)^T + \frac{1}{2} x^T [\nabla^2 f(x)] x \quad (2.62)$$

2.8 Otimização de múltiplas respostas

A literatura oferece diversas técnicas para otimização multi-objetivo. Dentre elas, têm sido utilizado, em diferentes aplicações, a função *desirability* (DERRINGER e SUICH, 1980), distância generalizada (KHURI e CONLON, 1981), integração multivariada (CHIAO e HAMADA, 2001), rendimento multivariado por redução quadrática gaussiana (LIU *et al.*, 2002), *goal programming* não-linear (KOVACH e CHO, 2009) e, mais recentemente, a função *desirability* robusta que considera incerteza do modelo (HE *et al.*, 2012). No entanto, alguns pesquisadores (HUANG e LIN, 2008; PAIVA *et al.*, 2007; SAFIZADEH, 2002) têm destacado um fenômeno que ocorre na modelagem de processos de manufatura e que algumas vezes é negligenciado: a correlação entre as múltiplas respostas. De acordo com Box *et al.* (1973), os resultados da otimização podem ser influenciados pela presença de tais correlações, pela instabilidade provocada nos coeficientes da regressão. Conseqüentemente, se a estrutura de variância-covariância é negligenciada, as equações de regressão não representam adequadamente as funções objetivo e restrições (CHIAO e HAMADA, 2001; KHURI e CONLON, 1981).

Algumas abordagens de otimização que consideram a correlação entre múltiplas respostas foram recentemente estabelecidas para focar nesta questão em particular. Chiao e Hamada (2001), por exemplo, trataram das limitações do método *desirability* em termos de influência da correlação na otimização, propondo um método baseado na distribuição de probabilidade normal multivariada. Na mesma direção, Duffy *et al.* (1998) e Liu *et al.* (2002) apresentaram propostas que levam em consideração a maximização do rendimento de processos multivariados (a probabilidade conjunta que garante a medida de desempenho dentro da especificação). Khuri e Conlon (1981) propuseram a minimização da distância generalizada entre as respostas e respectivos alvos escritos em termos da matriz de variância-covariância estimada. Bratchel (1989) empregou uma superfície de resposta de segunda ordem baseada em PCA para adequadamente representar um conjunto original de respostas.

Recentemente, Paiva *et al.* (2009) propuseram um método de otimização que combina PCA e RSM, convertendo as múltiplas funções objetivo originais em novas variáveis não correlacionadas e seus respectivos alvos. Todavia, se as múltiplas respostas recebem distintas importâncias relativas, o método de Paiva *et al.* (2009) é incapaz de atribuir a ponderação desejada. Com objetivo de suprir esta carência, Gomes *et al.* (2013) desenvolveram um

método para otimização de múltiplas respostas correlacionadas com ponderação que combina PCA, RSM e o conceito de MSE.

2.8.1 Caso univariado

Da própria natureza dos processos, dois objetivos principais devem ser avaliados quando se busca sua melhoria: a distância entre um valor real e um valor desejado (alvo – θ) para uma dada característica de qualidade, e sua variância (σ^2). Vining e Myers (1990) afirmaram que a otimização simultânea de média e variância pode ser realizada via metodologia de superfície de resposta dual. Supondo que a variável resposta seja Y e as variáveis experimentais controladas sejam x_1, \dots, x_k ; Vining e Myers (1990), primeiramente, propuseram o ajuste de dois modelos polinomiais de segunda ordem, tanto a média (μ) quanto a variância (σ^2) ou o desvio-padrão.

$$\mu = b_0 + \nabla f(x)^T + \frac{1}{2} x^T [\nabla^2 f(x)] x \quad (2.63)$$

$$\sigma^2 = b_0 + \nabla f(x)^T + \frac{1}{2} x^T [\nabla^2 f(x)] x \quad (2.64)$$

Em seguida, um determinado sistema de equações é escolhido, dependendo do objetivo desejado para o problema, sendo θ o alvo para a característica abordada.

Caso 1 – Minimização (STB – *Smaller-the-better*) – Minimizar a média (μ), mantendo a variância em um valor desejado.

$$\begin{aligned} & \text{Minimizar } \mu \\ & \text{Sujeito a: } \sigma^2 = T \end{aligned} \quad (2.65)$$

Caso 2 – Normalização (NTB – *Nominal-the-best*) – Minimizar variância, mantendo a média (μ) em um valor específico.

$$\begin{aligned} & \text{Minimizar } \sigma^2 \\ & \text{Sujeito a: } \mu = T \end{aligned} \quad (2.66)$$

Caso 3 – Maximização (LTB – *Larger-the-better*) – Maximizar a média (μ), mantendo variância em um valor desejado.

$$\begin{aligned} & \text{Maximizar } \mu \\ & \text{Sujeito a: } \sigma^2 = T \end{aligned} \quad (2.67)$$

Procede-se, então, à localização do ponto ótimo (estacionário) igualando-se o gradiente da função Lagrangeana a zero, tal que $\nabla[L(\mu(\mathbf{x}), \sigma(\mathbf{x}), \lambda)] = 0$, onde $[L(\mu(\mathbf{x}), \sigma(\mathbf{x}), \lambda) = \mu(\mathbf{x}) + \lambda\sigma(\mathbf{x})]$, λ é o multiplicador de Lagrange. Comumente, uma restrição adicional de rotacionalidade $g(\mathbf{x}) = \mathbf{x}'\mathbf{x} - a^2 \leq 0$ pode ser adicionada ao sistema para se evitar soluções que caiam fora da região experimental. Vining e Myers (1990) notaram que seu procedimento era mais bem ajustado para o caso de normalização. Para os casos de minimização e maximização, um valor aceitável para a resposta secundária (restrição) é normalmente desconhecido. A superfície de resposta para variância pode ser obtida utilizando várias estratégias, tais como replicação pura (SHIN *et al.*, 2011), arranjos cruzados (PAIVA *et al.*, 2012), arranjos combinados (MYERS *et al.*, 2009) ou a teoria de propagação de erro (PLANTE, 2001). Usando alguma destas estratégias, as funções de média e variância podem ser obtidas usando o algoritmo OLS.

2.8.2 Caso multi-objetivo

No contexto de otimização por RPD, MSE é uma função objetivo que combina superfícies de resposta para média $\hat{y}(\mathbf{x})$ e variância $\hat{\sigma}^2(\mathbf{x})$, além do respectivo alvo T . Esta função objetivo é sujeita apenas à restrição de região experimental, como inicialmente sugerido por Lin e Tu (1995):

$$\underset{\mathbf{x} \in \Omega}{\text{Min}} \text{MSE} = [\hat{y}(\mathbf{x}) - T]^2 + \hat{\sigma}^2(\mathbf{x}) \quad (2.68)$$

Na Eq. (2.68), \mathbf{x} representa o vetor de variáveis de controle e Ω denota a região experimental na qual \mathbf{x} está inserido. Esta expressão refere-se à média e variância de apenas uma superfície de resposta. Para múltiplas respostas, Köksoy (2006) propôs a aglutinação de diversas funções MSE, as quais poderiam ser ponderadas ou não. Para o caso de ponderação das funções MSE, a função objetivo global pode ser escrita como:

$$MSE_T = \sum_{i=1}^q w_i MSE_i = \sum_{i=1}^q w_i \{[\hat{y}(\mathbf{x}) - T]^2 + \hat{\sigma}^2(\mathbf{x})\} \quad (2.69)$$

onde MSE_T é o erro quadrático médio global, q é o número de superfícies de respostas e w_i são os pesos desejados.

A métrica Lp proposta por Ardakani e Noorossana (2008) é outro método de otimização multi-objetivo que considera o alvo das respostas:

$$\begin{aligned} \text{Min } \bar{f}(\mathbf{x}) &= \sum_{i=1}^q w_i \left[\frac{f_i(\mathbf{x}) - f_i^1}{f_i^{\max} - f_i^1} \right]^2 \\ \text{s.t. : } \mathbf{x}'\mathbf{x} &\leq \rho^2 \\ 0 &\leq w_i \leq 1 \end{aligned} \quad (2.70)$$

Na formulação da Eq. (2.70), $\bar{f}(\mathbf{x})$ é a função objetivo global e os valores f_i^1 e f_i^{\max} são obtidos da matriz *payoff* das funções objetivo, onde f_i^1 representa o valor encontrado com a otimização individual de $f_i(\mathbf{x})$ e f_i^{\max} é o valor máximo observado para a i -ésima função objetivo. A expressão $\mathbf{x}'\mathbf{x} \leq \rho^2$ descreve a restrição da região experimental esférica, onde ρ é o raio da esfera.

2.8.2.1 Método *Normal Boundary Intersection*

As somas ponderadas, como descrito na Eq. (2.69), são amplamente utilizadas para gerar soluções de compromisso (*trade-off*) em problemas multi-objetivo e formam, via de regra, um conjunto de soluções viáveis e não dominadas conhecidas como “Fronteira de Pareto”. Entretanto, se o conjunto de soluções de Pareto for não convexo, a fronteira passa a ser não convexa e descontínua, formando *clusters* de soluções Pareto-ótimas em regiões de grande curvatura, porém, descontínuas no espaço de solução (Figura 2.18), o que é típico de problemas mal condicionados. É importante destacar que um vetor de decisão $\mathbf{x}^* \in S$ é Pareto-ótimo se nenhum outro vetor $\mathbf{x} \in S$ existir de maneira que $f_i(\mathbf{x}) \leq f_i(\mathbf{x}^*)$ para todo $i=1,2,\dots,k$.

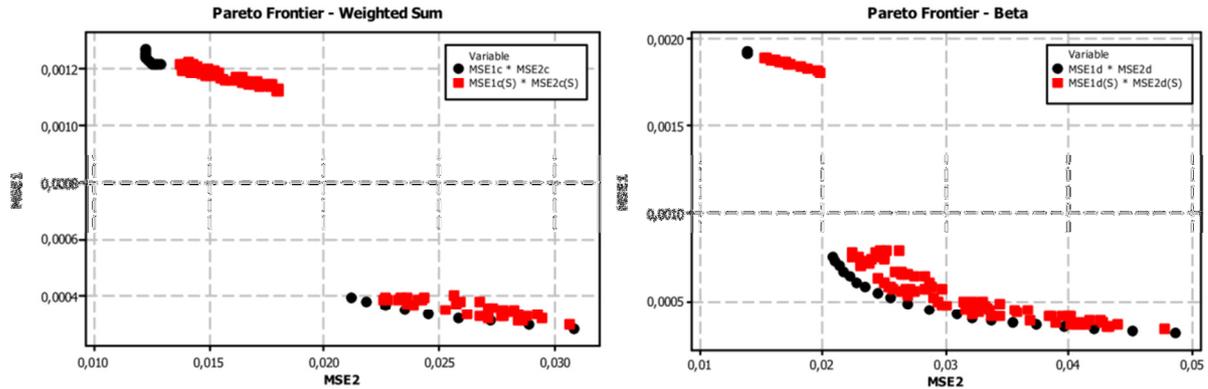


Figura 2.18 – Desvantagens do método de somas ponderadas
Fonte: Paiva (2012)

Como tal, as somas ponderadas dificilmente detectarão soluções nas regiões não-convexas da Fronteira ou em fronteiras não-convexas (descontínuas) que, eventualmente, podem existir (Figura 2.18). Além disso, este método também não é capaz de gerar uma fronteira uniformemente espaçada, mesmo que a distribuição dos pesos seja uniforme (SHUKLA e DEB, 2007; VAHIDINASAB e JADID, 2010).

Para contornar as desvantagens inerentes ao método das somas ponderadas, Das e Dennis (1998) propuseram o método da Interseção Normal à Fronteira (NBI, do inglês *Normal Boundary Intersection*), mostrando ser possível à construção de fronteiras contínuas e uniformemente distribuídas, independentemente da distribuição dos pesos ou das escalas relativas entre as diversas funções objetivo (Figura 2.19).

O primeiro passo a ser executado no método NBI compreende o cálculo dos elementos da matriz *Payoff* Φ , que representa os valores ótimos das múltiplas funções objetivo minimizados de modo individual. O vetor de solução que minimiza individualmente a i -ésima função objetivo $f_i(\mathbf{x})$ é representado por x_i^* , logo o valor mínimo de $f_i(\mathbf{x})$ neste ponto é representado por $f_i^*(x_i^*)$. Quando se substitui o ponto de ótimo individual x_i^* obtido na otimização de função objetivo nas demais funções, tem-se $f_i(x_i^*)$, ou seja, um valor não ótimo dessa função. Repetindo-se este algoritmo para todas as funções, pode-se representar a matriz *Payoff* como:

$$\Phi = \begin{bmatrix} f_1^*(x_i^*) & \cdots & f_i(x_i^*) & \cdots & f_1(x_m^*) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ f_i(x_i^*) & \cdots & f_i^*(x_i^*) & \cdots & f_i(x_m^*) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ f_m(x_i^*) & \cdots & f_m(x_i^*) & \cdots & f_m^*(x_m^*) \end{bmatrix} \quad (2.71)$$

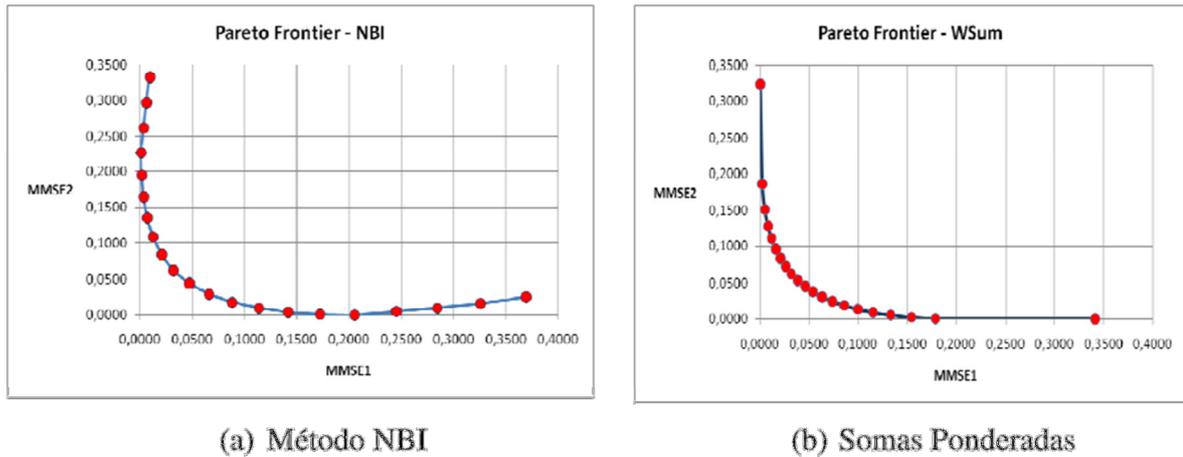


Figura 2.19 – Comparação entre NBI e método de somas ponderadas
Fonte: Paiva (2012)

Cada linha de Φ é composta por valores mínimos e máximos de $f_i(x)$. No método NBI, estes valores podem ser usados para normalizar as funções objetivo, principalmente quando as mesmas são representadas por escalas ou unidades diferentes. De maneira semelhante, escrevendo o conjunto de ótimos individuais em um vetor, tem-se $f^U = [f_1^*(x_i^*), \dots, f_i^*(x_i^*), \dots, f_m^*(x_i^*)]^T$. Este vetor é denominado Ponto de Utopia. Do mesmo modo, agrupando-se os valores máximos (não-ótimos) de cada função objetivo tem-se $f^N = [f_1^N, \dots, f_i^N, \dots, f_m^N]^T$. Este vetor é denominado de Ponto de Nadir (JIA e IERAPETRITOU, 2007; UTYUZHNIKOV *et al.*, 2009). Usando estes dois conjuntos de pontos extremos, a normalização das funções objetivo pode ser obtida como:

$$\bar{f}(x) = \frac{f_i(x) - f_i^U}{f_i^N - f_i^U} \quad i = 1, \dots, m \quad (2.72)$$

Esta normalização conduz, conseqüentemente, à normalização da matriz *Payoff*, $\bar{\Phi}$. De acordo com Vahidinasab e Jadid (2010), as combinações convexas de cada linha da matriz *Payoff* $\bar{\Phi}$ formam a “Envoltória Convexa de Mínimos Individuais” ou CHIM (*Convex Hull of Individual Minima*), ou ainda, a Linha de Utopia (Figura 2.20) (UTYUZHNIKOV *et al.*, 2009).

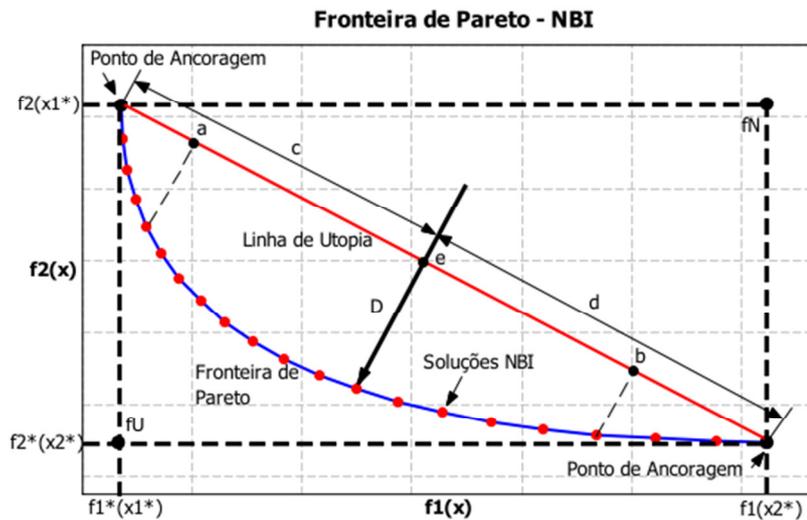


Figura 2.20 – Método de interseção normal à fronteira - NBI
Fonte: Paiva (2012)

Ressalta-se que uma distribuição igualmente espaçada de pontos ao longo da linha de utopia não garante uma distribuição uniforme de pontos na fronteira de Pareto. A Figura 2.20 ilustra os principais elementos associados à otimização multiobjetivo. Os pontos de ancoragem representam as soluções individuais de duas funções $f_i^*(x_i^*)$ (JIA e IERAPETRITOU, 2007; UTYUZHNIKOV *et al.*, 2009). A Figura 2.20 ilustra como o método NBI funciona. Os pontos a , b e e são calculados a partir da matriz *payoff* escalonada, $\bar{\Phi}w_i$. Considerando um conjunto de valores convexos para os pesos, w , tem-se que $\bar{\Phi}w_i$ representará um ponto na linha de utopia. Fazendo \hat{n} denotar um vetor unitário normal à linha de utopia nos pontos $\bar{\Phi}w_i$ na direção da origem; então $\bar{\Phi}w_i + D\hat{n}$, com $D \in \mathbb{R}$, representará o conjunto de pontos naquela normal (JIA e IERAPETRITOU, 2007; SHUKLA e DEB, 2007). O ponto de interseção desta normal com a fronteira da região viável que for mais próximo da origem corresponderá à maximização da distância entre a linha de utopia e a Fronteira de Pareto. Desse modo, o método NBI pode ser escrito como um problema de programação não-linear restrita, tal que:

$$\begin{aligned}
 & \underset{(x,t)}{\text{Max}} && D \\
 & \text{s.t.} && \bar{\Phi}w + D\hat{n} = \bar{F}(x) \\
 & && x \in \Omega
 \end{aligned} \tag{2.73}$$

O problema de otimização representado pelo sistema de equações (2.73) pode ser resolvido iterativamente para diferentes valores de w , o que cria, por conseguinte, uma Fronteira de Pareto igualmente espaçada. Uma escolha comum proposta por Jia e Ierapetritou (2007) é fazer $w_n = 1 - \sum_{i=1} w_i$. Por uma questão de simplificação, o parâmetro conceitual D pode ser algebricamente eliminado da Eq. (2.73), dado que ele está tanto na função objetivo quanto nas restrições de igualdade. Para o caso bidimensional, esta expressão simplificada pode ser reescrita como:

$$\begin{aligned}
 & \text{Min } \bar{f}_1(\mathbf{x}) \\
 & \text{s.t.: } \bar{f}_1(\mathbf{x}) - \bar{f}_2(\mathbf{x}) + 2w - 1 = 0 \\
 & \quad g_j(\mathbf{x}) \geq 0 \\
 & \quad 0 \leq w \leq 1
 \end{aligned} \tag{2.74}$$

onde $\bar{f}_1(\mathbf{x})$ e $\bar{f}_2(\mathbf{x})$ representam duas funções objetivo escalonadas (normalizadas).

2.8.3 Caso multivariado

Os métodos citados na seção anterior não consideram a influência da estrutura de correlação entre as respostas no resultado da otimização. Para tratar desta questão, Govindaluri e Cho (2007) apresentaram a seguinte formulação:

$$\begin{aligned}
 MSE_i &= [\hat{y}(\mathbf{x}) - T]^2 + \hat{\sigma}^2(\mathbf{x}) \\
 &+ \sum_{j=1}^{i-1} \frac{\hat{\sigma}_i(\mathbf{x})}{\hat{\sigma}_i(\mathbf{x}) + \hat{\sigma}_j(\mathbf{x})} \{ \hat{\sigma}_{ij}(\mathbf{x}) + [\hat{y}_i(\mathbf{x}) - T_i][\hat{y}_j(\mathbf{x}) - T_j] \}
 \end{aligned} \tag{2.75}$$

Apesar de coerente, computar o termo de covariância da superfície de resposta $\hat{\sigma}_{ij}(\mathbf{x})$ somente é possível se o arranjo possuir réplica ou ser um arranjo cruzado, o que aumentaria substancialmente o número de experimentos.

Outro método considerando a influência da correlação das respostas nos resultados da otimização é o proposto por Vining (1998). A função de perda esperada multivariada é a função multi-objetivo que deve ser minimizada:

$$E\{L[y(\mathbf{x}), \boldsymbol{\theta}]\} = \{E[y(\mathbf{x}) - \boldsymbol{\theta}]\}' \mathbf{C} \{E[y(\mathbf{x}) - \boldsymbol{\theta}]\} + \text{traço} \left[\mathbf{C} \sum_y(\mathbf{x}) \right] \quad (2.76)$$

onde $E\{L[y(\mathbf{x}), \boldsymbol{\theta}]\}$ é a função de perda esperada multivariada, \mathbf{x} representa o vetor de variáveis controláveis, $y(\mathbf{x})$ é o vetor de respostas, \mathbf{C} é uma matriz $q \times q$ positiva definida dos pesos associados com a perda decorrente dos desvios de $y(\mathbf{x})$ de seus respectivos alvos, com q respostas e $\sum_y(\mathbf{x})$ é a matriz variância-covariância.

Similarmente, Chiao e Hamada (2001) propuseram integração multivariada como método de otimização multi-objetivo de respostas correlacionadas. A solução ótima, no entanto, não determina alvos para as respostas. A formulação proposta pelos autores pode ser escrita como:

$$\begin{aligned} \text{Max } P(Y \in S) &= \frac{1}{\sqrt{|\boldsymbol{\Sigma}|} (2\pi)^q} \left[\int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_q}^{b_q} e^{-\frac{1}{2}(\mathbf{Y}-\boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1}(\mathbf{Y}-\boldsymbol{\mu})} d\mathbf{Y} \right] \\ \text{s.t. : } \mathbf{x}'\mathbf{x} &\leq \rho^2 \end{aligned} \quad (2.77)$$

onde Y é o vetor de múltiplas respostas, S é a região especificada para todas as respostas formada pelos limites a_i e b_i , $\boldsymbol{\Sigma}$ é a matriz $q \times q$ positiva definida de variância-covariância com q respostas e $\mathbf{x}'\mathbf{x} \leq \rho^2$ denota a restrição da região experimental esférica. Apesar de eficiente, computar uma integral normal multivariada não é uma tarefa trivial.

Uma abordagem mais simples consiste em transformar o conjunto original de respostas em escores de componentes principais e em seguida realizar a modelagem pelas PCs. Bratchell (1989) foi o primeiro autor a propor o uso de PCA com RSM. No entanto, sua abordagem não oferece alternativa em casos onde a primeira componente principal é incapaz de explicar, de forma significativa, o conjunto original de respostas. Além disso, para problemas com limites de especificação e alvo, não foi demonstrado como traduzir as especificações originais em termos de componentes principais.

Paiva *et al.* (2009) solucionaram esta questão combinando funções MSE com RSM escritos em termos de escores de componentes principais. O método será descrito em detalhes na seção seguinte.

2.8.3.1 Método do erro quadrático médio multivariado – MMSE

Partindo do trabalho de Bratchell (1989), Paiva *et al.* (2009) combinaram o conceito MSE com RSM e PCA. O método, chamado MMSE (*Multivariate mean square error*), descreve uma média geométrica das regressões das componentes principais, as quais excederam 80% de explicação acumulada das variáveis originais. O método consiste em converter as respostas correlacionadas, através de PCA, em novas variáveis não correlacionadas. Estas novas variáveis, os escores de componentes principais, são modeladas por RSM em funções de superfície de resposta. Por fim, considerando a formulação MSE, a média estimada $\hat{y}(\mathbf{x})$ é substituída pela função das componentes principais PC . Visto que o i -ésimo autovalor é a variância da i -ésima componente principal (JOHNSON e WICHERN, 2007), a variância $\hat{\sigma}^2(\mathbf{x})$ pode ser substituída pelo autovalor λ e o alvo T é transformado em alvo de componente principal, ζ_{PC} . O MMSE é então obtido pela seguinte expressão:

$$MMSE = (PC - \zeta_{PC})^2 + \lambda \quad (2.78)$$

Na Eq. (2.78), PC é um polinômio de segunda ordem escrito em função das variáveis de controle. O alvo das componentes principais (ζ_{PC}) é definido de forma heurística. De acordo com Johnson e Wichern (2007), o i -ésimo escore de componente principal é o produto das respostas padronizadas Z_j multiplicado por seus respectivos autovetores e_j . Neste caso, considerando o alvo para a j -ésima resposta, T_{Y_j} , o alvo escrito em termos de componentes principais (ζ_{PC}) é estabelecido por:

$$\zeta_{PC} = e' [Z(Y_j | T_{Y_j})] = \sum_{j=1}^q e_j [Z(Y_j | T_{Y_j})] \quad (2.79)$$

Onde $Z(Y_j | T_{Y_j}) = (T_{Y_j} - \mu_{Y_j}) (\sigma_{Y_j})^{-1}$, μ_{Y_j} é a média da j -ésima resposta e σ_{Y_j} é o desvio-padrão da j -ésima resposta. Neste método, a otimização é dada pela minimização de MMSE na Eq. (2.78), ou seja, PC tende a alcançar o alvo estabelecido com mínima variância. Se mais de uma PC é necessária, então MMSE é obtido pela média geométrica de acordo com:

$$\begin{aligned} \text{Min } MMSE_T &= \left(\prod_{i=1}^m MMSE_i \right)^{\frac{1}{m}} = \left\{ \prod_{i=1}^m \left[(PC_i - \zeta_{PC_i})^2 + \lambda_i \right] \right\}^{\frac{1}{m}}, \quad m \leq q \\ \text{s.t. : } g_n(\mathbf{x}) &\leq 0 \end{aligned} \quad (2.80)$$

Onde $MMSE_T$ é o erro quadrático médio multivariado total, $MMSE_i$ é o erro quadrático médio multivariado para a i -ésima PC , m é o número de PC s necessárias, q é o número de respostas, PC_i a função de superfície de resposta da i -ésima componente principal, ζ_{PC} o alvo da i -ésima PC , λ_i o autovalor da i -ésima PC e $g_n(\mathbf{x}) \leq 0$ as equações de restrições. A otimização das componentes principais implica na otimização do problema original.

2.8.3.2 Método do erro quadrático médio multivariado ponderado – WMMSE

Assim como alguns métodos tradicionais, MMSE não atribui pesos distintos às respostas originais na otimização. Se uma abordagem de ponderação for aplicada à formulação da Eq. (2.80), não haverá garantia de que as variáveis originais também serão adequadamente ponderadas. Gomes *et al.* (2013) sugeriram uma abordagem que pondera as variáveis originais antes de calcular os escores de componentes principais. Esta abordagem consiste basicamente em ponderar as respostas originais padronizadas e, em seguida, extrair os escores de componentes principais pela matriz variância-covariância. Os passos seguintes são similares ao do método MMSE e a formulação para WMMSE é a seguinte:

$$\begin{aligned} \text{Min } WMMSE_T &= \sum_{i=1}^m \left(\frac{v_i}{v_T} WMMSE_i \right) = \sum_{i=1}^m \left\{ \frac{v_i}{v_T} \left[(PC_i^* - \zeta_{PC_i}^*)^2 + \lambda_i^* \right] \right\}, \quad m \leq q \\ \text{s.t. : } g_n(\mathbf{x}) &\leq 0 \end{aligned} \quad (2.81)$$

Onde $WMMSE_T$ é o erro quadrático médio multivariado ponderado total, $WMMSE_i$ é o erro quadrático médio multivariado ponderado para a i -ésima PC , m é o número de PC s necessárias, q é o número de respostas, v_i é o percentual de explicação da i -ésima PC , tal que $\sum v_i = v_T$, PC_i^* é a função de superfície de resposta para a i -ésima PC obtida com respostas ponderadas, $\zeta_{PC_i}^*$ o alvo da i -ésima PC com respostas ponderadas, λ_i^* o autovalor da i -ésima PC com respostas ponderadas e $g_n(\mathbf{x}) \leq 0$ as equações de restrições. Novamente, a otimização das componentes principais ponderadas implica na otimização do problema original.

2.9 Cartas de controle multivariadas

Controle estatístico de processo (SPC – *Statistical Process Control*) teve origem em 1920 com Dr. Walter A. Shewhart. Em qualquer processo produtivo, independentemente de quão bem projetado ou cuidadosamente mantido, certa quantidade de variação naturalmente irá existir. Em SPC esta variação é chamada de causa comum de variação de um sistema estável, ou seja, neste caso o processo está sob controle estatístico. No entanto, outras causas de variação podem atuar no processo devido a: ajuste inapropriado de máquina, erro do operador, matéria-prima com defeito. Tal variação é, geralmente, maior que a variação de causa comum. Esta variação é denominada variação de causa especial e, neste caso, o processo é dito estar fora de controle. Carta de controle é uma técnica amplamente usada para monitoramento *online* de processos (MONTGOMERY, 2001; MONTGOMERY *et al.*, 2004).

A estrutura básica de uma carta de controle apresenta os limites inferior e superior de controle (LCL e UCL), assim como a linha central (L_c). Espera-se que um processo tenha comportamento sob controle, com a estatística de interesse próxima da linha central e entre os limites de controle. De acordo com Montgomery *et al.* (2004), o modelo geral para uma carta de controle segue:

$$\begin{aligned} LCL &= \mu_w - k\sigma_w \\ L_c &= \mu_w \\ UCL &= \mu_w + k\sigma_w \end{aligned} \quad (2.82)$$

onde w é a estatística de interesse para a característica da qualidade, k é a distância dos limites de controle para a linha central, μ_w é a média de w e σ_w é o desvio-padrão de w .

Para monitoramento de processos através de uma característica da qualidade do tipo contínua e que segue distribuição normal, geralmente, monitora-se a média e uma medida de variabilidade. O monitoramento da média é feito por uma carta \bar{x} e a variabilidade por uma carta S (desvio-padrão) ou R (amplitude). Estas cartas de controle estão entre as mais importantes e úteis técnicas de controle e monitoramento *online* (MONTGOMERY, 2001).

Atualmente, com métodos automatizados e eletrônicos para coleta de dados, é comum ser coletado 10 ou 20 variáveis de processo. Para tais processos, métodos mais eficientes devem ser adotados para controle e monitoramento. Tal abordagem leva em conta correlações entre as características e controlará a probabilidade global de alarme devido à causa especial de variação (JOHNSON e WICHERN, 2007). O uso de técnicas univariadas pode ser uma

forma inapropriada de analisar características correlacionadas, visto que elas afetam o processo conjuntamente. Por exemplo, se analistas empregarem cartas de controle univariadas para monitorar um processo multivariado, erro do tipo 1 (alarme falso), pode ser cometido. A probabilidade das cartas univariadas plotarem corretamente um ponto dita sob controle não é igual ao resultado esperado da ação conjunta apresentada em uma carta multivariada. A distorção destes valores aumenta com o número de variáveis (JOHNSON e WICHERN, 2007; PERUCHI *et al.*, 2013a). A literatura possui diversos estudos que analisaram, através de cartas de controle e índices de capacidade, processos multivariados. Alguns exemplos incluem: Chen *et al.* (2005), Villalobos *et al.* (2005), Yang e Rahim (2005), Chen *et al.* (2006), Pan (2007), Pan e Jarrett (2007), Machado e Costa (2008), Chen e Chen (2008), Psarakis (2011), Boone e Chakraborti (2012 e Wang (2012). Nesta tese, será abordado, principalmente, a aplicação de cartas de controle multivariadas através da técnica de redução de dimensionalidade PCA.

2.9.1 Caso univariado

2.9.1.1 Observações em subgrupos

Ordem temporal é, frequentemente, uma boa base para formar subgrupos, pois permite detectar causas especiais de variação no tempo. O monitoramento da média é feito por uma carta \bar{x} e a variabilidade por uma carta S (desvio-padrão) ou R (amplitude) (MONTGOMERY, 2001; MONTGOMERY *et al.*, 2004). A linha central e os limites de controle de uma carta de controle \bar{x} podem ser definidos como:

$$\begin{aligned} LCL &= \mu - k\hat{\sigma}/\sqrt{n_i} \\ L_c &= \mu \\ UCL &= \mu + k\hat{\sigma}/\sqrt{n_i} \end{aligned} \quad (2.83)$$

onde n_i é o tamanho do i -ésimo subgrupo, k é o número de desvios-padrão em relação à linha central (geralmente, usa-se 3), $\mu = \bar{\bar{x}}$ e σ é o desvio-padrão que depende do método escolhido para se estimá-lo (geralmente, usa-se o desvio-padrão *pooled*).

Tipicamente, para subgrupos de até oito observações, a carta de controle R , que avalia a amplitude das observações do subgrupo, é recomendada. A linha central e os limites de controle podem ser definidos como:

$$\begin{aligned}
 LCL &= \bar{R} - kd_3(n_i)\sigma \\
 L_c &= \bar{R} \\
 UCL &= \bar{R} + kd_3(n_i)\sigma
 \end{aligned}
 \tag{2.84}$$

onde n_i é o tamanho do i -ésimo subgrupo, k é o número de desvios -padrão em relação à linha central (geralmente, usa-se 3), σ é o desvio-padrão que depende do método escolhido para se estima-lo (geralmente, usa-se o desvio-padrão *pooled*), $\bar{R} = d_2(n_i)\sigma$, d_2 e d_3 são constantes usadas para estimar o desvio-padrão. Caso $LCL < 0$, então, $UCL = 0$.

Caso o tamanho do subgrupo seja superior a oito, uma carta de controle S , que avalia o desvio-padrão do subgrupo, pode ser empregada. A linha central e os limites de controle de uma carta de controle S podem ser definidos como:

$$\begin{aligned}
 LCL &= \bar{S} - kc_5(n_i)\sigma \\
 L_c &= \bar{S} \\
 UCL &= \bar{S} + kc_5(n_i)\sigma
 \end{aligned}
 \tag{2.85}$$

Onde n_i é o tamanho do i -ésimo subgrupo, k é o número de desvios-padrão em relação à linha central (geralmente, usa-se 3), σ é o desvio-padrão que depende do método escolhido para se estimá-lo (geralmente, usa-se o desvio-padrão *pooled*), $\bar{S} = c_4(n_i)\sigma$, c_4 e c_5 são constantes não tendenciosas usadas para estimar o desvio-padrão.

2.9.1.2 Observações individuais

Em algumas situações, o tamanho amostral do subgrupo será limitado a $n=1$. Nestes casos, as cartas de controle para indivíduos I e amplitudes móveis MR de observações sucessivas são sugeridas. A linha central e os limites de controle de uma carta de controle I podem ser definidos como:

$$\begin{aligned}
 LCL &= \mu - k\sigma \\
 L_c &= \mu \\
 UCL &= \mu + k\sigma
 \end{aligned}
 \tag{2.86}$$

onde k é o número de desvios-padrão em relação à linha central (geralmente, usa-se 3), $\mu = \bar{x}$, $\sigma = \overline{MR}/d_2(w)$, $w=2$ e d_2 é uma constante usada para estimar o desvio-padrão.

Tipicamente, para observações individuais, a carta de controle MR de amplitudes móveis avalia a variabilidade dos dados. A linha central e os limites de controle podem ser definidos como:

$$\begin{aligned} LCL &= \overline{MR} - kd_3(w)\sigma \\ L_c &= \overline{MR} \\ UCL &= \overline{MR} + kd_3(w)\sigma \end{aligned} \quad (2.87)$$

onde k é o número de desvios padrão em relação à linha central (geralmente, usa-se 3), $\overline{MR} = d_2(w)\sigma$, $w=2$, d_2 e d_3 são constantes usadas para estimar o desvio-padrão. Caso $LCL < 0$, então, $UCL = 0$.

2.9.2 Caso multivariado

PCA é muito útil em controle de qualidade multivariado. Jackson (1991) apresentou três tipos de cartas de controle por PCA: (1) a carta de controle T^2 obtida dos escores de PCs; (2) a carta de controle para resíduos das PCs; e (3) cartas de controle independentes para cada PC. Logo, tendo estabelecido o modelo PCA baseado nos dados históricos coletados apenas quando causas comuns de variação eram presentes, futuras observações multivariadas podem ser projetadas no plano definido pelos autovetores para obter seus escores e resíduos (BERSIMIS *et al.*, 2007).

2.9.2.1 Carta de controle de escores de PCs – observações individuais (n=1)

Cartas dos componentes principais baseados em D^2 de Hotelling podem ser plotadas para todas as componentes principais ou para k componentes. Usando PCA, a forma original da estatística D_i^2 , como derivado de Jackson (1991), pode ser transformada em:

$$D_i^2 = \sum_{i=1}^k Z_i^2 t_i^{-1} + \sum_{i=k+1}^p Z_i^2 t_i^{-1} \quad (2.88)$$

Se todas componentes p são usadas, o valor crítico para D_i^2 é:

$$L_u = p(m+1)(m-1)[m(m-p)]^{-1} F_{1-\alpha, p, m-p} \quad (2.89)$$

onde o número total de observações individuais independentes é m . Por outro lado, se k PCs são usadas, o valor crítico de D_i^2 é dado pela mesma fórmula substituindo p por k . Então, se um valor D_i^2 é maior que L_u , o processo é dito estar fora de controle.

2.9.2.2 Carta de controle de escores de PCs – subgrupos ($n>1$)

No caso onde m subgrupos, de tamanho $n>1$, são tomados em um intervalo de tempo homogêneo, a estatística D_i^2 para uso em componentes principais tem a seguinte forma:

$$D_i^2 = n \left(\sum_{i=1}^k \bar{Z}_i^2 l_i^{-1} + \sum_{i=k+1}^p \bar{Z}_i^2 l_i^{-1} \right) \quad (2.90)$$

onde \bar{Z}_i é a média de cada p z -escores sobre as n observações no subgrupo. Então, o valor crítico como dado por Jackson (1991) é

$$L_u = p(m-1)(n-1)(mn-m-p+1)^{-1} F_{1-\alpha, p, mn-m-p+1} \quad (2.91)$$

No caso onde k componentes são usadas, o valor crítico é dado pela mesma fórmula substituindo p por k . Conseqüentemente, se um valor de D_i^2 é maior que L_u então o processo é dito fora de controle.

2.9.2.3 Carta de controle de resíduos de PCs

O termo residual Q pode ser testado por meio da soma de quadrados dos resíduos:

$$Q = (\mathbf{x} - \hat{\mathbf{x}})' (\mathbf{x} - \hat{\mathbf{x}}) = \sum_{i=k+1}^p l_i y_i^2 = \sum_{i=k+1}^p z_i^2 \quad (2.92)$$

onde $\hat{\mathbf{x}} = \bar{\mathbf{x}} + \mathbf{Uz}$, \mathbf{U} é $p \times k$ e \mathbf{z} é $k \times 1$. O valor crítico para Q é:

$$Q_\alpha = \vartheta_1 \left[c_\alpha (2\vartheta_2 h_0^2)^{1/2} \vartheta_1^{-1} + \vartheta_2 h_0 (h_0 - 1) \vartheta_1^{-2} + 1 \right]^{1/h_0} \quad (2.93)$$

onde $\vartheta_T = \sum_{i=k+1}^p l_i^T$, $h_0 = 1 - 2\vartheta_1 \vartheta_3 / \vartheta_2^2$ e c_α é uma distribuição normal definida pela área α acima da cauda superior da distribuição se h_0 é positiva e abaixo da cauda inferior se h_0 é negativa. Esta distribuição permanece caso todas componentes sejam usadas ou não, mesmo quando algumas componentes não significantes são empregadas. A quantidade c é normalmente distribuída com média zero e variância unitária, e é dada pela fórmula:

$$c = \vartheta_1 \left[(Q \vartheta_1^{-1})^h - \vartheta_2 h_0 (h_0 - 1) \vartheta_1^{-2} - 1 \right] (2\vartheta_2 h_0^2)^{-1/2} \quad (2.94)$$

Outro teste estatístico para os resíduos tem sido proposto por Hawkins (1991) usando a soma não ponderada dos quadrados dos componentes não retidos $D_i^2 = y_{k+1}^2 + \dots + y_p^2$, o qual é distribuído como $k(m-1)(n-1)(mn-m-k+1)^{-1} F_{1-\alpha, p-k, n-p+k}$.

No caso de m subgrupos, de tamanho $n > 1$, o termo residual pode ser testado por meio de soma de quadrados dos resíduos $Q_M = n(\bar{\mathbf{x}} - \hat{\mathbf{x}})'(\bar{\mathbf{x}} - \hat{\mathbf{x}})$, onde $\hat{\mathbf{x}}$ é o vetor de média prevista. A estatística Q_M tem a mesma distribuição com mesmo grau de liberdade do próprio Q .

2.9.2.4 Carta de controle univariada de escores de PCs

No caso $n > 1$, a componente principal PC_i pode ser plotada para controlar processo em uma carta de controle univariada para cada i . Para monitoramento de média, os limites de controle e a linha central são obtidos de acordo com a Eq. (2.83). Neste caso, a linha central será zero, caso PCA tenha sido executada pela matriz de correlação dos dados (JACKSON, 1991; BERSIMIS *et al.*, 2007). As cartas de controle para avaliar variabilidade dos escores de componentes principais podem ser implementadas pelas Eqs. (2.84) e (2.85). Lembrando que, apesar de utilizar cartas de controle univariadas, escores de componentes principais estão sendo avaliados e, conseqüentemente, o grupo de variáveis originais está sendo simultaneamente monitorado.

Analogamente, no caso onde $n=1$, Eqs. (2.86) e (2.87) são usadas para monitorar, respectivamente, média e amplitudes móveis dos escores individuais de componentes principais.

2.9.3 Projeto econômico de cartas de controle

Muitas pesquisas desenvolvidas sobre projeto econômico de cartas de controle têm sido devotadas à carta \bar{x} . De acordo com Montgomery (2001), o modelo de Duncan foi o primeiro a tratar de um modelo econômico completo de uma carta de controle de Shewhart e incorporar otimização para determinar os parâmetros da carta. Neste caso, pretende-se determinar os parâmetros n (tamanho da amostra do subgrupo), k (fator de abertura dos limites de controle) e h (intervalo de amostragem). As categorias de custos que são comumente consideradas em projeto econômico de cartas de controle são:

- Custo de amostragem;
- Custo de investigação e correção de causas especiais de variação;
- Custo da produção de itens não conformes.

Segundo Montgomery (2001), o modelo de Duncan que representa a perda esperada por hora do processo avaliado é representado pela Eq. (2.95) abaixo:

$$E(L) = \left(\frac{a_1 + a_2 n}{h} \right) + \frac{a_4 \left[\frac{h}{(1-\beta)} - \tau + gn + D \right] + a_3 + a_3' \left[\frac{\alpha \times e^{-\lambda h}}{(1-e^{-\lambda h})} \right]}{\frac{1}{\lambda} + \frac{h}{(1-\beta)} - \tau + gn + D} \quad (2.95)$$

onde as variáveis constantes são:

a_1 : custo fixo de uma amostragem [\\$];

a_2 : custo variável de uma amostragem (proporcional ao tamanho da amostra) [\$/medição];

a_3 : custo de investigação e eliminação de uma causa especial [\\$];

a_3' : custo de investigação de um alarme falso [\\$];

$a_4 = V_0 - V_1$ onde V_0 é a receita da produção sob controle e V_1 é a receita ao se produzir fora de controle, logo, a_4 está relacionado com o custo do desperdício ou o quanto deixou de ganhar. Portanto, a_4 pode ser interpretado como custo por hora da penalidade associada à produção fora de controle [\$/h];

λ : taxa de falha (número de ocorrências de causas especiais por hora) [ocorrências/h]. Onde ocorrência é uma medição considerada causa especial;

δ : magnitude de desvio em relação à média que se deseja detectar quando o processo está fora de controle;

g : tempo exigido para efetuar e registrar uma medição [h/medição];

D: tempo necessário para investigar uma causa especial após ser detectada pela carta [h].

As variáveis de decisão são:

n: tamanho da amostra do subgrupo [medições];

k: fator de abertura dos limites de controle [adimensional];

h: intervalo de amostragem [h];

As variáveis calculadas em função das variáveis de decisão são:

τ : tempo esperado de ocorrência da causa especial entre o intervalo j -ésimo e $(j+1)$ -ésimo, assumindo que o processo começa sob controle seguindo uma distribuição exponencial com média $1/\lambda$ horas e é dado por [h]:

$$\tau = \frac{\int_{jh}^{(j+1)h} e^{-\lambda t} \lambda(t - jh) dt}{\int_{jh}^{(j+1)h} e^{-\lambda t} \lambda dt} = \frac{1 - (1 + \lambda h)e^{-\lambda h}}{\lambda(1 - e^{-\lambda h})} \quad (2.96)$$

α : probabilidade de ocorrer um alarme falso (erro tipo I) [adimensional]:

$$\alpha = 2 \int_k^{\infty} \phi(z) dz \quad (2.97)$$

$1 - \beta$: poder do teste (pois, β é a probabilidade de existir causa especial e esta não ser detectada – erro tipo II) [adimensional]:

$$1 - \beta = \int_{-\infty}^{-k - \delta\sqrt{n}} \phi(z) dz + \int_{k - \delta\sqrt{n}}^{+\infty} \phi(z) dz \quad (2.98)$$

onde $\phi(z) = (2\pi)^{-1/2} e^{-z^2/2}$ é a função de densidade normal padronizada.

Os parâmetros da carta de controle devem ser otimizados através da minimização do modelo econômico em Eq. (2.95) resultando no modelo de otimização não-linear abaixo:

$$\begin{aligned} & \text{Minimizar } E[L(n, k, h)] \\ & \text{S.t.: } \quad k, h \in \mathbf{R}_+^* \\ & \quad \quad n \in \mathbf{N}^* \end{aligned} \quad (2.99)$$

Portanto, um bom plano de controle pode ser estabelecido através da solução do problema de otimização da Eq. (2.99).

2.10 Considerações finais

O capítulo dois apresentou as principais técnicas e ferramentas quantitativas aplicadas em um projeto Seis Sigma, tanto para o caso univariado, quanto para o multivariado usando PCA. Observou-se que há na literatura diversas publicações aplicando individualmente cada uma das técnicas e ferramentas apresentadas, nos contextos univariado e multivariado. No entanto, este autor julga que resultados mais significativos podem ser alcançados, caso estas técnicas sejam integradas em um *roadmap* estruturado. Tratando-se de problemas multivariados, esta proposta representa uma contribuição original ao estado da arte do tema abordado. A integração proposta de análise estatística multivariada por PCA ao *roadmap* DMAIC do Seis Sigma será apresentada no capítulo a seguir.

3. MDMAIC: UM ROADMAP MULTIVARIADO

3.1 Considerações iniciais

Este capítulo detalhará a proposta de um novo *roadmap*, o MDMAIC (*Multivariate: define, measure, analyze, improve, control*), que deve ser utilizado para solução de problemas multivariados. Levando em consideração as limitações já apresentadas na seção 1.5 e a pesquisa bibliográfica do capítulo anterior, foram identificadas as seguintes oportunidades de exploração científica:

- Elaborar um *roadmap* estruturado que integre técnicas e ferramentas multivariadas, para solução eficiente de problemas mais complexos de manufatura;
- Explorar a análise de sistemas de medição no contexto multivariado de situações que envolvam diversas estruturas de correlação entre as grandezas medidas e diversos níveis de variabilidade associado ao equipamento de medição (PERUCHI *et al.*, 2013a);
- Determinar uma abordagem de controle estatístico de processo capaz de reduzir a dimensionalidade de um processo com múltiplas respostas;
- Estimar PPM (peças por milhão produzidas fora da especificação) e nível sigma para processos multivariados;
- Especificar de forma sistemática a atribuição de pesos para as variáveis de resposta em otimização multivariada;

As seções remanescentes deste capítulo irão abordar os tópicos mencionados acima através do *roadmap* MDMAIC proposto e apresentado na Figura 3.1.

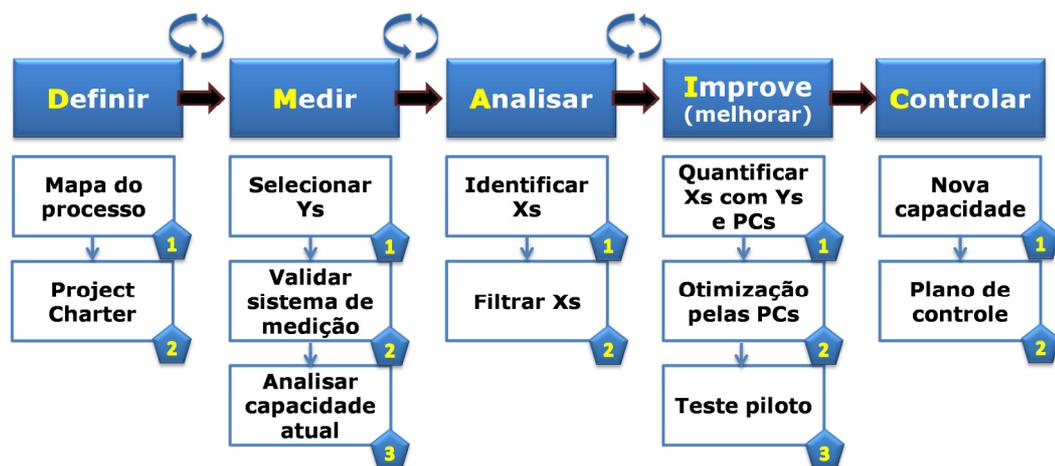


Figura 3.1 – Roadmap MDMAIC baseado em PCA

Adicionalmente, a Tabela 3.1 resume as principais propostas desta tese, as quais também serão detalhadas nas seções seguintes deste capítulo. Nesta Tabela não se pretende esgotar todas as formulações da literatura relacionadas a cada etapa, mas apenas destacar as mais importantes, as quais estão diretamente relacionadas às propostas da tese.

Tabela 3.1 – Resumo dos métodos univariados, multivariados e propostos associados a cada passo do MDMAIC

Literatura			
	Univariado	Multivariado	Propostas Multivariadas
D1	Um processo	Um ou mais processos	Um ou mais processos
D2	Definir problema, objetivo, meta, escopo, cronograma, equipe e potenciais benefícios financeiros do projeto	Definir problema, objetivo, meta, escopo, cronograma, equipe e potenciais benefícios financeiros do projeto	Definir problema, objetivo, meta, escopo, cronograma, equipe e potenciais benefícios financeiros do projeto
M1	QFD → CTQ	QFD → Y_1, Y_2, \dots, Y_q	QFD → Y_1, Y_2, \dots, Y_q pesos influenciam passos seguintes.
M2	(2.26) $\%R \& R = \frac{\sigma_{sm}}{\sigma_t}$	$\%R \& R_m = \prod_{i=1}^q (\%R \& R)_{pc_i}^{1/q}$	(3.16) $\%R \& R_m = \frac{\sigma_{sm;wpc}}{\sigma_{t;wpc}}$
	(2.27) $ndc = \sqrt{2} \frac{\sigma_p}{\sigma_{sm}}$	$ndc_m = \prod_{i=1}^q (ndc)_{pc_i}^{1/q}$	(3.17) $ndc_m = \sqrt{2} \frac{\sigma_{p;wpc}}{\sigma_{sm;wpc}}$
M3	(2.30) $C_p = \frac{USL - LSL}{6\sigma}$	(2.39) $MC_p = \left(\prod_{i=1}^v C_{p;PC_i} \right)^{1/v}$	(3.25) $WPC_{group} = W'(u'Y)$
	(2.31) $C_{pk} = \frac{d - \mu - M }{3\sigma}$	$MC_{pk}, MC_{pm} \text{ e } MC_{pmk}$ (2.40)	(3.28) $MWAC_p = \sum_{i=1}^{\xi} \psi(C_{p;WPC_i})$
	(2.32) $C_{pm} = \frac{USL - LSL}{6\sqrt{\sigma^2 + (\mu - T)^2}}$	$C_{p;PC_i} = \frac{USL_{PC_i} - LSL_{PC_i}}{6\sigma_{PC_i}}$ (2.41)	(3.29) $C_{p;wpc_i} = \frac{USL_{wpc} - LSL_{wpc}}{6\sigma_{wpc}}$
	(2.33) $C_{pmk} = \frac{d - \mu - M }{3\sqrt{\sigma^2 + (\mu - T)^2}}$	$MWC_p = \left(\prod_{i=1}^v C_{p;PC_i}^{\lambda_i} \right)^{1/\sum_{i=1}^v \lambda_i}$ $MWC_{pk}, MWC_{pm} \text{ e } MWC_{pmk}$ (2.42)	$MWAC_{pk}, MWAC_{pm} \text{ e } MWAC_{pmk}$
		$MXC_p = \frac{\sum_{i=1}^v \lambda_i C_{p;PC_i}}{\sum_{i=1}^v \lambda_i}$ $MXC_{pk}, MXC_{pm} \text{ e } MXC_{pmk}$	
A1	$y = f(x_1, x_2, \dots, x_m)$	$Y = f(x_1, x_2, \dots, x_m)$	$WPC = f(x_1, x_2, \dots, x_m)$
A2	$y = f(x_1, x_2, \dots, x_{m-k})$ com k não significativos	$Y = f(x_1, x_2, \dots, x_{m-k})$ com k não significativos	$WPC = f(x_1, x_2, \dots, x_{m-k})$ com k não significativos

Tabela 3.1 (continuação)

Literatura			
	Univariado	Multivariado	Propostas Multivariadas
	(2.61)	(2.62)	(3.36)
II	$y = b_0 + \nabla f(x)^T + \frac{1}{2} x^T [\nabla^2 f(x)] x$	$PC_i = b_0 + \nabla f(x)^T + \frac{1}{2} x^T [\nabla^2 f(x)] x$	$WPC_{group} = b_0 + \nabla f(x)^T + \frac{1}{2} x^T [\nabla^2 f(x)] x$
	(2.65)	(2.80)	(3.37)
	Minimizar μ	Min $MMSE_T =$	Min $\overline{WPC}_{\max}(\mathbf{x})$
	Sujeito a: $\sigma^2 = \theta$	$\left\{ \prod_{i=1}^m [(PC_i - \zeta_{PC_i})^2 + \lambda_i] \right\}^{\frac{1}{m}}$	s.t.: $\overline{WPC}_{\max}(\mathbf{x}) - \overline{WPC}_{\min}(\mathbf{x}) + 2w - 1 = 0$
	(2.66)		+ $2w - 1 = 0$
	Minimizar σ^2		$\mathbf{x}'\mathbf{x} \leq \rho^2$
I2	Sujeito a: $\mu = \theta$	s.t.: $g_n(\mathbf{x}) \leq 0$	$0 \leq w \leq 1$
	(2.67)	(2.81)	
	Maximizar μ	Min $WMMSE_T =$	
	Sujeito a: $\sigma^2 = \theta$	$\sum_{i=1}^m \left\{ \frac{v_i}{v_T} [(PC_i^* - \zeta_{PC_i}^*)^2 + \lambda_i^*] \right\}$	
		s.t.: $g_n(\mathbf{x}) \leq 0$	
I3	Experimentos para $\mathbf{y}^* = f(x_{*1}^*, x_{*2}^*, \dots, x_{*m-k}^*)$	Experimentos para $\mathbf{Y}^* = f(x_{*1}^*, x_{*2}^*, \dots, x_{*m-k}^*)$	Experimentos para $\mathbf{WPC}^* = f(x_{*1}^*, x_{*2}^*, \dots, x_{*m-k}^*)$
C1	Idem M3	Idem M3	Idem M3
	(2.83)	$LIC_{pc} = \mu_{w;pc} - k\sigma_{w;pc}$	$LIC_{wpc} = \mu_{w;wpc} - k\sigma_{w;wpc}$
	$LIC = \mu_w - k\sigma_w$	$L_{c;pc} = \mu_{w;pc}$	$L_{c;wpc} = \mu_{w;wpc}$
	$L_c = \mu_w$	$LSC_{pc} = \mu_{w;pc} + k\sigma_{w;pc}$	$LSC_{wpc} = \mu_{w;wpc} + k\sigma_{w;wpc}$
	(2.95)		(2.95)
	$E(L) = \left(\frac{a_1 + a_2 n}{h} \right) +$		$E(L) = \left(\frac{a_1 + a_2 n}{h} \right) +$
	$a_4 \left[\frac{h}{(1-\beta)} - \tau + gn + D \right]$		$a_4 \left[\frac{h}{(1-\beta)} - \tau + gn + D \right]$
C2	$\frac{1}{\lambda} + \frac{h}{(1-\beta)} - \tau + gn + D$		$\frac{1}{\lambda} + \frac{h}{(1-\beta)} - \tau + gn + D$
	$+ \frac{a_3 + a_3 \left[\frac{\alpha \times e^{-\lambda h}}{(1-e^{-\lambda h})} \right]}{\frac{1}{\lambda} + \frac{h}{(1-\beta)} - \tau + gn + D}$		$+ \frac{a_3 + a_3 \left[\frac{\alpha \times e^{-\lambda h}}{(1-e^{-\lambda h})} \right]}{\frac{1}{\lambda} + \frac{h}{(1-\beta)} - \tau + gn + D}$
	(2.99)		(3.40)
	Minimizar $E[L(n, k, h)]$		Min $\sum_{group=1}^g \psi_{group} \left\{ E[L(n, k_{group}, h)]_{group} \right\}$
	S.t.: $k, h \in \mathbf{R}_+^*$		
	$n \in \mathbf{N}^*$		

3.2 Etapa “Definir”

Esta etapa consiste, basicamente, em selecionar o problema a ser resolvido, avaliar seu impacto no consumidor e potenciais benefícios que o projeto pode proporcionar (DE KONING e DE MAST, 2006).

3.2.1 D1: identificar e mapear processo relevante

Neste primeiro passo deve-se apresentar o processo que deverá ser otimizado. A equipe envolvida no projeto deve possuir o mesmo nível de conhecimento do processo relevante. Rasis *et al.* (2002) afirmam que um SIPOC (*suppliers-inputs-process-outputs-customers*) é uma ferramenta simples que pode ser usada para identificar os fornecedores e seus *inputs* no processo, visualizar o processo em alto nível, os *outputs* do processo e os segmentos de clientes interessados nos *outputs*. As características multivariadas podem vir de um único processo, ou até mesmo de mais de um processo, de acordo com a Figura 3.2.

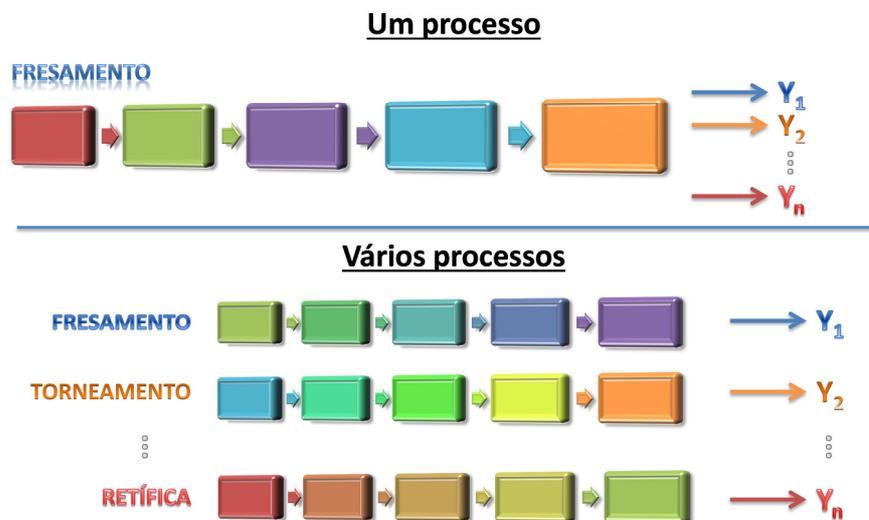


Figura 3.2 – Ilustração que caracteriza possíveis processos multivariados

3.2.2 D2: *Project charter*

Segundo Kumar e Sosnoski (2009), o *project charter* define o problema, objetivo, meta, escopo, cronograma, equipe e potenciais benefícios financeiros do projeto.

Problema: uma boa definição do problema deve situar um determinado período de tempo, ser específica e mensurável, descrever seu impacto sobre os negócios, explicitar a situação atual e a situação desejada.

Objetivo: depois de criada a descrição do problema é importante estabelecer objetivos e metas alcançáveis em um prazo determinado pelos membros da equipe.

Escopo: o escopo do projeto refere-se às fronteiras dentro das quais a equipe está trabalhando e, principalmente, com o que a equipe não está trabalhando.

Cronograma: com os objetivos e as metas do projeto pré-estabelecidas, um cronograma deverá ser criado discriminando as etapas a serem cumpridas. É necessário, nas reuniões semanais, que seja apresentado o status das atividades referentes ao projeto.

Equipe: como já descrito na seção 2.2, um treinamento diferenciado é parte integrante da abordagem Seis Sigma. Para atingir os objetivos de melhoria, o *Champion* deve identificar os projetos de importância estratégica e disponibilizar os recursos necessários. *Master Black Belts* devem providenciar todo suporte técnico exigido na condução dos projetos. E o *Black Belt* é o responsável por conduzir o projeto de melhoria com apoio dos *Green Belts*.

Potenciais benefícios financeiros: os projetos Seis Sigma devem iniciar com a determinação dos requisitos do cliente e é essencial definir metas de projeto para reduzir este *gap* quando comparado ao que a empresa entrega atualmente de qualidade, produtividade, confiabilidade e custo (BAÑUELAS e ANTONY, 2002). O impacto antecipado do projeto no desempenho global da empresa deve ser estimado. Antony *et al.* (2006), por exemplo, apresentaram um exemplo da Dow Chemical, na qual foi obtido os potenciais benefícios com base na diferença existente entre desempenho atual e a meta determinada no projeto.

Todo projeto Seis Sigma deve destacar as pessoas que serão afetadas por ele. Montgomery e Woodall (2008) apresentam uma visão geral do programa Seis Sigma e ao discutir sobre a evolução do Seis Sigma, estes autores destacam que a Geração III (a mais recente) do Seis Sigma tem um foco adicional de criar valor para a organização e para seus *stakeholders* (proprietários, empregados, clientes, fornecedores e a sociedade em geral).

3.3 Etapa “Medir”

Esta etapa tem como objetivo traduzir o problema para uma forma mensurável, validar o sistema de medição e avaliar a situação atual do processo (DE KONING e DE MAST, 2006).

3.3.1 M1: selecionar Ys

Quando há necessidade de ponderar as características Ys em um projeto Seis Sigma, o QFD pode ser empregado. Nesta tese, o método será aplicado de forma restrita conferindo, principalmente, o desdobramento da qualidade, através da casa da qualidade (HOQ). Como

mencionado na seção 2.4, o procedimento para traduzir a voz do cliente em características técnicas de projetos segue os seguintes passos:

- 1) Obtenção das necessidades do cliente através da voz do cliente – VOC;
- 2) Obtenção de Ys a partir das necessidades do cliente;
- 3) Correlação entre Ys e as necessidades do cliente;
- 4) Priorização dos Ys;

Um diagrama de árvore da qualidade é uma ferramenta que auxilia a identificar as necessidades do cliente e desdobra essas necessidades até o nível das características da qualidade. Em seguida, correlaciona-se as necessidades do cliente e as características do projeto, com objetivo de priorizar os Ys. Como visto na seção 2.4, os pesos relativos das características da qualidade Ys são calculados usando:

$$PrY_j = \frac{PaY_j}{\sum PaY} \quad (3.1)$$

Adicionalmente, pode-se construir um gráfico de Pareto com os pesos relativos obtidos para Ys, para auxiliar no processo de priorização dos Ys. O diferencial desta tese, no uso da técnica QFD, consiste em aplicar as importâncias relativas obtidas da HOQ nos passos seguintes do *roadmap* Seis Sigma, tais como: estimativa dos índices de capacidade, modelagem e otimização do processo, além do monitoramento por cartas de controle.

3.3.2 M2: validar sistema de medição

Wang e Chien (2010) compararam o método PCA com dois outros métodos para a análise do sistema de medição. No entanto, estes autores realizaram a análise individualmente para cada componente principal. Esta metodologia pode não ser adequada, pois a análise individual de cada uma das componentes pode proporcionar interpretações distintas. Quando as respostas apresentam correlações muito altas ($\%PC_1 > 90\%$, por exemplo), a análise da primeira componente principal explica razoavelmente bem a variabilidade do sistema de medição. No entanto, quando as correlações entre as respostas não são muito altas, há a necessidade de analisar mais de uma componente principal, pois apenas a primeira componente principal não é capaz de explicar todo o conjunto de dados. Assim, esta tese propõe um novo método de estudo GR&R multivariado que usa ponderação das componentes principais. Neste caso, o modelo tem como resposta as componentes principais ponderadas

através de seus respectivos autovalores. Esta proposta surgiu com base no trabalho de Paiva *et al.* (2010), que usaram uma técnica de otimização multi-objetivo baseada na ponderação das componentes principais para estudar um processo de soldagem com um conjunto de múltiplas respostas moderadamente correlacionadas. Logo, o modelo proposto para o estudo GR&R multivariado é dado por (PERUCHI *et al.*, 2013a):

$$WPC = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk} \begin{cases} i = 1, 2, \dots, p \\ j = 1, 2, \dots, o \\ k = 1, 2, \dots, r \end{cases} \quad (3.2)$$

onde:

$$WPC = \sum_{i=1}^q [\lambda_i(PC_i)] = \lambda_1 PC_1 + \lambda_2 PC_2 + \dots + \lambda_q PC_q \quad (3.3)$$

a resposta usada no modelo (3.2) é o resultado de uma ponderação das componentes principais por seus respectivos autovalores, de acordo com a Eq. (3.3). A variável μ é uma constante e $\alpha_i, \beta_j, (\alpha\beta)_{ij}, \varepsilon_{ijk}$ são variáveis aleatórias normais independentes com média zero e variância $\sigma_\alpha^2, \sigma_\beta^2, \sigma_{(\alpha\beta)}^2$ e σ_ε^2 , respectivamente.

Outra forma de obter WPC poderia ser através da explicação individual de cada componente principal, logo (PERUCHI, 2011):

$$WPC = \sum_{i=1}^q \left[\frac{\lambda_i}{\sum_{j=1}^p \lambda_j} (PC_i) \right] \quad (3.4)$$

Em Johnson e Wichern (2007), verifica-se que há uma variedade de regras para estimar o número adequado de eixos de componentes principais não triviais que podem ser adotadas para representar o conjunto de dados. No entanto, devido à ponderação das componentes principais por seus respectivos autovalores, todas as componentes principais podem ser incluídas no modelo. As componentes com maior autovalor terão maior importância no modelo ponderado e, apesar disso, nenhuma informação deixará de ser incluída no estudo.

Os componentes de variação do modelo (3.8) podem ser estimados usando análise de variância. Os resultados destes equacionamentos aplicados aos escores ponderados das componentes principais representarão todas as q características analisadas no estudo. Logo, as componentes de variação devido ao processo (σ_P^2), repetitividade ($\sigma_{repetitividade}^2$),

reprodutividade ($\sigma_{reprodutividade}^2$), sistema de medição (σ_{SM}^2) e variação total (σ_T^2), são estimadas através das Eqs. (3.5)-(3.9):

$$\hat{\sigma}_P^2 = \hat{\sigma}_\alpha^2 = \frac{MSP-MSPO}{or} \quad (3.5)$$

$$\hat{\sigma}_{repetitividade}^2 = \hat{\sigma}_\varepsilon^2 = MSE \quad (3.6)$$

$$\hat{\sigma}_{reprodutividade}^2 = \hat{\sigma}_\beta^2 + \hat{\sigma}_{\alpha\beta}^2 = \frac{MSO-MSPO}{pr} + \frac{MSPO-MSE}{r} \quad (3.7)$$

$$\hat{\sigma}_{SM}^2 = \hat{\sigma}_{repetitividade}^2 + \hat{\sigma}_{reprodutividade}^2 \quad (3.8)$$

$$\hat{\sigma}_T^2 = \hat{\sigma}_P^2 + \hat{\sigma}_{SM}^2 \quad (3.9)$$

onde MSP, MSO, MSPO e MSE são, respectivamente, as médias quadráticas para o fator peça, fator operador, termo de interação e o termo de erro. Caso o efeito de interação não seja significativo, o modelo completo pode ser reduzido para:

$$WPC = \mu + \alpha_i + \beta_j + \varepsilon_{ijk} \quad (3.10)$$

Neste caso, as componentes de variação do estudo GR&R multivariado, baseadas em escores ponderados de componentes principais, são estimadas através das Eqs. (3.11)-(3.15):

$$\hat{\sigma}_P^2 = \hat{\sigma}_\alpha^2 = \frac{MSP-MSE}{or} \quad (3.11)$$

$$\hat{\sigma}_{repetitividade}^2 = \hat{\sigma}_\varepsilon^2 = MSE \quad (3.12)$$

$$\hat{\sigma}_{reprodutividade}^2 = \hat{\sigma}_\beta^2 = \frac{MSO-MSE}{pr} \quad (3.13)$$

$$\hat{\sigma}_{SM}^2 = \hat{\sigma}_{repetitividade}^2 + \hat{\sigma}_{reprodutividade}^2 \quad (3.14)$$

$$\hat{\sigma}_T^2 = \hat{\sigma}_P^2 + \hat{\sigma}_{SM}^2 \quad (3.15)$$

Os índices multivariados de avaliação do sistema de medição, porcentagem R&R ($\%R\&R_m$) e número de categorias distintas (ndc_m), são obtidos através das Eqs. (3.16) e (3.17). Os critérios de aceitação do sistema de medição são os mesmos descritos na seção 2.5.

$$\%R\&R_m = \frac{\sigma_{sm;wpc}}{\sigma_{t;wpc}} \quad (3.16)$$

$$ndc_m = \sqrt{2} \frac{\sigma_{p;wpc}}{\sigma_{sm;wpc}} \quad (3.17)$$

3.3.3 M3: avaliar capacidade do processo atual e definir objetivos

Seja $\mathbf{Y}' = (Y_1, Y_2, \dots, Y_q)$ o vetor das q características de interesse com vetor de médias $\boldsymbol{\mu}$ e matriz variância-covariância $\boldsymbol{\Sigma}$ positiva definida. Assume-se que os dados do processo multivariado são tomados de uma distribuição normal multivariada.

Denotando os valores do q -vetor dos limites inferiores de especificação, limites superiores de especificação e valores alvos são definidos como segue:

$$\mathbf{LSL}' = (LSL_1, LSL_2, \dots, LSL_q) \quad (3.18)$$

$$\mathbf{USL}' = (USL_1, USL_2, \dots, USL_q) \quad (3.19)$$

$$\mathbf{T}' = (T_1, T_2, \dots, T_q) \quad (3.20)$$

Wang e Chen (1998) propuseram um procedimento para a construção dos índices de capacidade multivariado usando PCA. PCA usa a decomposição espectral da matriz variância-covariância $\boldsymbol{\Sigma}$

$$\boldsymbol{\Sigma} = \mathbf{EDE}' \quad (3.21)$$

onde $\mathbf{E} = (\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_q)$ é a matriz de autovetores de Σ com colunas \mathbf{e}_i ($i = 1, 2, \dots, q$), e $\mathbf{D} = \mathbf{U}'\Sigma\mathbf{U} = \text{diag}(\lambda_1, \dots, \lambda_q)$ é a matriz diagonal dos autovalores. Seguindo PCA, as especificações de engenharia da i -ésima componente principal (PC_i) e o valor alvo são

$$LSL_{PC_i} = \mathbf{e}_i' \mathbf{L} \mathbf{S} \mathbf{L} \quad USL_{PC_i} = \mathbf{e}_i' \mathbf{U} \mathbf{S} \mathbf{L} \quad T_{PC_i} = \mathbf{e}_i' \mathbf{T} \quad (3.22)$$

Wang e Chen (1998) propuseram avaliar a capacidade multivariada considerando um subconjunto v ($v \leq q$) de componentes principais. Eles definiram os ICPMs MC_p , MC_{pk} , MC_{pm} e MC_{pmk} usando os ICP univariados dos componentes principais. O índice de capacidade MC_p para o processo multivariado definido por Wang e Chien (1998) é

$$MC_p = \left(\prod_{i=1}^v C_{p;PC_i} \right)^{1/v} \quad (3.23)$$

Onde

$$C_{p;PC_i} = \frac{USL_{PC_i} - LSL_{PC_i}}{6\sigma_{PC_i}} \quad (3.24)$$

Alternativamente aos índices propostos por Wang e Chien (1998), Perakis e Xekalaki (2012), assim como Wang (2005), desenvolveram outros índices multivariados de capacidade tais como MXC_p e MWC_p . Estes autores não tratam especificamente de casos nos quais há presença de variáveis com correlações positivas, negativas e/ou não significativas. Nestes casos, os limites de especificação reescritos em termos de escore de componente principal podem ser mal estimados, quando se usa a matriz de correlação para extração dos autovalores e autovetores ao executar PCA. A extração pela matriz de variância-covariância pode ser uma alternativa em tais situações.

No entanto, pode existir o efeito de escala quando os autovalores e autovetores são extraídos pela matriz de variância-covariância ao executar PCA. Por conseguinte, esta tese propõe um novo método para calcular os limites de especificação em termos de escore de componente principal, para em seguida, estimar os índices multivariados de capacidade de processo. Recomenda-se separar os Ys em grupos de acordo com seus objetivos de

otimização como tal: grupo maximizar, grupo minimizar e grupo alvo. Desta forma, executa-se PCA individuais para cada grupo especificado. Cada grupo será representado por um vetor ponderado de escores de componentes principais por seus respectivos autovalores. Este resultado, já apresentado pela Eq. (3.4), pode ser reescrito na forma matricial abaixo:

$$\mathbf{WPC}_{group} = \mathbf{W}'(\mathbf{u}'\mathbf{Y}) \quad (3.25)$$

Onde \mathbf{WPC}_{group} representam os escores ponderados de componentes principais para os grupos $group=[maximizar, minimizar, alvo]$ e \mathbf{W} é um vetor que contem o percentual de explicação de cada componente principal e pode ser escrito como:

$$W = \left(\frac{\lambda_1}{\sum_{j=1}^p \lambda_j}, \frac{\lambda_2}{\sum_{j=1}^p \lambda_j}, \dots, \frac{\lambda_q}{\sum_{j=1}^p \lambda_j} \right) \quad p = 1, 2, \dots, q \quad (3.26)$$

Já os limites de especificação e alvos ponderados, podem ser obtidos pela Eq. (3.27) abaixo:

$$LSL_{wpc} = \mathbf{W}'\mathbf{LSL}_{pc} \quad USL_{wpc} = \mathbf{W}'\mathbf{USL}_{pc} \quad T_{wpc} = \mathbf{W}'\mathbf{T}_{pc} \quad (3.27)$$

De posse dos vetores ponderados e dos limites de especificação e alvos ponderados é possível estimar o ICPM como segue:

$$MWAC_p = \sum_{i=1}^{\xi} \psi(C_{p;WPC_i}) \quad (3.28)$$

onde:

$$C_{p;wpc_i} = \frac{USL_{wpc} - LSL_{wpc}}{6\sigma_{wpc}} \quad (3.29)$$

ξ é a quantidade de grupos (maximizar, minimizar e alvo); ψ é o peso atribuído para cada grupo, de acordo com a matriz QFD. Analogamente, MWC_p , MWC_{pk} , MWC_{pm} e MWC_{pmk} podem ser estimados substituindo na Eq. (3.28) o índice C_p da Eq. (3.29) por seus respectivos cálculos, Eqs. (2.30)-(2.33).

Adicionalmente, esta tese propõe o cálculo de PPM_m e nível sigma (Σ_{level}) para processos multivariados. $PPM_m(LSL_{wpc})$ é o número esperado de partes por milhão de escores ponderados de PC menor que o limite inferior de especificação, escrito em termos de escores ponderados de componente principal. $PPM_m(USL_{wpc})$ é o número esperado de partes por milhão de escores ponderados de PC maior que o limite superior de especificação, escrito em termos de escores ponderados de componente principal. Logo, PPM_m pode ser obtido através dos seguintes equacionamentos:

$$PPM_m(LSL_{wpc}) = 1.000.000 \left[1 - \Phi \left(\frac{\bar{x}_{wpc} - LSL_{wpc}}{\hat{\sigma}_{wpc}} \right) \right] \quad (3.30)$$

$$PPM_m(USL_{wpc}) = 1.000.000 \left[1 - \Phi \left(\frac{USL_{wpc} - \bar{x}_{wpc}}{\hat{\sigma}_{wpc}} \right) \right] \quad (3.31)$$

$$PPM_m = PPM_m(LSL_{wpc}) + PPM_m(USL_{wpc}) \quad (3.32)$$

onde $\Phi(X)$ é a função distribuição de probabilidade acumulada (cdf) de uma normal padronizada, \bar{x}_{wpc} é a média dos escores ponderados de PC e $\hat{\sigma}_{wpc}$ é o desvio-padrão global de WPC .

Já o nível sigma (Σ_{level} ou Σ_{bench}) para processos multivariados pode ser obtido por:

$$\Sigma_{LIE} = \frac{\bar{x}_{wpc} - LSL_{wpc}}{\hat{\sigma}_{wpc}} \quad (3.33)$$

$$\Sigma_{LSE} = \frac{USL_{wpc} - \bar{x}_{wpc}}{\hat{\sigma}_{wpc}} \quad (3.34)$$

$$\Sigma_{Level} = \Phi^{-1}(1 - P_1 - P_2) \quad (3.35)$$

Onde $P_1 = Prob(X < LSL_{wpc}) = 1 - \Phi(\Sigma_{LSL})$, $P_2 = Prob(X > USL_{wpc}) = 1 - \Phi(\Sigma_{USL})$, $\Phi(X)$ é a cdf de uma normal padronizada e $\Phi^{-1}(X)$ é a função cdf inversa de uma normal padronizada. Os resultados das Eqs. (3.32) e (3.35) referem-se a cada grupo WPC. Portanto, emprega-se a Eq. (3.28) substituindo C_p por PPM_m e Σ_{level} de cada grupo para obter o número global esperado de partes por milhão de escores ponderados de PC fora da especificação e o nível sigma global do processo multivariado, $(PPM_m)_{overall}$ e $(\Sigma_{level})_{overall}$, respectivamente.

Após estimar a capacidade do processo multivariado, define-se estatisticamente o objetivo do projeto. De acordo com Linderman *et al.* (2003), nem todo processo deve operar no nível Seis Sigma. O nível apropriado dependerá da importância estratégica do processo e o custo da melhoria em relação ao seu benefício. Para alcançar cinco ou seis sigmas serão necessários muito mais esforços e ferramentas estatísticas mais sofisticadas. As metas quantitativas de melhoria utilizadas no Seis Sigma definem os níveis alvo de defeitos por milhão de oportunidades (DPMO) e/ou sigma do processo. Para estabelecer as metas estatísticas de melhoria, nesta tese será empregada a abordagem proposta por Linderman *et al.* (2006) denominada regra 10x. Por exemplo, se o DPMO atual é de 30.000 para um processo, a meta de melhoria é a redução do DPMO em um fator de 10, ou seja, para 3.000.

3.4 Etapa “Analisar”

Nesta etapa identificam-se os fatores de influência e causas que determinam o comportamento dos Ys (DE KONING e DE MAST, 2006).

3.4.1 A1: Identificar potenciais Xs

Quando considerar os fatores que podem influenciar o desempenho de um processo ou sistema, o experimentalista descobre que estes fatores podem ser classificados como potenciais fatores de projeto ou fatores de perturbação. Os potenciais fatores de projeto são aqueles que o experimentalista deseja variar no experimento. Outras classificações para estes potenciais fatores de projeto podem ser fator de projeto, fator mantido constante e fator permitido variar. Fatores de projeto (ou controláveis ou Xs) são selecionados para estudo no experimento. Os fatores mantidos constantes são aqueles que exercem algum efeito na resposta, mas que para o propósito do experimento, este fator não é de interesse, logo, é

mantido em um nível específico. O fator permitido variar é aquele que possui impacto relativamente pequeno na resposta (MONTGOMERY, 2005).

Fatores de perturbação, por outro lado, podem ter grande efeito na resposta e, na maioria das vezes, não estamos interessados no contexto do presente experimento. Estes fatores são classificados como controláveis, incontroláveis e de ruído. Um fator perturbador controlável é aquele o qual os níveis podem ser definidos pelo experimentalista (por exemplo, lote de matéria-prima, dias da semana para conduzir o experimento, etc.). O princípio de blocagem é útil para lidar com este tipo de fator perturbador. Se um fator perturbador é incontrolável, mas ele pode ser medido, análise de covariância pode ser usada para compensar este efeito (por exemplo, umidade relativa do ar). Quando um fator que varia naturalmente e incontrolavelmente no processo pode ser controlado, este fator é chamado de fator de ruído. Em algumas situações, deseja-se determinar as variáveis de projeto que são insensíveis as variáveis de ruído. Este estudo configura o projeto de parâmetro robusto (MONTGOMERY, 2005).

Nesta tese, para identificar os fatores de potencial influência nos Ys será utilizado o diagrama de causa e efeito específico para planejamento de experimentos. De acordo com Montgomery (2005), o diagrama de causa e efeito é uma ferramenta útil para organizar algumas das informações geradas na pré-experimentação. A Figura 3.3 apresenta um diagrama de causa e efeito que pode ser construído, especificamente, para condução de experimentos. Neste caso, destacam-se as variáveis de controle as quais o experimentalista pretende avaliar, fatores incontroláveis os quais podem ser amenizados por aleatorização, fatores de ruído que podem ser bloqueados e os fatores constantes durante a condução dos experimentos.

3.4.2 A2: selecionar poucos vitais Xs

A maioria das aplicações de RSM é de natureza sequencial. Neste *roadmap*, para selecionar os poucos vitais X e modelar os Ys e WPCs será seguido a estrutura de fases proposta por Myers *et al.* (2009). Inicialmente, baseado em WPC para grupos de respostas (Eq. 3.25), identificam-se quais variáveis provavelmente serão importantes no estudo de superfície de resposta. Neste caso, o estudo é projetado para eliminar as variáveis que não são significativas. Este tipo de experimento é chamado de experimento exploratório (ou do inglês, *screening experiment*). O objetivo deste experimento é reduzir a lista de variáveis X para uma experimentação mais eficiente nos passos subsequentes. Estes experimentos, de acordo com Myers *et al.* (2009), referem-se à **fase 0** na experimentação sequencial.

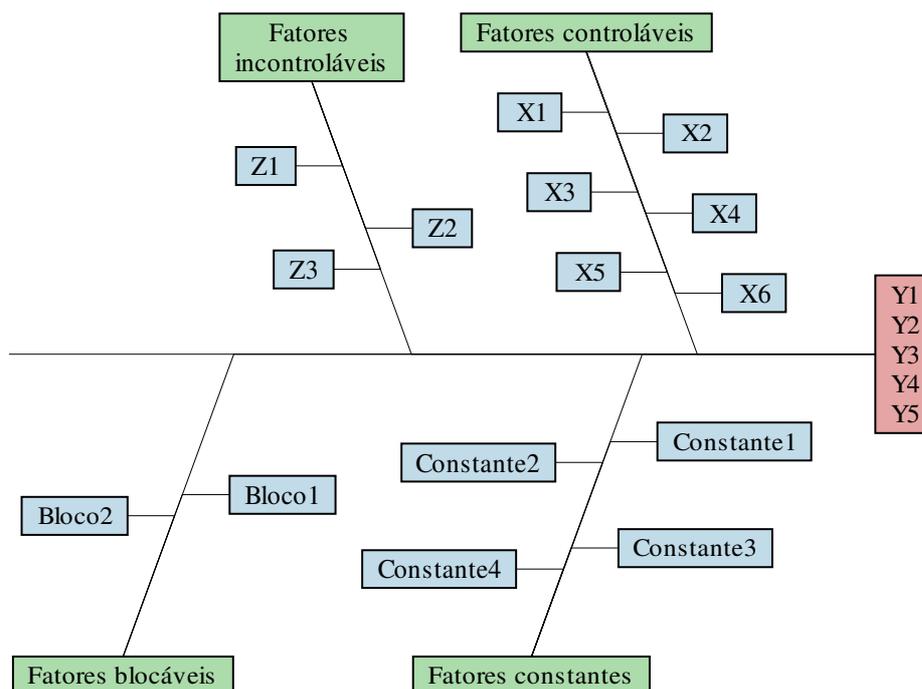


Figura 3.3 – Diagrama de causa e efeito orientado a DOE

Uma vez identificadas as variáveis Xs significativas, inicia-se a **fase 1** da metodologia de superfície de resposta. Neste caso, o objetivo é identificar se o processo está operando em uma região próxima ao ótimo, lembrando que a análise também é realizada sobre os vetores WPCs. Caso contrário, alteração nos níveis das variáveis deve ser promovida para deslocar as condições experimentais em direção à condição ótima de processamento. Caso necessário, usa-se o método *steepest ascent* de otimização para modelos de primeira ordem para encontrar a região de otimização.

Neste passo do projeto Seis Sigma, aplica-se as **fases 0 e 1** da metodologia sequencial de Myers *et al.* (2009) onde os vetores WPCs são avaliados segundo os modelos das Eqs. (2.45) e (2.63). Arranjos experimentais do tipo fatorial fracionado e fatorial completo com *center points* podem ser empregados. No próximo passo, II, será detalhada a **fase 2** da metodologia de Myers *et al.* (2009).

3.5 Etapa “Melhorar”

Esta etapa tem objetivo de definir e implementar ajustes ao processo para melhorar o desempenho dos Ys (DE KONING e DE MAST, 2006).

3.5.1 II: quantificar relacionamento dos Xs com os Ys e PCs

Continuando a metodologia de Myers *et al.* (2009), a **fase 2** inicia-se quando o processo está próximo ao ótimo. Neste caso, o experimentalista pretende ajustar o processo a um modelo de segunda ordem mais preciso, pois há curvatura na região analisada. Em seguida, métodos de otimização podem ser empregados sobre os modelos matemáticos de segunda ordem para otimizar o processo avaliado. A **fase 2** será dividida em duas partes. A primeira modela as variáveis respostas originais do processo de acordo com o modelo quadrático da Eq. (2.61). Esta modelagem determinará o resultado prático esperado após aplicar o método multivariado de otimização.

A segunda parte da **fase 2** da metodologia representa também início do método de modelagem e otimização proposto nesta tese e apresentado na Figura 3.4. Este método deriva do trabalho proposto por Gomes *et al.* (2013) e pretende aplicar três modificações, tais como:

- **Primeiro**, os autores não consideraram uma abordagem estruturada para definir os pesos de cada resposta da otimização;
- **Segundo**, como já mencionado na seção 3.3.3, correlações positivas, negativas e não significativas geram uma dificuldade ao traduzir os limites de especificação originais em termos de escores de componentes principais;
- **Terceiro**, levando em consideração a discussão na seção 2.8.3.1, aglutinação de múltiplos objetivos por média aritmética e/ou geométrica apresenta algumas deficiências na construção da fronteira de Pareto.

O terceiro tópico será tratado no próximo passo do projeto, pois se refere à otimização do processo multivariado. Para superar a primeira limitação, uma forma sistemática para atribuição de peso às características Ys do projeto será proposta com base na importância relativa obtida de uma matriz QFD.

Para a segunda limitação, recomenda-se separar os Ys em grupos de acordo com seus objetivos de otimização como tal: grupo maximizar, grupo minimizar e grupo alvo. Desta forma, executa-se PCA individuais para cada grupo especificado. Cada grupo será representado por um vetor ponderado de escores de componentes principais por seus respectivos autovalores, de acordo com a Eq. (3.25), da seção 3.3.3. Finalizando a **fase 2** da metodologia de Myers *et al.* (2009), a modelagem do processo multivariado será realizada para cada grupo de variáveis através de seus vetores de escores ponderados de componentes principais. Logo, o modelo multivariado de segunda ordem proposto assume:

$$\mathbf{WPC}_{group} = \mathbf{b}_0 + \nabla f(\mathbf{x})^T + \frac{1}{2} \mathbf{x}^T [\nabla^2 f(\mathbf{x})] \mathbf{x} \quad (3.36)$$

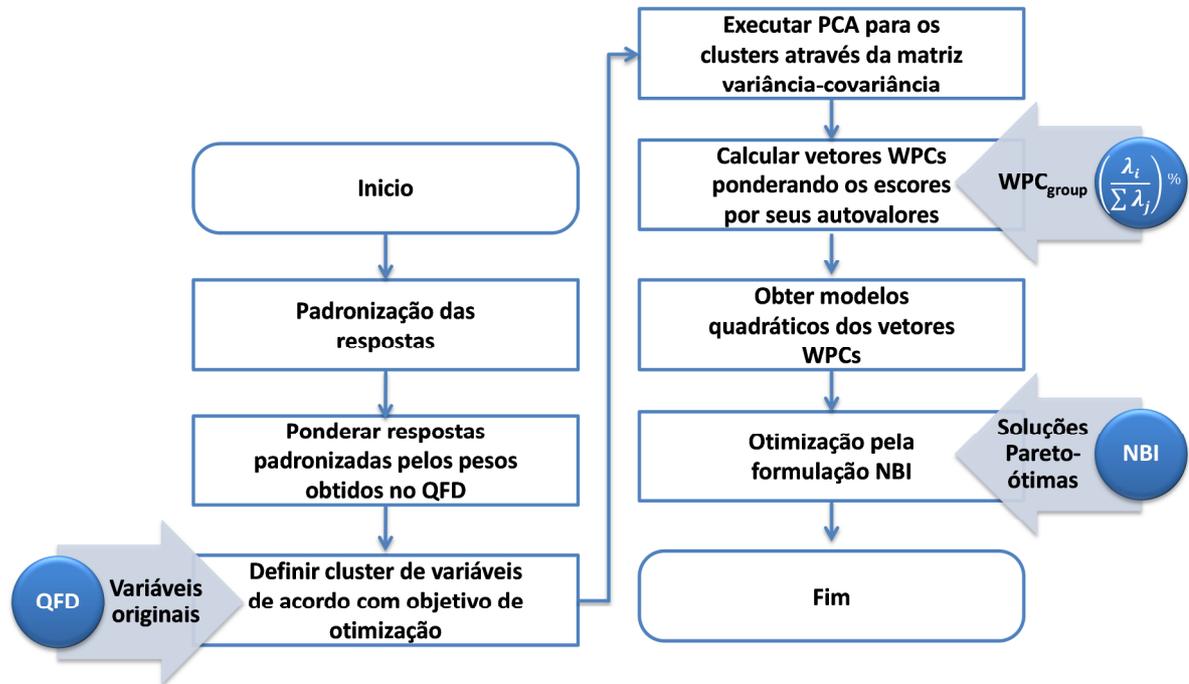


Figura 3.4 – Procedimento para otimização multivariada pelo método NBI-WPC

3.5.2 I2: otimização do processo pelas WPCs

Após finalizar a metodologia de Myers *et al.* (2009) e boa parte do método de modelagem e otimização proposto, inicia-se a aplicação do método NBI apresentado na seção 2.8.3.1 para os escores ponderados de componentes principais. Desta forma, considerando-se que sejam modelados dois grupos, um maximizar e outro minimizar, tem-se:

$$\begin{aligned} \text{Min } & \overline{WPC}_{\max}(\mathbf{x}) \\ \text{s.t.: } & \overline{WPC}_{\max}(\mathbf{x}) - \overline{WPC}_{\min}(\mathbf{x}) + 2w - 1 = 0 \\ & \mathbf{x}'\mathbf{x} \leq \rho^2 \\ & 0 \leq w \leq 1 \end{aligned} \quad (3.37)$$

Onde w são os pesos que estabelecem a relação de *trade-off* entre os grupos \overline{WPC}_{\max} e \overline{WPC}_{\min} , ρ é o raio da região esférica experimental, e $\overline{WPC}_{\max}(\mathbf{x})$ e $\overline{WPC}_{\min}(\mathbf{x})$ são funções escalonadas dadas por:

$$\overline{WPC}_{\max}(\mathbf{x}) = \frac{WPC_{\max}(\mathbf{x}) - WPC_{\max}^U}{WPC_{\max}^N - WPC_{\max}^U} \quad (3.38)$$

$$\overline{WPC}_{\min}(\mathbf{x}) = \frac{WPC_{\min}(\mathbf{x}) - WPC_{\min}^U}{WPC_{\min}^N - WPC_{\min}^U} \quad (3.39)$$

Uma questão que deve ser esclarecida refere-se às estratégias de ponderação do método proposto. Esquemáticamente, a Figura 3.5 apresenta as estratégias de ponderação e os resultados de cada etapa para o método proposto (também ilustrado na Figura 3.4).

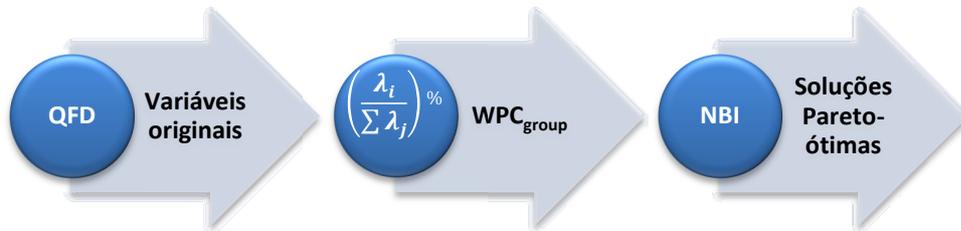


Figura 3.5 – Ilustração das ponderações do método de otimização proposto

A primeira estratégia pondera as variáveis originais pelos pesos da matriz QFD. A segunda estratégia pondera os escores de componentes principais pelos respectivos percentuais de explicação, para obter o vetor WPC de cada grupo de variáveis. E a terceira estratégia faz parte da formulação do método NBI para construir a fronteira com soluções Pareto-ótimas. A Figura 3.6 ilustra os principais elementos que configuram a otimização pelo método NBI. A determinação de pesos distintos (variando entre 0 e 1) para as variáveis de interesse é a estratégia que permite a construção da Fronteira de Pareto. Os pesos atribuídos durante a execução do método de otimização pode afetar a ponderação inicialmente atribuída as variáveis originais pela matriz QFD. Pesquisa futura deve ser conduzida com objetivo de investigar o comportamento da linha de utopia (que liga os pontos de ancoragem, ver Figura 3.6) para distintas correlações entre os vetores otimizados pelo método. Espera-se que correlações mais altas e objetivos de otimização concordantes determinem linha de utopia com tamanho reduzido em comparação a correlações mais baixas e objetivos conflitantes. Desta forma, deve ser proposto um índice, assim como o índice D do método *desirability*, para quantificar este fenômeno e avaliar mais efetivamente o impacto nos resultados ótimos e

a influência da ponderação pelo método NBI na ponderação inicial das variáveis respostas originais.

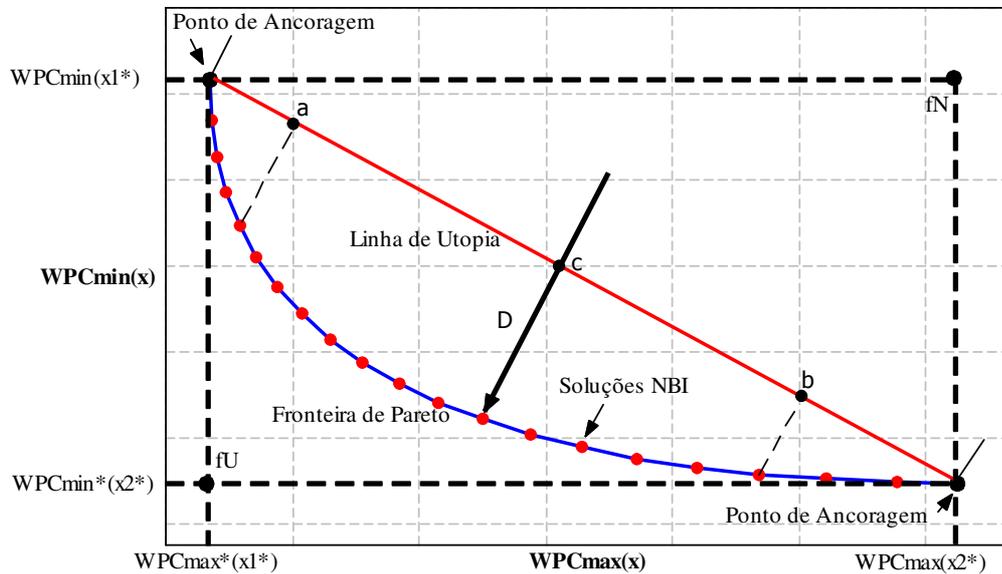


Figura 3.6 – Elementos da otimização por NBI

3.5.3 I3: conduzir teste piloto para as ações de melhoria

Etapa fundamental para validar os resultados obtidos pelo método de otimização, experimentos de confirmação devem ser realizados para confirmar a viabilidade do método NBI-WPC proposto.

3.6 Etapa “Controlar”

Esta etapa tem objetivo de ajustar o gerenciamento do processo e sistemas de controle para que as melhorias alcançadas sejam mantidas (DE KONING e DE MAST, 2006).

3.6.1 C1: determinar capacidade do processo melhorado

Mesmo procedimento do passo M3, seção 3.3.3.

3.6.2 C2: implementar planos de controle

Há na literatura diversas abordagens para plotar cartas de controle multivariadas baseadas em PCA, dentre elas, cartas de controle Shewhart para os escores de componentes principais (JACKSON, 1991; BERSIMIS *et al.*, 2007). No entanto, estes autores plotaram

cartas de controle individualmente para cada componente principal. Quando as características apresentam correlações muito altas ($\%PC_1 > 95\%$, por exemplo), a análise da primeira componente principal explica razoavelmente bem a variabilidade do conjunto de dados. No entanto, quando as correlações entre as respostas não são muito altas, há a necessidade de analisar mais de uma componente principal, pois apenas a primeira componente principal não é capaz de explicar todo o conjunto de dados das variáveis originais.

Adicionalmente, em SPC deseja-se avaliar a capacidade do processo, além de sua estabilidade. Como já mencionado na seção 3.3.3, a presença de correlações positivas, negativas e não significativas gera uma dificuldade ao traduzir os limites de especificação em termos de escores de componentes principais. Portanto, esta tese propõe um novo método para monitoramento de processos multivariados através de cartas de controle univariadas de escores ponderados de componentes principais. Assim como na seção 3.3.3, recomenda-se separar os Ys em grupos de acordo com seus objetivos de otimização como tal: grupo maximizar, grupo minimizar e grupo alvo. Desta forma, executa-se PCA individuais para cada grupo especificado. Cada grupo será representado por um vetor ponderado de escores de componentes principais por seus respectivos autovalores, de acordo com a Eq. (3.25), na seção 3.3.3.

As cartas de controle Shewhart para monitoramento de média e variabilidade, em casos de $n=1$ ou $n>1$, dos escores ponderados WPC_{group} devem ser criadas através das Eqs. (2.86)-(2.90), apresentadas na seção 2.9 desta tese.

Outra carta de controle utilizada para monitoramento de múltiplas repostas é uma extensão da carta de Shewhart, a T^2 de Hotelling (HOTELLING, 1947). Montgomery e Klatt (1972) desenvolveram um modelo para estudar o projeto econômico da carta T^2 de Hotelling usando uma taxa fixa de amostragem. Consequentemente, Chou e Chen (2006) aplicaram o modelo de custo dado em Montgomery e Klatt (1972) para economicamente projetar o esquema de intervalos variáveis de amostragem à carta T^2 de Hotelling. Chen (2007) propôs outro esquema de intervalos variáveis de amostragem para a carta T^2 de Hotelling, baseado no modelo pioneiro de Duncan (1956). O projeto econômico de cartas T^2 de Hotelling usando esquemas com tamanho variável de amostras tem sido estudado por Faraz e Saniga (2011). No entanto, a literatura ainda é escassa em modelos econômicos de cartas de controle multivariadas por PCA.

Nesta tese serão determinados os parâmetros ótimos da carta de controle plotadas por WPC_{group} através de uma modificação do modelo de Duncan apresentado pela Eq. (2.98). Deverá ser empregada uma otimização multi-objetivo para determinar, simultaneamente, os

parâmetros ótimos das cartas para os grupos de variáveis. O modelo de otimização proposto para g grupos de respostas é representado por:

$$\underset{\substack{k, h \in \mathbf{R}_+^* \\ n \in \mathbf{N}^*}}{\text{Minimizar}} \sum_{group=1}^g \psi_{group} \left\{ E[L(n, k_{group}, h)]_{group} \right\} \quad (3.40)$$

onde, $E[L(n, k_{group}, h)]_{group}$ representa o modelo econômico de carta de controle \bar{x} de cada grupo de respostas, n é o mesmo tamanho da amostra do subgrupo para WPC_{max} e WPC_{min} , h é o mesmo intervalo de amostragem definido para WPC_{max} e WPC_{min} , k_{group} é o fator de abertura dos limites de controle para cada g grupo e ψ_i é o peso obtido pela matriz QFD para cada grupo de resposta.

3.7 Considerações finais

Este capítulo apresentou a proposta desta tese que consistiu em desenvolver um método estruturado para solução de problemas multivariados. O *roadmap* MDMAIC proposto teve objetivo de gerar uma série de contribuições que serão recordadas a seguir:

- Uma estrutura de etapas e passos foi elaborada, com base na técnica estatística multivariada PCA, para reduzir a dimensão de problemas complexos de engenharia envolvendo múltiplas respostas correlacionadas;
- Um método multivariado para análise de sistema de medição, baseado em ponderação dos escores de componentes principais, foi proposto. Os índices de classificação do sistema de medição foram obtidos com base na formulação dos índices univariados, no entanto, sobre os escores ponderados de componentes principais;
- Uma abordagem similar à mencionada no tópico anterior foi adotada para avaliar estabilidade e capacidade de processos multivariados. A análise foi realizada através da separação das características em grupos e, em seguida, aplicação de PCA para cada grupo, ponderando os escores de componentes principais por seus percentuais de explicação. Os escores ponderados de cada grupo são utilizados para plotar as cartas de controle de forma eficiente, pois apenas uma carta é necessária para cada grupo (uma para monitorar média e outra para amplitude ou desvio-padrão). As formulações dos índices de capacidade univariados foram aplicadas aos escores ponderados para determinar os índices globais de capacidade de processo;

- PPM e nível sigma são outras métricas utilizadas em projetos Seis Sigma para determinar se um processo é capaz de atingir aos pré-requisitos especificados. A literatura é escassa sobre versões multivariadas destas métricas. Similarmente às métricas de capacidade tradicionais (C_p , C_{pk} , C_{pm} e C_{pmk}), esta tese propôs versões multivariadas de PPM e nível sigma usando os escores ponderados de componentes principais;
- Um novo método de modelagem e otimização que combina QFD, RSM, PCA e NBI foi proposto. QFD foi a estratégia utilizada para ponderar as superfícies de resposta que foram obtidas por RSM. Em seguida, vetores WPC de cada grupo de respostas foram ajustados aos modelos de segunda ordem. Por fim, a formulação NBI foi aplicada aos vetores WPC para obter as soluções Pareto-ótimas e otimizar o conjunto original de respostas que representam o processo multivariado;
- Com objetivo de sustentar as melhorias obtidas no projeto, um planejamento econômico de cartas de controle para processos multivariados foi proposto. Nesta tese, o planejamento consistiu em cartas \bar{X} e R para os vetores WPC que representam os grupos de variáveis minimizar, maximizar e alvo.

Após destacar as potenciais contribuições desta tese, o próximo capítulo ilustra a aplicação do *roadmap* MDMAIC na otimização do processo de soldagem com arame tubular para o revestimento de chapas de aço carbono ABNT 1020 com aço inoxidável ABNT 316L.

4. APLICAÇÃO DO ROADMAP MULTIVARIADO

4.1 Considerações iniciais

Este capítulo tem o objetivo de ilustrar uma aplicação para o *roadmap* MDMAIC proposto. Inicialmente na etapa definir do MDMAIC, o processo soldagem de revestimento será apresentado. Em seguida, na etapa medir, os Ys serão selecionados com seus respectivos pesos relativos, obtidos por matriz QFD e gráficos de Pareto. O sistema de medição será validado e o *baseline* para o processo multivariado será estabelecido. Na etapa analisar, os potenciais fatores de influência serão identificados e testados quanto aos seus impactos no vetor WPC de cada grupo de variáveis. A etapa de melhoria usará o método NBI-WPC para determinar as condições ótimas de funcionamento do processo de soldagem de revestimento. Finalmente, a etapa controlar validará os resultados da otimização comparando o resultado ótimo ao *baseline*. Estabilidade e capacidade do processo melhorado serão avaliadas nesta etapa final do projeto.

4.2 D1: identificar e mapear processo relevante

A soldagem de revestimento de aços carbono com aços inoxidáveis é definida por Palani e Murugan (2006, 2007) como a deposição de uma camada de aço inoxidável sobre superfícies de aços carbono ou aços de baixa liga com o objetivo de obter revestimentos com propriedades de anti-corrosão. Visto que o preço dos aços inoxidáveis é aproximadamente dez vezes maior que o preço dos aços carbono, a principal vantagem deste processo está relacionada ao fato de que camadas anticorrosivas podem ser produzidas de forma mais barata, a partir de materiais de menor custo, como os aços carbono. Além disso, o emprego de um procedimento de soldagem contribui para que os revestimentos sejam depositados com rapidez e economia de material.

Quanto às propriedades dos revestimentos de aços inoxidáveis, as características desejadas do material depositado, segundo Kannan e Murugan (2006), se resumem a uma resistência mecânica razoável, boa soldabilidade com o metal base e boas propriedades de resistência à corrosão geral e à corrosão localizada. Para Ferriere *et al.* (2006), os revestimentos de aços inoxidáveis sobre aços carbono se mostram como uma boa solução para os problemas de elaboração de materiais que combinem altos níveis de propriedades mecânicas com boa resistência à corrosão.

O processo de revestimento ocorre de forma que os cordões sejam depositados lateralmente e com um dado nível de sobreposição até que toda a região de interesse seja recoberta (Figura 4.1). O nível de sobreposição dos cordões depende da aplicação do revestimento e do processo de soldagem empregado. A Figura 4.2 ilustra três exemplos de camadas de revestimentos depositados a partir de processos de soldagem.

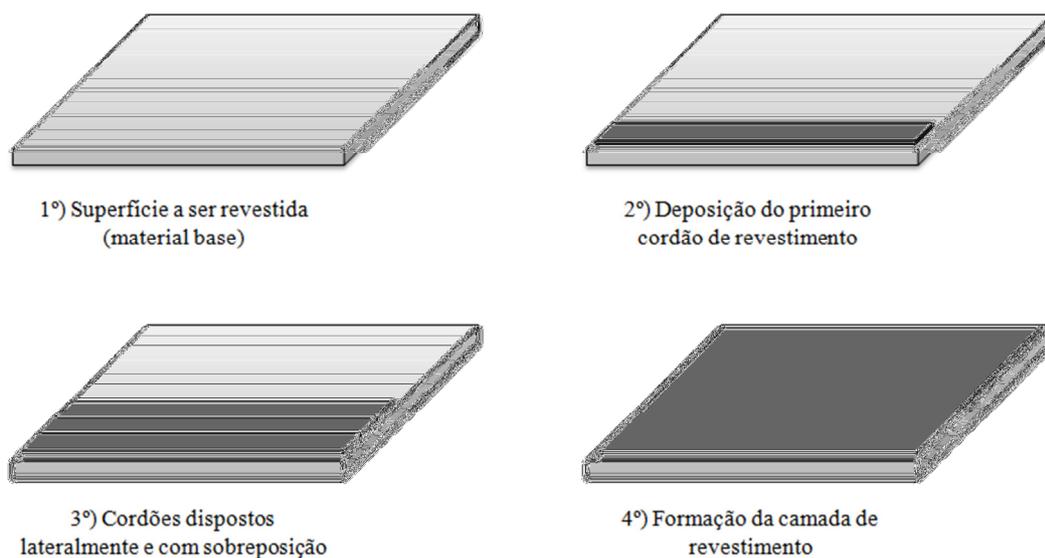


Figura 4.1 – Princípio de operação da soldagem de revestimento
Fonte: Gomes (2010)



Figura 4.2 – Exemplos de camadas de revestimento depositadas a partir de processos de soldagem
Fonte: Gomes (2010)

A principal diferença da soldagem de revestimento em relação às aplicações convencionais de soldagem diz respeito à geometria do cordão de solda. Ao contrário das aplicações convencionais, em que é desejável alta penetração (P) para garantir a resistência da junta soldada (Figura 4.3a), na soldagem de revestimento o perfil geométrico desejado se resume a grandes larguras do cordão (W), altos reforços (R), baixas penetrações (P) e baixos percentuais de diluição (D) (Figura 4.3b). A obtenção deste perfil geométrico característico é importante para que o processo permita recobrir a maior área possível com o menor número de passes, resultando em economias significativas de materiais e tempo. Assim, um dos maiores desafios da soldagem de revestimento consiste no ajuste adequado dos parâmetros do processo para que o material depositado adquira a geometria desejada.

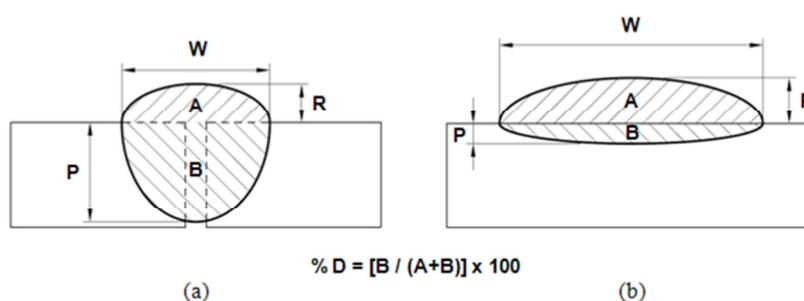


Figura 4.3 – Perfil geométrico desejado do cordão de solda: a) Soldagem convencional; b) Soldagem de revestimento

Fonte: Gomes *et al.* (2013)

4.3 D2: Project charter

As características do processo mencionadas no passo D1 têm feito da soldagem de revestimento de aço carbono com aço inoxidáveis uma operação de crescente aplicabilidade entre os mais diversos tipos de indústrias, como por exemplo, as indústrias petrolíferas, químicas, alimentícias, agrícolas, nucleares, navais, ferroviária, de construção civil, além de várias outras (GOMES *et al.*, 2013; KANNAN e MURUGAN, 2006; MURUGAN e PARMAR, 1994).

O principal objetivo deste projeto é otimizar o processo de soldagem com arame tubular para o revestimento de chapas de aço carbono ABNT 1020 com aço inoxidável ABNT 316L, visando identificar a combinação ótima dos parâmetros de soldagem que permitam a maximização das características geométricas do cordão de revestimento e da produtividade do processo. A Figura 4.4 apresenta o *Project charter* que resume as informações necessárias para iniciar o projeto.

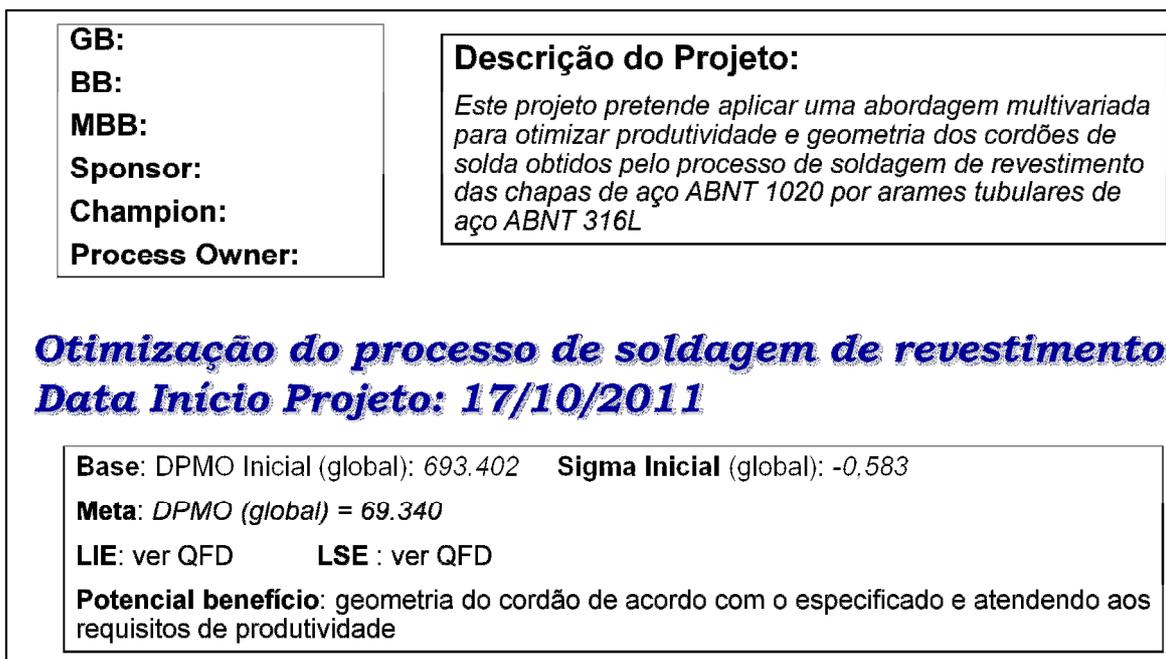


Figura 4.4 – Project charter

4.4 M1: selecionar Ys

Gomes (2010) classificou as pesquisas anteriores em soldagem de revestimento de acordo com a Tabela 4.1. As respostas analisadas podem ser divididas em três categorias, como pode ser observado no diagrama de árvore da Figura 4.5: características geométricas, produtividade/custo e propriedades finais dos revestimentos. As características geométricas envolvem penetração, reforço, largura do cordão e diluição; as respostas de produtividade/custo são a taxa de fusão, taxa de deposição, rendimento do processo; as propriedades do revestimento compreendem a dureza, composição química e microestrutura.

As características apresentadas na Tabela 4.1 foram distribuídas em uma matriz QFD e correlacionadas com as necessidades do cliente, de acordo com a Figura 4.6. Usando a Eq. (3.1), os pesos relativos de cada Y foram obtidos. Adicionalmente, um gráfico de Pareto com o resultado dos pesos absolutos (Eq. 2.9) de cada Y foi plotado (Figura 4.7). Em seguida, outro gráfico de Pareto, apenas com as variáveis selecionadas, foi plotado para determinar as importâncias relativas de cada Ys de acordo com as necessidades do cliente (Figura 4.8). Por decisão do experimentalista, os pesos dos Ys foram aproximados em 20% para *W*, *R*, *D* e *P* e em 10% para *TD* e %.

Tabela 4.1 – Respostas analisadas nas pesquisas anteriores abordando a soldagem MIG/MAG¹ ou com arame tubular² para o revestimento de aços carbono com aços inoxidáveis

Referência	P	R	W	D	TF	TD	%	H	Q	M
Murugan e Parmar (1994) ¹	*	*	*	*						
Murugan e Parmar (1997b) ¹				*				*	*	*
Ghosh <i>et al.</i> (1998) ¹	*	*		*				*	*	*
Corrêa <i>et al.</i> (2000) ¹					*	*	*			
Rajeev <i>et al.</i> (2001) ²				*				*	*	*
Kannan e Murugan (2006a) ²	*	*	*	*						
Kannan e Murugan (2006b) ²				*						*
Palani e Murugan (2006a) ²	*	*	*	*						
Palani e Murugan (2006b) ²	*	*	*	*						
Palani <i>et al.</i> (2006) ²	*	*	*	*						
Shahi e Pandey (2006) ¹				*						
Palani e Murugan (2007) ²	*	*	*	*						
Shahi e Pandey (2008a) ¹				*		*			*	*
Shahi e Pandey (2008b) ¹				*						

P – Penetração (mm); R – Reforço (mm); W – Largura do cordão (mm); D – Diluição (%); TF – Taxa de fusão (kg/h); TD – Taxa de deposição (kg/h); η - Rendimento (%); H – Dureza (HV); Q – Composição química; M – Microestrutura

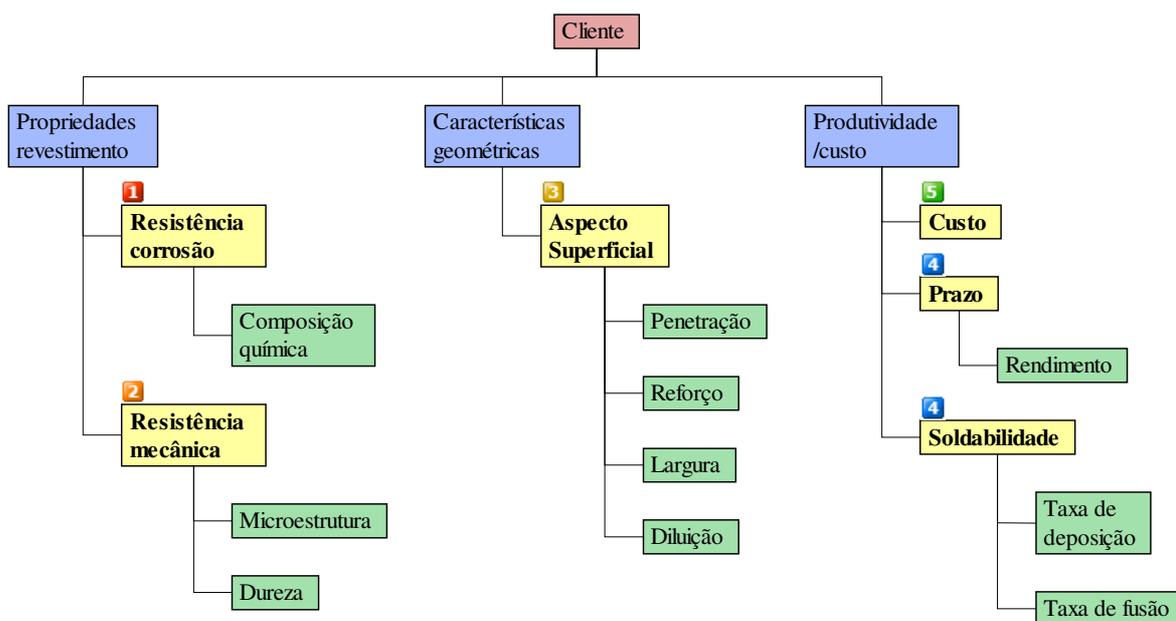


Figura 4.5 – Diagrama de árvore das necessidades do cliente

Para a medição das respostas de produtividade, as chapas de aço carbono foram pesadas antes e após a deposição dos cordões e o tempo de soldagem foi cronometrado. Com isso, a taxa de fusão, a taxa de deposição e o rendimento do processo foram calculados através das seguintes expressões (GOMES, 2010):

$$TF = \frac{l_a \cdot d_a \cdot 3,6}{t_s} \quad (4.1)$$

onde, TF – Taxa de fusão [kg/h], l_a – Comprimento do arame consumido, calculado por:
 $l_a = Va \cdot t_s / 60$ [m], Va – Velocidade de alimentação do arame [m/min], t_s – Tempo de soldagem [s] e d_a – Densidade linear do arame: 7,21 g/m.

Customer Wants (WHAT)	Customer Importance (1 - 10)	Functional Requirements / CTQs (HOW)										Relationship Check	
		Penetração (P)	Reforço (R)	Largura (W)	Diluição (D)	Taxa de Deposição (TD)	Rendimento (%)	Taxa de Fusão (TF)	Dureza (H)	Composição química (Q)	Microestrutura (M)		
Resistência corrosão	9	9	9	9	9				1	1	1	1	9
Resistência mecânica	6	9	9	9	9				3	1	1	1	9
Aspecto superficial	4		3	1				3		1	1	1	3
Soldabilidade	2	1	1	1	3	9	9	1	1	3	3		9
Custo	1	3	1		3	9	9	3		1	1		9
Prazo	3	1		3	1	9	9	3					9
		143	150	153	147	57	54	26	29	26	26		811
Relative Weight		18%	18%	19%	18%	7%	7%	3%	4%	3%	3%		
Unit of Measure		mm	mm	mm	%	kg/h	%	kg/h	HV				
Target		0,8	3,4	15	16%	4,5	95%						
LSL		0	2,47	9,89	0%	3,03	90%						
USL		1,79	4,28	20,45	35%	5,87	100%						

Figura 4.6 – HOQ para o processo de soldagem de revestimento

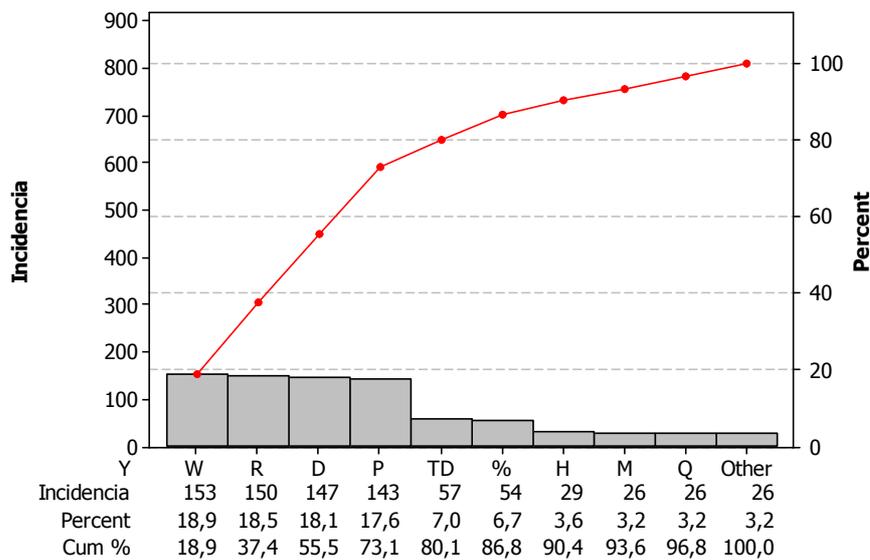


Figura 4.7 – Gráfico de Pareto para priorização dos Ys

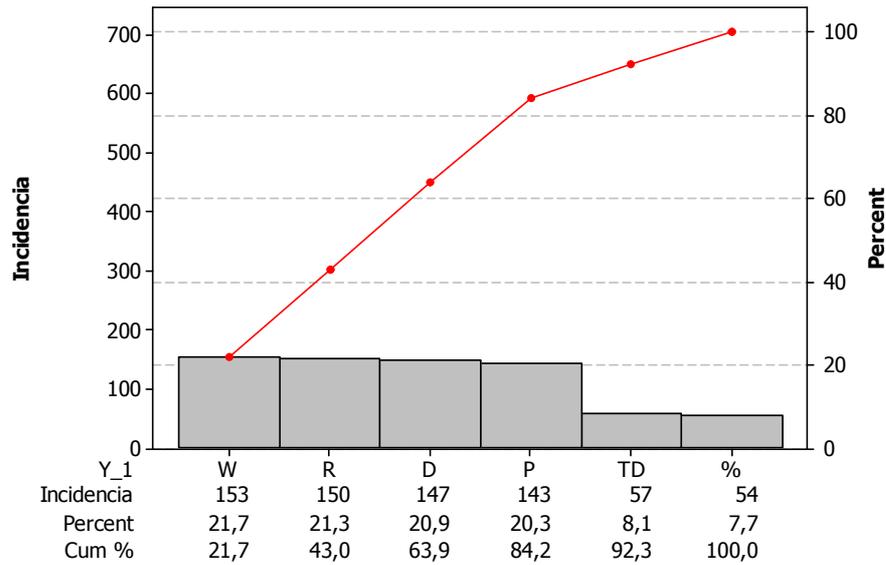


Figura 4.8 – Gráfico de Pareto com os pesos dos Ys selecionados

$$TD = \frac{(m_f - m_i) \cdot 3,6}{t_s} \quad (4.2)$$

onde, TD – Taxa de deposição [kg/h], m_i – Massa da chapa antes da soldagem [g], m_f – Massa da chapa depois da soldagem [g] e t_s – Tempo de soldagem [s].

$$\eta = \frac{TD}{TF} \cdot 100 \quad (4.3)$$

onde: η – Rendimento do processo [%], TD – Taxa de deposição [kg/h] e TF – Taxa de fusão [kg/h].

Através do software analisador de imagens, *Analysis Doc*[®], as características geométricas do cordão foram mensuradas, obtendo-se a largura (W), penetração (P), reforço (R), área de penetração (AP) e área total da solda (AT). O percentual de diluição (D) foi então calculado dividindo-se a área de penetração pela área total. Figura 4.9 ilustra as características geométricas selecionadas para o projeto. A unidade de medida fornecida pelo software é o *pixel*, logo, as medições unidimensionais foram convertidas para *mm* usando a Eq. (4.4) e as medições bidimensionais foram convertidas em *mm*² usando a Eq. (4.5).

$$Y_{real} = \frac{Y_{observado} \times Espessura_{real}}{Espessura_{observado}} \quad (4.4)$$

$$Y_{real} = \frac{Y_{observado} \times Espessura_{real}^2}{Espessura_{observado}^2} \quad (4.5)$$

onde Y_{real} é o valor real em *mm* para cada Y ; $Y_{observado}$ é o valor observado em *pixels* para cada Y ; $Espessura_{real}$ é o valor real constante das espessuras das chapas de 6,35 *mm* e; $Espessura_{observado}$ é o valor observado da espessura das chapas em *pixels*.

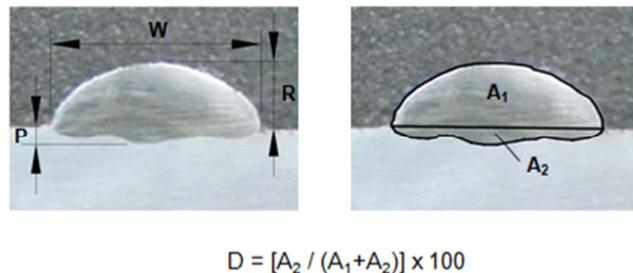


Figura 4.9 – Características geométricas do cordão de solda de revestimento
Fonte: Gomes (2010)

4.5 M2: validar sistema de medição

Os experimentos foram realizados através da deposição de um cordão de aço inoxidável sobre os corpos de prova de aço carbono, cortados em chapas de dimensões 120 x 60 x 6,35 mm. Tabela 4.2 apresenta a composição química do cordão de solda e do metal base. As características de produtividade são estimadas através de parâmetros de entrada do processo de soldagem, logo, não será validado o sistema de medição para estas variáveis. A característica percentual de diluição (D) é obtida através das medições da área total (AT) e área de penetração (AP). Conseqüentemente, o analista decidiu substituir a variável resposta D por três variáveis (AR, AP e AT) que são medidas de forma direta. Sendo assim, neste estudo GR&R foram avaliados seis parâmetros geométricos de um cordão de solda R (reforço), P (penetração), W (largura), AR (área de reforço), AP (área de penetração) e AT (área total). Para o estudo GR&R foram selecionados os corpos de prova obtidos pelas seções transversais denominadas “Medição 2”, na Figura 4.10. Os corpos de prova foram cortados e suas seções transversais devidamente preparadas e atacadas com nital 4%. Em seguida, foram

tiradas fotografias dos corpos de prova a partir de um mesmo ponto referencial, para evitar presença de erro sistemático.

Tabela 4.2 – Composição química (%) do metal base e metal de adição

Material	C	Mn	P	S	Si	Ni	Cr	Mo
Aço inoxidável E316LT1-1/4	0,03	1,58	-	-	1,00	12,4	18,5	2,46
Aço carbono ABNT 1020	0,18/0,23	0,30/0,60	0,04	0,05	-	-	-	-

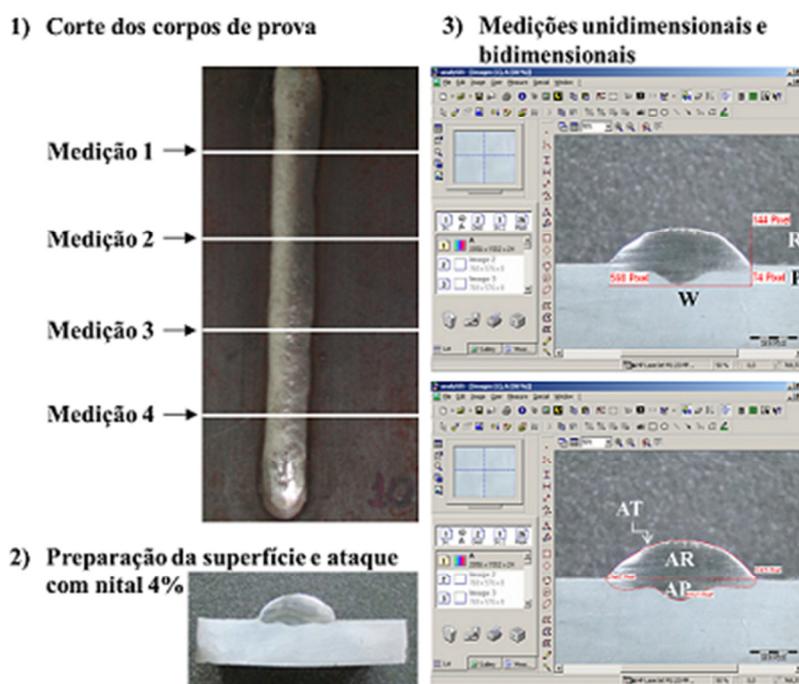


Figura 4.10 – Procedimento para medição da geometria do cordão de solda

Com o objetivo de selecionar uma quantidade de peças que representasse bem a amplitude de operação para as características em análise, a Figura 4.11 mostra as peças escolhidas para este estudo GR&R multivariado. As medições dos parâmetros geométricos do cordão de solda para o estudo GR&R multivariado estão apresentadas na Tabela A.1.

A Tabela 4.3 mostra que as correlações entre as Ys são significativas e estas variáveis são medidas pelo mesmo instrumento de medição, caracterizando-se a necessidade de usar técnicas estatísticas multivariadas para avaliar este SM. O método WPC pode ser utilizado para resumir o comportamento das Ys e proporcionar uma classificação geral para o SM. Inicialmente, foi feita a análise das componentes principais das respostas R, P, W, AR, AP e AT usando a matriz de correlação dos dados (Tabela 4.4). A resposta do modelo da Eq. (3.2) foi obtida pela ponderação das componentes principais usando a Eq. (4.6).

$$WPC = \sum_{i=1}^6 [\lambda_i(PC_i)] \quad (4.6)$$

$$= 4,868PC_1 + 0,799PC_2 + 0,271PC_3 + 0,047PC_4 + 0,015PC_5 + 0,001PC_6$$

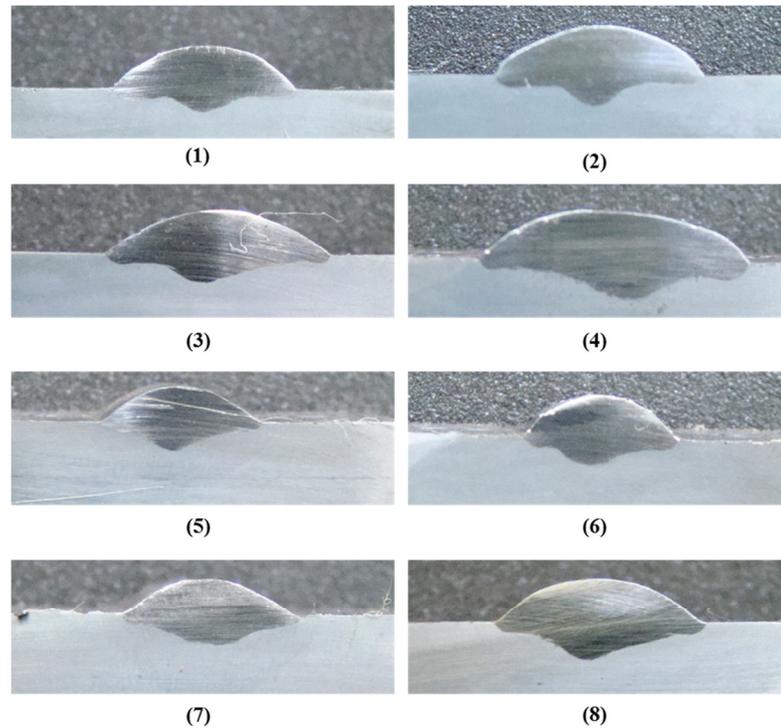


Figura 4.11 – Cordões de solda selecionados para o estudo de GR&R

Tabela 4.3 – Estrutura de correlação entre os Ys

	R	P	W	AP	AR
P	0,435*				
	0,000**				
W	0,691	0,645			
	0,000	0,000			
AP	0,488	0,884	0,842		
	0,000	0,000	0,000		
AR	0,888	0,607	0,930	0,743	
	0,000	0,000	0,000	0,000	
AT	0,817	0,732	0,955	0,864	0,978
	0,000	0,000	0,000	0,000	0,000

Nota: * Correlação de Pearson

** *P-value*

Os resultados da Eq. (4.6) foram ajustados para uma análise de variância *two-way*, de acordo com a Eq. (3.2). O vetor *WPC* representa o conjunto original das respostas R, P, W, AR, AP e AT. Usando os resultados da Eq. (4.6) foram estimadas as variâncias para processo (peça-a-peça), repetitividade, reprodutividade, SM e variação total. Em seguida, as variâncias e, com a Eq. (3.16), o índice multivariado de avaliação do SM foi estimado. O método WPC

classifica o SM como marginal, $\%R \& R_{wpc} = 10,53\%$. Um SM classificado como marginal pode ser considerado aceitável dependendo da aplicação. Neste caso, o analista avaliou que a variação do SM está razoável e decidiu validar o sistema de medição.

Tabela 4.4 – Análise de componentes principais para os Ys

	PC1	PC2	PC3	PC4	PC5	PC6
Autovalor	4,868	0,799	0,271	0,047	0,015	0,001
Proporção	0,811	0,133	0,045	0,008	0,002	0,000
Cumulativo	0,811	0,944	0,990	0,997	1,000	1,000
Variável	Autovetores					
R	0,363	-0,584	-0,547	-0,273	0,393	-0,003
P	0,358	0,592	-0,561	0,447	0,079	-0,021
W	0,429	-0,046	0,586	0,346	0,592	-0,007
AP	0,405	0,459	0,162	-0,742	0,014	-0,219
AR	0,434	-0,300	0,088	0,233	-0,567	-0,582
AT	0,451	-0,081	0,099	-0,021	-0,409	0,783

4.6 M3: avaliar capacidade do processo e definir objetivos

Antes de avaliar a capacidade de qualquer processo, deve-se observar se o processo está sob controle. De acordo com a proposta desta tese, a estabilidade do processo multivariado será avaliada através de duas cartas de controle Shewhart para os escores ponderados de PC , WPC_{max} e WPC_{min} obtidos pela Eq. (3.25). Figura 4.12 e Figura 4.13 resumem o estudo de estabilidade do processo de soldagem de revestimento dos dados observados na Tabela B.1. Estas cartas de controle são para processos com distribuição normal, logo, a normalidade dos vetores WPC_{max} e WPC_{min} foram verificadas. Os testes de Anderson-Darling sobre os escores ponderados de PC mostraram que os dados seguem distribuição normal ($p\text{-value}=0,667$ e $p\text{-value}=0,962$ para WPC_{max} e WPC_{min} , respectivamente). Em seguida, média e amplitude foram monitorados, através de cartas de controle \bar{X} e R , para verificar a estabilidade dos dados.

Após avaliar a estabilidade do processo, estimam-se os limites de especificação dos escores ponderados de componentes principais $WPCs$ para obter o índice global de capacidade de processo. Neste caso, os pesos da matriz QFD serão considerados apenas no final do estudo de capacidade para determinar o índice global de capacidade. Na Tabela 4.5 observa-se \bar{X} , S , LSL , T e USL que foram usados para transformação dos limites de especificação originais em termos de escores de componentes principais. Os limites de especificação e alvo foram padronizados (LSL' , T' e USL') para obter os limites de especificação e alvo em termos de PC (LSL_{pc} , T_{pc} e USL_{pc}), pela Eq. (3.22). Em seguida, estes resultados foram combinados com seus respectivos autovalores (percentuais de explicação

usando Eq. 3.26), para obter os limites de especificação e alvo das componentes principais ponderadas (LSL_{wpc} , T_{wpc} e USL_{wpc}) de cada grupo (maximizar e minimizar), usando a Eq. (3.27). Figura 4.12 e Figura 4.13 resumem o estudo de capacidade do processo de soldagem de revestimento.

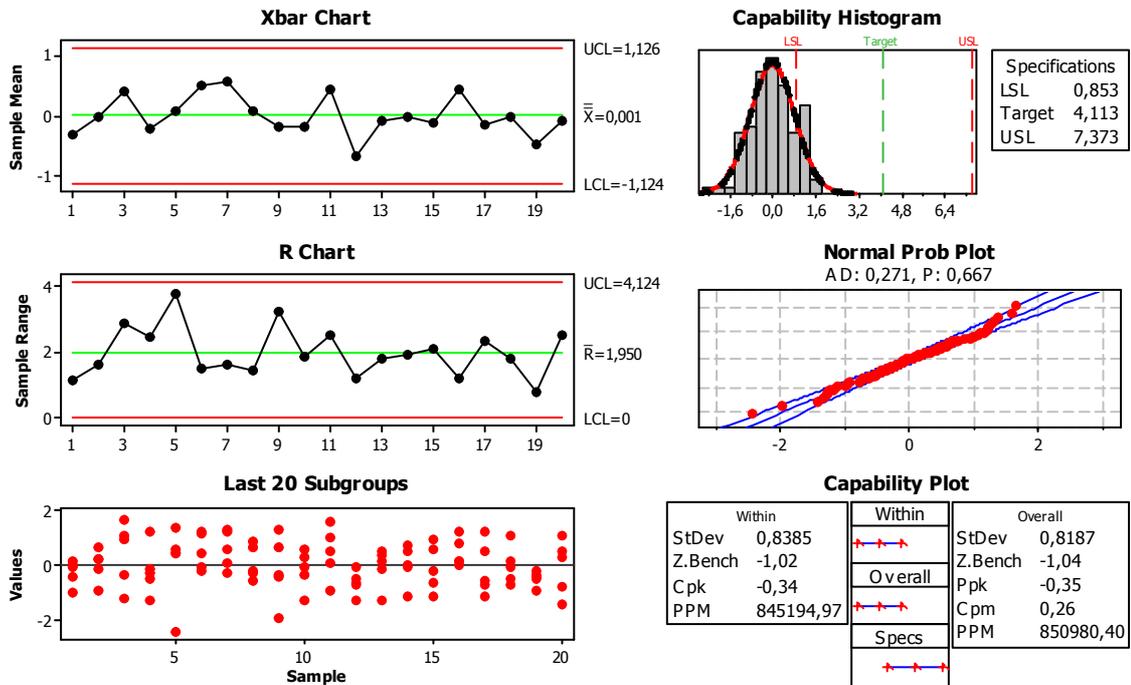


Figura 4.12 – Análise de estabilidade e capacidade para o grupo maximizar, WPC_{max}

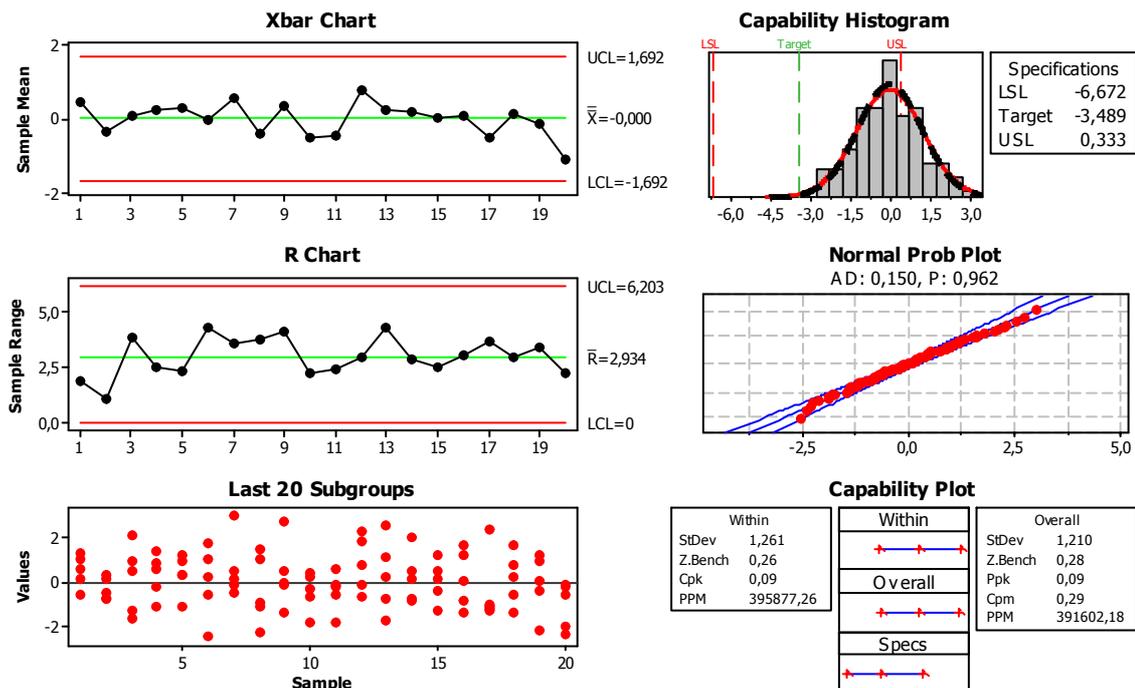


Figura 4.13 – Análise de estabilidade e capacidade para o grupo minimizar, WPC_{min}

Tabela 4.5 – Alvos e limites de especificação para os Ys, PCs e WPCs

<i>Univariado</i>	<i>Grupo maximizar</i>				<i>Grupo minimizar</i>	
	<i>W</i>	<i>R</i>	<i>TD</i>	<i>%</i>	<i>P</i>	<i>D</i>
\bar{X}	9,68	2,10	2,67	0,88	1,56	0,37
<i>S</i>	1,76	0,30	0,47	0,02	0,33	0,06
<i>LSL</i>	9,89	2,47	3,03	0,90	0,00	0,00
<i>A</i>	15,17	3,38	4,45	0,95	0,80	0,16
<i>USL</i>	20,45	4,28	5,87	1,00	1,79	0,35
<i>LSL'</i>	0,12	1,22	0,76	1,80	-4,70	-5,91
<i>T'</i>	3,12	4,22	3,76	4,80	-2,29	-3,29
<i>USL'</i>	6,12	7,22	6,76	7,80	0,71	-0,29
<i>Multivariado</i>	<i>PC₁</i>	<i>PC₂</i>	<i>PC₃</i>	<i>PC₄</i>	<i>PC₁</i>	<i>PC₂</i>
<i>LSL_{pc}</i>	0,287	2,057	0,580	0,834	-7,500	0,859
<i>T_{pc}</i>	3,669	5,649	3,141	3,093	-3,950	0,706
<i>USL_{pc}</i>	7,052	9,240	5,702	5,352	0,292	0,706
	<i>WPC_{max}</i>				<i>WPC_{min}</i>	
<i>LSL_{wpc}</i>	0,853				-6,672	
<i>T_{wpc}</i>	4,113				-3,489	
<i>USL_{wpc}</i>	7,373				0,333	

Assim como para o estudo de estabilidade, índices de capacidade multivariados foram estimados para cada grupo de variáveis. Os resultados para WPC_{max} e WPC_{min} devem ser aglutinados para estimar índices globais de capacidade do processo multivariado. Logo, $(PPM_m)_{overall}$, $(\Sigma_{level})_{overall}$ e $(MWP_{pk})_{overall}$ foram estimados usando a Eq. (3.28):

$$\begin{aligned}
 (PPM_m)_{overall} &= \sum_{i=1}^{\xi} \psi(PPM_{m;wpc_{group}}) \\
 &= \underbrace{(0,2+0,2+0,1+0,1)}_{\psi_{max}}(850.980,40) + \underbrace{(0,2+0,2)}_{\psi_{min}}(391.602,18) \\
 &= 667.229
 \end{aligned} \quad (4.7)$$

$$(\Sigma_{level})_{overall} = \sum_{i=1}^{\xi} \psi(\Sigma_{level;wpc_{group}}) = 0,6(-1,04) + 0,4(0,28) = -0,51 \quad (4.8)$$

$$MWP_{pk} = \sum_{i=1}^{\xi} \psi(P_{pk;wpc_{group}}) = 0,6(-0,35) + 0,4(0,09) = -0,17 \quad (4.9)$$

O *baseline* para o processo multivariado, que foi determinado pelas Eqs. (4.7)-(4.9), está aresentado na Tabela 4.6, assim como o objetivo de desempenho do projeto Seis Sigma.

Tabela 4.6 – Objetivo de desempenho para o processo multivariado

	Baseline			Objetivo
	PPM_m	Σ_{level}	MWP_{pk}	PPM_m
WPC_{max}	850.980	-1,04	-0,35	
WPC_{min}	391.602	0,28	0,09	
WPC_{global}	667.229	-0,51	-0,17	<66.723

4.7 A1: identificar potenciais Xs

A experimentação sequencial, sugerida por Myers *et al.* (2009), inicia-se com a **fase 0**, através da análise dos trabalhos da literatura sobre o processo de soldagem de revestimento. As pesquisas anteriores que utilizaram a soldagem MIG/MAG ou com arame tubular para o revestimento de aços carbono com aços inoxidáveis foram classificadas considerando as variáveis de controle estudadas, visando identificar quais entre eles são provavelmente mais importantes. A Tabela 4.7 apresenta os parâmetros analisados por esses trabalhos (GOMES, 2010).

Além das variáveis de controle mencionadas na Tabela 4.7, há outras variáveis, as quais foram mantidas constantes na execução dos experimentos. O C_{25} foi escolhido como gás de proteção e o ângulo da tocha foi fixado em 15° na posição empurrando (ver demais parâmetros constantes na Tabela 4.8). O diagrama de causa e efeito da Figura 4.14 resume as principais variáveis envolvidas em um processo de soldagem de revestimento.

Tabela 4.7 – Parâmetros estudados nas pesquisas anteriores abordando a soldagem MIG/MAG¹ ou com arame tubular² para o revestimento de aços carbono com aços inoxidáveis

Referência	I	Va	T	Vs	N	Ta
Murugan e Parmar (1994) ¹		*	*	*	*	
Murugan e Parmar (1997b) ¹	*			*	*	
Ghosh <i>et al.</i> (1998) ¹	*					
Corrêa <i>et al.</i> (2000) ¹	*					
Rajeev <i>et al.</i> (2001) ²	*		*	*	*	
Kannan e Murugan (2006a) ²	*			*	*	*
Kannan e Murugan (2006b) ²	*			*	*	*
Palani e Murugan (2006a) ²	*			*	*	
Palani e Murugan (2006b) ²	*			*	*	
Palani <i>et al.</i> (2006) ²	*			*	*	
Shahi e Pandey (2006) ¹		*	*	*	*	
Palani e Murugan (2007) ²	*			*	*	
Shahi e Pandey (2008a) ¹		*	*	*	*	
Shahi e Pandey (2008b) ¹		*	*	*	*	

I – Corrente (A); Va – Velocidade alimentação do arame (m/min); T – Tensão (V); Vs – Velocidade de soldagem (cm/min); Ta - Ângulo da tocha (°); N – Distância bico contato peça (mm)

Adaptado de GOMES (2010)

Tabela 4.8 – Parâmetros fixos do processo de soldagem de revestimento

Parâmetro	Valor/tipo adotado
Material do metal base	Aço carbono ABNT 1020
Material do metal de adição	Aço inoxidável E316LT1-1/4
Espessura do metal base	6,35 mm
Diâmetro do eletrodo	1,2 mm
Tipo do eletrodo	Arame tubular
Posição de soldagem	Posição plana
Ângulo da tocha	15° (empurrando)
Recuo do bico de contato	5 mm
Tipo do gás de proteção	C ₂₅
Vazão do gás de proteção	16 l/min

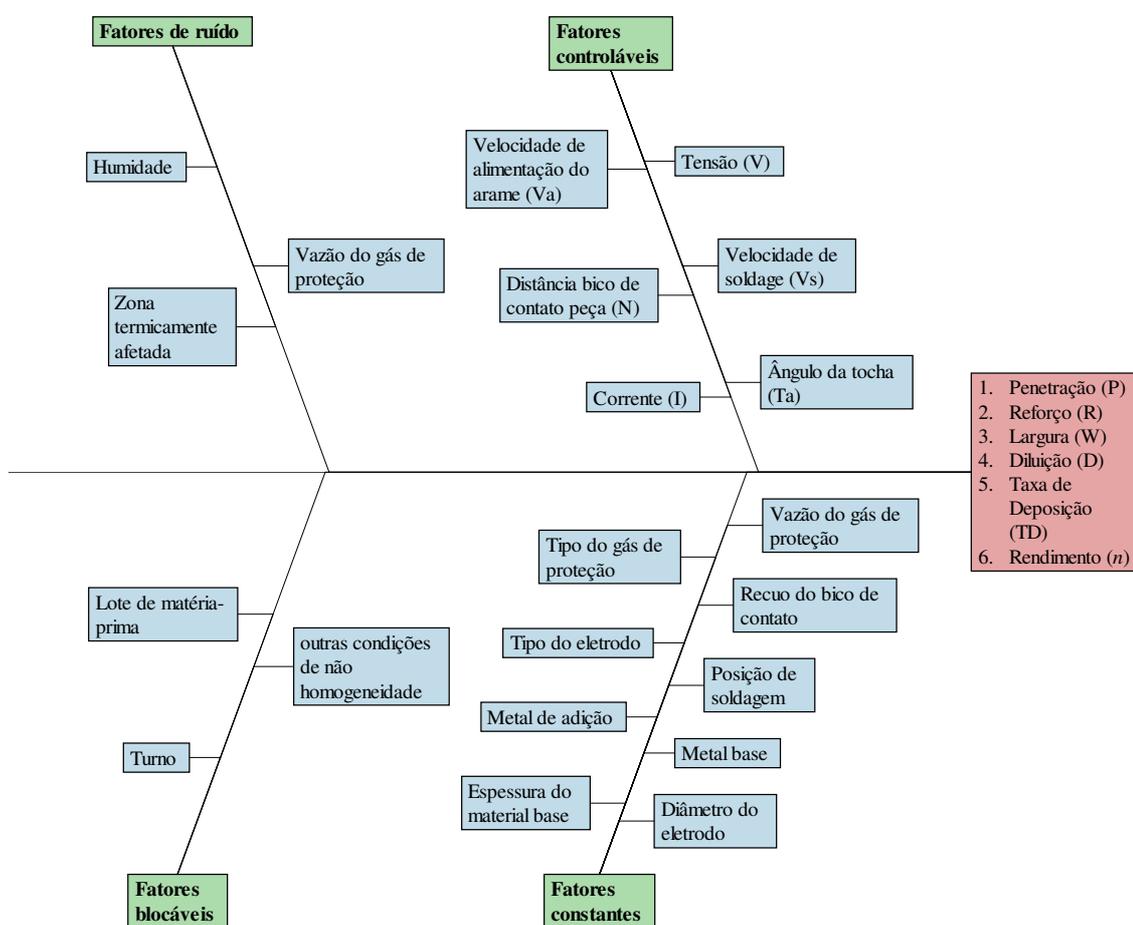


Figura 4.14 – Diagrama de causa e efeito para o DOE

A análise da Tabela 4.7 mostra que a corrente, a velocidade de soldagem e a distância bico de contato peça se caracterizam como parâmetros importantes para o revestimento de aços carbono com aços inoxidáveis empregando a soldagem MIG/MAG ou com arame tubular. Tais parâmetros foram considerados por quase todos os trabalhos analisados. Para a velocidade de alimentação do arame, verifica-se que esta se encontra diretamente relacionada com o efeito da corrente. Na medida em que a velocidade de alimentação foi considerada

pelos trabalhos que não incluíram corrente como parâmetros de análise, pode-se afirmar que o efeito da corrente foi estudado por todos os trabalhos relacionados pela Tabela 4.7. Considerando a tensão e o ângulo da tocha, poucos trabalhos se propuseram ao estudo desses parâmetros. O experimentalista considera que as variáveis de controle velocidade de alimentação do arame, tensão, velocidade de soldagem e distância bico de contato peça são os parâmetros de entrada mais importantes do processo de soldagem com arame tubular. Logo, no próximo passo do *roadmap* será validado se estes parâmetros são estatisticamente significativos para o processo multivariado.

4.8 A2: selecionar poucos vitais fatores de influência

A fixação dos níveis de trabalho foi feita através da análise das pesquisas anteriores e da execução de testes preliminares. Os testes preliminares foram realizados para verificar se o processo ocorria nas condições extremas de cada variável. Finalmente, após alguns ajustes, chegou-se aos limites finais para as condições de trabalho de cada parâmetro. A Tabela 4.9 apresenta os parâmetros analisados juntamente com níveis de trabalho.

Tabela 4.9 – Parâmetros variáveis e níveis de trabalho

Parâmetros	Unidade	Notação	Níveis de trabalho				
			-2	-1	0	+1	+2
Velocidade de alimentação do arame	m/min	Va	5,5	7,0	8,5	10,0	11,5
Tensão	V	T	24,5	27,0	29,5	32,0	34,5
Velocidade de soldagem	cm/min	Vs	20	30	40	50	60
Distância bico de contato peça	mm	N	10	15	20	25	30

Para concluir a **fase 0** da metodologia de Myers *et al.* (2009), um arranjo fatorial completo com *center points* foi planejado e as medições são apresentadas na Tabela A.2. Os gráficos de Pareto da Figura 4.15 e da Figura 4.16 mostraram que os parâmetros de controle selecionados são significativos para o processo.

A **fase 1** da metodologia de Myers *et al.* (2009) consiste em avaliar se a região avaliada é uma região de ótimo. O teste de hipóteses, que avalia a curvatura da região, determinou $p\text{-value}=0,017$ e $p\text{-value}=0,042$ para WPC_{max} e WPC_{min} , respectivamente, corroborando que a região é uma região próxima do ótimo (para um nível de significância de 0,05).

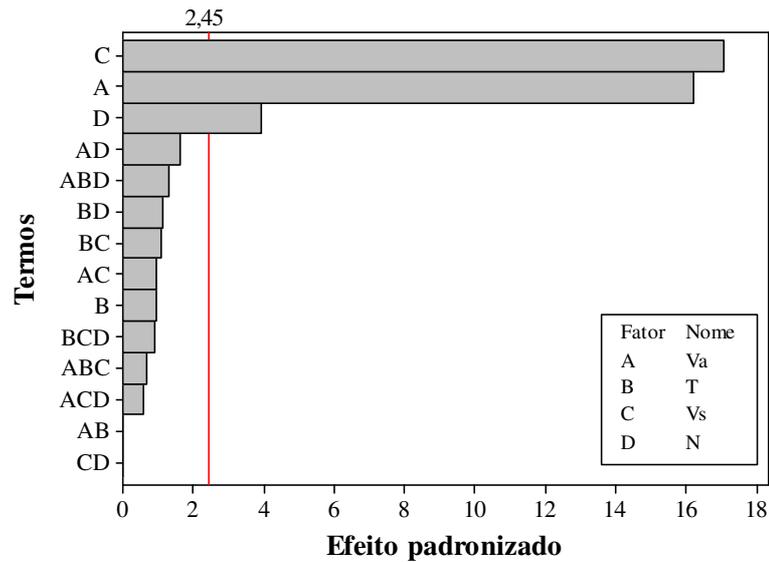


Figura 4.15 – Gráfico de Pareto para o vetor WPC_{max}

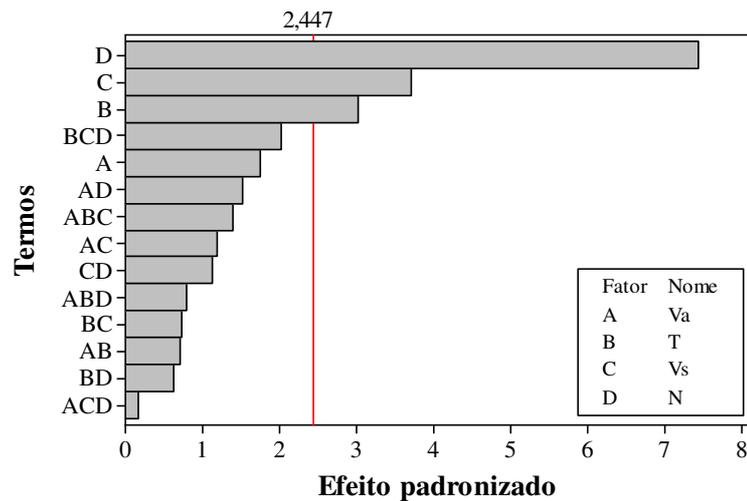


Figura 4.16 – Gráfico de Pareto para o vetor WPC_{min}

4.9 I1: quantificar relacionamento dos Xs com os Ys e PCs

Para quantificar o relacionamento entre Xs e Ys, a matriz experimental adotada foi o arranjo composto central (CCD) da Tabela A.2, contendo quatro fatores em dois níveis ($2^k = 2^4 = 16$), oito pontos axiais ($2k = 2 \cdot 4 = 8$), sete pontos centrais e 1 replicação, totalizando 31 experimentos. O valor adotado para α foi 2,0.

A otimização do processo de soldagem de revestimento será realizada através do procedimento detalhado na Figura 3.4. No entanto, devem-se modelar as variáveis originais para observar qual será o resultado real esperado de cada um dos Ys do projeto. Usando o

algoritmo OLS apresentado na seção 2.7.1, as características Ys do projeto foram modeladas segundo um modelo quadrático completo de superfície de resposta, de acordo com a Eq. (2.61). O modelo quadrático completo e outros modelos reduzidos foram analisados, com objetivo de determinar qual equação de transferência melhor se ajusta aos Ys do projeto. Os critérios de comparação usados para selecionar o modelo testam alguns pressupostos importantes em modelos ANOVA e de regressão. Os critérios de seleção consistem em identificar o maior $R^2(\text{adj.})$ e o menor s , além de avaliar os testes de adequação do modelo LOF (falta de ajuste) e AD (normalidade dos resíduos). A Tabela 4.10 resume esta análise comparativa. Os modelos selecionados para os Ys são representados pelas Eqs. (4.10)–(4.15).

Tabela 4.10 – Comparação entre os modelos completos (MC) e reduzidos (MR)

Resposta	$R^2(\text{adj.})$ (%)		s		LOF		Teste AD	
	MC	MR	MC	MR	MC	MR	MC	MR
W	97,83	98,34	0,2373	0,2238	0,039	0,068	0,323	0,085
P	77,87	86,16	0,1454	0,1245	0,320	0,585	0,139	0,602
R	92,24	93,43	0,0775	0,0713	0,062	0,113	0,874	0,411
D	90,77	94,30	0,0159	0,0140	0,031	0,076	0,525	0,723
TD	99,81	99,81	0,0223	0,0223	0,081	0,081	0,461	0,461
η	84,74	84,74	0,0065	0,0065	0,057	0,057	0,756	0,756

$$\begin{aligned} W = & 10,640 + 0,797Va + 0,656T - 1,451Vs - 0,629N \\ & + 0,270Vs^2 + 0,26VaT - 0,114VaVs - 0,102TVs + 0,067VsN \end{aligned} \quad (4.10)$$

$$\begin{aligned} P = & 1,639 + 0,122Va + 0,122T + 0,093Vs - 0,241N \\ & + 0,025Va^2 - 0,032T^2 - 0,118Vs^2 + 0,034VaT + 0,076VaVs - 0,100VaN \end{aligned} \quad (4.11)$$

$$\begin{aligned} R = & 2,597 + 0,191Va - 0,104T - 0,223Vs + 0,115N \\ & + 0,034T^2 + 0,019Vs^2 + 0,036N^2 - 0,030VaT - 0,023VaN \end{aligned} \quad (4.12)$$

$$\begin{aligned} D = & 0,310 - 0,003Va + 0,025T + 0,037Vs - 0,043N \\ & - 0,007T^2 - 0,012Vs^2 + 0,008VaT + 0,005VaVs - 0,004VaN - 0,008VsN \end{aligned} \quad (4.13)$$

$$\begin{aligned} TD = & 3,396 + 0,568Va - 0,009T + 0,021Vs + 0,031N \\ & - 0,019Va^2 - 0,022T^2 - 0,008Vs^2 - 0,023N^2 \\ & + 0,008VaT - 0,006VaVs - 0,012VaN - 0,010TVs + 0,020TN + 0,019VsN \end{aligned} \quad (4.14)$$

$$\begin{aligned} \eta = & 0,924 - 0,006Va - 0,003T + 0,006Vs + 0,009N \\ & - 0,004Va^2 - 0,006T^2 - 0,002Vs^2 - 0,006N^2 \\ & + 0,003VaT - 0,003VaVs - 0,005VaN - 0,003TVs + 0,006TN + 0,006VsN \end{aligned} \quad (4.15)$$

4.10 I2: Otimização do processo pelas PCs

Uma vez que os Ys do projeto foram modelados, aplica-se o procedimento proposto na Figura 3.4 para otimização do processo. Inicialmente, os Ys devem ser padronizados e ponderados de acordo com os pesos relativos obtidos pela matriz QFD e o gráfico de Pareto (Figura 4.6 e Figura 4.8). As respostas foram separadas em grupos, de acordo com seus objetivos de otimização, e mostradas na Tabela A.3.

Em seguida, executa-se a Análise de Componentes Principais sobre as repostas ponderadas (Tabela 4.11). É importante destacar que este procedimento deve ser realizado considerando a matriz de variância-covariância entre as repostas. Os vetores WPCs (grupos maximizar e minimizar) foram obtidos usando a Eq. (3.25), através da ponderação dos escores de componentes principais por seus percentuais de explicação (Eq. 3.26). É importante destacar que os vetores WPC_{max} e WPC_{min} não apresentaram correlação significativa ($r_{max,min}=-0,156$ e $p-value=0,420$). Logo, o efeito de correlação entre os grupos WPCs pode ser desprezado.

Tabela 4.11 – Análise de componentes principais para as repostas ponderadas

Componente	Grupo Maximizar				Grupo Minimizar		
	PC1	PC2	PC3	PC4	PC1	PC2	
Autovalor	0,596	0,023	0,007	0,006	0,727	0,007	
Proporção	0,627	0,240	0,071	0,063	0,909	0,091	
Cumulativo	0,627	0,867	0,937	1,000	0,909	1,000	
Variáveis	Autovetores				Variáveis	Autovetores	
0,2*Ws	0,624	-0,669	0,166	-0,368	0,2*Ps	0,707	0,707
0,2*Rs	0,710	0,642	-0,275	-0,088	0,2*Ds	0,707	-0,707
0,1*TDs	0,261	0,119	0,768	0,572			
0,1* η s	-0,196	0,354	0,554	-0,728			

Um modelo de segunda ordem deve ser ajustado para WPC_{max} e WPC_{min} , de acordo com a Eq. (3.36), usando o algoritmo OLS da seção 2.7.1. Figura 4.17 e Figura 4.18 ilustram, respectivamente, o comportamento de WPC_{max} e WPC_{min} através de gráficos de contorno e superfície de resposta. Adicionalmente, o Anexo C apresenta o comportamento das variáveis originais também utilizando gráficos de contorno e superfícies de resposta. Para selecionar o melhor modelo de superfície de resposta para WPC_{max} e WPC_{min} , os mesmos critérios abordados na seção anterior foram utilizados. Os modelos são apresentados a seguir:

$$\begin{aligned}
 WPC_{max} = & -0,0714 + 0,08652Va - 0,0755T - 0,3850Vs + 0,0751N \\
 & + 0,0529T^2 + 0,0468Vs^2 + 0,0548N^2 - 0,0307VaT - 0,0302VsN
 \end{aligned}
 \tag{4.16}$$

$$\begin{aligned}
 WPC_{\min} = & 0,0806 + 0,04602Va + 0,1008T + 0,1122Vs - 0,1858N \\
 & + 0,0288T^2 + 0,0752Vs^2 + 0,0294VaT + 0,0418VaVs - 0,0505VaN
 \end{aligned}
 \quad (4.17)$$

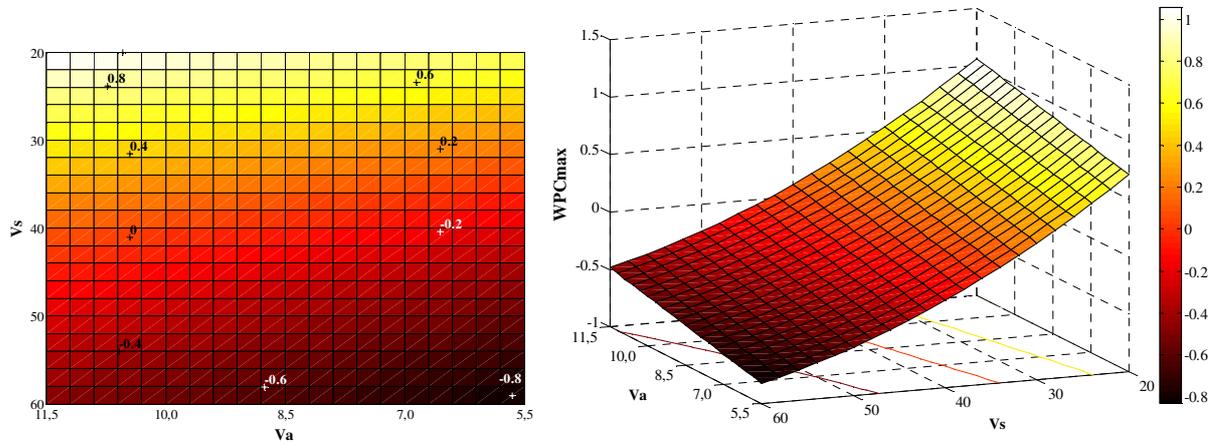


Figura 4.17 – Gráfico de contorno e de superfície de resposta para WPC_{max}

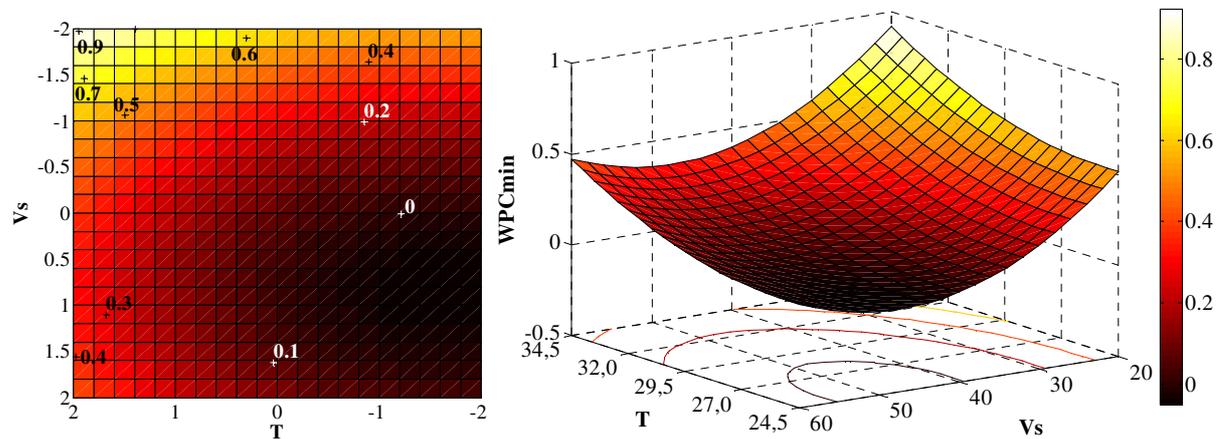


Figura 4.18 – Gráfico de contorno e de superfície de resposta para WPC_{\min}

Finalmente, a otimização pelos vetores WPC_{max} e WPC_{min} pode ser realizada através da formulação NBI da Eq. (3.37). Neste caso, a formulação NBI-WPC fica:

$$\begin{aligned}
 \text{Min } & \overline{WPC}_{\max}(\mathbf{x}) \\
 \text{s.t. : } & \overline{WPC}_{\max}(\mathbf{x}) - \overline{WPC}_{\min}(\mathbf{x}) + 2w - 1 = 0 \\
 & \mathbf{x}'\mathbf{x} \leq \rho^2 \\
 & 0 \leq w \leq 1
 \end{aligned}
 \quad (4.18)$$

onde w são os pesos que estabelecem a relação de *trade-off* entre os grupos WPC_{max} e WPC_{min} , ρ é o raio da região esférica experimental, e $\overline{WPC}_{\max}(\mathbf{x})$ e $\overline{WPC}_{\min}(\mathbf{x})$ são funções escalonadas dadas por:

$$\overline{WPC}_{\max}(\mathbf{x}) = \frac{WPC_{\max}(\mathbf{x}) - WPC_{\max}^U}{WPC_{\max}^N - WPC_{\max}^U} \quad (4.19)$$

$$\overline{WPC}_{\min}(\mathbf{x}) = \frac{WPC_{\min}(\mathbf{x}) - WPC_{\min}^U}{WPC_{\min}^N - WPC_{\min}^U} \quad (4.20)$$

A formulação da Eq. (4.18) foi aplicada para diversos valores de w ($w=0:0,05:1,00$) para construir a Fronteira de Pareto com as soluções Pareto-ótimas, apresentadas na Figura 4.19.

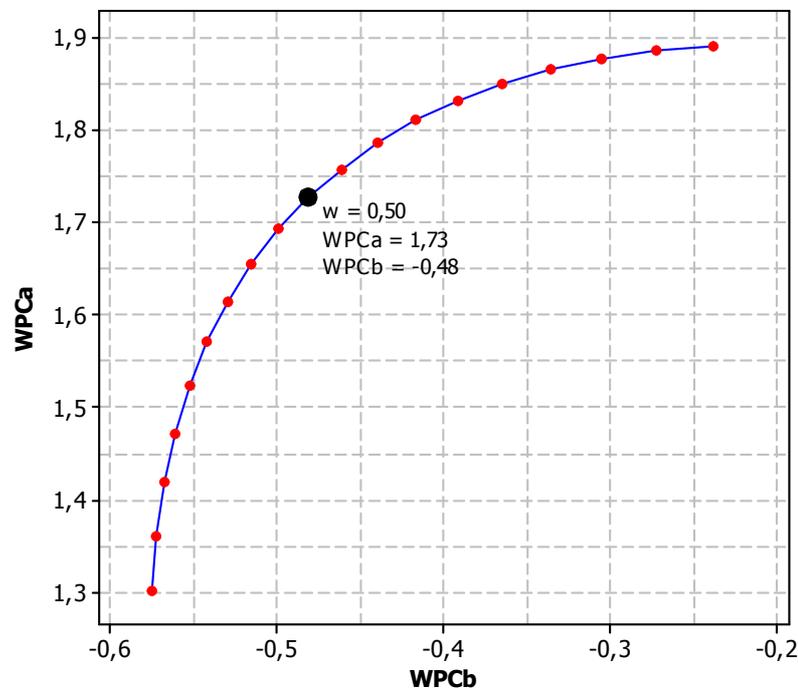


Figura 4.19 – Fronteira de Pareto equiespaçadas para os vetores WPC_{\max} (WPCa) e WPC_{\min} (WPCb)

4.11 I3: conduzir teste piloto para as ações de melhoria

Experimentos de confirmação foram realizados com o objetivo de comparar os resultados reais com os resultados esperados do método de otimização, NBI-WPC. Neste caso, o experimentalista adotou um peso $w=0,5$ para conduzir os experimentos de confirmação e os resultados esperados são apresentados na Tabela 4.12. As medições do experimento de confirmação podem ser observadas na Tabela B.2 (Anexo B), para os últimos 20 subgrupos monitorados.

Tabela 4.12 – Parâmetros ótimos da soldagem com arame tubular para as operações de revestimento de aço carbono ABNT 1020 com aço inoxidável ABNT 316L considerando pesos diferentes entre as respostas

Va	T	Vs	N	W	P	R	D	TD	η
10,2	28,2	26,4	23,6	12,92	0,96	3,36	17,64%	3,91	87,52%
m/min	V	cm/min	mm	mm	mm	mm	-	kg/h	-

4.12 C1: determinar capacidade do processo melhorado

Para determinar a capacidade do processo otimizado, o mesmo procedimento descrito no passo M3, seção 4.6, foi adotado. Inicialmente, avaliou-se a estabilidade do processo multivariado de duas cartas de controle Shewhart para os escores ponderados, WPC_{max} e WPC_{min} obtidos pela Eq. (3.25). Figura 4.20 e Figura 4.21 resumem o estudo de estabilidade do processo de soldagem de revestimento. Os testes de Anderson-Darling sobre os escores ponderados de PC mostraram que os dados seguem distribuição normal ($p\text{-value}=0,412$ e $p\text{-value}=0,370$ para WPC_{max} e WPC_{min} , respectivamente). Em seguida, as cartas de controle \bar{X} e R, Figura 4.20 e Figura 4.21, mostraram que o processo está estável.

A Tabela 4.13 reúne as informações necessárias para obter os índices de capacidade do processo multivariado. Assim como para o estudo de estabilidade, índices de capacidade multivariados foram estimados para cada grupo de variáveis.

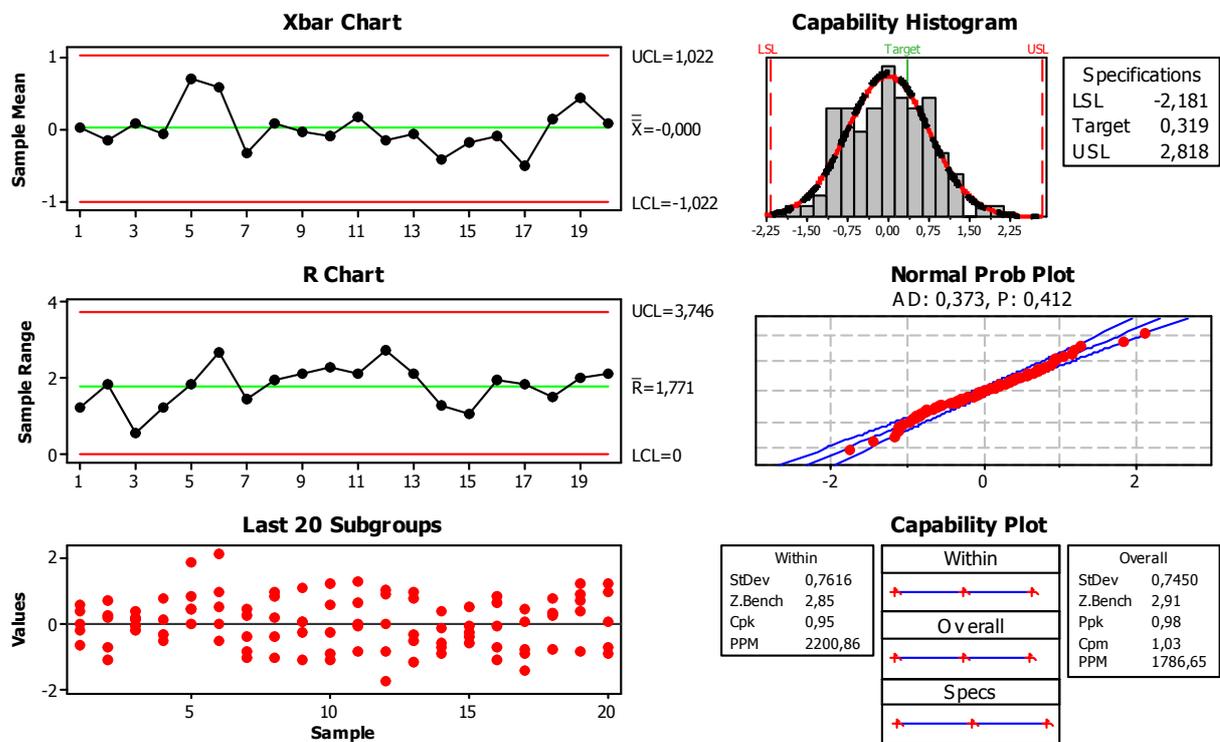


Figura 4.20 – Análise de estabilidade e capacidade para grupo de variáveis com objetivo de maximização

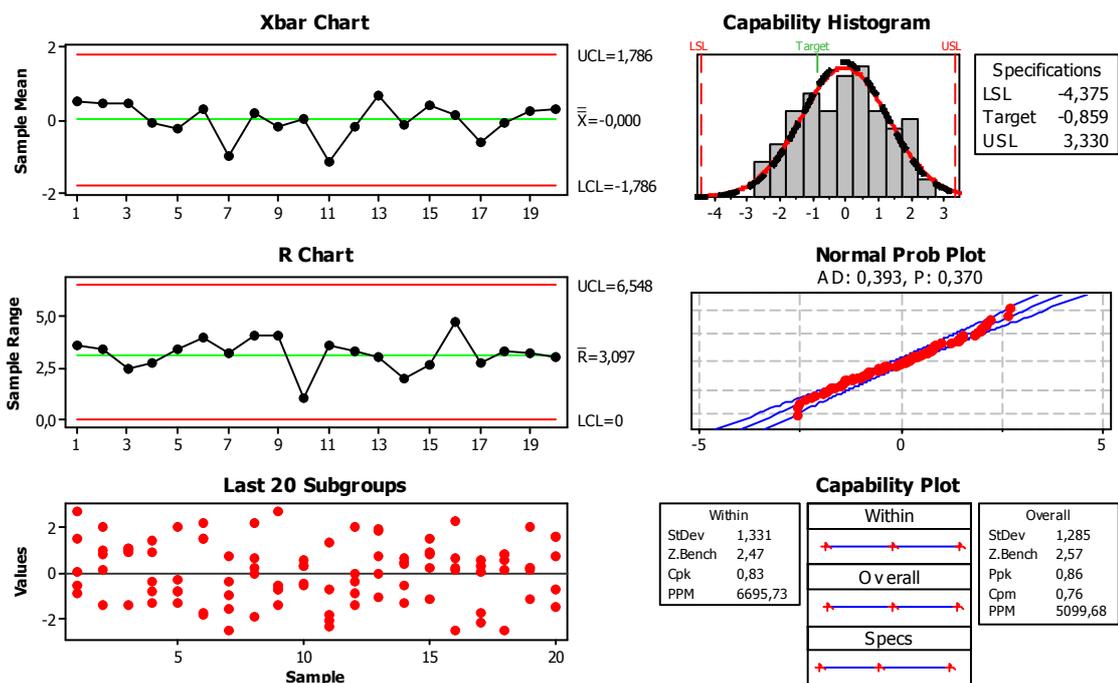


Figura 4.21 – Análise de estabilidade e capacidade para grupo de variáveis com objetivo de minimização

Tabela 4.13 – Alvos e limites de especificação para os Ys, PCs e WPCs na condição otimizada

Univariado	Grupo maximizar				Grupo minimizar	
	W	R	TD	η	P	D
\bar{X}	11,20	3,43	3,67	0,87	1,03	0,20
S	1,35	0,24	0,46	0,02	0,32	0,06
LSL	9,89	2,47	3,03	0,90	0,00	0,00
T	15,17	3,38	4,45	0,95	0,80	0,16
USL	20,45	4,28	5,87	1,00	1,79	0,35
LSL'	-0,97	-4,10	-1,39	2,06	-3,23	-3,36
T'	2,94	-0,25	1,70	5,05	-0,73	-0,57
USL'	6,85	3,60	4,79	8,05	2,39	2,62
Multivariado	$PC1$	$PC2$	$PC3$	$PC4$	$PC1$	$PC2$
$LSLIE_{pc}$	-4,399	-0,852	-0,127	1,952	-4,661	-0,091
T_{pc}	-0,277	2,417	-4,488	3,326	-0,923	0,113
USL_{pc}	3,846	5,687	-8,850	4,701	3,540	0,166
	WPC_{max}				WPC_{min}	
LSL_{wpc}	-2,181				-4,375	
T_{wpc}	0,319				-0,859	
USL_{wpc}	2,818				3,330	

Os resultados para WPC_{max} e WPC_{min} devem ser aglutinados para estimar índices globais de capacidade do processo multivariado. Logo, $(PPM_m)_{overall}$, $(\Sigma_{level})_{overall}$ e $(MWP_{pk})_{overall}$ foram estimados usando a Eq. (3.28) e apresentados na Tabela 4.14 como resultados alcançados. O projeto Seis Sigma multivariado foi capaz de otimizar o processo, melhorando significativamente os índices de capacidade em comparação ao *baseline* do projeto. A meta

que era de redução do PPM_m em 90% foi superada, alcançando uma redução total de 99%. Adicionalmente, o impacto das melhorias obtidas pela abordagem multivariada nas variáveis originais pode ser observado nas cartas de controle do Anexo D.

Tabela 4.14 – Comparação do processo melhorado com o baseline

	Baseline			Objetivo	Alcançado			
	PPM_m	Σ_{level}	MWP_{pk}	PPM_m	PPM_m	Σ_{level}	MWP_{pk}	Redução PPM_m
WPC_{max}	850.980	-1,04	-0,35	< 85.098	1.786	2,91	0,98	
WPC_{min}	391.602	0,28	0,09	< 39.160	5.100	2,57	0,86	
WPC_{global}	667.229	-0,51	-0,17	< 66.729	3.112	2,77	0,93	99%

4.13 C2: implementar planos de controle

O plano de controle para sustentar as melhorias alcançadas com o desenvolvimento deste projeto envolve o planejamento econômico de cartas de controle que monitorarão o processo otimizado. Algumas informações são necessárias para definir os parâmetros ótimos da carta, dentre elas: custo de amostragem, custo de investigação e correção de causas especiais, custo da produção de itens não conformes, taxa de defeito, magnitude do desvio do processo para o nível fora de controle, tempo de amostragem, tempo de investigação da causa especial, entre outras. A Tabela 4.15 apresenta os valores dos custos e tempos envolvidos no projeto da carta de controle de Shewhart por PCA, para monitorar o processo de soldagem com arame tubular para o revestimento de chapas de aço carbono ABNT 1020 com aço inoxidável ABNT 316L. Observa-se que os custos e tempos associados à carta de WPC_{max} são maiores comparando com WPC_{min} , pois WPC_{max} representa 4 variáveis, enquanto que WPC_{min} representa apenas 2 variáveis.

Usando a formulação proposta na Eq. (3.40), uma análise de sensibilidade foi realizada para valores distintos de n (tamanho da amostra do subgrupo). Os resultados da otimização são mostrados na Tabela 4.16. Como determinado na Eq. (3.40), o tamanho do subgrupo e o intervalo de amostragem devem ser os mesmos para as duas cartas, logo, apenas k , α e $(1-\beta)$ devem variar de uma carta para outra.

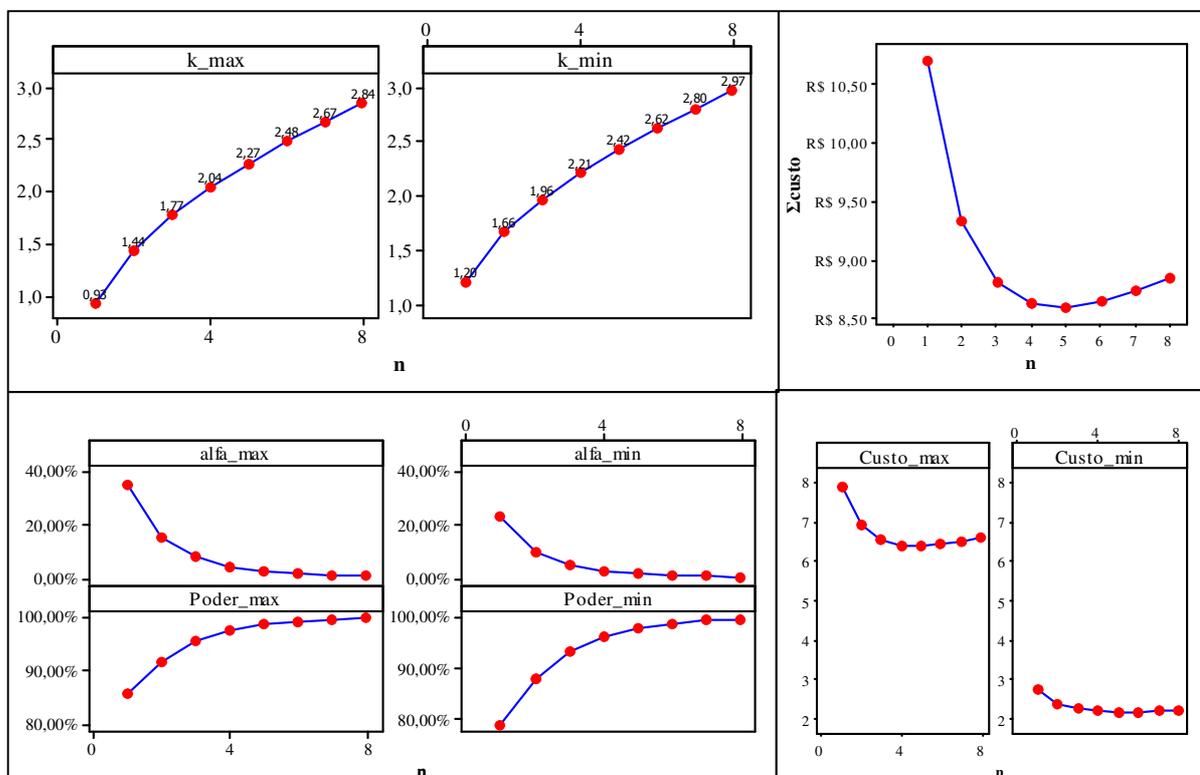
Tabela 4.15 – Dados para o projeto econômico das cartas de controle

	a_1	a_2	a_3	a_3'	a_4	λ	δ	g	D
WPC_{max}	R\$ 20,00	R\$ 0,67	R\$ 20,00	R\$ 33,33	R\$ 100,00	0,007	2,0	0,056	0,67
WPC_{min}	R\$ 10,00	R\$ 0,33	R\$ 10,00	R\$ 16,67	R\$ 50,00	0,003	2,0	0,028	0,33
	R\$	R\$/med.	R\$	R\$	R\$	ocorr./h	-	h/med.	h

Tabela 4.16 – Resultados ótimos da análise de sensibilidade para distintos tamanhos de subgrupo

Grupo Maximizar						Grupo Minimizar						$\Sigma[E(L)]$
α	$(1-\beta)$	n	k	h	$E(L)$	α	$(1-\beta)$	n	k	h	$E(L)$	
35,1%	85,9%	1	0,93	9,2	R\$ 7,94	23,1%	79,0%	1	1,20	9,2	R\$ 2,77	R\$ 10,71
14,9%	91,7%	2	1,44	8,9	R\$ 6,94	9,8%	87,9%	2	1,66	8,9	R\$ 2,40	R\$ 9,34
7,6%	95,5%	3	1,77	8,9	R\$ 6,56	5,0%	93,4%	3	1,96	8,9	R\$ 2,26	R\$ 8,82
4,1%	97,5%	4	2,04	9,1	R\$ 6,43	2,7%	96,4%	4	2,21	9,1	R\$ 2,21	R\$ 8,64
2,3%	98,6%	5	2,27	9,2	R\$ 6,42	1,5%	98,0%	5	2,42	9,2	R\$ 2,19	R\$ 8,61
1,3%	99,2%	6	2,48	9,3	R\$ 6,46	0,9%	98,9%	6	2,62	9,3	R\$ 2,20	R\$ 8,66
0,8%	99,6%	7	2,67	9,4	R\$ 6,53	0,5%	99,4%	7	2,80	9,4	R\$ 2,22	R\$ 8,75
0,4%	99,8%	8	2,84	9,6	R\$ 6,62	0,3%	99,6%	8	2,97	9,6	R\$ 2,25	R\$ 8,86

A Figura 4.22 auxilia o experimentalista em decidir quais os parâmetros ótimos das cartas de controle. Usando, principalmente, o custo total como critério de decisão, observa-se que a configuração que determinou um projeto ótimo é representado pelo subgrupo $n = 5$. Os custos e tempos assumidos neste projeto determinaram uma carta com custo esperado de amostragem minimizado, além de probabilidade de alarme falso e poder de detecção de causas especiais em níveis adequados.

Figura 4.22 – Análise de sensibilidade do projeto econômico das cartas de controle WPC_{max} e WPC_{min}

De acordo com o procedimento de medição apresentado na seção 4.5, o experimentalista julgou satisfatório o intervalo de inspeção disponível de 9,2 horas. Analisando o fator de abertura k , observa-se que WPC_{max} recebeu um fator ligeiramente menor em comparação a WPC_{min} . Desta análise, destaca-se que a probabilidade de alarme falso e poder de detecção de causas especiais são maiores para WPC_{max} , visto que este vetor representa 4 variáveis e merece maior atenção.

4.14 Considerações finais

Este capítulo descreveu, detalhadamente, como os métodos propostos no capítulo 3 podem ser integrados a um *roadmap* estruturado, o MDMAIC. Com o auxílio de softwares estatísticos, tal como o MINITAB[®], a aplicação do *roadmap* torna-se absolutamente viável. A simples conversão das características correlacionadas em escores não correlacionados (escores de componentes principais) e aplicação de técnicas Seis Sigma univariadas (já disponíveis nos softwares estatísticos) aos escores de PC , mostrou potencial significativo para aceitação, não apenas da academia, mas também da indústria. A separação dos Ys em grupos de acordo com o objetivo de otimização mostrou ser uma abordagem eficiente e efetiva na modelagem do processo multivariado. Após executar PCA para cada grupo de variáveis, os vetores WPCs resultantes para cada grupo não apresentaram correlação significativa. Neste caso, o coeficiente de correção de Pearson observado foi de $-0,156$ com $p\text{-value}=0,420$. Além dos resultados interessantes apresentados nas seções anteriores deste capítulo, há ainda algumas considerações que podem ser avaliadas em pesquisas futuras, tais como:

- Desenvolver um método baseado em PCA para selecionar potenciais projetos Seis Sigma, tal como DEA (*Data Envelopment Analysis*);
- O QFD depende da opinião de especialistas para atribuir pesos as necessidades do cliente e, em seguida, priorizar os Ys do projeto. Este procedimento qualitativo torna o processo de priorização dos Ys um pouco subjetivo. Uma abordagem híbrida QFD-GR&R (análise de concordância) poderia ser adotada para validar os pesos atribuídos às necessidades do cliente. Desta forma, poderia ser constatado se especialistas distintos são capazes de atribuir ponderações semelhantes às necessidades do cliente. A mesma proposta pode ser empregada com outras ferramentas qualitativas, como FMEA (*Failure mode and effect analysis*), por exemplo.
- Utilizar outros métodos de priorização para selecionar os Ys, tal como o AHP (*Analytic Hierarchy Process*);

- Considerar a importância relativa das variáveis originais em análise de sistemas de medição por PCA. Neste caso, espera-se que os resultados dos cálculos dos índices multivariados de classificação do sistema de medição apresentem comportamentos similares aos cálculos dos índices univariados das variáveis originais com maior ponderação na análise;
- Considerar a importância relativa das variáveis originais, antes de executar PCA, no controle estatístico de processos multivariados. Assim como mencionado no tópico acima, espera-se que a carta de controle multivariada por PCA apresente comportamento de maior similaridade às variáveis originais com maior ponderação no estudo de estabilidade do processo. Além disso, a expectativa de resultado dos índices multivariados de capacidade provavelmente deverá ser estimativas similares aos índices univariados com maior ponderação;
- Comparar os métodos multivariados propostos de controle estatístico de processo aos disponíveis na literatura. A abordagem de simulação utilizada em Peruchi *et al.* (2013a) poderá ser empregada. Diversos cenários envolvendo distintas estruturas de correlação entre as variáveis originais poderão ser simulados para comparar com as cartas de controle e índices de capacidade da literatura apresentados nas seções 2.9 e 2.6, respectivamente;
- A maioria dos trabalhos da literatura que empregam métodos de otimização ao QFD tem objetivo de maximizar a satisfação do cliente (necessidades do cliente) em função das características de projeto (os Y_s). No entanto, como discutido nesta tese, quando o objetivo é otimizar processos, através de modelagens do tipo $Y=f(x)$, onde x são parâmetros de controle de processo, ainda há potencial a ser explorado. Neste caso, desdobram-se as necessidades do cliente em características de projeto para, em seguida, otimizar o processo e alcançar a satisfação do cliente. Portanto, recomenda-se a aplicação da abordagem de otimização adotada nesta pesquisa para outros métodos de otimização, tais como os discutidos na seção 2.8. Finalmente, deve-se verificar qual método melhor se aproximaria ao ótimo individual de forma a respeitar as ponderações impostas inicialmente;
- Integrar ao MDMAIC os métodos de otimização multivariada que modelam média e variância, tais como os projetos de parâmetro robusto (RPD), através de arranjos cruzados, combinados e réplicas experimentais (auto replicável). Partindo da

premissa que projetos Seis Sigma devem reduzir variabilidade, RPD é uma estratégia que permite alcançar resultados de forma mais satisfatória;

- Comparar o modelo proposto de projeto econômico da carta de controle de Shewhart para os escores de componentes principais com os modelos para cartas multivariadas T^2 de Hotelling.

5. CONCLUSÃO

5.1 Conclusões gerais

É fato que as necessidades do cliente proporcionam aos processos industriais o caráter multivariado. Qualquer empresa ou profissional reconhece que o cliente está sempre interessado em receber produtos no prazo pré-determinado, com custos reduzidos e qualidade superando suas expectativas. O *trade-off* inerente ao relacionamento entre as características de produtividade, custo e qualidade, não permite que simples técnicas univariadas sejam capazes de otimizar tais processos. A otimização individual de uma dessas características inevitavelmente afetará o comportamento das outras. É por este motivo que a abordagem multivariada é essencial na solução efetiva de processos de manufatura.

A literatura está repleta de trabalhos que destacam a eficiência e eficácia das técnicas e ferramentas estatísticas multivariadas nas mais variadas aplicações. No entanto, observa-se que elas são empregadas individualmente para solução de problemas com escopo restrito. Em outras palavras, ou a variação do sistema de medição deve ser reduzida através de MSA, ou avalia-se o desempenho do processo por SPC, ou melhora-se um processo usando modelagem e otimização multivariada. Todavia, espera-se que resultados mais robustos sejam alcançados através da integração destes métodos em um *roadmap* que auxilia a definir, medir, analisar, melhorar e controlar problemas complexos.

A princípio, o objetivo desta tese poderia ser sintetizado em simplesmente replicar o *roadmap* univariado para o caso multivariado usando PCA. De certa forma, esta afirmação não se alterou com o desenvolvimento desta pesquisa, no entanto, as dificuldades enfrentadas motivaram a elaboração de diversas propostas para cada etapa do projeto. De forma geral, a abordagem de separar as variáveis em grupos, de acordo com seus objetivos de otimização, mostrou ser uma estratégia sensata e consistente nos desdobramentos do projeto Seis Sigma multivariado. Como pode ser visto na Tabela 3.1, esta abordagem proporcionou novas formulações que foram eficientes na otimização do processo de soldagem de revestimento. Além disso, esta metodologia apresenta potencial para aceitação não apenas da academia, mas também da indústria, pois softwares estatísticos possuem a maioria das rotinas necessárias no desenvolvimento dos métodos propostos.

Em suma, a aplicação do MDMAIC, no processo de soldagem com arame tubular para o revestimento de chapas de aço carbono ABNT 1020 com aço inoxidável ABNT 316L, permitiu as seguintes conclusões:

- O *roadmap* MDMAIC apresentou uma estrutura de etapas e passos bem elaborada, que utiliza a técnica multivariada PCA, para reduzir a dimensionalidade de problemas de manufatura com múltiplas respostas;
- O novo método de análise multivariada de sistemas de medição representou bem a variabilidade do equipamento que mede múltiplas respostas e, além disso, os índices multivariados de classificação auxiliaram o analista na validação do sistema de medição;
- Usando uma abordagem semelhante, novo método para controle estatístico multivariado de processos foi proposto. Neste caso, a separação das variáveis em grupos permitiu estimar os limites de especificação em termos de escores de componentes principais de forma mais contundente. Uma carta de controle para monitorar cada grupo de respostas foi plotada e novos índices de capacidade de processos multivariados foram propostos;
- Dentre os índices que avaliam o desempenho de processos, PPM_m (número de peças por milhão fora da especificação) e Σ_{level} (nível sigma) merecem destaque, pois pouca pesquisa tem sido realizada sobre estas métricas no contexto multivariado;
- Um novo método de modelagem e otimização, NBI-WPC, que combina QFD, RSM, PCA e NBI foi proposto e aplicado ao processo de soldagem de revestimento. A etapa controlar mostrou que o método foi efetivo em otimizar o desempenho do processo, promovendo uma redução no PPM_m em cerca de 99%;
- O projeto econômico das cartas de controle de Shewhart para os escores ponderados de componentes principais viabilizaram o monitoramento do processo. As cartas proporcionaram custo esperado de amostragem minimizado, baixa probabilidade de alarme falso e elevado poder de detecção de causas especiais no processo.

5.2 Sugestões para trabalhos futuros

Como já apontado na seção 4.14, há ainda alguns pontos que podem ser avaliados futuramente, devido à customização que pode ser empregada aos métodos propostos nesta tese. Os tópicos que podem ser explorados em pesquisas futuras são:

- Desenvolver um método baseado em PCA para selecionar potenciais projetos Seis Sigma, tal como DEA (*Data Envelopment Analysis*);
- Validar os pesos atribuídos por especialista em matrizes QFD através de análise de concordância;
- Utilizar outros métodos de priorização para selecionar os Ys, tal como o AHP (*Analytic Hierarchy Process*);
- Considerar a importância relativa das variáveis originais em análise de sistemas de medição por PCA;
- Considerar a importância relativa das variáveis originais, antes de executar PCA, no controle estatístico de processos multivariados;
- Comparar os métodos multivariados propostos de controle estatístico de processo aos disponíveis na literatura;
- Aplicar a abordagem proposta de QFD-otimização para outros métodos de otimização multivariada e verificar qual minimiza mais efetivamente a distância ao alvo das variáveis originais;
- Integrar ao MDMAIC os métodos de otimização multivariada que modelam média e variância, tais como os projetos de parâmetro robusto, para minimizar variância de forma mais eficiente;
- Comparar o modelo proposto de projeto econômico da carta de controle de Shewhart para os escores de componentes principais com os modelos para cartas multivariadas T^2 de Hotelling.

REFERÊNCIAS BIBLIOGRÁFICAS

- AAKRE, K.T.; VALLEY, T.B.; O'CONNOR, M.K. Improving Patient Flow for a Bone Densitometry Practice: Results from a Mayo Clinic Radiology Quality Initiative. **RadioGraphics**, v.30, p.309–315, 2010.
- ABOELMAGED, M.G. Six Sigma quality: a structured review and implications for future research. **International Journal of Quality & Reliability Management**, v.27, p.268-317, 2010.
- AL-REFAIE, A.; BATA, N. Evaluating measurement and process capabilities by GR&R with four quality measures. **Measurement**, v.43, p.842-851, 2010.
- ANDERSON-COOK, C.M.; PATTERSON, A.; HOERL, R. A Structured Problem-solving Course for Graduate Students: Exposing Students to Six Sigma as Part of their University Training. **Quality and Reliability Engineering International**, v.21, p.249–256, 2005.
- ANTONY, J.; BANUELAS, R.; KUMAR, A. **World class application of Six Sigma: real world examples of success**. Elsevier, Oxford, UK, 2006.
- ANTONY, J.; GIJO, E.V.; CHILDE, S.J. Case study in Six Sigma methodology: manufacturing quality improvement and guidance for managers. **Production Planning & Control**, v.23, p.624–640, 2012.
- ARDAKANI, M.K.; NOOROSSANA, R. A new optimization criterion for robust parameter design – the case of target is best. **International Journal of Advanced Manufacturing Technology**, v.38, p.851–859, 2008.
- ATTIVISSIMO, F. *et al.* Systematic errors and measurement uncertainty: An experimental approach. **Measurement**, v.44, p.1781-1789, 2011.
- AUTOMOTIVE INDUSTRY ACTION GROUP. **AIAG: Measurement systems analysis – Reference Manual**. 4 ed. Chrysler, Ford, General Motors Supplier Quality Requirements Task Force, 2010.
- AWAD, M. *et al.* A measurement system analysis approach for hard-to-repeat events. **Quality Engineering**, v.21, p.300-305, 2009.
- BALAKRISHNAN, A.; KALAKOTA, R.; WHINSTON, A.B., Document-centered information systems to support reactive problem-solving in manufacturing. **International Journal of Production Economics**, v.38, p.31–58, 1995.
- BAÑUELAS, R.; ANTONY, J. Critical success factors for the successful implementation of Six Sigma projects in organizations, **The TQM Magazine**, v.14, p.92-99, 2002.
- BARRY, S.J. *et al.* A risk-based statistical investigation of the quantification of polymorphic purity of a pharmaceutical candidate by solid-state ¹⁹F NMR. **Analytica Chimica Acta**, v.712, p.30–36, 2012.
- BERSIMIS, S.; PSARAKIS, S.; PANARETOS, J. Multivariate statistical process control charts: an overview. **Quality and Reliability Engineering International**, v.23, p.517-543, 2007.
- BERTRAND, J. W. M.; FRANSOO, J. C. Modelling and Simulation: operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v.22, p.241-264, 2002.

- BILGEN, B.; SEN, M. Project selection through fuzzy analytic hierarchy process and a case study on Six Sigma implementation in an automotive industry. **Production Planning & Control**, v.23, p.2–25, 2012.
- BOONE, J.M.; CHAKRABORTI, S. Two simple Shewhart-type multivariate non-parametric control charts. **Applied Stochastic Models in Business and Industry**, v.28, p.130–140, 2012.
- BOX, GEP. Teaching engineers experimental design with a paper helicopter. **Quality Engineering**, v.4, 1992.
- BOX, G.E.P. *et al.* Some problems associated with the analysis of multiresponse data. **Technometrics**, v.15, p.33–51, 1973.
- BRADY, J.; ALLEN, T. Six Sigma literature: a review and agenda for future research. **Quality and Reliability Engineering International**, v.22, p.335–67, 2006.
- BRATCHELL, N. Multivariate response surface modeling by principal components analysis. **Journal of Chemometrics**, v.3, p.579–588, 1989.
- BREYFOGLE, F.W. **Implementing Six-Sigma: Smarter Solutions Using Statistical Methods**, Wiley, New York, NY, 1999.
- BRYMAN, A. **Research methods and organization studies**. Routledge, 2004.
- BURDICK, R.K.; BORROR, C.M.; MONTGOMERY, D.C. A review of methods for measurement systems capability analysis. **Journal of Quality Technology**, v.35, p.342–354, 2003.
- BURDICK, R. K.; BORROR, C. M.; MONTGOMERY DC. **Design and analysis of gauge R&R studies: making decisions with confidence intervals in random and mixed ANOVA models**. Society for Industrial Mathematics, 2005.
- CHAKRAVORTY, S.S. Six Sigma programs: an implementation model. **International Journal of Production Economics**, v.119, p.1–16, 2009.
- CHAN, A.L.F. Use of six sigma to improve pharmacist dispensing errors at an outpatient clinic. **American Journal of Medical Quality**, v.19, 2004.
- CHANG, S.I. *et al.* Statistical Process Control for Monitoring Nonlinear Profiles: A Six Sigma Project on Curing Process. **Quality Engineering**, v.24, p.251–263, 2012.
- CHEN, H. A multivariate process capability index over a rectangular solid tolerance zone. **Statistica Sinica**. 4, 749–758, 1994.
- CHEN, K.S.; CHEN, T.W. 2008. Multi-process capability plot and fuzzy inference evaluation. **International Journal of Production Economics**, v.111, p.70–79, 2008.
- CHEN, M.N.; LYU, J.J. A Lean Six-Sigma approach to touch panel quality improvement. **Production Planning & Control**, v.20, p.445–454, 2009.
- CHEN, S.K.; MANGIAMELI, P.; ROETHLEIN, C.J. Predicting the output of a tube-bending process: a case study. **International Journal of Production Economics**, v.95, p.307–316, 2005.
- CHEN, K.S.; PEARN, W.L.; LIN, P.C. Capability measures for processes with multivariate Characteristics. **Quality and Reliability Engineering International**, v.19, p.101–110, 2003.
- CHEN, J.M.; TSOU, J.C. An optimal design for process quality improvement: modelling and application. **Production Planning & Control**, v.14, p.603–612, 2003.

- CHEN, K.S.; YU, K.T.; SHEU, S.H. Process capability monitoring chart with an application in the silicon-filler manufacturing process. **International Journal of Production Economics**, v.103, p.565–571, 2006.
- CHEN YK. Economic design of variable sampling interval T2 control charts—A hybrid Markov chain approach with genetic algorithms. **Expert Systems with Applications**, v.33, p.683-689, 2007.
- CHENG, L.C.; MELO FILHO, L.D.R. **QFD**: desdobramento da função qualidade na gestão de desenvolvimento de produtos. Blücher, São Paulo, 2007.
- CHIAO, H.; HAMADA, M. Analyzing experiments with correlated multiple responses. **Journal of Quality Technology**, v.33, p.451–465, 2001.
- CHOU C.Y.; CHEN C.H. Economic design of variable sampling intervals T² control charts using genetic algorithms. **Expert Systems with Applications**, v.30, p.233-242, 2006.
- COSTA, R. *et al.* Paper superficial waviness: Conception and implementation of an industrial statistical measurement system. **Analytica Chimica Acta**, v.544, p.135–142, 2005.
- DAS, I.; DENNIS, J.E. Normal boundary intersection: A new method for generating the Pareto surface in nonlinear multicriteria optimization problems. **SIAM Journal of Optimization**, v.8, p.631-657, 1998.
- DAWSON, D.; ASKIN, R.G. Optimal new product design using quality function deployment with empirical value functions. **Quality and Reliability Engineering International**, v.15, p.17–32, 1999.
- DE KONING, H.; DE MAST, J. Grounding of Six-Sigma's breakthrough cookbook: how to research a methodology?. **International Journal of Six-Sigma and Competitive Advantage**, v.1, p.263-275, 2005.
- DE KONING, H.; DE MAST, J. A rational reconstruction of six-sigma's breakthrough cookbook. **International Journal of Quality and Reliability Management**, v.23, p.766-787, 2006.
- DE MAST, J. Quality improvement from the viewpoint of statistical method. **Quality and Reliability Engineering International**, v.19, p.255-64, 2003.
- DE MAST, J.; LOKKERBOL, J. An analysis of the Six Sigma DMAIC method from the perspective of problem solving. **International Journal of Production Economics**, v.139, p.604–614, 2012.
- DE MAST, J.; VAN WIERINGEN, W. Measurement System Analysis for Bounded Ordinal Data. **Quality and Reliability Engineering International**, v.20, p.383-395, 2004.
- DE MAST, J. *et al.* Steps and strategies in process improvement. **Quality and Reliability Engineering International**, v.16, p.301–311, 2000.
- DEJAEGHER, B. *et al.* Improving method capability of a drug substance HPLC assay. **Journal of Pharmaceutical and Biomedical Analysis**, v.42, p.155–170, 2006.
- DELDOSSI, L.; ZAPPA, D. Measurement Uncertainty with Nested Mixed Effect Models. **Quality and Reliability Engineering International**, v.27, p.373-379, 2011.
- DERRINGER, G.C.; SUICH, R. Simultaneous optimization of several response variables. **Journal of Quality Technology**, v.12, p.214-219, 1980.
- DUFFY, J. *et al.* Assessing multivariate process/product yield via discrete point approximation. **IIE Transactions**, v.30, p.535–543, 1998.

- DUNCAN AJ. The economic design of X-bar charts used to maintain current control of a process. **Journal of American Statistical Association**, v.51, p.228-242, 1956.
- ERDMANN, T.P.; DOES, R.J.M.M.; BISGAARD, S. Quality quandaries: a gage R&R study in a hospital. **Quality Engineering**, v.22, p.46-53, 2010.
- FARAZ, A.; SANIGA, E. Economic statistical design of a T^2 control chart with double warning lines. **Quality and Reliability Engineering International**, v.27, p.125-139, 2011.
- FENG, Q.; ANTONY, J. Integrating DEA into Six Sigma methodology for measuring health service efficiency. **Journal of the Operational Research Society**, v.61, p.1112–1121, 2010.
- FERRIERE, A. *et al.* Corrosion resistance of stainless steel coatings elaborated by solar cladding process. **Solar Energy**, v.80, p.1338-1343, 2006.
- FLYNN, M.J.; SARKANI, S.; MAZZUCHI, T.A. Regression Analysis of Automatic Measurement Systems. **IEEE Transactions on Instrumentation and Measurement**, v.58, p.3373-3379, 2009.
- FRINGS, G.W.; GRANT, L. Who Moved My Sigma . . . Effective Implementation of the Six Sigma Methodology to Hospitals. **Quality and Reliability Engineering International**, v.21, p.311–328, 2005.
- FUNG, C.P.; KANG, P.C. Multi-response optimization in friction properties of PBT composites using Taguchi method and principal component analysis. **Journal of Materials Processing Technology**, v.170, p.602–610, 2005.
- FURTERER, S.; ELSHENNAWY, A. Implementation of TQM and lean Six Sigma tools in local government: a framework and a case study, **Total Quality Management and Business Excellence**, v.16, p.1179-91, 2005.
- GABRIELSSON, J.; NYSTRÖM, Å.; LUNDSTEDT, T. Multivariate Methods in the Developing an Evolutionary Strategy for Tablet Formulation. **Drug Development and Industrial Pharmacy**, v.26, p.275-296, 2003.
- GIJO, E.V.; SCARIA, J.; ANTONY, J. Application of Six Sigma Methodology to Reduce Defects of a Grinding Process. **Quality and Reliability Engineering International**, v.27, pp. 1221—1234, 2011.
- GOMES, José Henrique de Freitas. **Análise e otimização da soldagem de revestimento de chapas de aço carbono utilizando arame tubular inoxidável austenítico**. Dissertação (Mestrado em Engenharia de Produção) – Instituto de Engenharia de Produção e Gestão, UNIFEI, Itajubá. 2010.
- GOMES, J.H.F. *et al.* Weighted Multivariate Mean Square Error for processes optimization: A case study on flux-cored arc welding for stainless steel claddings. **European Journal of Operational Research**, v.226, p.522–535, 2013.
- GONG, L.; BURDICK, R.K.; QUIROZ, J. Confidence Intervals for Unbalanced Two-factor Gauge R&R Studies. **Quality and Reliability Engineering International**, v.21, p.727-741, 2005.
- GONZÁLEZ, I.; SÁNCHEZ, I. Capability indices and nonconforming proportion in univariate and multivariate processes. **International Journal of Advanced Manufacturing Technology**, v.44, p.1036-1050, 2009.
- GOVINDALURI, S.M.; CHO, B.R. Robust design modeling with correlated quality characteristics using a multicriteria decision framework. **International Journal of Advanced Manufacturing Technology**, v.32, p.423–433, 2007.

GUIDE TO THE EXPRESSION OF UNCERTAINTY IN MEASUREMENT. **GUM: Uncertainty of Measurement**. 1 ed. ISO/IEC Guide 98, 1995.

HAHN, G.J.; DOGANAKSOY, N.; HOERL, R.W. The evolution of Six-Sigma. **Quality Engineering**, v.12, p.317-26, 2000.

HAHN, G.J. *et al.* The impact of Six-Sigma improvement – a glimpse into the future of statistics. **The American Statistician**, v.53, p.208-15, 1999.

HARRY, M.J. **The Vision of Six-Sigma**, 5th ed., Tri Star, Phoenix, AZ, 1997.

HAWKINS, D.M. Multivariate Quality Control Based on Regression-Adjusted Variables. **Technometrics**, v.33, p.61-75, 1991.

HE, S.G.; WANG, G.A.; COOK, D.F. Multivariate measurement system analysis in multisite testing: An online technique using principal component analysis. **Expert Systems with Applications**, v.38, p.14602-14608, 2011.

HE, Z.; ZHU, P.F.; PARK, S.H. A robust desirability function method for multi-response surface optimization considering model uncertainty. **European Journal of Operational Research**, v.221, p.241–247, 2012.

HOTELLING, H. Analysis of a complex of statistical variables into principal components. **Journal of educational psychology**, v.24, p.417, 1933.

Hotelling H. **Multivariate quality control**: Illustrated by the air testing of sample bombsights. Techniques of Statistical Analysis, Eisenhart C, Hastay MW, Wallis WA (eds). New York : MacGraw-Hill, 1947.

HUANG, M.S.; LIN, T.Y. 2008. Simulation of a regression-model and PCA based searching method developed for setting the robust injection molding parameters of multi-quality characteristics. **International Journal of Heat and Mass Transfer**, v.51, p.5828–5837, 2008.

JACKSON, J.E. **A User Guide to Principal Components**. New York: John Wiley and Sons, Inc., 1991.

JIA, Z.; IERAPETRITOU, G. Generate Pareto optimal solutions of scheduling problems using normal boundary intersection technique. **Computers and Chemical Engineering**, v.31, p.268-280, 2007.

JOHNSON, J.A. *et al.* A “Six Sigma” Black Belt Case Study: G.E.P. Box’s Paper Helicopter Experiment Part A. **Quality Engineering**, v.18, p.413-430, 2006.

JOHNSON, R.A.; WICHERN, D. **Applied Multivariate Statistical Analysis**. 5 ed. New Jersey: Prentice-Hall, 2007.

JURAN, J.M. **Juran on Planning for Quality**. New York: Free Press, 1988.

KAIJA, K. *et al.* Inkjetting dielectric layer for electronic applications, **Microelectronic Engineering**, v.87, p.1984–1991, 2010.

KANNAN, T.; MURUGAN, N. Effect of flux cored arc welding process parameters on duplex stainless steel clad quality. **Journal of Materials Processing Technology**, v.176, p.230–239, 2006.

KANG, N.; KIM, J.; PARK, Y. Integration of marketing domain and R&D domain in NPD design process. **Industrial Management & Data Systems**, v.107, p.780-801, 2007.

- KANO, N. *et al.* Attractive quality and must-be quality. **The Journal of the Japanese Society for Quality Control**, v.14, p.39-48, 1984.
- KAZEMZADEH, R.B. *et al.* A general framework for multiresponse optimization problems based on goal programming. **European Journal of Operational Research**, v.189, p.421–429, 2008.
- KHURI, A.I., CONLON, M. Simultaneous optimization of multiple responses represented by polynomial regression functions. **Technometrics**, v.23, p.363–375, 1981.
- KNOWLES, G.; VICKERS, G.; ANTHONY, J. Implementing Evaluation of the Measurement Process in an Automotive Manufacturer: a Case Study. **Quality and Reliability Engineering International**, v.19, p.397-410, 2003.
- KÖKSOY, O. Multiresponse robust design: Mean Square Error (MSE) criterion. **Applied Mathematics and Computation**, v.175, p.1716–1729, 2006.
- KOTZ, S.; JOHNSON, N.L. Process capability indices—a review, 1992–2000. **Journal of Quality Technology**, v.34, p.2–19, 2002.
- KOTZ, S.; LOVELACE, C.R. **Process Capability Indices in Theory and Practices**. London: Arnold, 1998.
- KOVACH, J., CHO, B.R. A D-optimal design approach to constrained multiresponse robust design with prioritized mean and variance considerations. **Computers and Industrial Engineering**, v.57, p.237–245, 2009.
- KUMAR, M. *et al.* Winning Customer Loyalty in an Automotive Company through Six Sigma: a Case Study. **Quality and Reliability Engineering International**, v.23, p.849–866, 2007.
- KUMAR, M. *et al.* Implementing the Lean Sigma framework in an Indian SME: a case study. **Production Planning & Control**, v.17, p.407–423, 2006.
- KUMAR, U.D. *et al.* On the optimal selection of process alternatives in a Six Sigma implementation. **International Journal of Production Economics**, v.111, p.456–467, 2008.
- KUMAR, S.; SOSNOSKI, M. Using DMAIC Six Sigma to systematically improve shopfloor production quality and costs. **International Journal of Productivity and Performance Management**, v.58, p.254-273, 2009.
- KUMARAVADIVEL, A.; NATARAJAN, U. Application of Six-Sigma DMAIC methodology to sand-casting process with response surface methodology. **International Journal of Advanced Manufacturing Technology**, v.69, p.1403–1420, 2013.
- KUMI, S.; MORROW, J. Improving self service the six sigma way at Newcastle University Library. **Program: electronic library and information systems**, v.40, p.123-136, 2006.
- KWAK, Y.H.; ANBARI, F.T. Benefits, obstacles, and future of six sigma approach. **Technovation**, v.26, p.708-715, 2006.
- LEE, K.L.; WEI, C.C. Reducing Mold Changing Time by Implementing Lean Six Sigma. **Quality and Reliability Engineering International**, v.26, p.387-395, 2010.
- LI, M.H.C.; AL-REFAIE, A. Improving wooden parts' quality by adopting DMAIC procedure. **Quality and Reliability Engineering International**, v.24, p.351-360, 2008.
- LI, M.H.C.; AL-REFAIE, A.; YANG, C.Y. DMAIC Approach to Improve the Capability of SMT Solder Printing Process. **IEEE Transactions on Electronics Packaging Manufacturing**, v.31, 2008.

- LIAO H.C. Multi-response optimization using weighted principal components. **International Journal of Advanced Manufacturing Technology**, v.27, p.720–725, 2006.
- LIN, D.K.J.; TU, W. Dual response surface optimization. **Journal of Quality Technology**, v.27, p.34-39, 1995.
- LINDERMAN, K. *et al.* Six sigma: a goal theoretic perspective. **Journal of Operations Management**, v.21, p.193–203, 2003.
- LINDERMAN, K.; SCHROEDER, R.G.; CHOO, A.S. Six Sigma: the role of goals in improvement teams. **Journal of Operations Management**, v.24, p.779–790, 2006.
- LIU, S. *et al.* Product and process yield estimation with Gaussian quadrature (GQ) reduction: Improvements over the GQ full factorial approach. **European Journal of Operational Research**, v.140, p.655–669, 2002.
- LO, W.C.; TSAI, K.M.; HSIEH, C.Y. Six Sigma approach to improve surface precision of optical lenses in the injection-molding process. **International Journal of Advanced Manufacturing Technology**, v.41, p.885–896, 2009.
- LYU, J.; CHEN, M.N. Gauge capability studies for attribute data. **Quality and Reliability Engineering International**, v.24, p.71-82, 2008.
- MACHADO, A.G.M.; COSTA, A.F.B. The double sampling and the EWMA charts based on the sample variances. **International Journal of Production Economics**, v.134, p.148, 2008.
- MAJESKE, K.D. Approval criteria for multivariate measurement systems. **Journal of Quality Technology**, v.40, p.140-154, 2008.
- MCADAM, R.; LAFFERTY, B. A multilevel case study critique of Six Sigma: statistical control or strategic change?. **International Journal of Operations and Production Management**, v.24, p.530–549, 2004.
- MINGERS, J.; ROSENHEAD, J. Problem structuring methods in action. **European Journal of Operational Research**, v.152, p.530–554, 2004.
- MONTGOMERY, D.C. **Statistical Quality Control**, 5 ed. New York: John Wiley and Sons, Inc., 2001.
- MONTGOMERY, D.C. **Design and analysis of experiments**. New York: John Wiley and Sons, Inc., 2005.
- MONTGOMERY, D.C. *et al.* A university-based six sigma program. **Quality and Reliability Engineering International**, v.21, p.243–248, 2005.
- MONTGOMERY, D.C.; RUNGER, G.C.; HUBELE, N.F. **Engineering Statistics**. New York: John Wiley and Sons, Inc., 2004.
- MONTGOMERY, D.C.; KLATT P.J. Economic design of T^2 control charts to maintain current control of a process. **Management Science**, v.19, p.76-89, 1972.
- MONTGOMERY, D.C.; WOODALL, W.H. An Overview of Six Sigma. **International Statistical Review**, v. 76, pp. 329-346, 2008.
- MOSKOWITZ, H.; KIM, K.J. QFD optimizer: a novice friendly quality function deployment decision support system for optimizing product designs. **Computers & Industrial Engineering**, v.32, p.641-655, 1997.

- MUKHERJEE, I.; RAY, P.K. A systematic solution methodology for inferential multivariate modeling of industrial grinding process. **Journal of Materials Processing Technology**, v.196, p.379-392, 2008.
- MURUGAN, N.; PARMAR, R.S. Effects of MIG process parameters on the geometry of the bead in the automatic surfacing of stainless steel. **Journal of Materials Processing Technology**, v.41, p.381-398, 1994.
- MYERS, R.H.; MONTGOMERY, D.C.; ANDERSON-COOK, C.M. **Response Surface Methodology**, Hoboken. New Jersey: John Wiley & Sons, Inc, 2009.
- PAIVA, A. P. **Metodologia de Superfície de Resposta e Análise de Componentes Principais em otimização de processo de manufatura com múltiplas respostas correlacionadas**. Tese (Doutorado em Engenharia Mecânica) – Instituto de Engenharia Mecânica, UNIFEI, Itajubá. 2006.
- PAIVA, A.P. **Otimização Robusta Multivariada por Interseção Normal à Fronteira: uma proposta de Fronteiras Equiespaçadas de Pareto por Análise de Componentes Principais**. [S.l.]: Projeto CNPq – Bolsa de Produtividade em Pesquisa, 2012.
- PAIVA, A.P. *et al.* A multivariate mean square error optimization of AISI hardened steel turning. **International Journal of Advanced Manufacturing Technology**, v.43, p.631-643, 2009.
- PAIVA, A.P. *et al.* Multi-objective optimization of pulsed gas metal arc welding process based on weighted principal component scores, **International Journal of Advanced Manufacturing Technology**, v.50, p.113-125, 2010.
- PAIVA, A.P. *et al.* A multivariate robust parameter design approach for optimization of ABNT 52100 hardened steel turning with wiper mixed ceramic tool. **International Journal of Refractory Metals and Hard Materials**, v.30, p.152-163, 2012.
- PAIVA, A.P.; FERREIRA, J.R.; BALESTRASSI, P.P. A multivariate hybrid approach applied to AISI 52100 hardened steel turning optimization. **Journal of Materials Processing Technology**, v.189, p.35-26, 2007.
- PALANI, P.K.; MURUGAN, N. Development of mathematical models for prediction of weld bead geometry in cladding by flux cored arc welding. **International Journal of Advanced Manufacturing Technology**, v.30, p.669–676, 2006.
- PALANI, P.K.; MURUGAN, N. Optimization of weld bead geometry for stainless steel claddings deposited by FCAW. **Journal of Materials Processing Technology**, v.190, p.291–299, 2007.
- PAN, J.N. A study of multivariate pre-control charts. **International Journal of Production Economics** v.105, pp.160–170, 2007.
- PAN, X.; JARRETT, J. Using vector autoregressive residuals to monitor multivariate processes in the presence of serial correlation. **International Journal of Production Economics**, v.106, p.204–216, 2007.
- PANDE, P.S.; NEUMAN, R.P.; CAVANAGH, R.R. **The Six-Sigma Way: How GE, Motorola, and Other Top Companies Are Honing Their Performance**, New York: McGraw-Hill, 2000.
- PEARN, W.L.; WANG, F.K.; YEN, C.H. Multivariate capability indices: distributional and inferential properties. **Journal of Applied Statistics**, v.34, p.941–962, 2007.

PERAKIS, M.; XEKALAKI, E. On the Implementation of the Principal Component Analysis–Based Approach in Measuring Process Capability. **Quality and Reliability Engineering International**, v.28, p.467–480, 2012.

PERUCHI, R.S. **Método dos componentes principais ponderados aplicado em avaliação de sistemas de medição com grandezas correlacionadas**. Dissertação (Mestrado em Engenharia de Produção) – Instituto de Engenharia de Produção e Gestão, UNIFEI, Itajubá. 2011.

PERUCHI, R.S. *et al.* Simulated Analysis for Multivariate GR&R study. In: International Conference on Industrial Engineering and Operations Management, 2012, Guimarães, Portugal. **Anais... XVIII ICIEOM**, 2012a.

PERUCHI, R.S. *et al.* Um estudo GR&R multivariado aplicado no torneamento do aço ABNT 12L14. In: Congresso Nacional de Engenharia Mecânica, 2012, São Luís. **Anais... VII CONEM**, 2012b.

PERUCHI, R.S. *et al.* Análise das medições de um software analisador de imagens para os parâmetros geométricos em um cordão de solda de revestimento. In: Congresso Nacional de Engenharia Mecânica, 2012, São Luís. **Anais... VII CONEM**, 2012c.

PERUCHI, R.S. *et al.* Uma abordagem ponderada em análise multivariada de variância para estimar um índice de avaliação do sistema de medição. In: Simpósio Brasileiro de Pesquisa Operacional, 2012, Rio de Janeiro. **Anais... XLIV SBPO**, 2012d.

PERUCHI, R.S. *et al.* Um método para análise de sistemas de medição com múltiplas características da qualidade correlacionadas. In: Encontro Mineiro de Engenharia de Produção, 2012, Itajubá. **Anais... VIII EMEPRO**, 2012e.

PERUCHI, R.S. *et al.* Aplicação das etapas definir e medir do roadmap DMAIC para um exemplo didático de projeto seis sigma. In: Encontro Nacional de Engenharia de Produção, 2012, Bento Gonçalves. **Anais... XXXII ENEGEP**, 2012f.

PERUCHI, R.S. *et al.* Um exemplo didático das etapas analisar, melhorar e controlar de um projeto seis sigma. In: Simpósio de Engenharia de Produção, 2012, Bauru. **Anais... XIX SIMPEP**, 2012g.

PERUCHI, R.S. *et al.* A new multivariate gage R&R method for correlated characteristics. **International Journal of Production Economics**, v.144, p.301-3015, 2013a.

PERUCHI, R.S. *et al.* Weighted approach in estimating evaluation indexes for measurement systems with correlated characteristics. In: ISSAT International Conference on Reliability and Quality Design, 2013, Honolulu, Hawaii, USA. **Anais... 19th ISSAT RQD**, 2013b.

PERUCHI, R.S. *et al.* Measurement system analysis applied to AISI 12L14 steel turning. In: ISSAT International Conference on Reliability and Quality Design, 2013, Honolulu, Hawaii, USA. **Anais... 19th ISSAT RQD**, 2013c.

PERUCHI, R.S. *et al.* Weighted approach for multivariate analysis of variance in measurement system analysis. **Precision Engineering**, v.38, p.651-38i, 2014.

PLANTE, R.D. Process capability: a criteria for optimizing multiple response product and process design. **IIE Transactions**, v.33, p.497-509, 2001.

POLINI, W.; TURCHETTA, S. Test protocol for micro-geometric wear of sintered diamond tools. **Wear**, v.257, p.246-256, 2004.

PSARAKIS, S. The use of neural networks in statistical process control charts. **Quality and Reliability Engineering International**, v.27, p.641–650, 2011.

PYZDEK, T. **The Six-Sigma Handbook: a Complete Guide for Greenbelts, Blackbelts, and Managers at All Levels**, McGraw-Hill, New York, NY, 2001.

RASIS, D.; GITLOW, H.; POPOVICH, E. Paper organizers international: a fictitious Six-Sigma green belt case study I. **Quality Engineering**, v.15, p.127-45, 2002.

RENCHER, AC. **Methods of multivariate analysis**. New York: John Wiley and Sons, Inc., 2002.

SAFIZADEH, M.H. Minimizing the bias and variance of the gradient estimate in RSM simulation studies. **European Journal of Operational Research**, v.136, p.121–135, 2002.

SAHOO, A.K.; TIWARI, M.K.; MILEHAM, A.R. Six Sigma based approach to optimize radial forging operation variables. **Journal of Materials Processing Technology**, v. 202, pp. 125-136, 2008.

SCAGLIARINI, M. Multivariate process capability using principal component analysis in the presence of measurement errors. **ASTA Advances in Statistical Analysis**, v.95, p.113-128, 2011.

SCHROEDER, R.H. *et al.* Six Sigma: definition and underlying theory. **Journal of Operations Management**, v.26, p.536–554, 2008.

SELLERS, M.M. *et al.* Development and Participant Assessment of a Practical Quality Improvement Educational Initiative for Surgical Residents. **Journal of American College of Surgeons**, v.216, 2013.

SENL, S. Measurement system analysis using designed experiments with minimum $\alpha - \beta$ Risks and n . **Measurement**, v.36, p.131-141, 2004.

SHIAU, Y.R. Decision support for off-line gage evaluation and improving on-line gage usage, **Journal of Manufacturing Systems**, v.19, p.318-331, 2000.

SHIN, S. *et al.* Computing trade-offs in robust design: Perspectives of the mean square error. **Computers and Industrial Engineering**, v.60, p.248-255, 2011.

SHINDE, R.L.; KHADSE, K.G. Multivariate process capability using principal component analysis. **Quality and Reliability Engineering International**, v.25, p.69-77, 2009.

SHUKLA, P.K.; DEB, K. On finding multiple Pareto-optimal solutions using classical and evolutionary generating methods. **European Journal of Operational Research**, v.181, p.1630-1652, 2007.

TAAM, W.; SUBBAIAH, P.; LIDDY, J.W. A note on multivariate capability indices. **Journal of Applied Statistics**, v.20, p.339–351, 1993.

TANCO, M. *et al.* Implementation of Design of Experiments projects in industry. **Applied Stochastic Models Business and Industry**, v.25, p.478–505, 2009.

TANG, L.C. *et al.* Fortification of Six Sigma: Expanding the DMAIC Toolset. **Quality and Reliability Engineering International**, v.23, pp. 3-18, 2007.

TJAHJONO, B. *et al.* Six Sigma: a literature review. **International Journal of Lean Six Sigma**, v.1,p.216-233, 2010.

TONG, J.P.C.; TSUNG, F.; YEN, B.P.C. A DMAIC approach to printed circuit board quality improvement. **International Journal of Advanced Manufacturing Technology**, v.23, p.523–531, 2004.

- TSOU, J.-C.; CHEN, J.-M. Case study: quality improvement model in a car seat assembly line. **Production Planning & Control**, v.16, p.681–690, 2005.
- VAHIDINASAB, V.; JADID, S. Normal boundary intersection method for suppliers' strategic bidding in electricity markets: An environmental/economic approach. **Energy Conversion and Management**, v.51, p.1111-1119, 2010.
- UTYUZHNIKOV, S.V.; FANTINI, P.; GUENOV, M.D. A method for generating a well-distributed Pareto set in nonlinear multiobjective optimization. **Journal of Computational and Applied Mathematics**, v.223, p.820-841, 2009.
- VAN DEN HEUVEL, E.; TRIP, A. Evaluation of measurement systems with a small number of observers. **Quality Engineering**, v.15, p. 323-331, 2002.
- VILLALOBOS, J.R.; MUÑOZ, L.; GUTIERREZ, M.A. Using fixed and adaptive multivariate SPC charts for online SMD assembly monitoring. **International Journal of Production Economics**, v.95, p.109–121, 2005.
- VINING, G.G. A compromise approach to multiresponse optimization. **Journal of Quality Technology**, v.30, p.309–313, 1998.
- VINING, G.; MYERS, R.H. Combining Taguchi and Response Surface Philosophies: A Dual Response Approach. **Journal of Quality Technology**, v.22, p.38-44, 1990.
- VINODH, S.; KUMAR, S.V.; VIMAL, K.E.K. Implementing lean sigma in an Indian rotary switches manufacturing organization. **Production Planning & Control**, v.25, p.288–302, 2014.
- WANG, C.H. Constructing multivariate process capability indices for short-run production. **International Journal of Advanced Manufacturing Technology**, v.26, p.1306–1311, 2005.
- WANG, W. A simulation-based multivariate Bayesian control chart for real time condition-based maintenance of complex systems. **European Journal of Operational Research**, v.218, p.726–734, 2012.
- WANG, F.K.; CHEN, J.C. Capability index using principal components analysis. **Quality Engineering**, v.11, p.21–27, 1998.
- WANG, F.K.; CHIEN, T.W. Process-oriented basis representation for a multivariate gauge study. **Computers and Industrial Engineering**, v.58, p.143-150, 2010.
- WANG, F.K.; DU, T.C.T. Using principal component analysis in process performance for multivariate data. **Omega**, v.28, p.185–194, 2000.
- WANG, F.K.; YANG, C.W. Applying principal component analysis to a GR&R study. **Journal of the Chinese Institute of Industrial Engineering**, v.24, p.182-1889, 2007.
- WHITE, T.K.; BORROR, C.M. Two-dimensional Guidelines for Measurement System Indices. **Quality and Reliability Engineering International**, v.27, p.479-487, 2011.
- WOODALL, W.H.; BORROR, C.M. Some relationships between gage R&R criteria. **Quality and Reliability Engineering International**, v.24, p.99-106, 2008.
- WU, F.C. Optimization of correlated multiple quality characteristics using desirability function. **Quality and Reliability Engineering International**, v.17, p.119–126, 2004.
- WU, C.W.; PEARN, W.L.; KOTZ, S. An overview of theory and practice on process capability indices for quality assurance. **International Journal of Production Economics**, v.117, p.338-359, 2009.

YANG, Y.S. *et al* Quality Function Deployment-based optimization and exploration for ambiguity, **Journal of Engineering Design**, 14:1, 83-113, 2003.

YANG, S.F.; RAHIM, M.A. Economic statistical process control for multivariate quality characteristics under Weibull shock model. **International Journal of Production Economics**, v.98, p.215–226, 2005.

YEH, D.Y.; CHENG, C.H.; CHI, M.L. A modified two-tuple FLC model for evaluating the performance of SCM: By the Six Sigma DMAIC process. **Applied Soft Computing**, v.7, p.1027–1034, 2007.

YUAN, J.; WANG, K.; YU, T.; FANG, M. Reliable multi-objective optimization of high-speed WEDM process based on Gaussian process regression. **International Journal of Machine Tools and Manufacture**, v.48, p.47–60, 2008.

ZU, X.; FREDENDALL, L.W.; DOUGLAS, T.J. The evolving theory of quality management: the role of Six Sigma. **Journal of Operations Management**, v.26, p.630–650, 2008.

ANEXO A – Dados experimentais

Tabela A.1 – Matriz experimental para o estudo GR&R multivariado

i	j	Univariado						Multivariado						
		R	P	W	AP	AR	AT	PC1	PC2	PC3	PC4	PC5	PC6	WPC
1	1	2,50	1,46	11,02	7,72	20,75	28,71	-1,149	-0,959	0,369	0,184	-0,197	0,056	-6,2530
1	2	2,73	1,46	11,43	8,47	22,52	30,17	-0,509	-1,280	0,233	-0,051	-0,042	-0,034	-3,4421
1	3	2,66	1,48	11,29	8,43	20,82	28,99	-0,761	-1,030	0,206	-0,032	0,052	0,010	-4,4700
2	1	3,05	1,89	12,59	9,97	27,90	38,04	1,738	-0,762	-0,646	0,508	-0,038	0,036	7,7010
2	2	3,14	1,91	13,01	10,85	29,70	39,89	2,309	-0,814	-0,594	0,362	-0,044	-0,033	10,4437
2	3	3,16	1,86	12,97	10,45	29,21	39,20	2,112	-1,009	-0,555	0,342	0,020	-0,015	9,3388
3	1	2,47	1,55	12,43	10,45	20,85	30,27	-0,197	-0,227	0,822	-0,121	0,175	-0,054	-0,9204
3	2	2,63	1,54	12,84	9,79	22,99	32,26	0,189	-0,758	0,742	0,075	0,191	-0,008	0,5207
3	3	2,53	1,57	12,53	9,76	21,06	30,63	-0,165	-0,418	0,687	0,090	0,237	0,018	-0,9431
4	1	2,65	2,18	14,49	15,52	26,28	42,20	3,207	1,571	0,213	0,052	0,210	0,067	16,9275
4	2	2,78	2,16	15,00	17,51	31,32	47,90	4,375	1,359	0,484	-0,393	-0,196	-0,029	22,4935
4	3	2,97	2,14	15,18	16,63	32,35	48,73	4,542	0,790	0,289	-0,253	-0,081	0,029	22,8030
5	1	1,91	1,60	8,81	7,06	11,90	18,48	-3,247	0,789	-0,091	0,392	-0,209	-0,037	-15,1838
5	2	2,09	1,53	9,33	7,58	13,13	20,24	-2,814	0,309	0,067	0,093	-0,069	-0,026	-13,4302
5	3	2,14	1,58	9,23	7,71	12,58	19,73	-2,754	0,426	-0,169	0,087	0,040	-0,039	-13,1049
6	1	2,67	1,74	9,83	9,90	17,97	27,90	-0,705	0,052	-0,851	-0,332	-0,002	0,024	-3,6371
6	2	2,81	1,65	10,25	9,59	20,36	29,76	-0,408	-0,605	-0,668	-0,370	-0,053	0,014	-2,6709
6	3	2,80	1,70	10,10	9,93	19,10	28,71	-0,468	-0,331	-0,820	-0,435	0,063	-0,003	-2,7844
7	1	2,01	1,55	9,51	8,37	12,79	21,35	-2,667	0,636	0,256	-0,009	-0,115	0,039	-12,4064
7	2	2,04	1,44	9,63	8,32	13,56	21,36	-2,733	0,262	0,517	-0,180	-0,150	-0,016	-12,9622
7	3	2,01	1,55	9,51	8,68	12,49	20,77	-2,669	0,711	0,265	-0,108	-0,059	-0,015	-12,3572
8	1	2,34	2,01	11,32	11,64	18,32	29,85	0,112	1,487	-0,394	0,212	0,088	0,000	1,6360
8	2	2,47	1,96	11,55	11,45	20,37	31,31	0,404	1,015	-0,363	0,190	0,032	-0,032	2,6867
8	3	2,43	1,99	11,44	11,87	18,61	30,45	0,297	1,334	-0,435	0,084	0,165	0,010	2,3976
1	1	2,59	1,47	11,20	8,13	20,48	29,03	-0,945	-1,002	0,297	0,041	-0,031	0,072	-5,3191
1	2	2,66	1,42	11,39	8,44	22,17	29,91	-0,695	-1,243	0,417	-0,078	-0,106	-0,021	-4,2680
1	3	2,72	1,45	11,44	8,57	21,80	30,06	-0,576	-1,224	0,276	-0,110	0,009	0,011	-3,7097
2	1	3,03	1,79	12,74	10,51	28,43	38,88	1,763	-0,928	-0,276	0,217	-0,130	0,029	7,7750
2	2	3,16	1,77	13,01	9,93	30,14	39,38	1,968	-1,383	-0,336	0,354	-0,091	-0,030	8,3971
2	3	3,19	1,83	12,97	10,76	29,13	39,39	2,143	-1,109	-0,499	0,149	0,048	-0,014	9,4170
3	1	2,51	1,54	12,63	10,13	21,57	31,50	-0,064	-0,420	0,852	-0,015	0,155	0,023	-0,4126
3	2	2,58	1,57	12,73	9,78	22,57	31,91	0,109	-0,588	0,708	0,130	0,168	-0,003	0,2627
3	3	2,53	1,54	12,50	9,78	21,45	30,70	-0,192	-0,518	0,766	0,025	0,178	-0,009	-1,1354
4	1	2,61	2,11	14,84	16,20	28,52	44,22	3,501	1,410	0,652	-0,125	-0,027	0,001	18,3369
4	2	2,92	2,03	15,00	15,36	32,80	47,25	4,028	0,352	0,491	-0,089	-0,207	-0,029	20,0126
4	3	3,00	2,11	15,22	15,82	33,30	48,64	4,462	0,461	0,293	-0,072	-0,128	0,008	22,1624
5	1	2,06	1,51	8,89	6,66	12,50	19,22	-3,212	0,209	-0,063	0,251	-0,149	0,017	-15,4751
5	2	2,05	1,62	9,24	7,81	12,36	20,00	-2,759	0,711	-0,125	0,206	-0,032	-0,006	-12,8865
5	3	2,14	1,58	9,23	7,50	12,72	19,91	-2,768	0,380	-0,178	0,152	0,018	-0,017	-13,2111
6	1	2,78	1,65	9,92	9,37	19,67	28,91	-0,642	-0,553	-0,756	-0,371	-0,091	0,017	-3,7912
6	2	2,99	1,64	10,36	9,32	21,85	31,05	-0,095	-1,039	-0,852	-0,369	-0,026	0,020	-1,5422
6	3	2,80	1,70	10,10	10,00	19,05	28,49	-0,472	-0,313	-0,819	-0,458	0,079	-0,025	-2,7911
7	1	1,92	1,56	9,31	8,61	12,13	20,64	-2,813	0,900	0,279	-0,043	-0,169	0,011	-12,9024
7	2	2,13	1,42	9,76	7,91	14,03	21,80	-2,652	-0,028	0,458	-0,122	-0,083	0,018	-12,8140
7	3	2,05	1,52	9,69	8,48	13,03	21,12	-2,599	0,512	0,317	-0,080	-0,030	-0,013	-12,1579
8	1	2,47	1,99	11,62	11,88	19,85	31,78	0,528	1,194	-0,398	0,126	0,091	0,019	3,4220
8	2	2,49	1,98	11,57	11,88	20,14	31,41	0,523	1,111	-0,421	0,085	0,092	-0,040	3,3266
8	3	2,47	1,97	11,53	11,90	19,11	30,50	0,368	1,181	-0,410	0,034	0,190	-0,032	2,6294

Tabela A.1 (continuação)

i	j	Univariado						Multivariado						
		R	P	W	AP	AR	AT	PC1	PC2	PC3	PC4	PC5	PC6	WPC
1	1	2,69	1,54	11,39	8,13	21,73	30,12	-0,547	-1,047	0,060	0,188	0,001	0,054	-3,4718
1	2	2,74	1,37	11,76	8,67	23,45	31,05	-0,421	-1,552	0,573	-0,199	-0,079	-0,048	-3,1448
1	3	2,66	1,44	11,33	8,15	21,50	29,57	-0,778	-1,214	0,308	0,004	-0,038	0,031	-4,6717
2	1	3,12	1,86	13,00	11,33	28,93	40,41	2,265	-0,793	-0,422	0,112	-0,036	0,047	10,2833
2	2	3,25	1,82	13,20	10,51	30,87	40,48	2,382	-1,355	-0,477	0,270	-0,023	-0,048	10,3935
2	3	3,25	1,80	13,08	10,62	29,67	39,51	2,205	-1,323	-0,482	0,135	0,082	-0,037	9,5529
3	1	2,61	1,55	12,88	10,61	22,63	32,63	0,314	-0,546	0,813	-0,135	0,201	-0,011	1,3080
3	2	2,55	1,57	12,73	10,24	22,40	31,75	0,125	-0,444	0,783	0,021	0,156	-0,040	0,4715
3	3	2,57	1,51	12,63	9,88	21,39	31,12	-0,120	-0,647	0,811	-0,067	0,249	0,027	-0,8821
4	1	2,77	2,10	15,40	16,07	31,29	47,35	4,114	0,968	0,664	-0,008	-0,076	0,049	20,9753
4	2	3,03	2,19	15,42	16,51	34,69	50,08	4,942	0,659	0,190	-0,052	-0,192	-0,051	24,6282
4	3	2,95	2,09	15,14	15,36	33,40	48,37	4,298	0,431	0,339	0,062	-0,210	0,013	21,3581
5	1	2,12	1,59	9,28	7,48	12,64	20,51	-2,741	0,433	-0,144	0,196	-0,010	0,045	-13,0286
5	2	2,02	1,63	9,19	8,00	12,67	20,36	-2,711	0,789	-0,108	0,187	-0,116	-0,019	-12,5883
5	3	2,09	1,60	9,18	7,19	12,71	19,73	-2,843	0,469	-0,210	0,315	-0,031	-0,009	-13,5067
6	1	2,78	1,79	10,16	10,12	19,37	29,19	-0,263	-0,051	-0,963	-0,281	0,045	-0,007	-1,5966
6	2	2,85	1,69	10,21	9,45	20,05	29,50	-0,372	-0,573	-0,852	-0,301	0,029	0,025	-2,5108
6	3	2,82	1,71	10,24	10,17	19,30	29,18	-0,326	-0,305	-0,803	-0,466	0,093	0,001	-2,0688
7	1	2,06	1,50	9,54	8,52	13,17	21,43	-2,630	0,432	0,323	-0,171	-0,100	0,003	-12,3792
7	2	2,04	1,50	9,63	8,69	12,96	21,27	-2,616	0,527	0,370	-0,180	-0,068	-0,009	-12,2239
7	3	2,05	1,52	9,66	8,52	12,83	21,04	-2,619	0,528	0,305	-0,102	-0,019	-0,005	-12,2481
8	1	2,43	2,03	11,52	12,05	19,26	31,72	0,507	1,393	-0,460	0,127	0,090	0,051	3,4638
8	2	2,47	1,96	11,55	11,98	19,63	31,01	0,421	1,145	-0,343	0,013	0,115	-0,037	2,8726
8	3	2,44	2,04	11,53	12,13	18,74	30,83	0,467	1,458	-0,509	0,108	0,195	0,007	3,3056

Tabela A.2 – Matriz experimental para modelagem e otimização

Fase	Xs				Ys					
	Va	T	Vs	N	W	P	R	D	TD	η
0	7	27	30	15	11,19	1,37	2,63	26,44%	2,718	89,74%
	10	27	30	15	12,99	1,66	3,12	25,82%	3,881	89,71%
	7	32	30	15	12,70	1,69	2,50	31,49%	2,699	89,14%
	10	32	30	15	15,05	1,98	2,78	31,25%	3,871	89,47%
	7	27	50	15	9,21	1,65	2,17	36,22%	2,773	91,58%
	10	27	50	15	9,96	1,94	2,67	33,69%	3,924	90,70%
	7	32	50	15	9,75	1,54	2,06	37,12%	2,647	87,43%
	10	32	50	15	11,51	2,18	2,42	41,08%	3,822	88,36%
	7	27	30	25	10,32	1,25	2,87	22,46%	2,740	90,49%
	10	27	30	25	11,43	1,00	*	18,32%	3,870	89,47%
	7	32	30	25	11,27	1,32	2,85	23,71%	2,743	90,60%
	10	32	30	25	13,34	1,10	3,18	21,96%	3,885	89,81%
	7	27	50	25	7,99	1,11	2,55	24,96%	2,847	94,03%
	10	27	50	25	8,62	1,23	2,80	23,31%	3,901	90,17%
	7	32	50	25	8,48	1,37	2,36	28,77%	2,832	93,52%
	10	32	50	25	10,84	1,64	2,60	30,19%	3,969	91,74%
1	8.5	29.5	40	20	10,82	1,71	2,60	31,05%	3,421	93,04%
	8.5	29.5	40	20	10,93	1,72	2,59	31,67%	3,380	91,91%
	8.5	29.5	40	20	10,74	1,62	2,65	30,88%	3,402	92,51%
	8.5	29.5	40	20	10,61	1,80	2,50	32,83%	3,382	91,98%
	8.5	29.5	40	20	10,64	1,49	2,62	29,99%	3,388	92,15%
	8.5	29.5	40	20	10,59	1,49	2,61	31,09%	3,398	92,40%
	8.5	29.5	40	20	10,57	1,50	2,56	31,02%	3,404	92,58%
2	5.5	29.5	40	20	9,07	1,38	2,21	31,56%	2,204	92,62%
	11.5	29.5	40	20	12,21	2,14	3,06	30,95%	4,454	89,52%
	8.5	24.5	40	20	9,42	1,20	3,03	22,84%	3,324	90,41%
	8.5	34.5	40	20	11,69	1,86	2,46	35,58%	3,311	90,04%
	8.5	29.5	20	20	14,93	0,95	*	18,58%	3,319	90,27%
	8.5	29.5	60	20	8,48	1,43	2,25	35,78%	3,423	93,08%
	8.5	29.5	40	10	11,73	2,18	2,61	40,44%	3,242	88,15%
8.5	29.5	40	30	9,22	1,28	2,89	24,16%	3,385	92,05%	

Tabela A.3 – Padronização e ponderação das respostas da modelagem e otimização

Xs				Ys padronizados e ponderados						Grupo maximizar					Grupo minimizar		
Va	T	Vs	N	0,2W	0,2P	0,2R	0,2D	0,1TD	0,1 η	PC ₁	PC ₂	PC ₃	PC ₄	WPC	PC ₁	PC ₂	WPC
-1	-1	-1	-1	0,039	-0,100	0,001	-0,105	-0,122	-0,071	0,0069	-0,0651	-0,1265	-0,0329	-0,02238	-0,1450	0,0041	-0,13139
1	-1	-1	-1	0,247	0,071	0,353	-0,126	0,106	-0,073	0,4463	0,0482	-0,0151	-0,0086	0,28977	-0,0388	0,1397	-0,02251
-1	1	-1	-1	0,213	0,088	-0,094	0,067	-0,126	-0,107	0,0545	-0,2558	-0,0944	-0,0643	-0,03799	0,1100	0,0147	0,10135
1	1	-1	-1	0,484	0,260	0,109	0,059	0,104	-0,087	0,4237	-0,2720	0,0819	-0,0651	0,20210	0,2257	0,1426	0,21814
-1	-1	1	-1	-0,188	0,063	-0,333	0,229	-0,111	0,039	-0,3905	-0,0870	-0,0031	0,0064	-0,26557	0,2063	-0,1172	0,17689
1	-1	1	-1	-0,102	0,236	0,029	0,142	0,114	-0,014	-0,0110	0,0958	0,0552	0,1103	0,02697	0,2676	0,0662	0,24924
-1	1	1	-1	-0,127	-0,002	-0,405	0,259	-0,136	-0,209	-0,3612	-0,2656	-0,1294	0,1568	-0,28953	0,1819	-0,1850	0,14849
1	1	1	-1	0,076	0,382	-0,146	0,394	0,094	-0,153	-0,0009	-0,1877	0,0403	0,1503	-0,03330	0,5493	-0,0085	0,49852
-1	-1	-1	1	-0,060	-0,174	0,175	-0,241	-0,118	-0,026	0,0611	0,1300	-0,1628	-0,0419	0,05532	-0,2936	0,0475	-0,26255
1	-1	-1	1	0,067	-0,324	*	-0,382	0,104	-0,087	*	*	*	*	*	-0,4996	0,0411	-0,45043
-1	1	-1	1	0,048	-0,132	0,159	-0,198	-0,117	-0,020	0,1165	0,0492	-0,1365	-0,0845	0,06986	-0,2333	0,0472	-0,20781
1	1	-1	1	0,287	-0,264	0,398	-0,258	0,107	-0,067	0,5027	0,0532	-0,0171	-0,0313	0,32475	-0,3693	-0,0038	-0,33600
-1	-1	1	1	-0,329	-0,257	-0,052	-0,156	-0,097	0,186	-0,3041	0,2409	-0,0116	-0,0646	-0,13778	-0,2920	-0,0717	-0,27198
1	-1	1	1	-0,256	-0,189	0,123	-0,212	0,110	-0,045	-0,0356	0,2475	-0,0169	0,1789	0,04718	-0,2837	0,0164	-0,25638
-1	1	1	1	-0,274	-0,103	-0,190	-0,026	-0,100	0,155	-0,3622	0,1039	0,0165	-0,0525	-0,20430	-0,0908	-0,0546	-0,08750
1	1	1	1	-0,001	0,057	-0,021	0,023	0,123	0,049	0,0073	0,0194	0,1269	0,0372	0,02060	0,0566	0,0243	0,05363
-2	0	0	0	-0,205	-0,095	-0,303	0,070	-0,223	0,101	-0,4210	-0,0480	-0,0655	-0,0988	-0,28634	-0,0181	-0,1165	-0,02706
2	0	0	0	0,157	0,358	0,309	0,049	0,218	-0,084	0,3909	0,0898	0,0618	0,1006	0,27738	0,2874	0,2184	0,28109
0	-2	0	0	-0,164	-0,202	0,288	-0,228	-0,003	-0,031	0,1071	0,2835	-0,1261	0,0556	0,12978	-0,3039	0,0188	-0,27455
0	2	0	0	0,097	0,193	-0,122	0,207	-0,006	-0,053	-0,0170	-0,1626	0,0159	0,0103	-0,04792	0,2827	-0,0095	0,25611
0	0	-2	0	0,471	-0,355	*	-0,374	-0,004	-0,039	*	*	*	*	*	-0,5153	0,0130	-0,46726
0	0	2	0	-0,273	-0,065	-0,272	0,214	0,016	0,129	-0,3842	0,0554	0,1133	0,0399	-0,21704	0,1051	-0,1970	0,07759
0	0	0	-2	0,102	0,381	-0,012	0,373	-0,019	-0,165	0,0827	-0,1367	-0,0864	0,0728	0,01748	0,5330	0,0058	0,48504
0	0	0	2	-0,188	-0,155	0,191	-0,183	0,009	0,067	0,0074	0,2728	-0,0400	0,0083	0,06783	-0,2391	0,0199	-0,21557
0	0	0	0	-0,003	0,100	-0,022	0,052	0,016	0,127	-0,0383	0,0344	0,0878	-0,0799	-0,01456	0,1075	0,0337	0,10076
0	0	0	0	0,009	0,109	-0,025	0,073	0,008	0,059	-0,0217	-0,0001	0,0467	-0,0395	-0,01277	0,1287	0,0249	0,11925
0	0	0	0	-0,012	0,049	0,020	0,046	0,012	0,095	-0,0086	0,0561	0,0539	-0,0593	0,00819	0,0672	0,0018	0,06123
0	0	0	0	-0,027	0,156	-0,095	0,113	0,008	0,063	-0,0946	-0,0195	0,0629	-0,0228	-0,06099	0,1899	0,0301	0,17539
0	0	0	0	-0,025	-0,034	-0,004	0,016	0,009	0,073	-0,0302	0,0408	0,0448	-0,0385	-0,00841	-0,0124	-0,0351	-0,01450
0	0	0	0	-0,030	-0,031	-0,011	0,053	0,011	0,088	-0,0409	0,0457	0,0552	-0,0455	-0,01360	0,0158	-0,0597	0,00897
0	0	0	0	-0,032	-0,022	-0,050	0,051	0,012	0,099	-0,0716	0,0257	0,0726	-0,0485	-0,03660	0,0202	-0,0519	0,01366

ANEXO B – Dados simulados

Tabela B.1 – Experimentos de *baseline*

N	Ys						Grupo maximizar					Grupo minimizar		
	W	P	R	D	TD	η	PC ₁	PC ₂	PC ₃	PC ₄	WPC	PC ₁	PC ₂	WPC
1	8,06	1,50	1,91	0,39	2,00	0,90	-2,268	0,459	0,129	0,766	-1,0103	0,137	-0,385	0,0849
1	7,39	1,71	2,02	0,39	2,65	0,91	-1,674	1,529	0,410	-0,028	-0,4398	0,596	0,045	0,5414
1	7,85	1,40	2,20	0,34	2,82	0,88	-0,345	0,852	-0,456	-0,537	-0,0421	-0,659	-0,036	-0,5975
1	8,78	1,87	2,27	0,41	2,69	0,89	-0,277	0,930	-0,202	0,188	0,1050	1,065	0,253	0,9849
1	8,51	1,86	2,26	0,44	2,50	0,88	-0,329	0,448	-0,724	0,111	-0,1134	1,466	-0,198	1,3015
2	8,60	1,62	2,17	0,38	2,56	0,88	-0,354	0,245	-0,525	-0,100	-0,1820	0,274	-0,007	0,2461
2	9,50	1,28	1,55	0,37	2,36	0,89	-1,604	-0,758	1,073	-0,135	-0,9783	-0,555	-0,623	-0,5615
2	11,85	1,51	2,40	0,29	2,57	0,86	1,445	-0,637	-0,475	0,831	0,6278	-0,969	0,746	-0,7989
2	11,02	1,55	2,18	0,38	2,58	0,86	0,788	-0,762	-0,241	0,305	0,2169	0,107	-0,141	0,0825
2	9,08	1,38	2,31	0,32	2,68	0,89	-0,305	1,164	-0,015	0,516	0,2019	-0,911	0,153	-0,8056
3	14,19	2,31	2,16	0,43	3,75	0,85	3,482	-1,068	1,221	-0,656	1,6348	2,232	0,949	2,1051
3	8,92	1,74	1,78	0,43	1,81	0,88	-1,923	-0,888	-0,120	0,610	-1,2348	1,100	-0,343	0,9569
3	8,81	1,09	2,08	0,33	2,36	0,89	-1,016	0,395	-0,054	0,436	-0,4031	-1,421	-0,584	-1,3379
3	10,72	1,76	2,51	0,37	3,06	0,85	2,181	-0,294	-0,990	-0,354	0,9626	0,422	0,447	0,4246
3	8,76	1,17	2,66	0,27	3,32	0,87	1,553	1,461	-0,984	-0,545	1,0931	-1,950	0,308	-1,7268
4	10,27	2,00	2,09	0,41	2,30	0,89	-0,745	0,251	0,451	1,112	-0,1878	1,433	0,429	1,3341
4	11,68	1,62	2,39	0,32	3,28	0,88	1,651	0,754	0,699	0,316	1,1908	-0,383	0,634	-0,2820
4	7,83	1,67	1,86	0,40	2,79	0,87	-0,632	-0,213	-0,207	-1,258	-0,5303	0,605	-0,120	0,5332
4	7,94	1,26	2,26	0,31	2,37	0,90	-1,321	1,404	-0,247	0,725	-0,2816	-1,305	0,042	-1,1720
4	10,68	1,67	1,49	0,44	1,88	0,87	-1,465	-2,122	0,655	0,393	-1,2742	0,989	-0,539	0,8379
5	13,55	1,81	2,55	0,34	3,44	0,84	3,889	-0,982	-0,317	-0,220	1,7672	0,213	0,853	0,2762
5	11,06	1,27	2,29	0,31	2,82	0,88	0,649	0,518	0,470	0,716	0,6008	-1,295	0,047	-1,1625
5	8,05	1,92	2,46	0,42	2,91	0,89	0,031	1,637	-0,573	-0,040	0,4093	1,318	0,228	1,2101
5	10,37	1,72	2,20	0,36	2,91	0,86	0,974	-0,229	-0,146	-0,264	0,4221	0,280	0,387	0,2906
5	6,69	1,43	1,14	0,50	1,21	0,87	-3,985	-2,535	-0,476	-0,495	-2,9297	1,183	-1,727	0,8953
6	9,37	1,60	2,07	0,38	2,68	0,88	-0,369	0,372	0,261	0,065	-0,0644	0,250	-0,092	0,2160
6	9,42	1,86	2,27	0,41	2,96	0,87	0,620	0,478	-0,254	-0,305	0,4131	1,134	0,128	1,0342
6	8,68	0,83	2,20	0,26	2,41	0,88	-0,566	0,347	-0,558	0,288	-0,2369	-2,774	-0,330	-2,5320
6	13,48	2,15	2,00	0,42	3,63	0,86	2,613	-0,905	1,525	-0,706	1,2385	1,895	0,638	1,7706
6	9,44	1,47	2,65	0,32	3,28	0,86	1,810	1,084	-0,922	-0,416	1,1448	-0,764	0,389	-0,6497
7	11,44	1,50	2,10	0,40	3,00	0,89	0,498	0,538	1,289	0,509	0,5863	0,160	-0,434	0,1008
7	11,63	1,79	2,59	0,37	3,00	0,87	1,847	0,594	-0,165	0,774	1,2087	0,497	0,505	0,4974
7	9,79	1,47	2,41	0,33	3,72	0,90	1,132	2,315	1,029	-0,352	1,3155	-0,638	0,255	-0,5499
7	10,33	2,40	1,73	0,51	2,79	0,87	-0,138	-0,853	0,848	-0,581	-0,2788	3,327	0,235	3,0206
7	11,54	1,50	2,34	0,36	2,09	0,85	1,066	-1,611	-1,264	0,940	0,0889	-0,203	-0,050	-0,1882
8	10,15	1,26	2,04	0,33	2,32	0,87	-0,202	-0,755	-0,208	0,361	-0,3051	-1,062	-0,234	-0,9796
8	8,77	1,37	2,28	0,29	3,34	0,89	0,288	1,799	0,517	-0,459	0,6606	-1,314	0,496	-1,1347
8	8,82	1,82	1,97	0,42	2,78	0,88	-0,417	0,159	0,167	-0,529	-0,2111	1,133	-0,027	1,0180
8	9,51	1,97	1,89	0,44	2,36	0,86	-0,389	-1,119	-0,333	-0,265	-0,5735	1,662	0,076	1,5051
8	12,13	1,01	2,50	0,25	2,60	0,87	1,478	-0,154	-0,265	1,237	0,8356	-2,574	0,231	-2,2963
9	11,46	1,69	2,44	0,33	3,38	0,86	2,289	0,252	0,037	-0,274	1,2779	-0,219	0,779	-0,1198
9	6,26	1,37	1,44	0,40	1,90	0,91	-3,910	0,269	0,659	-0,112	-1,9717	-0,037	-0,755	-0,1078
9	10,47	1,63	1,73	0,41	2,60	0,86	0,081	-1,616	0,283	-0,662	-0,4337	0,606	-0,325	0,5139
9	13,14	1,30	2,32	0,28	2,50	0,86	1,698	-1,220	-0,078	1,138	0,6688	-1,599	0,498	-1,3917
9	7,31	2,23	1,92	0,51	2,95	0,89	-1,144	1,091	0,396	-0,945	-0,3587	3,037	-0,199	2,7171
10	7,56	1,46	2,41	0,31	2,95	0,89	-0,286	1,895	-0,440	-0,175	0,3111	-0,870	0,457	-0,7387
10	9,33	1,04	2,15	0,28	2,18	0,90	-1,118	0,498	0,021	1,082	-0,3645	-2,059	-0,133	-1,8682
10	12,12	1,65	2,01	0,37	2,25	0,86	0,469	-1,559	0,141	0,854	-0,0889	0,170	0,203	0,1731
10	10,39	1,67	2,18	0,38	3,11	0,88	0,797	0,425	0,492	-0,214	0,5739	0,410	0,072	0,3763
10	7,02	1,40	1,94	0,36	1,82	0,89	-2,509	0,237	-0,641	0,489	-1,3006	-0,388	-0,270	-0,3765

Tabela B.1 (continuação)

N	Ys						Grupo maximizar					Grupo minimizar		
	W	P	R	D	TD	η	PC ₁	PC ₂	PC ₃	PC ₄	WPC	PC ₁	PC ₂	WPC
11	11,31	1,47	2,57	0,32	3,55	0,87	2,304	1,152	0,295	-0,056	1,5790	-0,696	0,311	-0,5960
11	11,00	1,44	2,08	0,38	3,07	0,85	1,494	-0,942	0,001	-0,773	0,4733	-0,111	-0,382	-0,1377
11	6,92	1,63	1,90	0,41	2,40	0,86	-1,144	-0,458	-1,039	-1,084	-0,9381	0,643	-0,324	0,5470
11	10,30	1,46	2,05	0,37	2,63	0,89	-0,397	0,428	0,775	0,614	0,0350	-0,212	-0,208	-0,2114
11	10,06	1,12	2,47	0,26	3,20	0,90	0,624	2,012	0,662	0,573	1,0058	-2,121	0,254	-1,8857
12	7,56	2,12	1,87	0,48	2,58	0,89	-1,462	0,478	0,126	-0,539	-0,6889	2,499	-0,095	2,2418
12	9,24	1,67	1,78	0,42	2,34	0,88	-1,276	-0,402	0,477	0,073	-0,7433	0,818	-0,341	0,7033
12	11,10	1,38	1,98	0,33	2,44	0,88	-0,124	-0,572	0,582	0,659	-0,1096	-0,797	0,018	-0,7166
12	7,54	1,46	2,04	0,38	2,54	0,89	-1,236	0,747	-0,224	-0,264	-0,5025	-0,112	-0,325	-0,1330
12	7,42	1,96	1,63	0,47	2,21	0,89	-2,397	-0,112	0,320	-0,355	-1,3189	2,048	-0,338	1,8121
13	10,44	1,68	2,18	0,37	2,59	0,87	0,542	-0,497	-0,288	0,183	0,1419	0,220	0,306	0,2287
13	10,96	2,12	1,31	0,52	2,13	0,86	-1,167	-2,630	1,018	-0,317	-1,2823	2,903	-0,532	2,5631
13	9,64	1,40	2,17	0,32	3,19	0,87	0,865	0,305	0,092	-0,773	0,4887	-0,903	0,241	-0,7896
13	12,18	1,95	1,95	0,39	2,86	0,88	0,663	-0,541	1,262	0,382	0,3633	1,110	0,565	1,0559
13	9,54	0,99	2,04	0,31	2,65	0,88	-0,220	-0,022	0,116	-0,051	-0,1177	-1,892	-0,534	-1,7579
14	8,54	1,67	2,01	0,39	2,92	0,87	-0,132	0,199	-0,033	-0,886	-0,0978	0,503	-0,019	0,4511
14	11,51	2,17	1,89	0,45	2,69	0,83	1,401	-2,447	-0,378	-0,847	-0,0348	2,192	0,398	2,0147
14	10,93	1,69	2,37	0,35	2,91	0,85	1,690	-0,465	-0,620	-0,118	0,7087	0,111	0,454	0,1448
14	10,30	1,32	2,22	0,33	2,89	0,90	-0,045	1,243	0,927	0,693	0,4703	-0,993	-0,007	-0,8958
14	9,03	1,17	1,72	0,38	1,92	0,88	-1,859	-0,891	0,120	0,437	-1,1939	-0,744	-0,896	-0,7591
15	8,85	1,61	2,19	0,37	3,41	0,86	1,017	0,551	-0,117	-1,378	0,5644	0,163	0,040	0,1509
15	7,94	1,87	1,89	0,43	1,98	0,87	-1,430	-0,931	-0,946	-0,155	-1,1304	1,332	-0,024	1,1979
15	11,86	1,79	2,26	0,37	3,15	0,87	1,517	0,158	0,692	0,231	0,9460	0,449	0,522	0,4560
15	11,25	1,46	1,95	0,34	2,33	0,86	0,263	-1,492	-0,009	0,341	-0,2411	-0,512	0,104	-0,4506
15	9,47	1,09	2,01	0,33	2,07	0,87	-0,846	-0,698	-0,432	0,546	-0,6402	-1,418	-0,576	-1,3348
16	13,24	2,08	1,90	0,42	2,48	0,86	1,082	-2,067	0,641	0,578	0,1241	1,739	0,490	1,6153
16	11,67	1,37	2,37	0,31	3,36	0,86	2,189	0,095	0,245	-0,259	1,2023	-1,055	0,253	-0,9259
16	10,40	1,97	2,13	0,40	2,56	0,84	1,199	-1,723	-1,136	-0,573	0,0068	1,244	0,525	1,1724
16	11,61	1,30	2,48	0,27	2,66	0,87	1,488	-0,219	-0,486	0,848	0,7668	-1,684	0,568	-1,4609
16	8,74	1,58	2,25	0,37	2,77	0,88	-0,170	0,892	-0,188	-0,003	0,1366	-0,007	0,075	0,0014
17	7,08	1,17	2,10	0,34	2,29	0,89	-1,516	0,633	-0,752	-0,048	-0,7170	-1,107	-0,552	-1,0520
17	8,92	2,10	1,40	0,50	2,53	0,87	-1,337	-1,443	0,754	-1,185	-1,1488	2,622	-0,325	2,3298
17	7,85	1,12	2,09	0,32	2,29	0,88	-1,079	0,130	-0,746	-0,038	-0,6195	-1,481	-0,375	-1,3718
17	10,95	1,22	2,23	0,32	2,85	0,85	1,408	-0,755	-0,398	-0,228	0,4887	-1,269	-0,180	-1,1610
17	12,06	1,33	2,43	0,29	3,15	0,88	1,663	0,675	0,652	0,691	1,2041	-1,404	0,434	-1,2218
18	7,91	1,69	2,37	0,36	2,52	0,88	-0,357	0,828	-1,057	0,095	-0,0572	0,163	0,375	0,1838
18	11,11	1,81	1,79	0,40	2,01	0,86	-0,426	-2,019	0,002	0,494	-0,7418	0,835	0,220	0,7743
18	6,92	1,89	1,86	0,47	2,87	0,90	-1,726	1,404	0,649	-0,789	-0,5463	1,855	-0,457	1,6258
18	11,10	1,27	2,59	0,28	2,94	0,87	1,756	0,457	-0,519	0,551	1,0675	-1,576	0,363	-1,3838
18	9,64	1,42	2,21	0,33	2,69	0,88	0,139	0,272	-0,134	0,140	0,1493	-0,697	0,089	-0,6192
19	7,15	1,29	1,96	0,39	2,94	0,88	-0,720	0,572	-0,216	-1,315	-0,3671	-0,366	-0,779	-0,4069
19	8,71	1,45	1,90	0,39	1,97	0,89	-1,657	-0,400	-0,221	0,561	-0,9717	0,031	-0,512	-0,0229
19	9,24	1,82	1,84	0,44	2,58	0,90	-1,317	0,549	1,051	0,244	-0,4322	1,313	-0,192	1,1641
19	7,48	0,97	2,25	0,26	2,28	0,88	-0,857	0,372	-1,273	0,020	-0,4793	-2,507	-0,010	-2,2599
19	8,32	1,76	2,05	0,42	2,76	0,89	-0,655	0,661	0,070	-0,364	-0,1950	0,987	-0,135	0,8762
20	7,38	1,23	1,80	0,38	2,61	0,90	-1,782	0,699	0,443	-0,555	-0,7702	-0,545	-0,874	-0,5779
20	10,24	1,02	2,39	0,26	3,42	0,88	1,487	1,038	0,266	-0,411	1,0745	-2,333	0,048	-2,0977
20	7,64	1,33	1,71	0,40	1,93	0,89	-2,375	-0,485	-0,160	0,042	-1,4211	-0,149	-0,839	-0,2169
20	8,57	0,91	2,57	0,26	2,43	0,89	-0,114	1,225	-1,102	0,867	0,2473	-2,653	-0,108	-2,4007
20	9,20	1,60	2,33	0,35	3,04	0,86	0,995	0,318	-0,661	-0,635	0,5012	-0,187	0,352	-0,1332

Tabela B.2 – Experimentos de confirmação

N	Ys						Grupo maximizar					Grupo minimizar		
	W	P	R	D	TD	η	PC ₁	PC ₂	PC ₃	PC ₄	WPC	PC ₁	PC ₂	WPC
1	11,00	0,96	3,15	0,21	3,74	0,85	0,029	-1,052	1,567	0,574	-1,0103	-0,025	0,301	0,0849
1	12,34	0,85	3,21	0,18	3,27	0,88	-0,660	-1,045	-0,778	0,661	-0,4398	-0,633	0,188	0,5414
1	10,46	1,42	3,41	0,25	4,13	0,87	0,005	0,947	0,577	0,359	-0,0421	1,563	-0,173	-0,5975
1	11,31	1,78	3,25	0,30	3,46	0,85	0,027	-1,302	0,957	0,115	0,1050	2,885	-0,437	0,9849
1	11,28	0,82	3,73	0,15	3,69	0,85	1,408	-0,275	0,553	-1,028	-0,1134	-0,998	-0,080	1,3015
2	11,30	1,31	3,37	0,22	3,83	0,87	0,158	-0,033	0,340	0,347	-0,1820	0,880	-0,341	0,2461
2	9,55	0,86	3,15	0,24	3,27	0,90	-2,519	0,449	-0,463	0,089	-0,9783	0,084	0,843	-0,5615
2	11,07	1,25	3,48	0,24	4,36	0,88	0,423	1,400	0,111	0,705	0,6278	0,977	-0,008	-0,7989
2	10,00	0,52	3,39	0,16	3,97	0,87	-0,239	0,695	0,855	0,024	0,2169	-1,586	0,690	0,0825
2	9,73	1,37	2,99	0,31	3,66	0,88	-1,974	0,128	0,728	0,886	0,2019	2,083	0,569	-0,8056
3	9,29	1,35	3,71	0,23	3,78	0,89	-0,504	1,725	-0,229	-1,149	1,6348	1,094	-0,312	2,1051
3	10,88	1,14	3,30	0,25	4,21	0,89	-0,614	1,404	-0,261	1,128	-1,2348	0,863	0,370	0,9569
3	12,09	1,29	3,55	0,23	3,42	0,87	0,390	-0,448	-0,727	-0,311	-0,4031	0,981	-0,167	-1,3379
3	10,61	0,81	3,53	0,11	3,52	0,88	-0,466	0,447	-0,446	-0,536	0,9626	-1,534	-0,547	0,4246
3	10,72	1,44	3,57	0,21	3,77	0,86	0,600	0,109	0,613	-0,587	1,0931	1,106	-0,705	-1,7268
4	11,12	1,30	3,26	0,27	3,77	0,90	-1,153	0,779	-0,816	0,890	-0,1878	1,483	0,278	1,3341
4	10,44	0,68	3,37	0,14	3,60	0,91	-1,566	1,191	-1,179	0,220	1,1908	-1,439	0,113	-0,2820
4	10,76	0,78	3,57	0,17	4,23	0,87	0,654	1,138	0,426	0,104	-0,5303	-0,918	0,202	0,5332
4	8,95	1,28	3,59	0,23	3,82	0,88	-0,516	1,317	0,621	-1,030	-0,2816	0,889	-0,207	-1,1720
4	9,90	0,85	3,35	0,19	3,60	0,88	-1,017	0,452	0,249	-0,196	-1,2742	-0,482	0,311	0,8379
5	11,66	0,86	3,43	0,20	4,42	0,88	0,747	1,034	0,234	1,083	1,7672	-0,377	0,378	0,2762
5	13,18	1,63	3,46	0,27	3,76	0,86	1,416	-1,005	-0,061	0,544	0,6008	2,177	-0,459	-1,1625
5	12,34	0,88	3,64	0,15	3,72	0,87	1,069	-0,060	-0,591	-0,173	0,4093	-0,886	-0,222	1,2101
5	10,12	0,83	3,43	0,16	3,78	0,88	-0,523	0,694	0,267	-0,165	0,4221	-0,858	0,039	0,2906
5	12,14	0,80	3,99	0,12	4,64	0,86	2,860	1,622	0,022	-0,257	-2,9297	-1,441	-0,436	0,8953
6	12,65	0,62	3,73	0,12	4,07	0,87	1,788	0,415	-0,492	0,055	-0,0644	-1,859	-0,035	0,2160
6	11,19	1,47	3,24	0,30	3,67	0,85	0,033	-0,829	0,983	0,370	0,4131	2,253	0,308	1,0342
6	8,46	1,32	3,09	0,27	3,78	0,88	-2,020	0,755	1,332	0,226	-0,2369	1,525	0,241	-2,5320
6	12,63	0,75	3,88	0,09	5,01	0,86	3,063	1,883	0,148	0,666	1,2385	-1,915	-0,677	1,7706
6	11,92	1,43	3,56	0,26	3,93	0,87	0,835	0,304	-0,231	0,183	1,1448	1,586	-0,169	-0,6497
7	12,35	0,37	3,49	0,09	3,71	0,87	0,688	-0,288	-0,427	0,258	0,5863	-2,754	0,179	0,1008
7	12,72	0,92	3,54	0,18	3,86	0,88	0,908	0,096	-0,803	0,486	1,2087	-0,405	0,079	0,4974
7	10,92	1,07	3,07	0,25	3,59	0,86	-0,787	-0,835	0,896	0,767	1,3155	0,698	0,510	-0,5499
7	12,07	0,57	3,31	0,14	2,96	0,87	-0,647	-1,422	-0,789	-0,125	-0,2788	-1,761	0,268	3,0206
7	11,26	0,77	3,34	0,16	2,93	0,89	-1,362	-0,665	-1,170	-0,372	0,0889	-1,064	0,103	-0,1882
8	13,71	1,28	3,54	0,21	4,05	0,85	2,136	-0,691	-0,089	0,816	-0,3051	0,715	-0,375	-0,9796
8	11,48	1,03	3,27	0,21	4,03	0,88	-0,107	0,336	0,148	1,038	0,6606	0,191	0,201	-1,1347
8	10,27	1,00	3,44	0,19	3,58	0,90	-1,189	1,013	-0,799	-0,177	-0,2111	-0,111	0,041	1,0180
8	9,67	1,50	3,11	0,30	3,11	0,87	-1,809	-0,910	0,772	-0,265	-0,5735	2,249	0,188	1,5051
8	13,37	0,72	3,66	0,09	3,76	0,85	2,265	-1,077	0,023	-0,069	0,8356	-2,023	-0,644	-2,2963
9	11,42	0,93	3,73	0,15	4,20	0,86	1,664	0,715	0,480	-0,305	1,2779	-0,816	-0,376	-0,1198
9	12,33	0,64	3,55	0,14	3,35	0,86	0,796	-1,016	-0,345	-0,437	-1,9717	-1,543	0,213	-0,1078
9	10,77	1,70	3,00	0,31	3,26	0,89	-2,018	-0,616	-0,203	0,800	-0,4337	2,842	-0,118	0,5139
9	11,26	0,79	3,57	0,17	2,94	0,84	0,772	-2,042	0,827	-1,604	0,6688	-0,859	0,222	-1,3917
9	12,36	0,95	3,72	0,16	3,17	0,86	1,158	-1,164	-0,536	-1,153	-0,3587	-0,581	-0,202	2,7171
10	14,16	0,94	3,79	0,17	4,10	0,86	2,689	-0,093	-0,943	0,413	0,3111	-0,587	-0,173	-0,7387
10	12,29	0,88	3,31	0,18	3,30	0,85	0,299	-1,608	0,171	0,138	-0,3645	-0,512	0,150	-1,8682
10	12,28	1,18	3,47	0,20	3,84	0,84	1,481	-0,929	0,818	0,178	-0,0889	0,342	-0,330	0,1731
10	9,11	1,04	3,14	0,24	3,23	0,89	-2,401	0,118	0,229	-0,208	0,5739	0,491	0,452	0,3763
10	12,56	1,09	3,28	0,21	3,02	0,89	-1,015	-0,924	-1,732	0,383	-1,3006	0,300	0,042	-0,3765

Tabela B.2 (continuação)

N	Ys						Grupo maximizar					Grupo minimizar		
	W	P	R	D	TD	η	PC ₁	PC ₂	PC ₃	PC ₄	WPC	PC ₁	PC ₂	WPC
11	10,12	0,53	3,69	0,08	3,55	0,89	-0,325	1,009	-0,594	-1,124	1,5790	-2,489	-0,287	-0,5960
11	12,71	1,50	3,63	0,23	3,75	0,85	1,764	-0,764	0,099	-0,177	0,4733	1,384	-0,702	-0,1377
11	10,72	0,46	3,60	0,11	2,70	0,87	-0,518	-1,169	-0,507	-1,809	-0,9381	-2,278	0,239	0,5470
11	11,16	0,91	3,78	0,15	4,36	0,86	1,900	1,003	0,768	-0,377	0,0350	-0,814	-0,271	-0,2114
11	10,92	0,67	3,75	0,10	3,39	0,89	-0,108	0,709	-1,229	-1,147	1,0058	-1,992	-0,378	-1,8857
12	11,17	0,82	3,72	0,15	3,98	0,85	1,674	0,069	0,944	-0,739	-0,6889	-1,015	-0,095	2,2418
12	9,73	1,36	3,09	0,31	3,23	0,86	-1,505	-1,004	1,151	-0,136	-0,7433	2,038	0,601	0,7033
12	10,72	1,09	3,58	0,18	4,30	0,85	1,255	0,711	1,238	-0,054	-0,1096	-0,066	-0,319	-0,7166
12	10,61	0,70	3,61	0,13	3,58	0,88	-0,154	0,611	-0,442	-0,725	-0,5025	-1,491	-0,026	-0,1330
12	8,61	0,75	2,90	0,21	3,01	0,90	-3,672	-0,058	0,124	0,149	-1,3189	-0,484	0,750	1,8121
13	9,66	1,37	3,01	0,29	3,25	0,88	-2,396	-0,331	0,323	0,357	0,1419	1,901	0,398	0,2287
13	9,85	1,00	3,49	0,20	4,42	0,87	0,208	1,646	0,962	0,265	-1,2823	-0,053	0,092	2,5631
13	10,79	1,55	3,44	0,27	4,63	0,88	0,529	1,723	0,602	1,009	0,4887	2,028	-0,249	-0,7896
13	11,29	1,07	3,29	0,25	3,32	0,87	-0,713	-0,668	-0,221	0,085	0,3633	0,711	0,555	1,0559
13	11,95	0,72	3,40	0,16	3,49	0,89	-0,436	-0,013	-1,106	0,340	-0,1177	-1,189	0,194	-1,7579
14	12,03	1,12	2,96	0,23	3,08	0,86	-0,915	-2,281	0,468	0,843	-0,0978	0,620	0,227	0,4511
14	10,54	0,61	3,25	0,15	3,31	0,88	-1,389	-0,191	-0,275	0,023	-0,0348	-1,508	0,340	2,0147
14	11,08	0,81	3,40	0,19	3,17	0,88	-0,715	-0,588	-0,467	-0,460	0,7087	-0,614	0,377	0,1448
14	14,95	1,21	3,34	0,20	3,54	0,84	1,970	-2,445	-0,285	1,137	0,4703	0,458	-0,327	-0,8958
14	13,32	1,13	3,40	0,21	3,12	0,84	1,249	-2,590	0,211	-0,130	-1,1939	0,373	-0,045	-0,7591
15	11,85	0,69	3,36	0,15	3,45	0,87	-0,168	-0,606	-0,378	0,211	0,5644	-1,283	0,228	0,1509
15	11,09	1,25	3,12	0,28	3,78	0,86	-0,314	-0,718	1,109	0,862	-1,1304	1,481	0,509	1,1979
15	13,37	1,28	3,27	0,23	2,94	0,85	0,368	-2,592	-0,403	0,191	0,9460	0,895	-0,196	0,4560
15	12,15	1,09	3,53	0,20	3,74	0,85	1,264	-0,711	0,421	-0,067	-0,2411	0,206	-0,038	-0,4506
15	11,12	1,17	3,26	0,24	3,24	0,85	-0,085	-1,673	1,044	-0,282	-0,6402	0,788	0,185	-1,3348
16	10,57	1,12	3,44	0,20	3,16	0,89	-1,161	-0,002	-0,824	-0,663	0,1241	0,234	-0,136	1,6153
16	12,06	1,18	3,64	0,18	3,95	0,87	1,030	0,510	-0,513	0,040	1,2023	0,145	-0,523	-0,9259
16	9,73	1,65	3,34	0,28	3,91	0,89	-1,022	1,137	0,287	0,204	0,0068	2,388	-0,349	1,1724
16	11,37	1,15	3,24	0,23	2,89	0,88	-1,324	-1,230	-0,709	-0,184	0,7668	0,679	0,170	-1,4609
16	11,42	0,45	3,84	0,08	4,11	0,88	1,095	1,582	-0,842	-0,473	0,1366	-2,699	-0,141	0,0014
17	9,65	0,98	3,03	0,23	3,66	0,90	-2,541	0,905	-0,220	0,953	-0,7170	0,283	0,526	-1,0520
17	10,73	1,03	3,33	0,20	2,92	0,85	-0,552	-1,685	0,583	-0,917	-1,1488	0,021	0,046	2,3298
17	13,23	0,51	3,55	0,10	3,73	0,87	1,286	-0,550	-0,713	0,406	-0,6195	-2,357	-0,030	-1,3718
17	11,20	1,19	3,58	0,21	3,55	0,87	0,291	-0,002	-0,221	-0,590	0,4887	0,534	-0,170	-1,1610
17	11,51	0,63	3,29	0,12	2,63	0,89	-1,816	-1,099	-1,653	-0,428	1,2041	-1,875	-0,077	-1,2218
18	10,52	0,98	3,19	0,21	3,36	0,89	-1,550	-0,150	-0,222	0,264	-0,0572	0,071	0,291	0,1838
18	13,73	1,20	3,47	0,21	4,11	0,87	1,452	-0,058	-0,831	1,293	-0,7418	0,582	-0,172	0,7743
18	10,28	0,38	3,69	0,09	3,72	0,87	0,349	0,698	0,149	-1,030	-0,5463	-2,688	0,210	1,6258
18	11,62	1,30	3,42	0,22	3,92	0,87	0,369	0,196	0,054	0,480	1,0675	0,822	-0,370	-1,3838
18	9,88	1,29	3,50	0,22	4,10	0,89	-0,597	1,798	-0,114	0,077	0,1493	0,880	-0,248	-0,6192
19	7,78	0,94	3,40	0,23	3,20	0,88	-2,024	0,538	0,867	-1,569	-0,3671	0,171	0,584	-0,4069
19	12,92	1,10	3,77	0,19	4,09	0,88	1,550	0,929	-1,314	0,222	-0,9717	0,123	-0,197	-0,0229
19	9,92	0,68	3,55	0,15	4,06	0,88	-0,138	1,432	0,282	-0,233	-0,4322	-1,307	0,270	1,1641
19	11,88	1,13	3,64	0,20	4,05	0,88	0,977	0,782	-0,456	0,122	-0,4793	0,226	-0,214	-2,2599
19	13,12	1,67	3,68	0,26	4,15	0,85	2,470	-0,283	0,230	0,265	-0,1950	2,157	-0,652	0,8762
20	8,75	1,43	3,14	0,26	3,61	0,91	-2,754	1,352	-0,122	0,303	-0,7702	1,663	-0,109	-0,5779
20	9,58	1,00	3,80	0,14	4,43	0,86	1,196	1,868	1,131	-0,859	1,0745	-0,751	-0,599	-2,0977
20	9,12	1,36	3,15	0,27	3,46	0,88	-1,820	0,098	0,864	-0,100	-1,4211	1,640	0,187	-0,2169
20	9,81	1,14	3,31	0,24	3,90	0,87	-0,543	0,484	1,041	0,105	0,2473	0,719	0,248	-2,4007
20	12,65	0,81	3,86	0,11	4,01	0,88	1,754	0,830	-1,126	-0,290	0,5012	-1,558	-0,592	-0,1332

ANEXO C – Superfícies de resposta

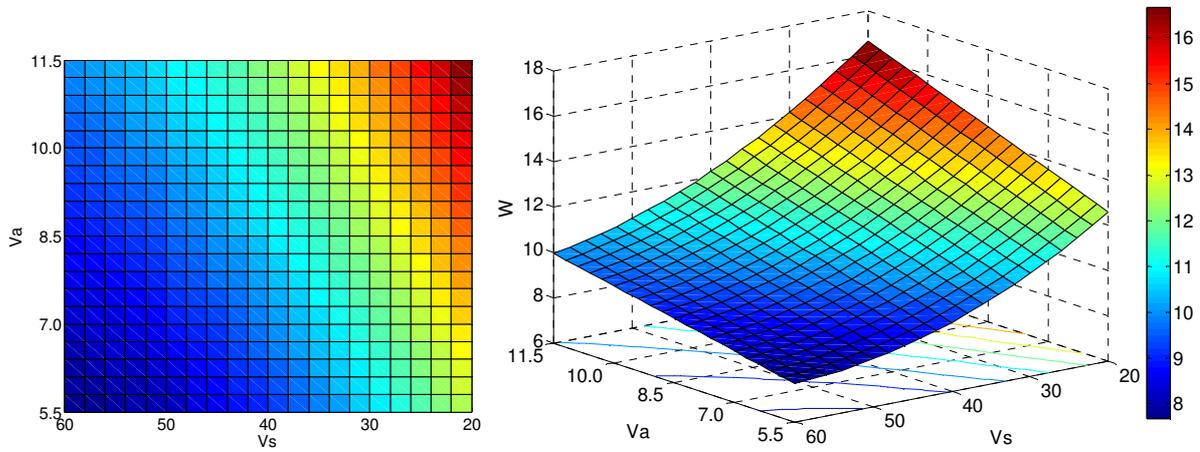


Figura C.1 – Gráfico de contorno e de superfície de resposta para W (largura)

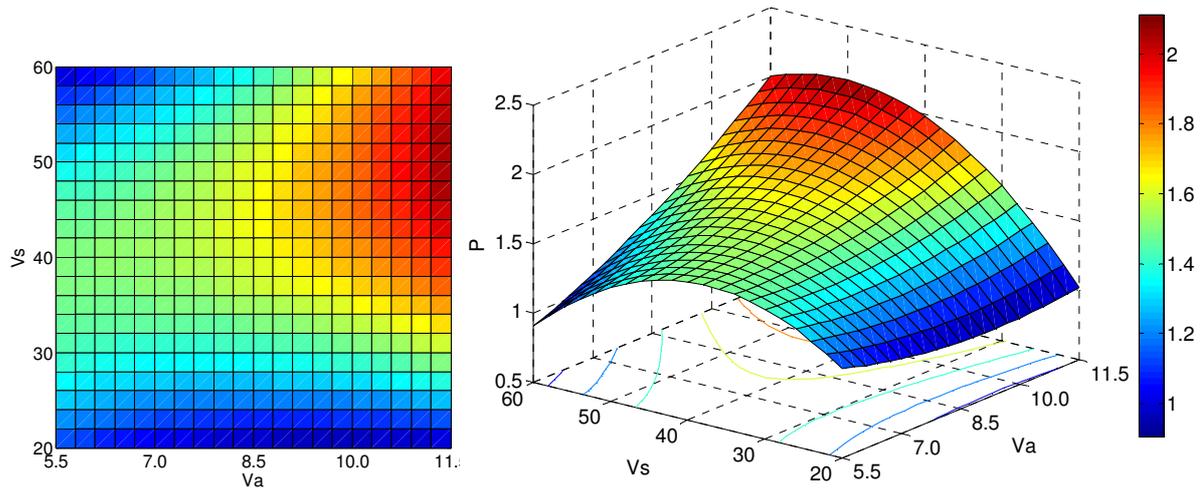


Figura C.2 – Gráfico de contorno e de superfície de resposta para P (penetração)

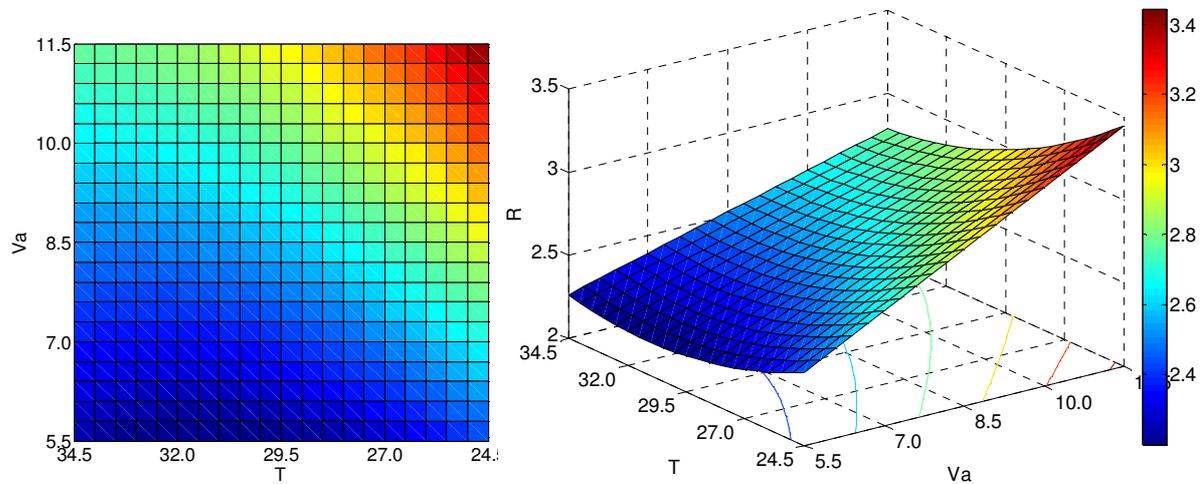


Figura C.3 – Gráfico de contorno e de superfície de resposta para R (reforço)

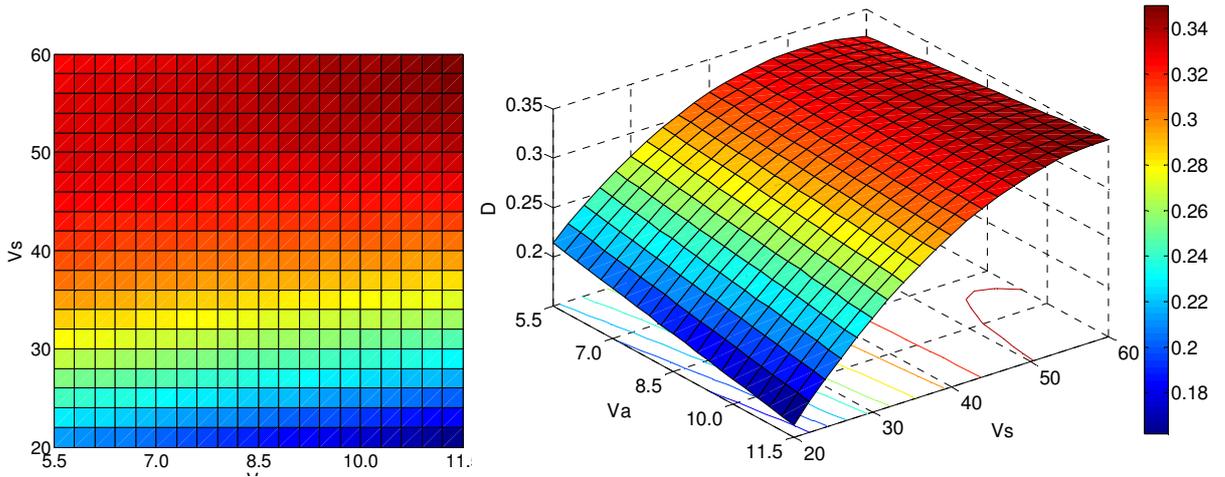


Figura C.4 – Gráfico de contorno e de superfície de resposta para D (diluição)

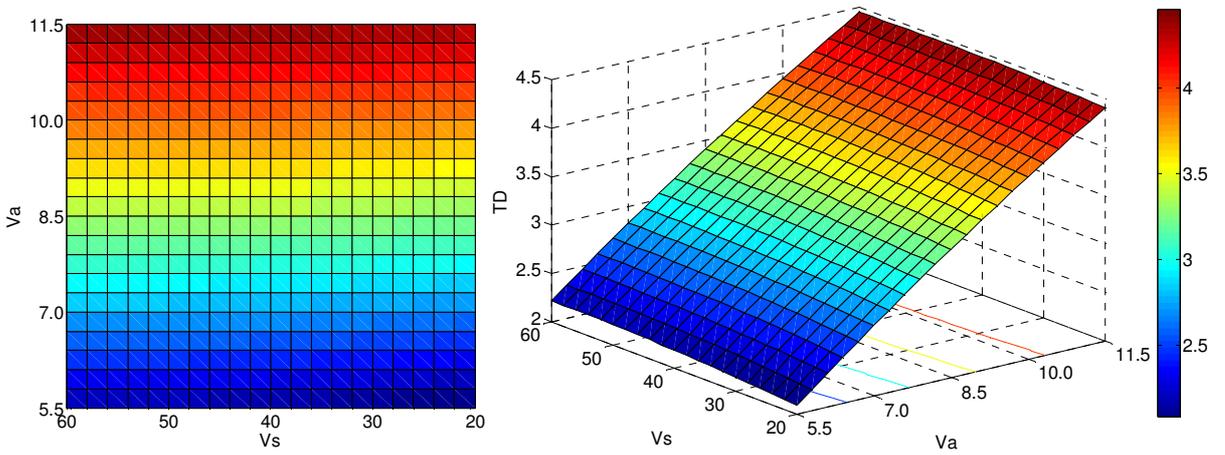


Figura C.5 – Gráfico de contorno e de superfície de resposta para TD (taxa de deposição)

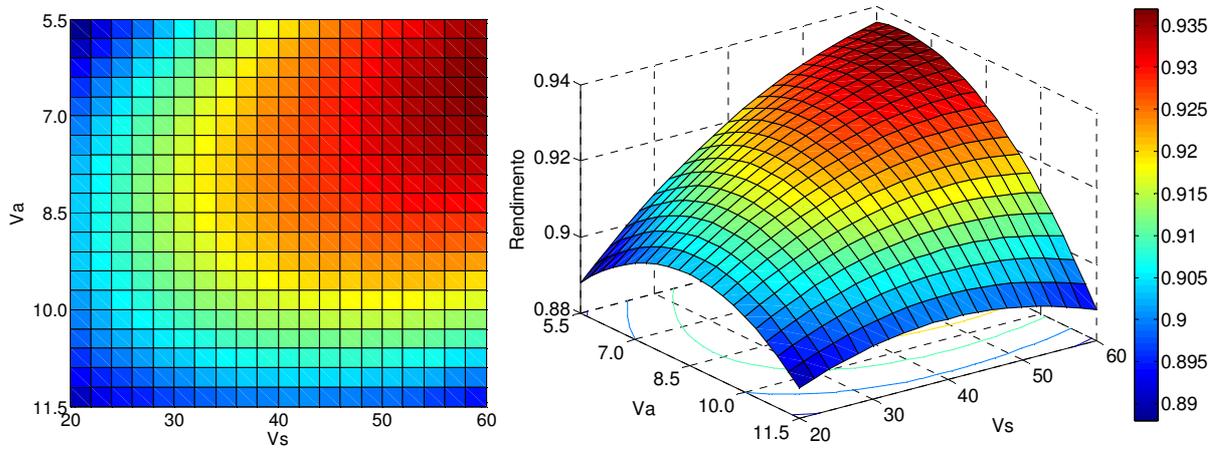


Figura C.6 – Gráfico de contorno e de superfície de resposta para η (rendimento)

ANEXO D – Cartas de controle

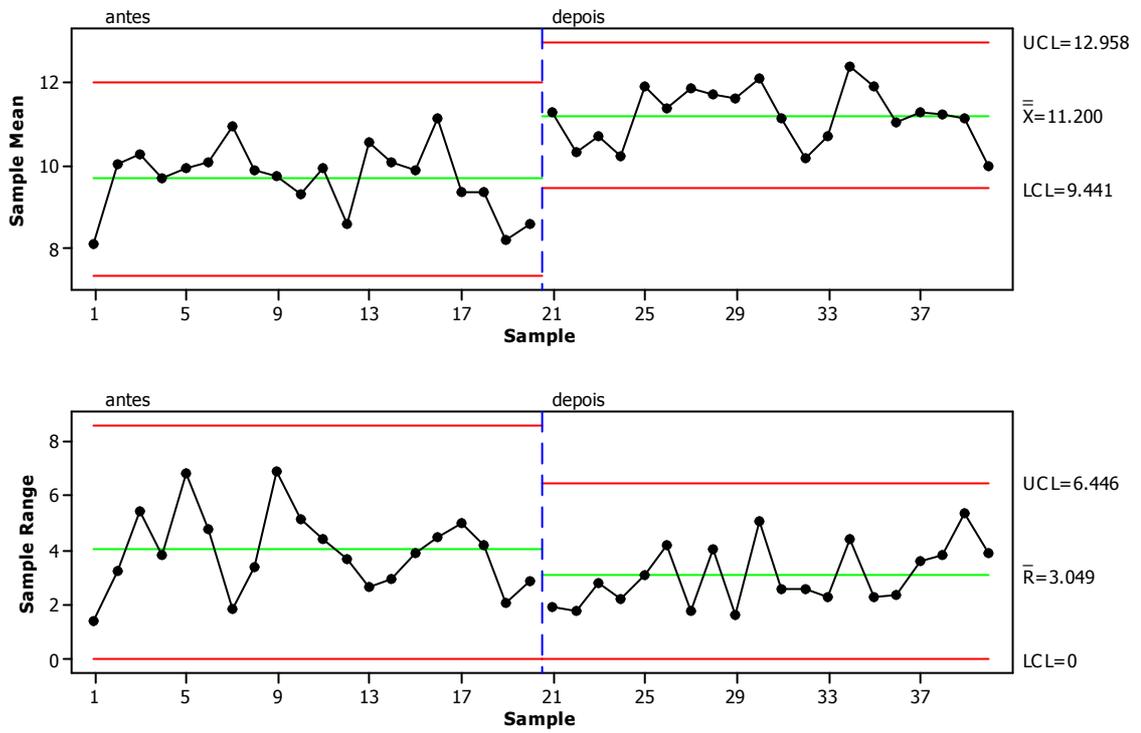


Figura D.1 – Cartas de controle comparando baseline e melhoria em *W* (largura)

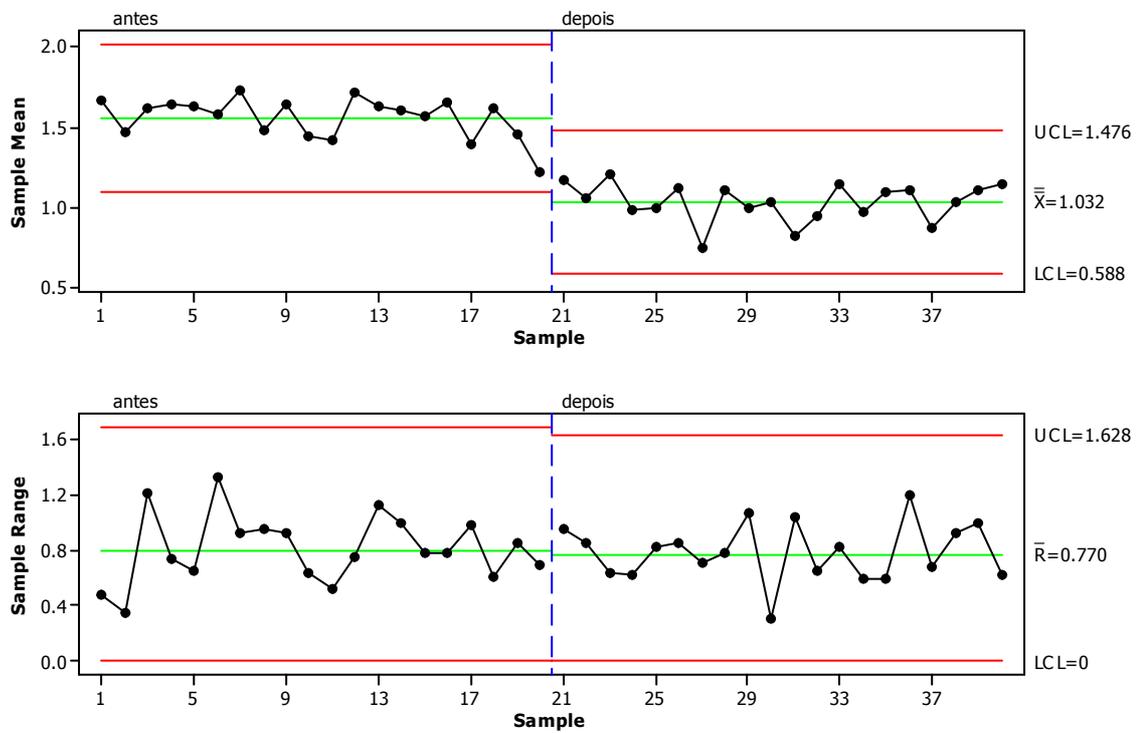


Figura D.2 – Cartas de controle comparando baseline e melhoria em *P* (penetração)

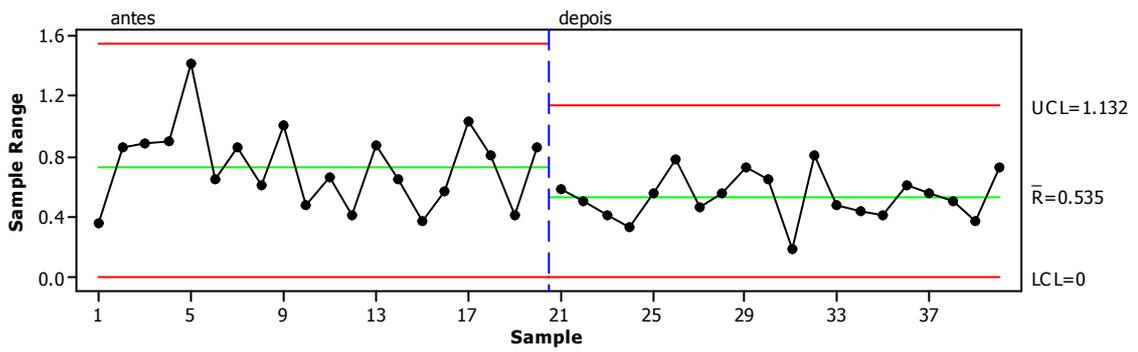
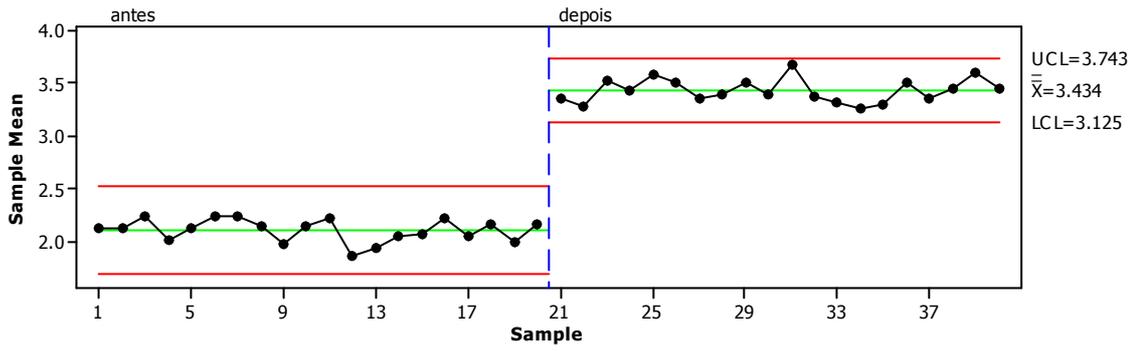


Figura D.3 – Cartas de controle comparando baseline e melhoria em *R* (reforço)

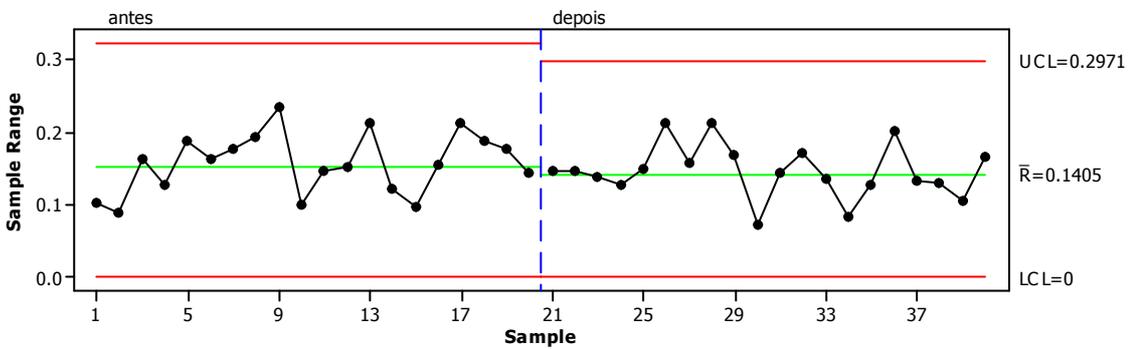
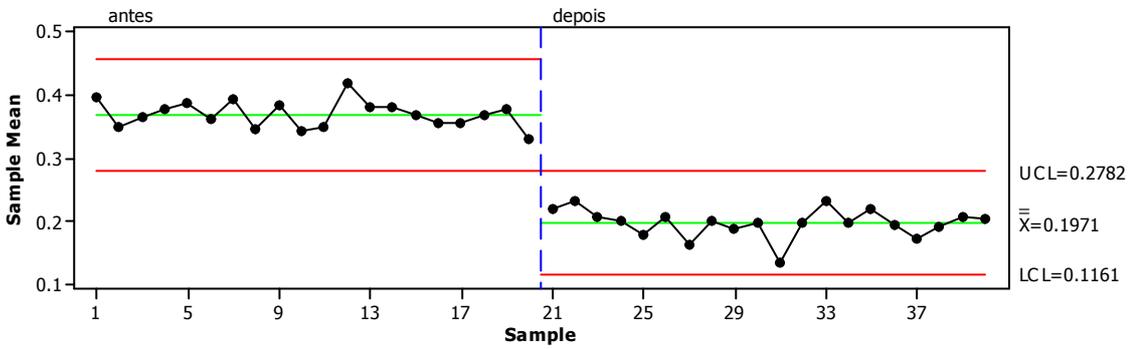


Figura D.4 – Cartas de controle comparando baseline e melhoria em *D* (diluição)

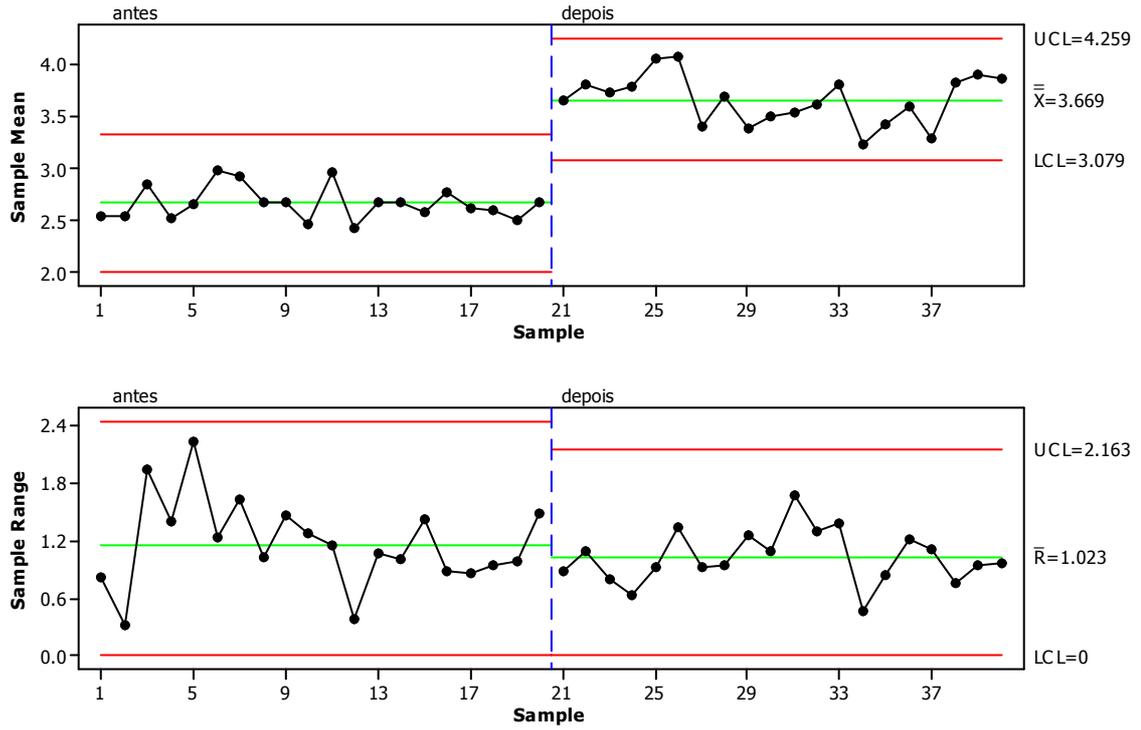


Figura D.5 – Cartas de controle comparando baseline e melhoria em TD (taxa de deposição)

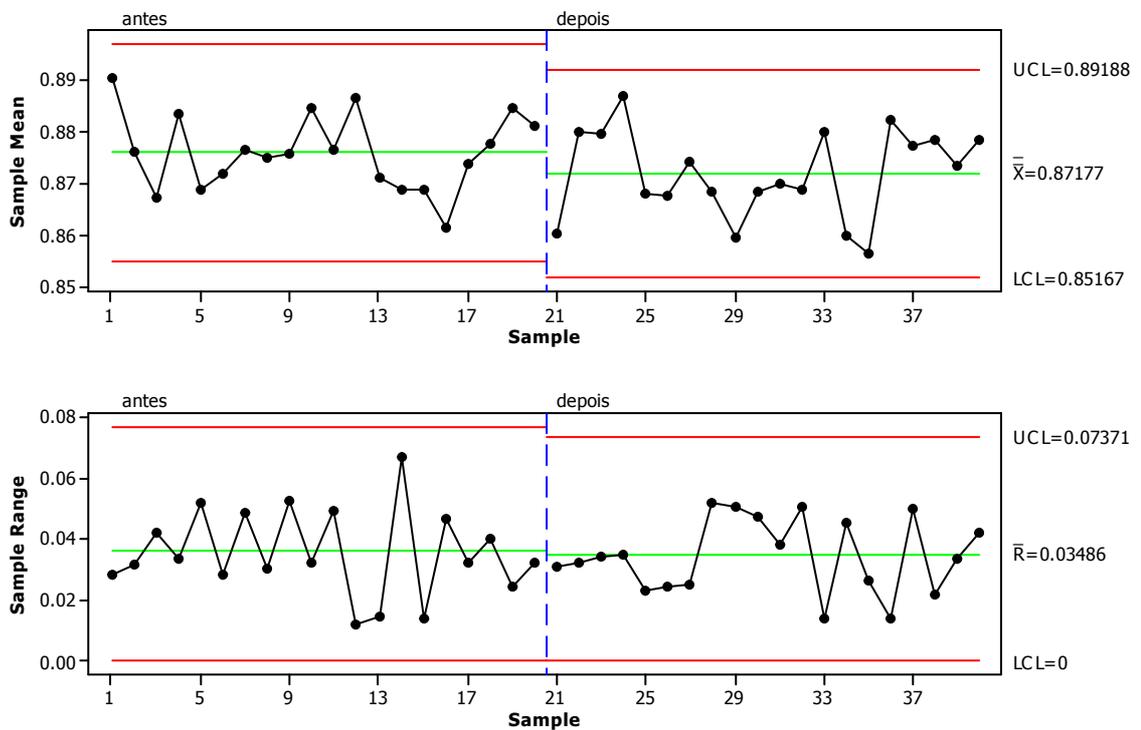


Figura D.6 – Cartas de controle comparando baseline e melhoria em η (rendimento)