

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
MESTRADO PROFISSIONALIZANTE EM ENGENHARIA**

**IMPLANTAÇÃO DA METODOLOGIA SEIS SIGMA E APLICAÇÃO DA TÉCNICA
ESTATÍSTICA PROJETO DE EXPERIMENTOS NA RESOLUÇÃO DE
PROBLEMAS E OTIMIZAÇÃO DE PROCESSOS DE FABRICAÇÃO**

Luis Antonio Usevicius

Porto Alegre/RS
2004

LUIS ANTONIO USEVICIUS

**IMPLANTAÇÃO DA METODOLOGIA SEIS SIGMA E APLICAÇÃO DA TÉCNICA
ESTATÍSTICA PROJETO DE EXPERIMENTOS NA RESOLUÇÃO DE
PROBLEMAS E OTIMIZAÇÃO DE PROCESSOS DE FABRICAÇÃO**

Trabalho de Conclusão do Curso de Mestrado Profissionalizante em Engenharia como requisito parcial à obtenção do título de Mestre em Engenharia – modalidade Profissionalizante – Ênfase Engenharia de Produção, Universidade Federal do Rio Grande do Sul.

Orientador: Professor Phd. Flávio S. Fogliatto

Porto Alegre/RS

2004

LUIS ANTONIO USEVICIUS

IMPLANTAÇÃO DA METODOLOGIA SEIS SIGMA E APLICAÇÃO DA TÉCNICA
ESTATÍSTICA PROJETO DE EXPERIMENTOS NA RESOLUÇÃO DE PROBLEMAS E
OTIMIZAÇÃO DE PROCESSOS DE FABRICAÇÃO

Este Trabalho de Conclusão foi analisado e julgado adequado para a obtenção do título de Mestre em Engenharia e aprovado em sua forma final pelo Orientador e pelo Coordenador do Mestrado Profissionalizante em Engenharia, Escola de Engenharia - Universidade Federal do Rio Grande do Sul.

Prof. Flávio S. Fogliatto, Phd

Orientador Escola de Engenharia/UFRGS

Profa. Helena Beatriz Bettella Cybis, Dra.

Coordenadora MP/Escola de Engenharia/UFRGS

BANCA EXAMINADORA

Prof. Dra. Istefani de Paula

ULBRA

Prof. Dr. José Luis Ribeiro

PPGEP/UFRGS

Prof. Dra. Márcia Echeveste

D. ESTATÍSTICA/UFRGS

Dedico esta dissertação a minha esposa Luciana e a meus filhos Antonia e Arthur, pelo amor, paciência e compreensão na execução deste trabalho.

A meus pais Antonio e Martha pela dedicação, educação, pelo compartilhar e pela numerosa família, meus irmãos e irmãs.

AGRADECIMENTOS

Agradeço aos professores e administração do PPGEF, pela competência e dedicação em transmitir um ensino de qualidade, uma expectativa gerada na aula inaugural e plenamente atendida. Este ensino e dedicação motivaram a produzir a dissertação, tarefa não fácil, porém compensadora, à medida que foi produzindo aprendizado e aplicação de conhecimento prático tornando o desafio diário de resolução de problemas, mais fácil e agradável.

Agradeço a meu orientador Prof. Flávio Fogliatto, pela presteza na correção e orientação do trabalho, pelas constantes críticas e principalmente pela dedicação ao ensino.

Quero agradecer a minha esposa Luciana e meus dois filhos, Antonia e Arthur nascidos durante a execução da dissertação, pelo confortante amor e carinho recebido em todos os momentos.

Agradeço a Deus e a meu Senhor Jesus Cristo em quem tenho força, alegria e motivação em todas as coisas.

Buy the truth and do not sell it; get wisdom, discipline and understanding [...] for wisdom is more precious than rubies, and nothing you desire can compare with her”; “The fear of the Lord is the beginning of wisdom; all who follow his precepts have good understanding [...].

Proverbs 23:23, 8:11; Psalms 111:10.

RESUMO

Esta dissertação apresenta a aplicação da metodologia Seis Sigma em um projeto de redução de custos variáveis de produção no processo de fabricação usinagem de uma indústria automotiva do estado do Rio Grande do Sul. O projeto faz parte da certificação de *Black Belts* promovida na empresa analisada. São apresentados propostas metodológicas, conceituação, aspectos de treinamento, indicadores e ferramentas estatísticas para implantação do programa Seis Sigma. É analisado o efeito do retrabalho nos processos através do conceito de “fábrica escondida” e também o efeito da prevenção e eliminação de defeitos. A técnica estatística enfatizada é o Projeto e Análise de Experimentos (PAE), onde são apresentados modelos para o planejamento e condução do projeto de experimentos. São revisadas análises de variância, ANOVA, experimentos fatoriais de dois ou mais fatores, experimentos fatoriais fracionados e regressão, sendo introduzido também o método de superfície de resposta. O programa Seis Sigma é desdobrado através de um estudo de caso utilizando a metodologia PDCA, em que a aplicação das ferramentas estatísticas e a passagem entre fases do ciclo PDCA é estruturada através de um caminho (*roadmap*), denominado mapa de raciocínio. O planejamento do PAE é apresentado através do mapeamento dos processos e através da utilização da planilha de planejamento da otimização experimental de produtos e processos. Chega-se a um modelo de teste de otimização de vida útil do ferramental considerando dois fatores a dois níveis, ou seja, um projeto fatorial 2². A aplicação do modelo atinge o objetivo de redução de custos variáveis de produção através do aumento da vida útil do ferramental de desgaste utilizado no processo de fabricação, usinagem.

Palavras-chave: Metodologia Seis Sigma. Projeto e Análise de Experimentos. Indústria automobilística.

ABSTRACT

This thesis presents the application of the Six Sigma methodology in a cost reduction project implemented in the machining process of an automotive industry in the state of Rio Grande do Sul. The project is part of a Black Belt certification program carried by the company. Different Six Sigma methodologies proposals and concepts, training aspects, Six Sigma metrics and statistical tools are reviewed in order to implement Six Sigma programs. Process rework through the “hidden factory” concept and also the effect of preventing and eliminating defects are analyzed. The main statistical tool emphasized is the design of experiments (DOE). Experiment planning and guiding approaches are presented, as well as ANOVA, factorial experiments of one or more factors, fractional experiments, regression and introduction to response surface methodology. The Six Sigma program is deployed through a case study using the PDCA methodology, where the application of statistical tools and the transition between phases are structured using a roadmap, named thought map. DOE planning is presented using process mapping and the process and product experiment optimization planning spreadsheet. A tool life optimization model experiment is accomplished considering two factors at two levels, a 2^2 factorial experiment. The model applied reached its objective, reducing costs through the increase of tool life in the machining fabrication process.

Key word: Six Sigma methodology. Design and analyses of experiment. Automotive industry.

LISTA DE FIGURAS

Figura 1 - Ciclo DMAIC	18
Figura 2 - Quadro resumo comparativo das metodologias de implantação e a relação das fases propostas pelos autores dentro dos ciclos PDCA e DMAIC.....	20
Figura 3 - Quadro DMAIC e ferramentas utilizadas	23
Figura 4 - Ferramentas Seis Sigma conforme currículo de orientação em manufatura	24
Figura 5 - Quadro DEMAIC incluindo ferramentas.....	25
Figura 6 - Organização da pesquisa-ação	32
Figura 7 - Comparação entre as fases da metodologia pesquisa-ação e programa Seis Sigma.....	33
Figura 8 - Visualização do conceito fábrica escondida	38
Figura 9 - Exemplos de gráficos de controle de processo baseados nos indicadores DPU e RTY	41
Figura 10 - Quadro comparativo entre indicadores Seis Sigma e indicadores tradicionais de desempenho.	42
Figura 11 - Gráfico do ponto de equilíbrio com reta custo-lucro.....	43
Figura 12 - Gráfico do ponto de equilíbrio mostrando o impacto da redução de defeitos	44
Figura 13- Lucro e Perda como função da taxa de defeitos para 1000 CTQ's.....	45
Figura 14 - Fluxo natural do mapa do pensamento	49
Figura 15 - Exemplo de mapa do pensamento para reduzir variabilidade no ângulo do pino	49
Figura 16 - Relacionamento entre ferramentas estatísticas e o mapa do pensamento.....	50
Figura 17 - Exemplo de mapa do processo	51
Figura 18 - Sistema de variáveis do processo.	54
Figura 19 - Gráficos do efeito dos níveis dos fatores X (designados por + ou -) na variável resposta Y	56
Figura 20 - Interação entre dois fatores de um experimento	56
Figura 21 - Experimento fatorial envolvendo dois fatores.....	56
Figura 22 - Fatoriais de dois e três fatores a dois níveis versus OFAT.....	57

Figura 23 - Experimento fatorial 2^3 . Projeção em duas dimensões do cubo.....	58
Figura 24 - Etapas de um experimento.....	61
Figura 25 - Quadro comparativo das propostas de seqüências de projetos de experimentos.....	62
Figura 26 - Fluxo guia para projeto e análise de experimentos.....	63
Figura 27 - Exemplo de diagrama de pontos.....	64
Figura 28 - Exemplo de gráfico box plot.....	64
Figura 29 - Tabela de probabilidade e plotagem <i>half-normal</i>	81
Figura 30 - Interação dos fatores B versus C.....	81
Figura 31: Gráfico da resposta versus nível do fator codificado.....	91
Figura 32 - Plotagem normal dos resíduos e residuais versus valores previstos.....	92
Figura 33 - (a) Representação em árvore do fatorial 2^3 , (b) Partição das respostas para o experimento 2^3	95
Figura 34 - Plotagem de contorno do rendimento como função do tempo e temperatura de reação.....	97
Figura 35 - Projeto composto para 3 fatores.	98
Figura 36 - Contornos de uma superfície entre temperatura e concentração de um determinado produto.....	99
Figura 37 - Estabilidade do produto: (a) peso baixo da peça (20), (b) peso alto da peça (40)...	100
Figura 38 - Estabilidade do produto.....	100
Figura 39 - Geometria e seção transversal de uma ferramenta desgastada.....	103
Figura 40 - Mapa de raciocínio – sub-etapa identificação do problema.....	105
Figura 41 - Mapa de raciocínio – análise do fenômeno.....	106
Figura 42 - Gráfico de Pareto dos gastos DVO.....	106
Figura 43 - Estratificação dos maiores gastos da conta ferramenta.....	107
Figura 44 - Mapa de raciocínio -análise do fenômeno.....	108
Figura 45 - Mapa do raciocínio - análise do fenômeno.....	108
Figura 46 - Gráfico consumo de ferramentas do lado esquerdo da máquina, operação 20.....	109
Figura 47 - Gráfico do consumo de ferramentas do lado direito da máquina, operação 20.....	109
Figura 48 - Mapa de raciocínio - análise do fenômeno.....	110

Figura 49 - Mapa de raciocínio - análise do processo	111
Figura 50 - Mapa de processo da operação 20, primeiro estágio da máquina.....	112
Figura 51 - Mapa do processo da operação 20, segundo estágio da máquina.....	112
Figura 52 - Mapa de raciocínio etapa análise do fenômeno	113
Figura 53 - Mapa de processo de usinagem do bloco na mandriladora	113
Figura 54 - Gráfico de Pareto dos fatores de controle para variável quantidade de blocos	120
Figura 55 - Gráfico do efeito do fator de controle velocidade de corte sobre a variável de resposta quantidade de blocos produzidos.....	121
Figura 56 - Plotagem de probabilidade normal para variável de resposta quantidade	122
Figura 57 - Gráfico de Pareto dos fatores para variável desgaste	122

LISTA DE TABELAS

Tabela 1 - Escala sigma e número de defeitos correspondentes (considerando resultados de um processo centrado no valor nominal).....	37
Tabela 2 - Ilustração do impacto da obtenção de um nível de qualidade seis sigma em comparação com um nível de qualidade quatro sigma.....	37
Tabela 3 - Ênfase das ferramentas conforme a área de aplicação	53
Tabela 4 - Diferenças entre PAE e CEP	55
Tabela 5 - Dados típicos de um experimento de fator simples.....	70
Tabela 6 - Tabela de análise de variância para um fator	73
Tabela 7 - Arranjo geral para projeto fatorial de dois fatores	73
Tabela 8 - Graus de liberdade para experimento fatorial	74
Tabela 9- Tabela ANOVA <i>Two way</i> para modelo de efeitos fixos	75
Tabela 10 - Transformações de dados	78
Tabela 11 - Projeto fatorial completo com três fatores a dois níveis	79
Tabela 12 - Projeto de experimento fatorial completo considerando interações.....	80
Tabela 13 - ANOVA para exemplo	82
Tabela 14 – Fatorial 2^k versus fatorial fracionado.....	83
Tabela 15 - Sinais algébricos para construção de um experimento 2^4	84
Tabela 16 - Resoluções para experimentos a dois níveis	85
Tabela 17 - Estrutura de confundimento para sete fatores em 16 ensaios (somente interações de dois fatores).....	85
Tabela 18 - Matriz para fração principal de um projeto 2^{7-4} ou 2^{6-3}	86
Tabela 19 - Matriz para fração espelho de um projeto 2^{7-4} ou 2^{6-3}	87
Tabela 20 - Experimento fatorial fracionado saturado (interações selecionadas incluídas).....	88
Tabela 21 - Exemplo de saída do projeto da Tabela 20.....	89
Tabela 22 - Segundo bloco de ensaios duplicados (interações selecionadas)	90
Tabela 23 - Residuais para previsão	92

Tabela 24 - Dados exemplo $y = 3A - 4B + 0,25C + N(0,1)$ e $y^* = 3A - 4B + 3AB + 0,25C + N(0,1)$	95
Tabela 25 - Descrição do título, objetivos do projeto, equipe e local de trabalho	114
Tabela 26 - Levantamento das características de qualidade importantes ao cliente	115
Tabela 27 - Variáveis de respostas elencadas pela equipe técnica	115
Tabela 28 - Parâmetros do processo (fatores) selecionados pela equipe técnica	116
Tabela 29 - Fatores de ruído no experimento	116
Tabela 30 - Atribuição das interações e relações	117
Tabela 31 - Atribuição das relações entre fatores e variáveis de resposta	117
Tabela 32 - Atribuição das interações entre fatores	117
Tabela 33 - Priorização dos parâmetros do processo	118
Tabela 34 - Fatores controláveis do experimento.....	118
Tabela 35 – Descrição das variáveis de resposta.....	119
Tabela 36 – Descrição das variáveis de ruído	119
Tabela 37 - Planilha do experimento.....	119
Tabela 38- Análise de variância para quantidade.....	121
Tabela 39 - Análise de variância para desgaste.....	123
Tabela 40 - Capacidade sigma dos processos.....	135
Tabela 41 - Tabela de Conversão Sigma.....	135

SUMÁRIO

1. INTRODUÇÃO	15
1.1 TEMA.....	18
1.2 OBJETIVO GERAL	27
1.3 OBJETIVOS ESPECÍFICOS.....	27
1.4 JUSTIFICATIVA	28
1.5 MÉTODO DE PESQUISA E TRABALHO.....	29
1.6 ESTRUTURA DO TRABALHO.....	34
1.7 LIMITAÇÕES DO TRABALHO.....	34
2 REVISÃO BIBLIOGRÁFICA	36
2.1 TERMINOLOGIA SIGMA E ESCALA SIGMA	36
2.2 FÁBRICA ESCONDIDA E INDICADORES SEIS SIGMA	38
2.3 ECONOMIA DO PROGRAMA SEIS SIGMA	43
2.4 SEIS SIGMA APLICADO A PROCESSOS.....	46
2.4.1 Controle de processos.....	47
2.4.2 Mapa do raciocínio ou pensamento	48
2.4.3 Mapa do processo	51
2.5 TREINAMENTO NO PROGRAMA SEIS SIGMA	52
3 PROJETO E ANÁLISE DE EXPERIMENTOS (PAE)	54
3.1 PRINCÍPIOS BÁSICOS DO PAE	59
3.2 EXPERIMENTOS COMPARATIVOS SIMPLES	63
3.3 MODELO PARA OS DADOS.....	66
3.4 TESTES DE HIPÓTESES	67
3.5 INTERVALOS DE CONFIANÇA.....	68
3.6 ANÁLISE DE VARIÂNCIA (ANOVA – ANALYSIS OF VARIANCE)	69
3.7 TESTE DE HIPÓTESE PARA ANOVA ONE-WAY.....	71

3.8 TABELA DE CÁLCULOS ANOVA.....	72
3.9 ANÁLISE DE VARIÂNCIA A DOIS FATORES (TWO-WAY ANOVA).....	73
3.10 ANÁLISE DE RESÍDUOS.....	75
3.11 ANÁLISE DOS RESÍDUOS: AVALIAÇÃO DE NORMALIDADE	76
3.12 ANÁLISE DOS RESIDUAIS: SEQUÊNCIA DE TEMPO.....	77
3.13 ANÁLISE DOS RESIDUAIS: VALORES AJUSTADOS	77
3.14 EFEITOS DE SIGNIFICÂNCIA E PLOTAGEM DE PROBABILIDADE	78
3.15 EXPERIMENTOS FATORIAIS 2^K COMPLETOS	79
3.16 EXPERIMENTOS FATORIAIS FRACIONADOS	83
3.17 EXPERIMENTOS FRACIONADOS SATURADOS	88
3.18 MODELAMENTO DA RESPOSTA ATRAVÉS DE REGRESSÃO	90
3.19 MÉTODO DE SUPERFÍCIE DE RESPOSTA PARA OTIMIZAÇÃO	96
4 ESTUDO DE CASO: EXEMPLO DE APLICAÇÃO DE PROJETO SEIS SIGMA UTILIZANDO PROJETO DE EXPERIMENTOS.....	101
4.1 VIDA ÚTIL DA FERRAMENTA	102
4.2 PROJETO SEIS SIGMA.....	103
4.2.1 Metodologia utilizada no experimento	104
4.2.2 Etapa planejamento do ciclo PDCA (P)	104
4.2.2.1 <i>Identificação do problema</i>	104
4.2.2.2 <i>Análise do Fenômeno</i>	106
4.2.2.3 <i>Análise do processo</i>	110
4.2.3.4 <i>Estabelecimento do plano de ação</i>	123
5 CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS.....	125
REFERÊNCIAS	130
APÊNDICE A - Ferramentas da qualidade utilizadas no programa Seis Sigma.....	134
ANEXO A - Conversão de processos para escala seis sigma.....	135

1. INTRODUÇÃO

A crescente popularidade do programa Seis Sigma deve-se aos casos de aplicações bem sucedidas em grandes corporações, como a Motorola e General Electric. Tais aplicações transformaram o Seis Sigma em uma das poucas iniciativas de orientação técnica a gerar interesse significativo na comunidade financeira, na mídia e na liderança das grandes corporações (HOERL, 2001).

Parte da popularidade do programa é devido ao seu foco na redução de custos e na melhoria da lucratividade. Essa melhoria é obtida através do rastreamento e eliminação das causas raízes dos defeitos, assim como da melhoria da eficiência em todas as operações, a partir do chão de fábrica até os níveis gerenciais (BISGAARD; FREIESLEBEN, 2001). O programa Seis Sigma incluem métodos específicos que recriam o processo de modo que defeitos e erros nunca apareçam (HARRY; SCHROEDER, 2000). A eliminação de erros em processos e produtos no Seis Sigma envolve a medição e melhoria da capacidade do processo na produção de itens conformes (INGLE ; ROE, 2001).

Os métodos de Taguchi produziram fruto no programa Seis Sigma (ANDERSON; KRABER, 2002). Os programas de qualidade anteriores ao Seis Sigma focavam na conformidade às especificações do produto, mesmo que isso implicasse em retrabalho, refugo, testes e inspeção final. Tais programas consideravam geralmente o fato de um produto ou serviço ser constituído de um único elemento (HARRY; SCHROEDER, 2000). Na visão do Seis Sigma, conforme proposto por Taguchi na redução de variabilidade do processo (ANDERSON; KRABER, 2002) um produto ou serviço é composto por vários elementos que individualmente podem atender as especificações, mas que, uma vez utilizados em conjunto, podem não atender as especificações devido ao somatório das variações dos componentes individuais (HARRY; SCHROEDER, 2000).

A Motorola, primeira empresa a adotar o programa, focou na redução da variabilidade no produto e processo para prevenção de defeitos (SANDERS; HILD, 2001). A idéia básica do Seis Sigma é continuamente reduzir as variações dos processos e produtos. Aparentemente pequenas variações nas condições ambientais, operador, matéria-prima e maquinário podem causar problemas de qualidade significativos (INGLE; ROE, 2001).

Freqüentemente, os indicadores de desempenho real de empresas e processos são descritos em termos de médias. Exemplos são o custo médio, tempo de ciclo médio e tempo médio de entrega de um item ou processo. O desempenho do processo expresso em termos de valores médios pode esconder problemas, por não considerar a variação inerente ao processo (BISGAARD; FREIESLEBEN, 2001).

Os conceitos fundamentais do Seis Sigma consideram o fato de que a variação dos produtos e processos deve ser conhecida por ser um fator que afeta tempos de fabricação, custos de produto e processo, qualidade do produto e, finalmente, a satisfação do cliente. A etapa crucial do Seis Sigma consiste na definição e medição da variação dos processos com o objetivo de descobrir suas causas, desenvolvendo meios operacionais eficientes para controlar e reduzir esta variação (SANDERS; HILD, 2001).

A proposta do programa Seis Sigma é a lucratividade da empresa como um todo, ampliando a visão de produto, serviço e do processo gerador do produto e ou serviço.

A estratégia de aplicação do programa Seis Sigma envolve o uso de técnicas estatísticas dentro de uma metodologia estruturada, a fim de adquirir o conhecimento necessário para a obtenção de produtos ou serviços mais baratos, melhores e mais rápidos do que a concorrência (BREYFOGLE, 1999).

Os resultados esperados a partir da adoção de um programa Seis Sigma são (SANDERS; HILD, 2001): a) desenvolvimento de produtos mais robustos de forma mais rápida, b) obtenção de processos de manufatura mais eficientes e capazes, c) obtenção de um resultado financeiro global mais confiável.

Segundo Pande *et al.* (2001), os benefícios do Seis Sigma são: a) visão de processos e controle, relacionando as variáveis do mesmo com os resultados, sejam objetivos estratégicos, como lucro ou requisitos dos clientes; conhecimento de quais variáveis no processo tem maior influência, monitoramento das mesmas e tomada de ação para correção e melhoria dos resultados do processo; b) determinar uma meta de desempenho comum aos diferentes processos, comparando-os com a capacidade Seis Sigma, ou seja, 99,9997% produtos conformes; c) acelerar a taxa de melhoria; d) promover aprendizagem; e) executar mudanças estratégicas.

Para a obtenção dos resultados do Seis Sigma, a implantação com sucesso do programa envolve conforme Sanders e Hild (2001): a) desenvolvimento do pensamento crítico e da integração do conhecimento e experiência atuais com as ferramentas do Seis Sigma; b)

educação do gerenciamento na filosofia, métodos, aplicações e seus papéis; c) suporte para metas estabelecidas como meios, oportunidades, e mecanismos para atendê-las; d) integração de todas as iniciativas concorrentes e comunicação através da organização sobre como cada iniciativa se alinha com os planos e objetivos estratégicos; e) tradução dos objetivos internos e relacionamento com as necessidades dos clientes externos; f) alinhamento das metas dos projetos com as metas do departamento e então com as metas da organização; g) valorização e recompensa no atendimento de conhecimento sobre o processo/produto além do atendimento de economia em um projeto.

Segundo Bisgaard e Freiesleben (2001) o programa Seis Sigma é baseado fortemente no uso de métodos estatísticos para entender o resultado e comportamento do processo e produto. Tais métodos são bem conhecidos (SANDERS; HILD, 2000), porém o programa Seis Sigma criado pela Motorola trouxe outras características que o tornaram único e novo.

A Motorola criou um pacote eficiente de ferramentas de análise de dados e resolução de problemas dentro de um processo de solução de problemas. Este pacote foi ensinado a uma grande parte da força de trabalho (SANDERS; HILD, 2000). Os funcionários que foram treinados e experimentados na aplicação das técnicas estatísticas aos processos de negócio receberam o título de *Black Belt* (Faixa Preta) (CHASE, 1999).

Hoerl (2001) focaliza nos *Black Belts* como sendo a estrutura técnica necessária na implantação dos programas Seis Sigma. Ele propõe uma discussão do currículo para a formação de *Black Belts*, define os tipos de projetos envolvidos e habilidades necessárias para este trabalho e propõe comparações com os currículos de Engenheiro da Qualidade e Mestre em Estatística. As proposições de Hoerl são amplamente discutidas por Montgomery *et al* (2001), Abraham e Mackay (2001), Snee (2001), Pyzdek (2001), Hill (2001), Bailey (2001), Breyfogle *et al.* (2001).

Atualmente, a implantação da metodologia e a formação de *Black-Belts* encontram-se difundidas através de consultorias, ou através de cursos de extensão universitária.

1.1 TEMA

O tema central desta dissertação é o programa Seis Sigma. Dois assuntos específicos dentro do tema central são enfocados: a) propostas metodológicas para a implantação prática dos programas Seis Sigma disponíveis na literatura, e b) técnicas estatísticas de apoio recomendadas na implantação.

Referente ao item (a) as propostas metodológicas focam em projetos de melhoria contínua baseados em técnicas estatísticas voltados para o atendimento do nível de qualidade Seis Sigma. O ciclo de melhoria amplamente utilizado no Seis Sigma, denominado de Definir-Medir-Analisar-Melhorar-Controlar (DMAIC), (ver Figura 1), é baseado no ciclo de melhoria Planejar-Executar-Verificar-Agir (PDCA).

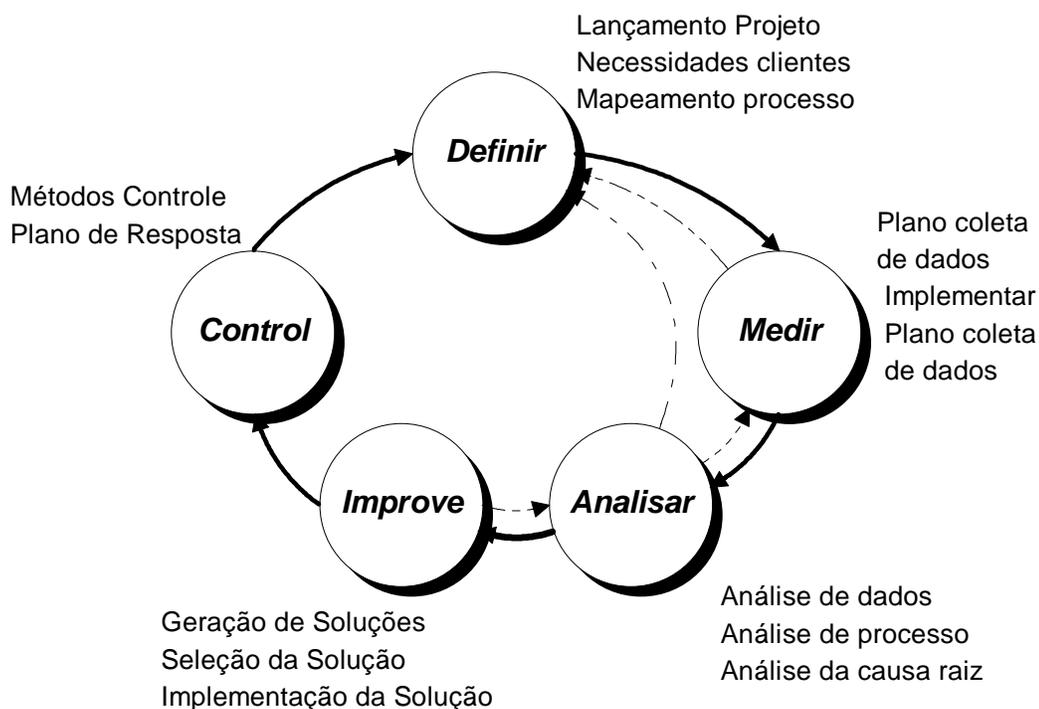


Figura 1 - Ciclo DMAIC
Fonte: ECKES, 2003.

Os programas de qualidade anteriores ao Seis Sigma utilizavam uma abordagem tradicional de solução de problemas, baseada na aplicação do ciclo de melhoria PDCA e de ferramentas de Análise e Solução de Problemas da Qualidade (WERKEMA, 2000).

O Seis sigma aprimora a abordagem tradicional propondo a resolução de problemas dividida em etapas bem distintas dentro do ciclo PDCA, ou DMAIC, com a utilização de ferramentas estatísticas específicas. As quatro etapas propostas por Werkema (2000) são: a) identificação do problema; b) análise do fenômeno; c) análise do processo; d) análise das alternativas estratégicas e estabelecimento do plano de ação.

Harry e Schroeder (2000) e Pande *et al.* (2001), definem como metodologia de implantação um Mapa (*Six Sigma Road Map*), dividido em estágios onde são inseridas as fases do ciclo DMAIC. Harry e Schroeder (2000) incluem ao DMAIC, três fases, R-Reconhecer, S-Padronizar, I-Integrar formando o acrônimo RDMAICSI. A proposta do Mapa é definir um passo a passo de implantação do programa. Os estágios no Mapa propostos por Harry e Schroeder (2000) são identificação, caracterização, otimização e institucionalização.

Para Pande *et al.* (2001), os estágios no Mapa são: a) identificar processos essenciais e clientes-chave; b) definir necessidades de clientes; c) medir o desempenho atual; d) priorizar, analisar e implementar melhorias; e) expandir e integrar o sistema Seis Sigma.

As propostas metodológicas de Harry e Schroeder e Pande *et al.* são muitos similares. Ambos autores focalizam o programa nas principais necessidades dos clientes, para só então definirem os projetos Seis Sigma a serem desenvolvidos pelos *Black Belts*, enquanto Werkema focaliza diretamente nos projetos de resolução de problemas, sendo que estes devem estar alinhados com as metas da empresa. Os projetos Seis Sigma podem ser projetos de redução de custo, de melhoria da qualidade, de otimização de recursos, dependendo do enfoque a ser dado pela empresa. A Figura 2 apresenta um resumo comparativo das metodologias do programa Seis Sigma.

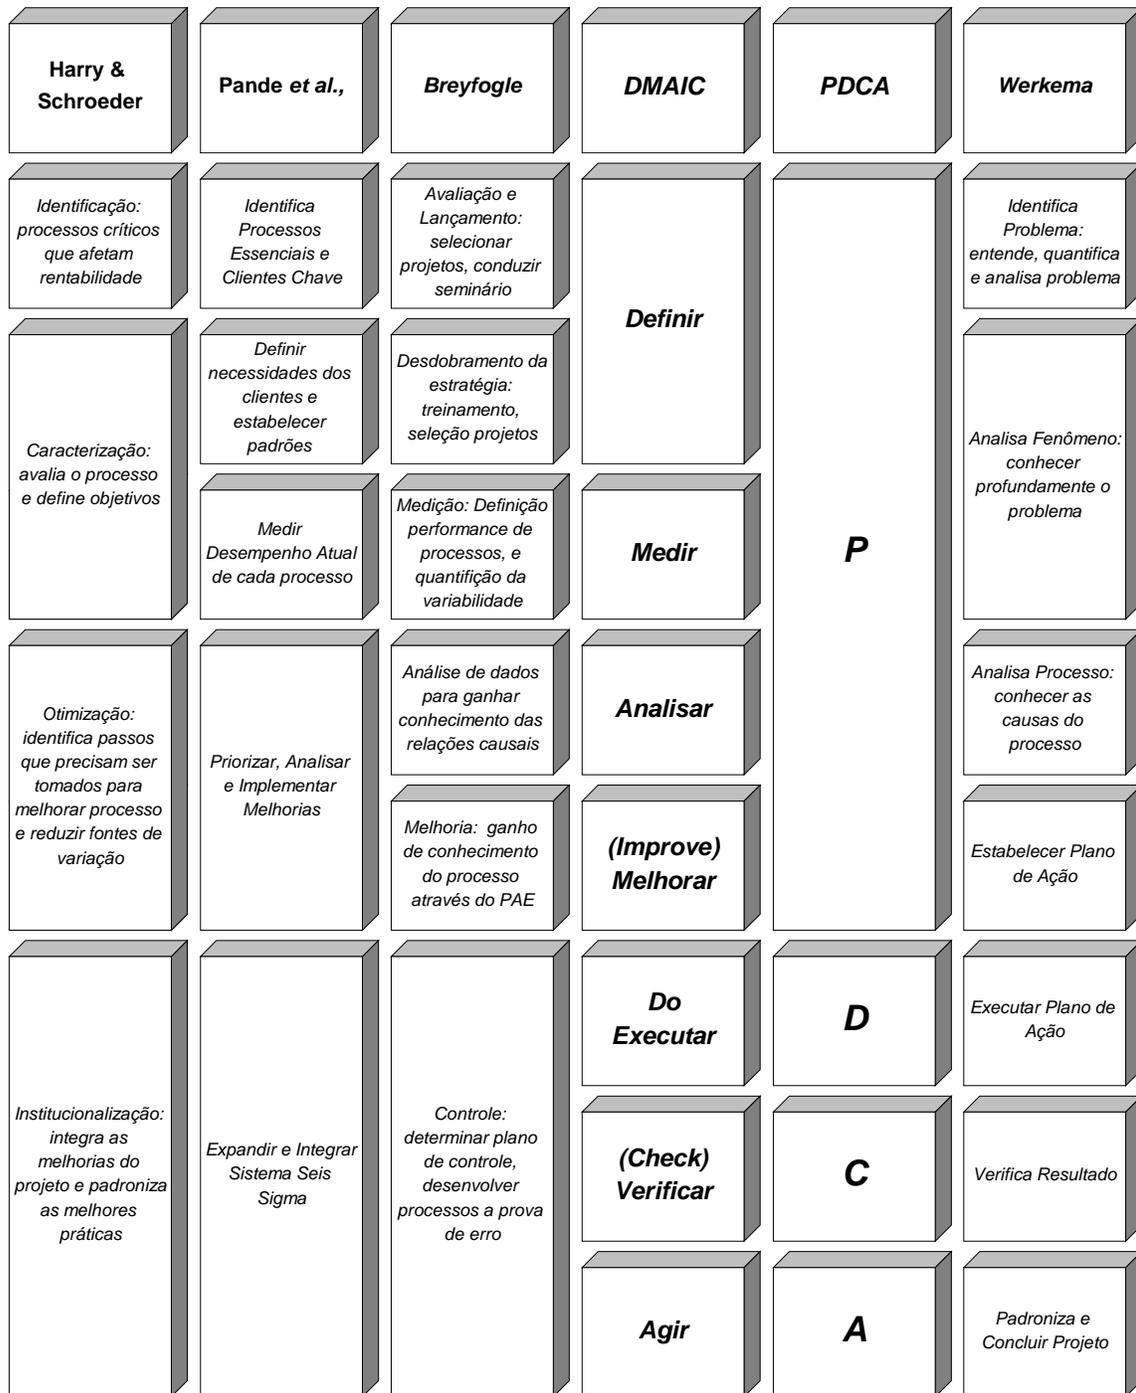


Figura 2 - Quadro resumo comparativo das metodologias de implantação e a relação das fases propostas pelos autores dentro dos ciclos PDCA e DMAIC.

Relativamente ao item (b), ferramentas estatísticas de apoio dá-se especial destaque à proposta de utilização do projeto de experimento no contexto do programa Seis Sigma.

As principais ferramentas estatísticas normalmente propostas nas metodologias de implantação do programa Seis Sigma podem ser encontradas dentro de 4 grupos do currículo do programa de Certificação de Engenheiro da Qualidade (*Certified Quality Engineer Body of Knowledge*) (HOERL, 2001):

- a) planejamento, controle, garantia do produto e qualidade de processos:
 - amostragem,
 - análise do sistema de medição;
- b) confiabilidade e gerenciamento de risco:
 - FMEA,
 - FTA;
- c) melhoria da qualidade e resolução de problemas:
 - ferramentas de gerenciamento e planejamento (Diagramas de Afinidade, Diagrama de Árvore, Diagrama de Matriz),
 - ferramentas da qualidade (Gráfico de Pareto, Diagramas de Causa e Efeito, Gráficos de Controle, Folhas de Verificação, Histogramas);
- d) métodos quantitativos:
 - aquisição e resumo de dados;
- e) métodos gráficos:
 - representando relações (Diagramas de Dispersão),
 - representando distribuições (Histogramas, Plotagem de Probabilidade),
 - tomada de decisão estatística,
 - teste de hipótese,
 - análise de variância,
 - regressão;
- f) projeto e análise de experimentos;

- g) controle estatístico do processo;
- h) análise da capacidade do processo.

Algumas ferramentas não-estatísticas de outras disciplinas são utilizadas. As ferramentas também podem ser organizadas conforme o currículo de treinamento para formação de *Black-Belts*, que é normalmente dividido em 4 semanas de acordo com as fases do Seis Sigma pelo método DMAIC (HAHN *et al.*, 1999):

- a) semana 1: Visão geral do Seis Sigma & Mapa MAIC, Mapeamento de Processo, QFD, FMEA, Conceitos de Eficácia Organizacional, Estatística Básica, Capacidade de Processo, Análise do Sistema de Medição;
- b) semana 2: Revisão tópicos semana 1, raciocínio estatístico, Teste de Hipóteses e Intervalos de Confiança, Correlação, Análise Multivariada e Regressão;
- c) semana 3: ANOVA, PAE: experimentos fatoriais, experimentos fracionados, projetos de blocos balanceados, Projeto de Superfície de Resposta, Regressão Múltipla;
- d) semana 4: Planos de Controle, Mecanismos a prova de erro, Desenvolvimento de Equipe, Processo Contínuo, Administração, e Rastreamento de Projetos, Exercício final.

Algumas empresas adicionaram a fase Definir no início para garantir que os projetos sejam corretamente escolhidos. Este currículo corresponde aproximadamente a 160 horas, dividido em quatro meses. São quatro semanas com espaçamento de um mês. A seguir a disposição das ferramentas propostas em cada fase segundo Werkema (2000), conforme PDCA:

- a) fase definir ou identificar o problema: Métrica Seis Sigma, Gráficos Seqüenciais, Carta de Controle, Análise de Séries Temporais, Análise Econômica, Mapa de Raciocínio;
- b) fase medição ou conhecer o problema: Análise de Sistema de Medição, Estratificação, Plano para Coleta de Dados, Folha de Verificação, Amostragem, Diagrama de Pareto, Histograma, *Boxplot*, Capacidade de Processo, Análise Multivariada;
- c) fase analisar ou conhecer o processo: Fluxograma, Mapa de Processo, Mapa de Produto, FMEA, FTA, *Brainstorming*, Diagrama de Dispersão, Diagrama de Causa

e Efeito, Diagrama de Afinidades, Testes de Hipóteses, Análise de Variância, Planejamento e Análise de Experimentos (PAE), Análise de Tempos de Falha, Testes de Vida Acelerado, Regressão;

- d) fase melhorar ou propor plano de ação: Matriz de Priorização, Pesquisa de Mercado (Testes de Mercado), Pesquisa Operacional, Operação Evolutiva (EVOP), Diagrama de Processo Decisório (PDPC), Diagrama de *Gantt*;
- e) fase controle ou verificação do resultado: Procedimento Operacional Padrão, *Poka-Yoke*, Relatório de Anomalias, Plano de Ação.

Hiltsdorf (2002) propõe o ciclo DMAIC, incluindo QFD na fase Definir (Figura 3).

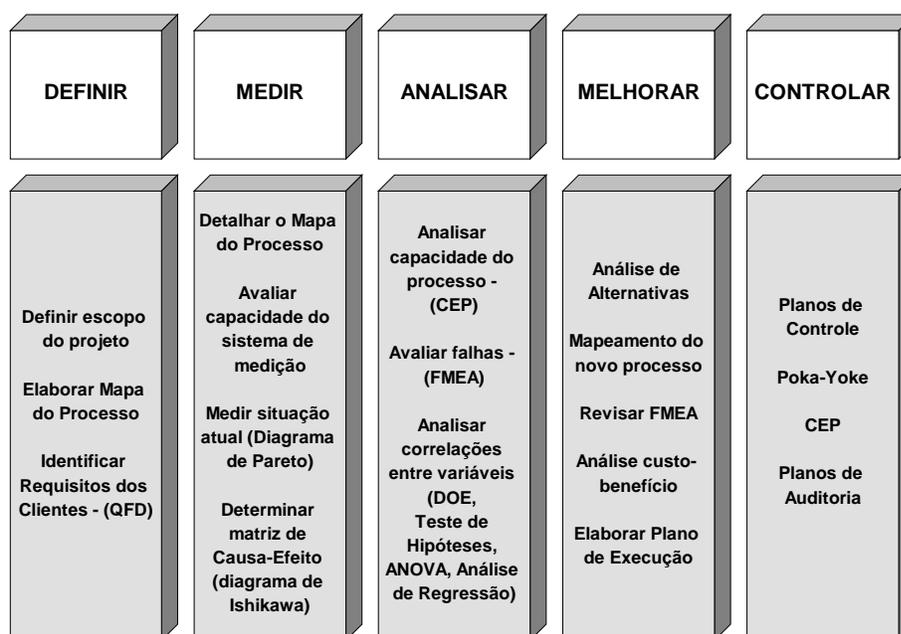


Figura 3 - Quadro DMAIC e ferramentas utilizadas
 Fonte: HILSDORF, 2002.

Hoerl (2001) inclui as ferramentas estatísticas de apoio em uma proposta de currículo de formação de *Black Belts*, com orientação em manufatura baseado no ciclo DMAIC (Figura 4). Hoerl inclui *Design for Six Sigma* (DFSS), e gerenciamento de projetos na fase Contextualização.

Contextualização	Definir	Medir
<p>Porque Seis Sigma</p> <p>Processos DMAIC & DFSS</p> <p>Fundamentos de gerenciamento de Projetos</p> <p>Fundamentos de Eficiência de Equipe</p>	<p>Seleção de Projetos</p> <p>Escopo de Projetos</p> <p>Desenvolvimento de plano de projeto</p> <p>Projetos multi-geradores</p> <p>Identificação de Processos (SIPOC)</p>	<p>QFD</p> <ul style="list-style-type: none"> - Identificar necessidades clientes - Desenvolver métricas críticas para qualidade (CTQ's) <p>Amostragem (quantidade e qualidade de dados) Análise dos Sistemas de Medição</p> <p>CEP - Parte I</p> <ul style="list-style-type: none"> - Conceito do controle estatístico (estabilidade do processo) - As implicações da instabilidade nas medidas de capacidade <p>Análise de Capacidade</p>
Analisar	Melhorar (Improve)	Controlar
<p>Ferramentas Gráficas Básicas de Melhoria</p> <p>Ferramentas de Planejamento e Gerenciamento</p> <p>Intervalos de Confiança</p> <p>Teste de Hipótese ANOVA</p> <p>Regressão</p> <p>Desenvolvimento de Projetos conceituais em DFSS</p>	<p>DOE (foco em fatorial 2 níveis, projetos de screening, e RSM)</p> <p>FMEA</p> <p>Monitoramento (das melhorias do DMAIC)</p> <p>Poka-yoke</p> <p>Ferramentas de Projeto DFSS</p> <ul style="list-style-type: none"> - fluxo CTQ - fluxo de Capacidade - simulação 	<p>Desenvolvimento de Plano de Controle</p> <p>CEP Parte II</p> <ul style="list-style-type: none"> - utilização de gráficos de controle <p>Monotiramento de novos projetos em DFSS</p>

Figura 4 - Ferramentas Seis Sigma conforme currículo de orientação em manufatura
Fonte: HOERL, 2001.

Werkema (2001) propõe a utilização de ferramentas estatísticas conforme Figura 5, através do ciclo DMAIC.

D	M	A	I	C
		<i>Determinar as causas do Problema prioritário</i>		<i>Garantir que o alcance da meta seja mantido a longo prazo</i>
		Fluxograma		
		Mapa de Processo		
		Mapa de Produto	<i>Propor, avaliar e implementar soluções para o problema prioritário</i>	Avaliação de Sistema de Medição/Inspeção (MSE)
		Análise do Tempo de Ciclo		Diagrama de Pareto
	<i>Determinar a localização ou foco do problema</i>	FMEA / FTA	Brainstorming	Carta de Controle
	Avaliação de Sistema de Medição/Inspeção (MSE)	Avaliação de Sistema de Medição/Inspeção (MSE)	Diagrama de Causa e Efeito	Histograma
<i>Definir com precisão o escopo do projeto</i>	Estratificação	Histograma	Diagrama de Afinidades	Índices de Capacidade
Mapa de Raciocínio	Plano para Coleta de Dados	<i>Boxplot</i>	Diagrama de Relações	Métricas Seis Sigma
Project Charter	Folha de Verificação	Estratificação	Diagrama de Matriz	Procedimentos Padrão
Métricas do Seis Sigma	Amostragem	Diagrama de Dispersão	Matriz de Priorização	Poka-Yoke
Gráfico Sequencial	Diagrama de Pareto	Cartas "Multi-Vari"	FMEA	Manuais
Carta de Controle	Métricas do Seis Sigma	<i>Brainstorming</i>	<i>Stakeholder Analysis</i>	Reuniões
Análise de Série Temporais	Gráfico Sequencial	Diagrama de Causa e Efeito	Testes de Operação	Palestras
Análise Econômica (suporte da Contabilidade)	Carta de Controle	Diagrama de Afinidades	Testes de Mercado	<i>OJT (On the Job Training)</i>
Voz do Cliente SIPOC	Análise de Série Temporais	Diagrama de Relações	Simulação	Plano p/Coleta de Dados
	Histograma	Diagrama de Matriz	Operação Evolutiva (EVOP)	Folha de Verificação
	<i>Boxplot</i>	Matriz de Priorização	Testes de Hipóteses	Amostragem
	Índice Capacidade	Carta de Controle	<i>5W2H</i>	Carta de Controle
	Análise Multivariada	Análise de Regressão	Diagrama de Ávore	Histograma
		Testes de Hipótese	Diagrama de Gantt	Índices de Capacidade
		Análise de Variância	<i>PERT/CPM</i>	Aud. do Uso dos Padrões
		Planejamento de Experimentos	Diagrama do Processo Decisório (PDPC)	Relatórios de Anomalias
		Análise de Tempos de Falhas		<i>OCAP (Out of Control Action Plan)</i>
		Testes de Vida Acelerado		

Figura 5 - Quadro DEMAIC incluindo ferramentas
Fonte: WERKEMA, 2001.

A ênfase ou inclusão de determinada ferramenta depende da orientação do currículo, seja na área financeira, ou de manufatura. No currículo existe um treinamento formal no ciclo DMAIC ou PDCA, com o objetivo integrar as várias ferramentas nos processos de melhoria

Seis Sigma. Uma razão principal do porquê o Seis Sigma não é uma coleção de ferramentas estatísticas é o papel importante do *Black Belt* dentro da estratégia de implantação do programa (HOERL, 2001). Um exemplo é o currículo da GE nas organizações financeiras. O curso é voltado para pessoas com experiência anterior em finanças, que aplicarão os projetos Seis Sigma em processos de finanças, negócios gerais e comércio eletrônico. O Projeto e Análise de Experimentos (PAE) têm sido muito aplicados em finanças (estudo de preço). O PAE e CEP são comuns em todos os currículos, variando a profundidade de aplicação. Na GE há redução no tratamento de probabilidade estatística básica, dando mais ênfase em técnicas gráficas (*scatter plot, boxplot*) (HOERL, 2001).

A ferramenta de especial interesse nesta dissertação é o PAE. Montgomery (2000) considera uma ferramenta criticamente importante na engenharia para a melhoria dos processos de manufatura e também no desenvolvimento de novos processos. A aplicação antecipada das técnicas de projeto de experimentos em processos de desenvolvimento pode resultar em:

- a) melhoria da eficiência dos processos;
- b) redução de variabilidade e conformidade mais próxima da nominal;
- c) redução de tempo de desenvolvimento;
- d) redução de custos globais.

Montgomery (2001) define PAE, como o processo de planejamento do experimento para que os dados apropriados que podem ser analisados por métodos estatísticos sejam coletados, resultando em conclusões objetivas e válidas. O uso do Projeto e Análise de Experimentos é necessário quando se deseja extrair conclusões significativas dos dados. Quando o problema envolve dados que estão sujeitos a erros experimentais, a metodologia estatística é o único modo objetivo de análise. Existem dois aspectos em qualquer problema experimental: o projeto do experimento e a análise estatística dos dados.

Para Juran (1988), um projeto de experimentos pode ser utilizado para entendimento do relacionamento das múltiplas variáveis do processo e os resultados associados no produto. Para Echeveste e Ribeiro (1999), é uma técnica estatística eficiente para estudar os efeitos das variáveis que interferem em um processo. O projeto de experimento pode auxiliar de duas formas importantes: a) permite analisar estruturadamente problemas complexos e b) diminui o tempo de procura de uma solução.

Segundo Breyfogle (1999), as técnicas de projeto de experimento proporcionam um método estruturado para alterar simultaneamente as variáveis de um processo e observar os resultados com relação a melhorias e/ou degradações. Os experimentos podem incluir todas as combinações possíveis de um conjunto de variáveis de entrada de um processo, ou um subconjunto de todas as combinações.

1.2 OBJETIVO GERAL

O objetivo principal desta dissertação de mestrado é apresentar os conceitos fundamentais associados ao programa Seis Sigma e ilustrar a sua aplicação em um estudo de caso na indústria metal-mecânica, enfatizando a utilização do projeto de experimentos, na solução de problemas, melhoria da qualidade de produtos e otimização dos processos de fabricação.

1.3 OBJETIVOS ESPECÍFICOS

- a) apresentar um estudo comparativo entre as metodologias Seis Sigma;
- b) detalhar a utilização da ferramenta estatística de Projeto e Análise de Experimentos, conforme proposta na metodologia Seis Sigma, e ilustrar a sua aplicação na melhoria e otimização dos processos através de um estudo de caso em uma empresa do setor metal-mecânico;
- c) apresentar o desenvolvimento completo de um projeto Seis Sigma em um projeto na indústria metal-mecânica. Com relação a este item, Hoerl (2001) declara que exemplos reais são criticamente importantes para motivação e aprendizado. A apresentação de casos reais completos que ilustrem o fluxo do ciclo DMAIC, e onde as ferramentas estatísticas individuais são integradas são chave no Seis Sigma. Infelizmente a maioria dos casos é confidencial e não podem ser publicados. Segundo Hoerl (2001), os estudantes têm maior dificuldade de entender o fluxo entre as fases da metodologia Seis Sigma do que a aplicação individual das ferramentas.

1.4 JUSTIFICATIVA

O Seis Sigma tem sido identificado como a maior mudança ocorrida na concepção da qualidade contemporânea iniciada por Deming e Juran nos anos 50 (SIQUEIRA CAMPOS, 2003).

Em uma primeira exposição aos conceitos Seis Sigma, nota-se uma forte similaridade com conceitos difundidos em programas de Qualidade Total. De fato, as origens de muitos princípios e ferramentas do Seis Sigma se encontram nos trabalhos seminais de Deming e Juran (PANDE *et al.*, 2001).

Até hoje, vários são os casos de fracassos em implantações corporativas de atividades de melhoria da qualidade e redução de variabilidade, como Zero Defeito, Engenharia de Valor, TQM. Uma das razões foi à incapacidade de alcançarem resultados práticos e mensuráveis nos negócios. O Seis Sigma tem tido sucesso por ter alcançado estes resultados (MONTGOMERY *et al.*, 2001). O resultado do programa Seis Sigma auditado por contadores e auditores, são expressivos, conforme abaixo (HAHN *et al.*, 2001):

- d) Motorola – um bilhão de dólares de economia em três anos e o prêmio Malcom Baldrige;
- e) Allied Signal – acima de dois bilhões de dólares de economia cumulativos desde a introdução do programa;
- f) GE - acima de um bilhão de dólares de economia em 1998, e dois bilhões em 1999.

No Brasil, o grupo Brasmotor reportou ganhos superiores a vinte milhões de reais em 1999, devido ao Programa Seis Sigma (WERKEMA, 2001).

O programa Seis Sigma tem sido discutido no meio acadêmico através do trabalho de Hoerl (2001), que procura definir o conjunto de habilidades específicas do *Black Belt*, atuação e tipos de projetos do *Black Belt* e propõem uma discussão sobre o currículo de formação de *Black Belts* com o de Engenheiro da Qualidade e Mestre em Estatística. Hahn *et al.* (1999) estudam o impacto do programa Seis Sigma no futuro das profissões de estatístico.

Bailey (2001) define as áreas de conhecimento necessárias para engenheiro da qualidade, estatístico e *Black Belt*. Montgomery *et al.* (2001) sugerem uma maior participação das universidades nos Programas Seis Sigma, como uma oportunidade de aproximar indústria e academia, e ambos usufruírem os grandes benefícios potenciais do programa.

1.5 MÉTODO DE PESQUISA E TRABALHO

Adotou-se a metodologia da pesquisa-ação no desenvolvimento do trabalho.

A pesquisa-ação objetiva a resolução e entendimento dos problemas atuantes, não se limitando a uma forma de ação, porém aumentando o conhecimento e o “nível de consciência” das pessoas e grupos envolvidos (THIOLLENT, 2002).

Na pesquisa-ação, o pesquisador desenvolve um papel ativo no equacionamento dos problemas encontrados, no acompanhamento e na avaliação das ações desencadeadas em função dos problemas. A ênfase da pesquisa-ação pode ser dada aos seguintes aspectos: resolução de problemas e produção de conhecimento.

A proposta da pesquisa-ação é estudar dinamicamente os problemas, decisões, ações, negociações, conflitos que ocorrem entre os agentes durante os processos de transformação da situação (THIOLLENT, 2002).

O planejamento da pesquisa-ação é flexível, não seguindo uma série de fases rigidamente ordenadas. Há um ponto de partida, a Fase Exploratória e um ponto de chegada, a Divulgação dos resultados. As tarefas intermediárias, ou temas não são considerados fases, pois poderá haver uma multiplicidade de caminhos na investigação, como outros problemas, mudança de tema e alteração na ordem das tarefas em função de imprevistos que possam ocorrer.

A organização da pesquisa-ação proposta por Thiollent, (2002), segue:

- a) fase exploratória – descobrir o campo da pesquisa, verificar os interessados e suas expectativas, diagnosticar a situação, definir problemas prioritários e eventuais ações. Verificar a viabilidade de intervenção da pesquisa-ação e a estratégia metodológica;
- b) tema da pesquisa – designar o problema prático, a área do conhecimento a ser abordada. É chave para identificar e selecionar as áreas de conhecimento disponíveis;
- c) colocação dos problemas – definir a problemática na qual o tema escolhido faça sentido. Problemas não devem ser triviais. Se coletar três informações fosse necessário para resolver um problema do dia a dia ou para tomar uma decisão rotineira, não seria necessário desencadear um processo de investigação e ação. O problema envolve:

- análise e delimitação da situação atual,
 - delineamento da situação final, em função da desejabilidade e da factibilidade,
 - identificação de todos os problemas a serem resolvidos para permitir a passagem do planejar todas as ações correspondentes para execução e avaliação das ações;
- d) teoria – gerar idéias, hipóteses ou diretrizes para orientar a pesquisa e as interpretações;
- e) hipóteses – explicação provisória que se pretende explorar e demonstrar (HOLANDA; RICCIO, 2000), suposição formulada a respeito de possíveis soluções (THIOLLENT, 2002). Papel da hipótese na organização da pesquisa:
- identificar informações necessárias,
 - evitar dispersão,
 - focalizar determinados segmentos do campo de observação,
 - selecionar os dados;
- f) seminário – acordados os objetivos e problemas a serem examinados, inicia-se a constituição do grupo que irá conduzir a investigação e o conjunto do processo. No seminário é examinada, discutida e tomada ação acerca do processo de investigação. Centralizam-se as informações coletadas e discutem-se as interpretações. São realizadas atas de reunião. Com as informações reunidas e dentro da perspectiva teórica adotada, o seminário elabora diretrizes de pesquisa (hipóteses) e diretrizes de ação submetidas à aprovação dos interessados, que serão testadas na prática. Algumas das principais tarefas do seminário são:
- definir tema e equacionar os problemas para os quais a pesquisa foi solicitada,
 - elaborar a problemática na qual serão tratados os problemas e as correspondentes hipóteses de pesquisa,
 - constituir grupos de estudos e pesquisa e coordenar suas atividades,
 - centralizar informações de diversas fontes e grupos,
 - elaborar as interpretações,
 - buscar soluções e definir diretrizes de ação,
 - acompanhar e avaliar as ações,
 - divulgar resultados pelos canais apropriados;

- g) campo de observação, amostragem e representatividade qualitativa – delimitação do campo de observação, no qual se aplica o tema da pesquisa. Pode ser necessário definir amostras representativas. Existem três posições com relação à necessidade de construir amostras para a observação de parte representativa do conjunto da população: pesquisa sem amostra, considerando a totalidade da população; utilização de amostra, determinando o tamanho da amostra, o controle de sua representatividade e o cálculo de confiabilidade a partir de regras estatísticas e valorização de critérios de representatividade qualitativa;
- h) coleta de dados – realizar entrevistas, questionários para obtenção de informações. Ênfase no questionamento e explicação. Objetivo não é orientar as respostas em função das expectativas dos pesquisadores e sim descondicionar as pessoas para que não respondam com facilidade, isto é como se a resposta fosse um reflexo do senso comum;
- i) aprendizagem – a capacidade de aprendizagem é associada ao processo de investigação. As ações investigadas envolvem produção e circulação de informação, elucidação e tomada de decisões, e outros aspectos supondo uma capacidade de aprendizagem dos participantes;
- j) saber formal / saber informal – estabelecer forma de comunicação e compreensão mútua entre o participante comum que conhece os problemas e o especialista. O saber popular é rico, espontâneo e muito apropriado à situação local e o saber do especialista é incompleto não se adequando a todas as situações;
- k) plano de ação – deve-se concretizar em alguma forma de ação planejada, objetivo de análise, deliberação, e avaliação;
- l) divulgação externa dos resultados – retornar as informações e resultados aos grupos implicados na pesquisa e divulgar externamente a outros setores, mediante acordo prévio dos participantes.

Pelo visto acima a pesquisa-ação inicia com o ciclo de identificação do problema, análise, planejamento da ação, execução e padronização do resultado. Tudo isto através de uma equipe, dotada de conhecimento específico sobre o assunto e uma metodologia. Este time possui uma coordenação através do agente investigador (HOLANDA; RICCIO, 2000).

Para Lewin a pesquisa-ação se constitui em um ciclo de análise, fato-achado, concepção, planejamento, execução e mais fato achado ou avaliação, sendo então, uma repetição deste círculo inteiro de atividades. Cunningham (1993) destaca o aprendizado no relacionamento do investigador com um problema. Aargyris & Schon,

(1991) destacam que as intervenções são uma manipulação experimental e a resolução dos problemas é a meta. No entanto, a maioria dos investigadores de ação concorda que a pesquisa-ação consiste em ciclos de planejamento, ação, reflexão ou avaliação, e mais adiante ação (HOLANDA; RICCIO, 2000, p.4).

As fases da pesquisa-ação utilizadas no trabalho foram a fase exploratória através da definição do projeto pelo nível gerencial da empresa; a colocação dos problemas; o seminário, onde mensalmente o projeto do estudo de caso era revisado; coleta de dados; aprendizagem, através do mapeamento do processo junto a equipe técnica e de operação; plano de ação e divulgação externa dos resultados.

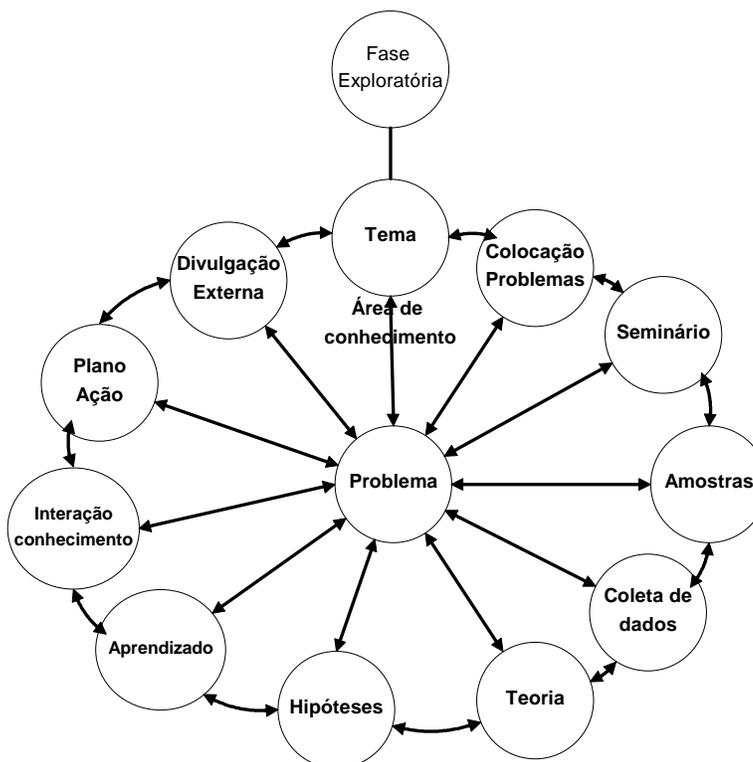


Figura 6 - Organização da pesquisa-ação
Fonte: Adaptado de HOLANDA; RICCIO, 2000.

O processo da pesquisa-ação conforme mostrado acima tem similaridade com os ciclos de melhoria PDCA ou DMAIC utilizados no Seis Sigma. Algumas das ferramentas ou fases de investigação, como coleta de dados, hipóteses, planos de ação são utilizados no Seis Sigma. O papel do investigador na pesquisa-ação e do agente *Black Belt* também é comum na

função, habilidades necessárias e forma de atuação. A implantação do programa Seis Sigma também utiliza seminários conforme proposto por Werkema (2000). A correlação entre as etapas da pesquisa-ação e etapas do programa Seis Sigma está representada na Figura 7.

	Pesquisa-Ação	Seis Sigma
P	Fase Exploratória	Identificação do Problema
	Tema da Pesquisa	
	Colocação dos Problemas	
	Seminário	
	Campo de Observação	Análise do Fenômeno
	Coleta de Dados	
	Teoria	Análise de Processo
	Hipóteses	
	Aprendizado	
	Conhecimento	
D	Plano de Ação	Execução do Plano
C		Verificação Resultado
A	Divulgação Resultados Externa	Padronização
		Conclusão

Figura 7 - Comparação entre as fases da metodologia pesquisa-ação e programa Seis Sigma
Fonte: THIOLENT, 2002; WERKEMA, 2000.

O método de desenvolvimento do trabalho consistiu de duas grandes etapas:

- a) revisão bibliográfica da literatura sobre Seis Sigma - a partir de livros, manuais de treinamento e artigos técnicos, foi montado o referencial teórico para o estudo de caso;

- b) estudo de caso - estudo de caso da aplicação da metodologia Seis Sigma em um projeto com o objetivo de reduzir os custos variáveis do ferramental de produção de uma linha de fabricação de componentes de uma indústria metal-mecânica. No desdobramento do projeto, utilizou-se o projeto de experimento para a otimização do uso do ferramental através do aumento da vida útil do mesmo.

1.6 ESTRUTURA DO TRABALHO

A dissertação está estruturada em capítulos conforme descritos na seqüência.

No Capítulo 1 são apresentadas as considerações iniciais, o tema abordado, justificativas para a escolha do tema, delineamento dos objetivos a serem alcançados, método e estrutura do trabalho e as limitações do trabalho. É apresentada uma comparação entre as metodologias do programa Seis Sigma e as ferramentas estatísticas utilizadas.

O capítulo 2 consiste na revisão bibliográfica sobre o programa Seis Sigma, suas métricas, inserção do Seis Sigma nos processos e ferramentas de encaminhamento dos projetos de melhoria dentro do programa Seis Sigma. Também são apresentados aspectos referentes ao treinamento de *Black Belts*.

No capítulo 3 apresentam-se os fundamentos do projeto e análise de experimentos.

No capítulo 4 é apresentado o estudo de caso da implantação de um projeto Seis Sigma em uma indústria metal-mecânica, juntamente com a utilização do projeto de experimentos.

No capítulo 5 são apresentados conclusões e futuros desdobramentos da pesquisa.

1.7 LIMITAÇÕES DO TRABALHO

As limitações desta dissertação de mestrado enquadram-se em três categorias: a) de ordem prática; b) relativa à pesquisa bibliográfica realizada; e c) relativas ao escopo de aplicação da pesquisa.

No que diz respeito às limitações de ordem prática, o estudo de caso apresentado no Capítulo 4 apresenta a metodologia para implantação do Seis Sigma conforme desenvolvida por uma empresa de consultoria. Outras propostas metodológicas estão disponíveis na

literatura, mas não foram aplicadas no caso em questão. O projeto apresentado faz parte de um projeto de certificação de *Black-Belt* em uma empresa do setor metal-mecânico.

No que diz respeito às limitações da pesquisa bibliográfica, a apresentação das ferramentas estatísticas mais usuais como o Controle Estatístico de Processo (CEP), Diagrama de Pareto, Gráfico de Controle, entre outras, é feita nas referências bibliográficas. Maior aprofundamento acerca dessas ferramentas pode ser feito através de pesquisa nas referências bibliográficas citadas.

No que diz respeito às limitações relativas ao escopo de aplicação da pesquisa salienta-se que a aplicação da metodologia Seis Sigma foi desenvolvida em uma empresa de atividade fabril. Processos de prestação de serviço presentes na empresa não foram abordados. Segundo Pande *et al.* (2001), os ganhos potenciais em atividades não fabris tendem a ser mais significativo do que no ambiente fabril por duas razões:

- a) as oportunidades fora do chão de fábrica, como finanças, serviços a clientes, logística e Tecnologia da Informação são chave para a vantagem competitiva sustentada, já que produtos se transformam em commodities rapidamente;
- b) a maioria das atividades não-fabris é apenas 70% eficientes, possibilitando, assim, um maior potencial de ganho se comparadas às atividades fabris.

2 REVISÃO BIBLIOGRÁFICA

A empresa que adota uma estratégia Seis Sigma busca para seus processos, especialmente os processos chaves desdobrados a partir da estratégia da empresa, um desempenho, em longo prazo, superior em termos de qualidade, com no máximo 3,4 ppm (partes por milhão) de defeitos ou falhas (HILSDORF, 2002).

Segundo Pande *et al.* (2000), o Seis Sigma é um sistema flexível para obter liderança e desempenho nos negócios. Baseia-se em muitas das idéias mais importantes de gestão e melhores práticas do século passado, criando uma nova forma de negócios para o século XX. Analisando o Seis Sigma sob a ótica global da empresa, ele pode ser entendido como um programa de qualidade que busca, através de uma metodologia de desenvolvimento de projetos com forte viés estatístico e quantitativo, a excelência no desempenho de todas as operações da empresa, integrando manufatura e serviços. Por meio do Seis Sigma, a estratégia de qualidade torna-se uma estratégia de negócios (HILSDORF, 2002).

O Seis Sigma também é tratado constantemente como uma filosofia ou como objetivo (HARRY; SCHROEDER, 2000). Neste trabalho será tratado como um programa de qualidade com o objetivo de atingir 3,4 ppm nos processos.

2.1 TERMINOLOGIA SIGMA E ESCALA SIGMA

O conceito sigma (σ) foi criado em 1980 como forma de desenvolver uma métrica universal de qualidade para mensurar o desempenho de processos, independente de sua complexidade (HARRY; SCHROEDER, 2000). O índice 6σ mede a capacidade do processo em atender às especificações de projeto, analogamente aos tradicionais índices Cp e Cpk utilizados no Controle Estatístico do Processo (CEP).

Um processo é definido como tendo desempenho Seis Sigma quando estiver com a média da população centrada no valor nominal da especificação, e os limites de especificação estiverem distantes seis desvios padrões da média da população (HILSDORF, 2002).

No Seis Sigma, tem-se 99,9999998% de produtos perfeitos, isto é, DOIS defeitos por bilhão de unidades produzidas. Mesmo se o valor médio dos resultados do processo se afastar

do valor ideal em 1,5 sigma, não se espera obter mais do que 3,4 produtos defeituosos por milhão de unidades (ppm) fabricadas.

A escala sigma é uma medida estatística que quantifica a variação existente entre os resultados de qualquer processo ou procedimento, sendo utilizada para medir o nível de qualidade associado a um processo, transformando a quantidade de defeitos por milhão em um número na escala sigma. Quanto maior o valor alcançado na escala sigma, maior o nível de qualidade (WERKEMA, 2000). A relação entre a escala sigma e o número de defeitos gerados no processo vem explicitada na Tabela 1. A Tabela 2 traz uma ilustração dos benefícios da obtenção do nível sigma de qualidade em empresas de diversos segmentos atuando a um nível de qualidade quatro sigma.

Tabela 1 - Escala sigma e número de defeitos correspondentes (considerando resultados de um processo centrado no valor nominal).

Escala Sigma	Defeitos (ppm)
1	317.400
2	45.600
3	2.700
4	63
5	0,57
6	0,002
7	0,000003

Fonte: WERKEMA, 2000.

Tabela 2 - Ilustração do impacto da obtenção de um nível de qualidade seis sigma em comparação com um nível de qualidade quatro sigma.

Quatro Sigma (99,38%conforme)		Seis Sigma (99,99966%conforme)
Sete horas de falta de energia elétrica por mês		Uma hora de falta de energia elétrica a cada 34 anos
5.000 operações cirúrgicas incorretas por semana		1,7 operação cirúrgica incorreta por semana
3.000 cartas extraviadas para cada 3000.000 cartas postadas		1 carta extraviada para cada 3000.000 cartas postadas
Quinze minutos de fornecimento de água não potável por dia		Um minuto de fornecimento de água não potável a cada sete meses
Uma aterrissagem de emergência no aeroporto de Guarulhos por dia		Uma aterrissagem de emergência em todos os aeroportos do Brasil a cada cinco anos
Um canal de TV 1,68 horas fora do ar por semana		Um canal de TV 1,8 segundos fora do ar por semana

Fonte: WERKEMA, 2000; KEENE, 2000.

Analisando a Tabela 1, verifica-se que, quanto mais alto o valor na escala sigma, menor a probabilidade de um processo produzir defeitos. Cada ponto na escala sigma produz uma redução exponencial de defeitos. Como resultado, a necessidade de testes e inspeções diminuem, os custos baixam, os tempos de ciclo diminuem e a satisfação dos clientes aumenta (HARRY; SCROEDER, 2000).

2.2 FÁBRICA ESCONDIDA E INDICADORES SEIS SIGMA

Segundo Harry e Schroeder (2000), empresas que produzem produtos e serviços a um nível de qualidade quatro sigma ou inferior, gastam uma grande quantidade de tempo e recursos praticando a detecção e correção de problemas e erros. Esta prática institucionaliza o que os autores denominam por “fábrica escondida” (*hidden factory*), um sistema preparado para corrigir defeitos durante o processo de fabricação; ver Figura 8. Tal sistema utiliza espaço, tempo e recursos na detecção, inspeção, análise e reparo de defeitos.

Com o aumento da taxa de defeitos, o efeito da “fábrica escondida” em um processo ou empresa tende a se amplificar, com conseqüente proliferação de custos. Para Harry e Schroeder (2000), é necessário tornar visível o efeito da fábrica escondida. Os indicadores de rendimento usuais, como pesquisa de clientes, relatórios de rejeição, estatísticas de devolução de produtos e reclames de garantia são capazes de quantificar o número de unidades (de serviços ou produtos) conformes produzidas. Tradicionalmente, esse tipo de dado é utilizado para calcular o rendimento do processo, isto é, a razão entre o número de itens conformes que emergem do processo e o número total de itens produzidos.

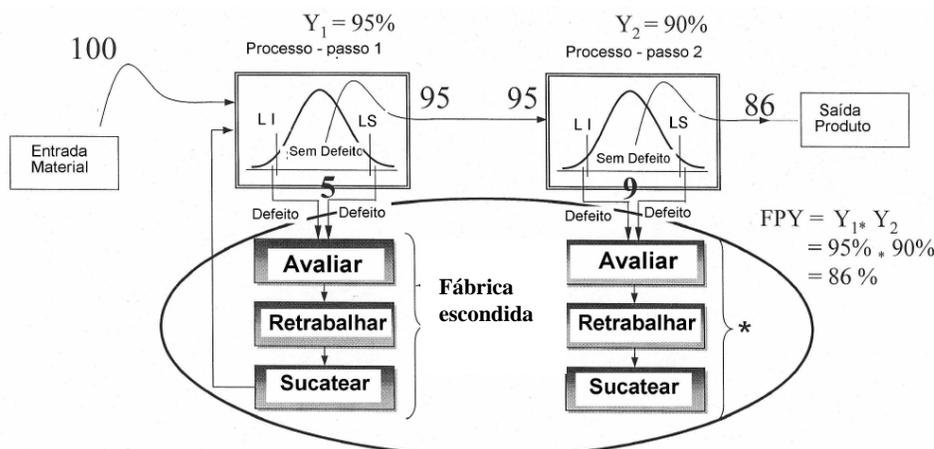


Figura 8 - Visualização do conceito fábrica escondida

O rendimento é uma medida de eficiência de aplicação intuitiva, mas que não evidencia operações e processos de retrabalho.

Werkema (2001) classifica os indicadores Seis Sigma como baseados em a) produtos defeituosos, que não levam em consideração o número de defeitos, e b) em produtos com defeitos, quando é computado o número de defeitos nas unidades defeituosas assinaladas. Os indicadores baseados em produtos defeituosos calculam o rendimento conforme descrito anteriormente, enquanto os indicadores por defeitos, além de mostrar o rendimento, identificam a quantidade de defeitos por unidade, relacionando-se, assim, com os custos de correção de defeitos. Os indicadores por defeitos são baseados na noção de oportunidades de ocorrência de defeitos, em que cada especificação necessária à satisfação do consumidor de um produto representa uma oportunidade para a ocorrência de um defeito (HILSDORF, 2002; HARRY, SCHROEDER, 2000). A classificação dos indicadores, conforme Werkema (2001), segue descrita a seguir:

Baseados em produtos defeituosos:

- a) proporção de defeituosos (p) - razão entre o número de produtos defeituosos e o número de unidades avaliadas no processo;
- b) rendimento final (Y) - unidade menos a proporção de defeituosos ($1 - p$).

Baseados em defeitos:

- a) defeitos por unidade (DPU) - razão entre o número de defeitos encontrados e o número de unidades avaliadas no processo. Hilsdorf (2002) considera o indicador DPU como a taxa média de defeitos encontrados por unidade de produto;
- b) defeitos por oportunidade (DPO) - razão entre DPU e o número de oportunidades para defeitos. As oportunidades para defeito de um produto correspondem às características críticas para qualidade do produto;
- c) defeitos por milhão de oportunidades (DPMO) - multiplicação de DPO por 1.000.000. O DPMO pode também ser expresso na escala Sigma, usando a tabela de conversão apresentada no Anexo A. Os objetivos do programa Seis Sigma, medidos através do DPMO são aplicados nas características críticas para a qualidade *critical to quality characteristics* (CTQ's) e não necessariamente para todo o produto ou processo.

A ocorrência de defeitos, quando mensurados em uma amostra coletada de um processo, pode ser modelada pela distribuição de Poisson (BREYFOGLE, 1999). Neste caso a probabilidade de se observar exatamente x defeitos na amostra é dada pela distribuição de Poisson, cuja distribuição de probabilidade é dada por:

$$P(X = x) = \frac{e^{-\mu} \mu^x}{x!} \quad x = 0, 1, 2, 3, \quad (1)$$

onde x é o número de ocorrências de defeitos e μ é a média da distribuição de Poisson que corresponde à taxa média de ocorrência de falhas. Uma aproximação da distribuição de Poisson é dada na equação 2 (LAFRAIA, 2001; BREYFOGLE, 1999):

$$P(X = x) = \frac{e^{-np} (np)^x}{x!} \quad (2)$$

em que $\mu = np$, sendo n , o tamanho da amostra e p a probabilidade de ocorrência de falha. A probabilidade de zero ocorrência de falhas $P(X = 0)$ tem aplicação com as métricas Seis Sigma, tornando a equação (2) em (BREYFOGLE, 1999; BUCHAIM, 1994):

$$P(X = 0) = e^{-DPU} \quad (3)$$

Harry e Schroeder (2000) propõem os seguintes indicadores para o Seis Sigma desdobrados do indicador DPU:

- a) rendimento pontual do processo (*First Throughput Yield* - FTY) - probabilidade de que todas as oportunidades para defeitos produzidos em uma etapa específica do processo estejam dentro das especificações. Corresponde à probabilidade de encontrar zero defeitos ao inspecionar uma amostra que emerge do processo; ou seja:

$$FTY = P(X = 0) = e^{-DPU} \quad (4);$$

- b) rendimento final do processo (*Rolled Throughput Yield* - RTY) - probabilidade de uma unidade de produto ou serviço passar por todas as etapas do processo livre de defeitos. O indicador é obtido pelo produto dos FTY avaliados em cada etapa do processo; ou seja:

$$RTY = \prod_{i=1}^n FTY = e^{-\sum_{i=1}^n DPU} \quad (5)$$

Graves (2002) propõe o uso dos indicadores RTY e DPU no controle de processos, através da tabulação diária dos valores observados para os indicadores e plotagem em gráficos de controle, conforme exemplificado na Figura 9. O autor também propõe avaliar o impacto de melhorias nos processos através do uso conjunto dos gráficos de controle para os indicadores RTY e DPU.

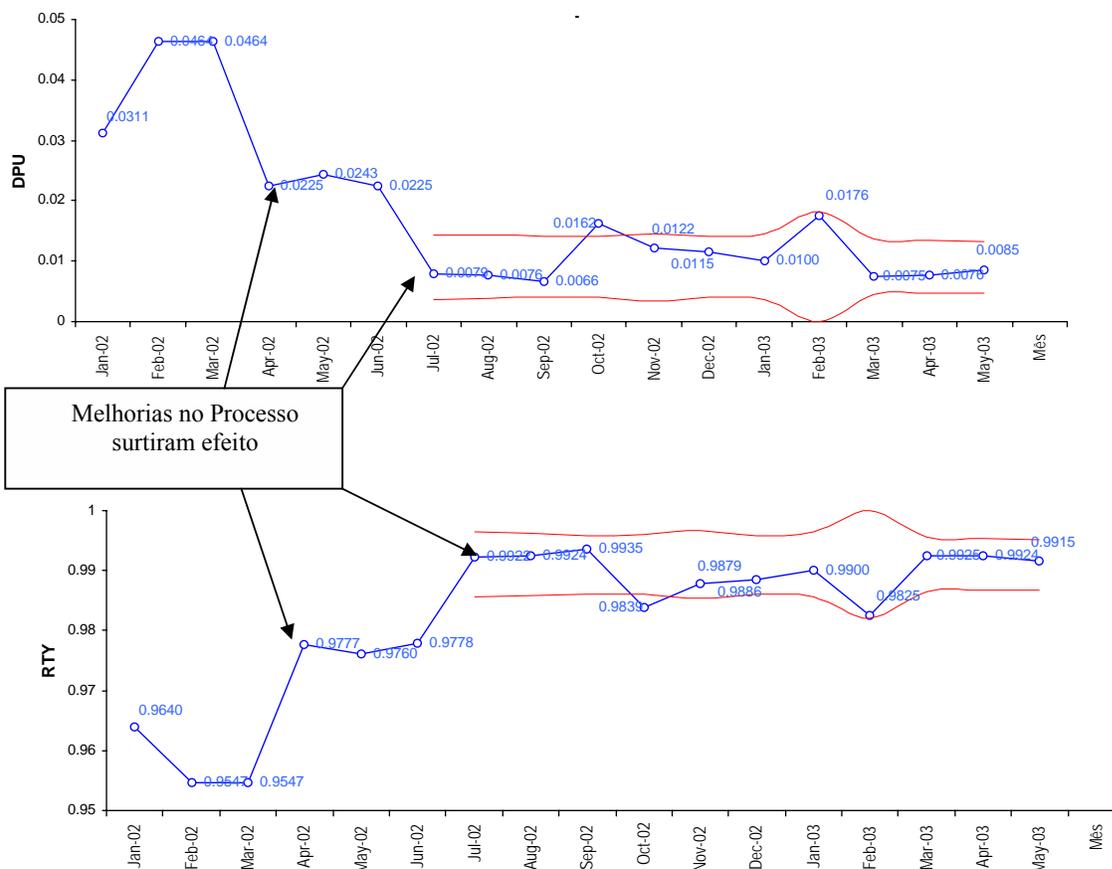


Figura 9 - Exemplos de gráficos de controle de processo baseados nos indicadores DPU e RTY
Fonte: GRAVES, 2002.

Uma outra utilização dos indicadores do Seis Sigma é na elaboração de cartas de controle para atributos, na inspeção de itens não-conformes em processos produtivos. Os valores de proporção de defeituosos (p) e defeitos por unidade (DPU) podem ser plotados em cartas de controle tipo p e u , respectivamente, e avaliados seguindo critérios usuais do controle estatístico de processos (AIAG, 1995). As cartas de controle por variáveis são utilizadas com mais frequência em processos na indústria automobilística, embora as cartas

por atributos usando indicadores-chave da qualidade global possam, freqüentemente, identificar áreas do processo passíveis de melhoria (GRAVES, 2002).

A Figura 10 traz um resumo comparativo das métricas utilizadas no programa Seis Sigma e das métricas comumente utilizadas na medição de produtividade em processos de manufatura.

	Y Rendimento Inicial	FTY Rendimento Pontual do Processo	RTY Rendimento Final do Processo
Avaliação das quantidades de peças produzidas	F	M	M
Avaliação das quantidades de defeitos produzidos por unidades avaliadas	I	F	F
Oportunidades para Defeitos (Características Críticas para Qualidade) contidos em uma unidade de produto ou serviço	I	F	F
Complexidade do Produto	I	F	F
Custo de Produção, Retrabalho, Mão-de-obra, Tempo de Ciclo (Fábrica Escondida)	I	F	F
Avaliação em uma Etapa do Processo	I	F	I
Avaliação em cada Etapa do Processo	I	I	F

Figura 10 - Quadro comparativo entre indicadores Seis Sigma e indicadores tradicionais de desempenho.

Legenda: F – relação forte, M – relação moderada, I – relação inexistente.

2.3 ECONOMIA DO PROGRAMA SEIS SIGMA

A proposta do programa Seis Sigma de redução de custos e melhoria da lucratividade através da prevenção e eliminação de defeitos, pode ser visualizada pelo modelo proposto por Bisgaard e Freiesleben (2001). No modelo, considerando-se um volume de produção de x peças e a ocorrência de uma taxa de defeitos q , será necessário produzir um volume maior, dado por $v = x / (1 - q)$, para atender ao volume original. Os custos variáveis alocados para o volume planejado serão alocados para um volume maior, criando um custo unitário extra, conforme o conceito de fábrica escondida, visto anteriormente.

Bisgaard e Freiesleben (2001) propõem uma ilustração gráfica da relação custo-lucro em um diagrama de equilíbrio (Figura 11), baseado na equação:

$$\pi = \frac{(S - C)s}{S} - F = \frac{ms}{S} - F = m_r s - F \quad (6)$$

onde π é o lucro final, S são as vendas totais do período, C o custo variável do período, F o custo fixo do período, $m = S - C$, a margem de contribuição e $m_r = m/S$ a margem de contribuição relativa e s é a variável volume de vendas.

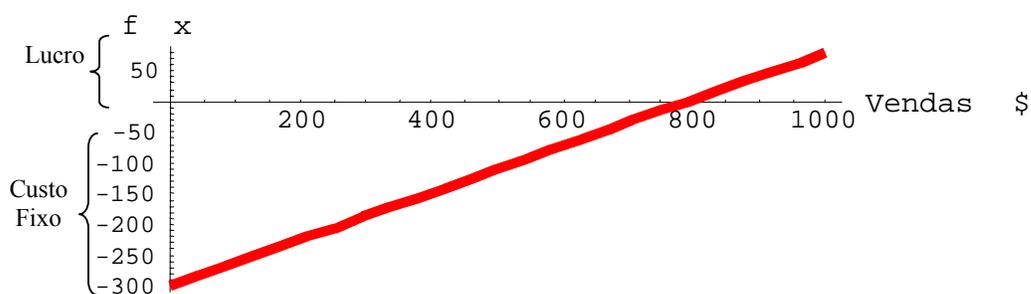


Figura 11 - Gráfico do ponto de equilíbrio com reta custo-lucro
Fonte: BISGAARD; FREIESLEBEN, 2001

O gráfico da Figura 11 mostra uma função linear das vendas s com intercepto em $-F$ e declinação dada pela contribuição marginal m_r . O ponto de equilíbrio s_0 é o volume de vendas que produz lucro zero e pode ser computado por $s_0 = C + F$ ou $s_0 = F/m_r$. A reta traçada entre os pontos (venda zero, custo fixo máximo) e (ponto de equilíbrio) considera um processo com taxa de defeito de 10%.

Considerando uma redução na taxa de defeitos para zero, os custos fixos permanecem os mesmos, porém a margem de contribuição m_r é maior, aumentando a declinação da reta custo-lucro, conforme ilustrado na Figura 12.

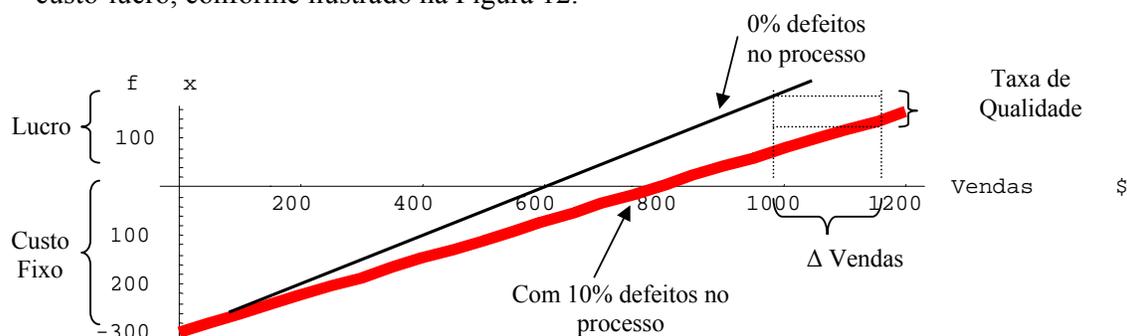


Figura 12 - Gráfico do ponto de equilíbrio mostrando o impacto da redução de defeitos

Fonte: BISGAARD; FREIESLEBEN, 2001

Na Figura 12, o ponto de equilíbrio diminui, e o lucro é maior para o volume de vendas anterior. Para atingir o lucro do processo com zero defeito utilizando o processo com 10% de defeitos, a venda deve ser aumentada. A redução de defeitos, a princípio, é algo possível de ser atingido, enquanto o aumento de vendas é relativo, pois depende de investimentos em propaganda e marketing, por exemplo.

Bisgaard e Freiesleben (2001) também expressam a função lucro-perda em termos de unidades produzidas e vendidas, através da equação (7):

$$\pi = px - cx - F = (p - c)x - F = m_u x - F \quad (7)$$

onde x é o número de unidades despachadas, p é o preço unitário de venda, c é o custo unitário variável e m_u é a margem de contribuição unitária. O ponto de equilíbrio expresso em unidades vendidas é então $x_0 = F/m_u$. Considerando a fabricação de m diferentes produtos, a equação custo-lucro torna-se:

$$\pi = \sum_{i=1}^m p_i x_i - \sum_{i=1}^m c_i x_i - F \quad (8)$$

onde x_i é o número de produtos vendidos, p_i é o preço unitário de venda, c_i é o custo unitário variável do i -ésimo produto e F o custo fixo do período.

Considerando a ocorrência de defeitos na equação (8), para enviar x unidades de produtos bons obtidos a partir de um processo com taxa de defeitos q , é necessário produzir n unidades, das quais nq serão defeituosas; assim, $x = n - nq = n(1 - q)$ ou $n = x/(1 - q)$ e a equação do lucro torna-se:

$$\pi = px - cn - F \quad \text{ou} \quad \pi = \left(p - \frac{c}{1 - q} \right) x - F. \quad (9)$$

O ponto de equilíbrio da função lucro-perda é obtido zerando a equação (9) e resolvendo para x_0 ,

$$x_0 = \frac{F}{\left(p - \frac{c}{1 - q} \right)} \quad (10)$$

Para avaliar o efeito marginal ($\Delta\pi$) no lucro para uma pequena mudança (Δq) na taxa de defeito q , deriva-se a equação(9) com relação à q , obtendo-se:

$$\frac{\partial \pi}{\partial q} = -cx(1 - q)^{-2}. \quad (11)$$

Como $\Delta\pi \approx (\partial\pi/\partial q)\Delta q$, tem-se:

$$\Delta\pi = -cx(1 - q)^{-2} \Delta q. \quad (12)$$

A ilustração da variação do lucro com a taxa de defeitos na equação (12), pode ser visualizada na Figura 13. Caso a taxa de defeitos ultrapassar o ponto de equilíbrio na Figura 13, ocorrerá prejuízo.

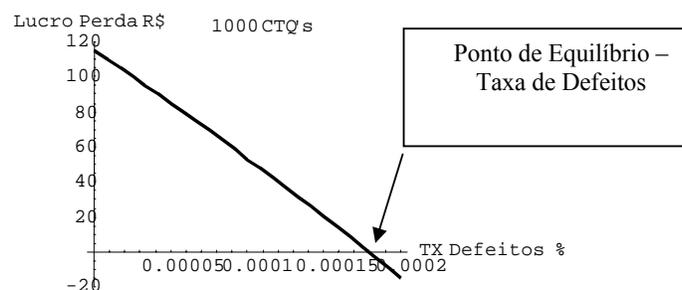


Figura 13 - Lucro e Perda como função da taxa de defeitos para 1000 CTQ's
Fonte: BISGAARD; FREIESLEBEN, 2001.

Harry e Schroeder (2000) exemplificam que quanto mais complexo o produto, maior a probabilidade de um defeito ocorrer em algum lugar do mesmo. Caso o produto for encontrado com defeito e corrigido durante o processo de fabricação, outros defeitos não identificados podem ser encontrados posteriormente no cliente durante o uso inicial do produto. Entretanto, se o produto foi produzido livre de defeitos, ele raramente falha durante o uso inicial no cliente.

2.4 SEIS SIGMA APLICADO A PROCESSOS

A satisfação do cliente está relacionada com o rendimento da fábrica e o rendimento da fábrica está relacionado com o rendimento dos processos (HARRY, SCHROEDER, 2000). Conforme Werkema (2000), o programa Seis Sigma é aplicado a processos e não a empresas.

O fluxo de processo, ou seqüência de atividades envolvidas na realização de um trabalho é composto de entradas, transformações e saídas. Os seis tipos básicos de entradas são pessoas, capital, energia, materiais, tecnologia, e forças ambientais/competitivas, comumente representados nos diagramas de causa e efeito, *Ishikawa* ou espinha de peixe. O processo de transformação envolve a) atividades que agregam valor ao produto, que contabilizam no tempo de processamento do produto, b) atividades que não agregam valor no processamento do produto, como tempos de espera excessivos, *set-ups* demasiadamente longos, retrabalho, transporte e manuseio repetitivos e c) desperdícios, como geração de sucata, rejeições (REID *et al.*, 2000). As formas comumente encontradas para mapear e visualizar o processo utilizadas no programa Seis Sigma são:

- a) diagramas EPS (Entrada – Processo – Saída);
- b) diagrama de fluxo do processo;
- c) mapa do processo – FEPSC (Fornecedor, Entradas, Processo, Saídas, Cliente – do inglês SIPOC - *Supplier, Input, Process, Output, Customer*), normalmente utilizado no estágio inicial dos projetos Seis Sigma;
- d) diagramas de causa e efeito;
- e) mapa do fluxo do valor;

- f) mapa do processo – normalmente utilizado na fase de análise do processo durante os projetos Seis Sigma. Será utilizado no estudo de caso no Capítulo 4 e será detalhado na seção 2.4.3.

2.4.1 Controle de processos

A Divisão Automotiva da Força Tarefa de Requisitos da Qualidade da Sociedade Americana para o Controle de Qualidade /Grupo de Ação da Indústria Automotiva (ASQC/AIAG), através da publicação dos manuais de referência (CEP, MSA, FMEA) da norma TS 16949 (ex-norma QS9000), reforçam a necessidade da melhoria contínua e controle de processos em toda a cadeia de fornecimento da indústria automotiva. Os seguintes pontos que antecedem a introdução dos métodos estatísticos abordados nos manuais são enfatizados:

- a) a coleta de dados e utilização dos métodos estatísticos não deve ser a meta final; o objetivo é o aumento da compreensão sobre os processos;
- b) deve-se utilizar o estudo da variação e dos sinais estatísticos para melhorar o desempenho do processo em qualquer área, fabril ou administrativa;
- c) a aplicação do CEP deve contemplar processos, e não somente produtos;
- d) deve-se promover uma análise de confiabilidade dos dados através de sistemas de medição adequados.

O manual de CEP da Força Tarefa ASQC/AIAG especificamente propõe um sistema de controle de processo, com ênfase em quatro elementos: processo, informações sobre o desempenho, ações sobre o processo, ações no resultado do processo. As informações sobre o processo podem ser verificadas pelos resultados obtidos. Entretanto, a informação mais útil acerca do desempenho do processo vem do entendimento do processo e de sua variabilidade interna. As ações sobre o processo são mais econômicas se comparadas às ações sobre o resultado do processo, como, por exemplo, ações de inspeção; tais ações deveriam ser usadas estritamente como medida provisória em processos instáveis e incapazes. As variações encontradas no processo devidas a causas especiais, a menos que sejam identificadas, afetarão de forma imprevisível o resultado do processo.

Para Box e Luceño (2000), a detecção de causas especiais é possível a partir da observação de pequenas corridas do processo. Já, a proporção de peças defeituosas que

emerge do processo está relacionada a índices de capacidade, que geralmente refletem uma longa observação do processo.

2.4.2 Mapa do raciocínio ou pensamento

O mapa de raciocínio consiste em uma documentação progressiva da forma de raciocínio durante a execução de um trabalho. Trata-se de uma ferramenta importante no programa Seis Sigma, sendo utilizada durante todo o desenvolvimento do projeto realizado pelo *Black Belt*. Um mapa de raciocínio deve documentar a meta geral do trabalho (objetivo geral), questões a serem respondidas, atividades a serem realizadas de forma a responder as questões propostas, novas questões e novos passos que surgirem durante o projeto e respostas para as novas questões (WERKEMA, 2000).

Hild *et al.* (2000) refere-se ao mapa de raciocínio como mapa do pensamento.

Não existe uma maneira correta de construir o mapa, já que se pode melhorar o entendimento e ganhar novo conhecimento sobre um processo de diversas maneiras. Porém, existe um conjunto de elementos críticos que certificam que o mapa do pensamento será eficiente na condução do trabalho. Tais elementos são (HILD *et al.*, 2000): a) o objetivo geral e quantificável do projeto ou processo; b) alternativas principais e questões iniciais a serem consideradas; c) caminhos paralelos de questionamento e subseqüentes trabalhos desenvolvidos; d) priorização das questões a serem respondidas; e) ferramentas e metodologias utilizadas para procurar as respostas às questões; f) história do trabalho realizado para obter as respostas e a documentação das respostas; e g) evolução das métricas e sua relação com o trabalho sendo realizado.

Werkema (2000) acrescenta um elemento à lista acima: a justificativa da utilização das ferramentas selecionadas no projeto.

Um fluxograma para elaboração do mapa do pensamento proposto por Hild *et al.* (2000) é apresentado na Figura 14 e um exemplo do mapa na Figura 15. No fluxograma o conhecimento existente (idéias ou suspeitas) motiva perguntas, as quais direcionam o tipo de informação necessária e os tipos de ferramentas a serem utilizadas no projeto (por exemplo, CEP ou PAE), as quais, por sua vez, proporcionam respostas e novas perguntas referentes a desdobramentos futuros do projeto.

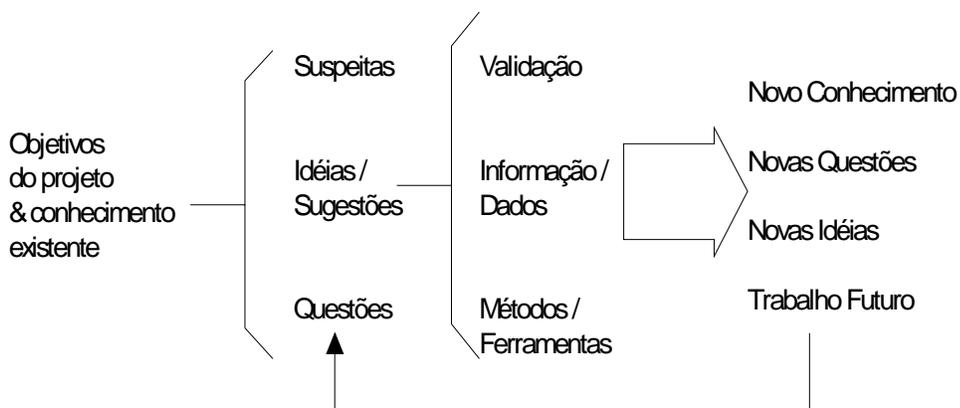


Figura 14 - Fluxo natural do mapa do pensamento
 Fonte: HILD *et al.*, 2000.

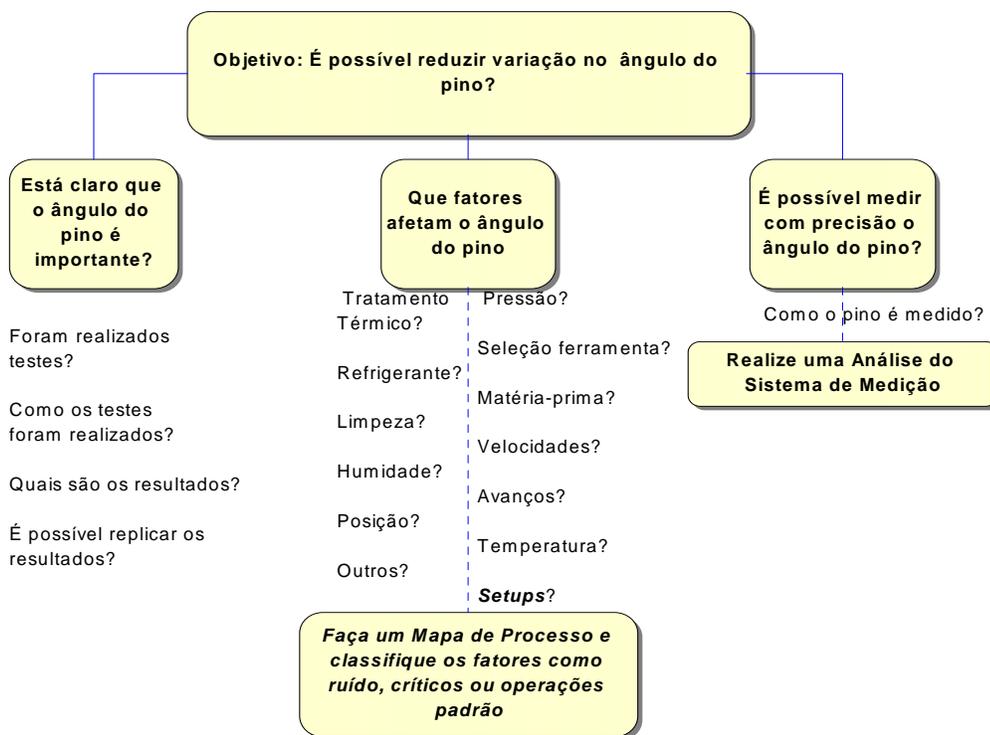


Figura 15 - Exemplo de mapa do pensamento para reduzir variabilidade no ângulo do pino
 Fonte: HILD *et al.*, 2000.

Freqüentemente, as equipes que trabalham nos projetos Seis Sigma necessitam saber: os próximos passos, alterações que estão sendo feitas no processo/projeto, e porque e como manter o histórico do progresso do trabalho. O exemplo de mapa na Figura 15 traz tais informações, já que imediatamente comunica os objetivos, a direção, razões e natureza hierárquica do trabalho, além de fatores e questões relacionadas com o objetivo global.

A Figura 16 ilustra a relação entre ferramentas estatísticas e o mapa do pensamento. A construção do conhecimento seqüencial é baseada na habilidade de questionar e responder corretamente aos questionamentos, desenvolver e testar hipóteses, entender e documentar teorias não testadas. Mapas do pensamento são importantes para melhorar a geração de idéias, comunicar e resolver problemas de forma eficiente (HILD *et al.*, 2000).

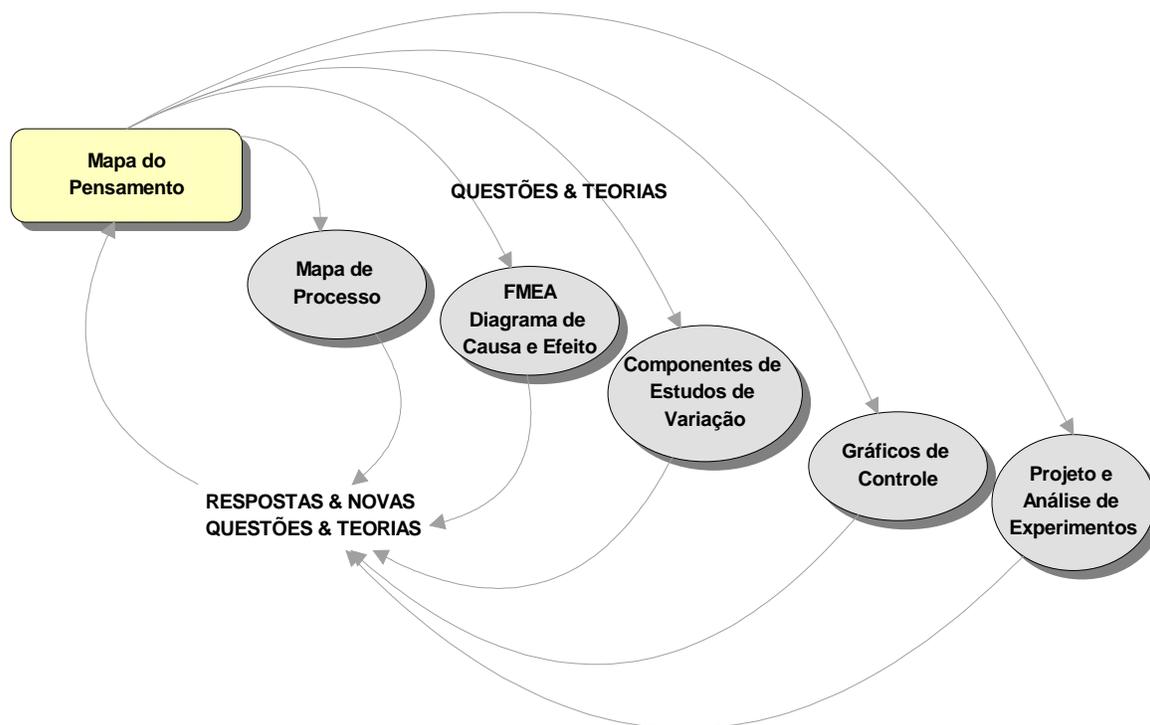


Figura 16 - Relacionamento entre ferramentas estatísticas e o mapa do pensamento
Fonte: HILD *et al.*, 2000

2.4.3 Mapa do processo

Na proposta de Werkema (2000), os mapas de processo são usados para documentar o conhecimento existente sobre os processos. Para tanto, devem descrever os limites do processo, as entradas e saídas, principais atividades e tarefas, e os parâmetros, conforme exemplificados na Figura 17.

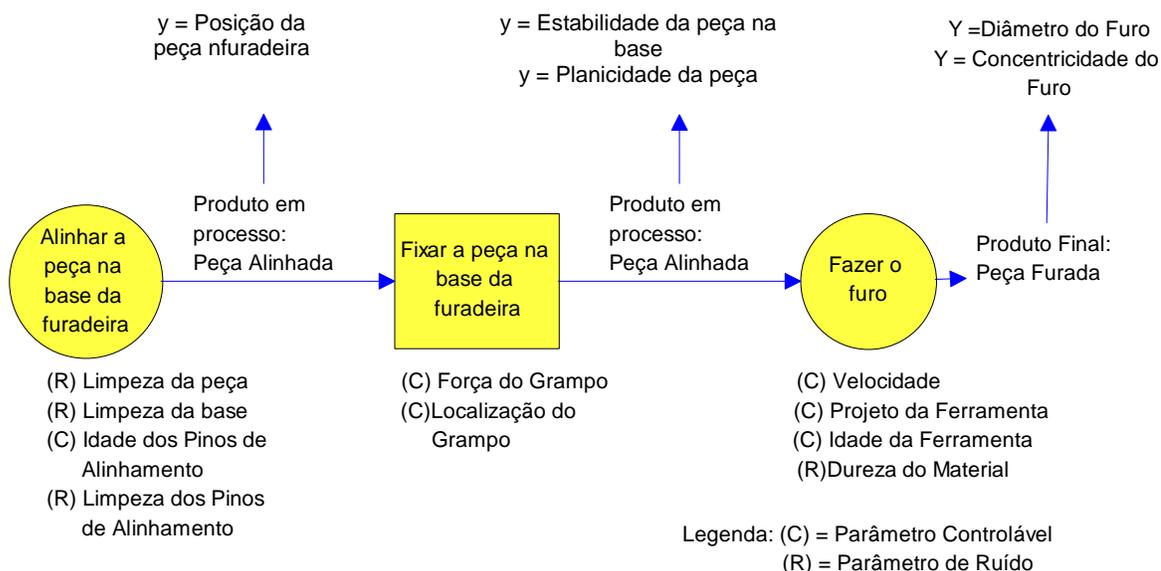


Figura 17 - Exemplo de mapa do processo
Fonte: WERKEMA, 2000.

Os componentes de um mapa de processo são: a) parâmetro de produto final (Y) que caracteriza o produto no estágio de produto acabado; b) parâmetro de produto em processo (y) que caracteriza o produto antes do estágio de produto acabado; e c) parâmetro de processo (x), usualmente uma característica mensurável de um processo que pode afetar o desempenho do produto, tais como temperatura, pressão, velocidade, tempo.

No mapa de processo também são identificados os parâmetros de processo controláveis, que são fatores que podem ser ajustados em um valor pré-determinado e mantido em torno deste valor, e parâmetros de ruído, que são fatores que não podem ser (ou preferencialmente não são) ajustados em um valor pré-determinado e mantido em torno deste valor.

O mapa de processo é a base para a caracterização do processo. Nele ocorre a determinação dos relacionamentos existentes entre os parâmetros de processo e os parâmetros de produto. Se a caracterização do processo indica que a variação em um parâmetro controlável ou em um parâmetro de ruído exerce um impacto significativo no rendimento do produto, o parâmetro é identificado como um parâmetro crítico.

O mapa do processo deve inicialmente documentar como o processo realmente opera. Todas as operações, que agregam valor ou não, devem ser incluídas. O mapa deve facilitar a realização da etapa de quantificação e priorização do processo e deve ser revisto com frequência.

2.5 TREINAMENTO NO PROGRAMA SEIS SIGMA

A estrutura do treinamento de Seis Sigma, conforme Hoerl (2001), é baseada no questionamento sobre a razão da utilização das ferramentas estatísticas propostas na metodologia, sua função e forma de uso.

A importância do questionamento no encaminhamento dos projetos Seis Sigma e na utilização de determinada ferramenta pode ser visualizada na seção 2.4.2.

Hoerl (2001) considera o método de ensino das ferramentas, dentro de uma estrutura e proporcionar aplicação instantânea, como mais importante do que as ferramentas em si.

Para Snee (2001), devido ao trabalho do *Black Belt* e a expectativa em torno dos projetos Seis Sigma ser focada em melhoria do processo, todos os aspectos do treinamento devem enfatizar a melhoria. É importante que a apresentação das ferramentas seja feita através de *roadmaps* (ver Capítulo 1) e procedimentos para utilização de cada ferramenta e do método geral. Isto torna a curva de aprendizado no treinamento mais rápido.

Hoerl (2001) recomenda adequar o treinamento enfatizando exemplos relativos a área funcional dos estudantes. O tipo de treinamento depende do ambiente de trabalho. Fatores chave são o tipo de companhia (serviço ou manufatura), tipo de função (operações, transacional, administrativa ou desenvolvimento de novos produtos) e tipo de indústria (montagem, processamento, química, etc). A Tabela 3 apresenta um exemplo de aplicação de ferramentas estatísticas dependendo da área ou ambiente de aplicação (HOERL, 2001). O

exemplo está centrado em duas ferramentas: as metodologias de projeto de experimentos e de superfície de resposta.

Tabela 3 - Ênfase das ferramentas conforme a área de aplicação

Área de Aplicação	PAE	MSR
Engenharia Química	Mais ênfase, em particular experimentos com misturas	Menos ênfase
Manufatura	Mais ênfase	Menos ênfase
Projeto de Produto	Menos ênfase	Mais ênfase

3 PROJETO E ANÁLISE DE EXPERIMENTOS (PAE)

Na introdução à melhoria contínua do manual de CEP da norma TS 16949, ex-norma QS9000 (AIAG, 1995), adverte-se para o fato de as técnicas estatísticas serem aplicadas rotineiramente a produtos, em vez de processos. A aplicação das técnicas estatísticas para controlar produtos deveria ser só o primeiro passo. O pleno potencial das técnicas para a melhoria da qualidade, aumento da produtividade e redução de custo não será alcançado a não ser que os processos que geram a saída (de produtos ou peças) tornem-se o foco da aplicação das ferramentas estatísticas. Nesse contexto, a ferramenta PAE mostra-se adequada, pois pode ser aplicada na análise e melhoria das variáveis do processo. O processo em questão pode ser tratado genericamente, conforme Figura 18.

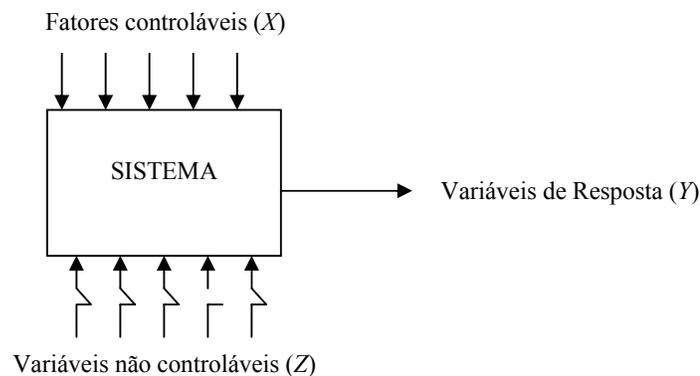


Figura 18 - Sistema de variáveis do processo.
Fonte: ANDERSON; WHITCOMB, 2000.

As entradas do processo ilustrado na Figura 18 podem ser: fatores controláveis denominados de X que podem ser do tipo numérico, como temperatura, ou categórico, como fornecedor de matéria-prima. Também podem ser variáveis não-controláveis, denominadas de Z , tais como temperatura ambiente ou umidade, e que podem ser uma causa principal de variabilidade. Às vezes tais causas podem não ser identificáveis.

Outras formas de variação são desvios em torno dos ajustes dos fatores controláveis, incluindo erros de amostragem e medição. É possível medir as saídas ou respostas de um processo de forma quantitativa ou semi-quantitativa. É utilizado o símbolo Y para designar as respostas. A variabilidade do sistema pode ser detectada coletando dados do sistema e plotando em um gráfico de dados por tempo, para visualizar o desempenho do processo. O CEP fornece indícios para avaliar a variabilidade natural do sistema, filtrar o ruído causado

pela variabilidade, sendo assim, uma forma passiva de atuação. Entretanto, para realizar melhorias sistemáticas, ao contrário de somente eliminar causas especiais, deve ser aplicado o PAE (ANDERSON; WHITCOMB, 2000). A Tabela 4 ilustra diferenças de aplicação e função entre o CEP e PAE.

Tabela 4 - Diferenças entre PAE e CEP

	CEP	PAE
Quem utiliza	Operador	Engenheiro
Função	Monitorar	Mudar
Resultado	Controlar	Melhoria
Causa de Variabilidade	Especial (perturbação)	Comum (sistemática)

Fonte: ANDERSON; WHITCOMB, 2000

Alguns objetivos dos projetos de experimentos incluem (ANDERSON; WHITCOMB, 2000): a) determinar quais variáveis são mais influentes na resposta Y; e b) determinar onde ajustar as variáveis influentes X para que Y esteja sempre próximo do valor nominal desejado, para que a variabilidade seja pequena e para que o efeito das variáveis não controláveis Z seja minimizado.

Experimentos envolvem muitos fatores, sendo que alguns fatores são de interesse principal. Baseado em longa experiência com o processo, alguns fatores podem ser ignorados, pois seus efeitos são tão pequenos que não possuem valor prático. Esta decisão deve ser tomada freqüentemente sobre os fatores que devem ser considerados no experimento. O método geral de planejar e conduzir o experimento é chamado de estratégia de experimentação. As estratégias, com relação à combinação dos fatores testados, podem ser de dois tipos (MONTGOMERY, 2001):

A escolha baseada em opinião de especialista – selecionar uma combinação arbitrária dos fatores, testá-los e verificar o ocorrido. Esta tentativa pode continuar indefinidamente, mudando os níveis de um fator e deixando os outros fixos para o próximo teste, baseado no resultado do teste anterior.

A experimentação com um fator por vez – *one factor at a time* (OFAT) – consiste em selecionar um ponto de partida ou um fator de referência por vez e, então sucessivamente variar cada fator ao longo do seu campo de variação, com os outros fatores fixos no valor de referência.

Após todos os testes terem sido realizados, uma série de gráficos (ilustrados na Figura 19) pode ser construída mostrando como a resposta é afetada pelos fatores.

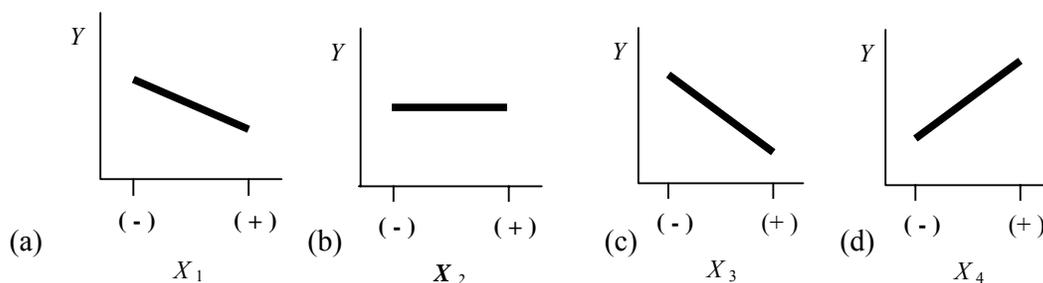


Figura 19 - Gráficos do efeito dos níveis dos fatores X (designados por + ou -) na variável resposta Y

Para análise dos gráficos da Figura 19, suponha que se deseja o menor valor possível para a variável de resposta Y. No gráfico (a), a inclinação do fator X_1 é negativa, concluindo que o nível (+) do fator X_1 melhorará o resultado. A escolha da combinação ótima do experimento seria: X_1 nível (+); X_3 nível (+); X_4 nível (-). O fator X_2 não tem efeito sobre a variável de resposta. Esta estratégia não considera a possível interação entre os fatores, ilustrada na Figura 20. Interações podem ser definidas como o efeito apresentado por um fator em produzir diferentes efeitos na resposta quando combinado em níveis diferentes dos outros fatores.

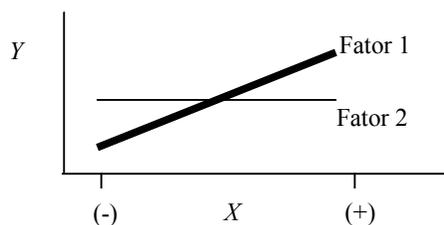


Figura 20 - Interação entre dois fatores de um experimento

Um dos projetos experimentais adequados para analisar o efeito de vários fatores simultaneamente sobre uma variável de resposta é o experimento fatorial, ilustrado na Figura 21. Em um experimento fatorial, fatores são variados conjuntamente, ao invés de um fator por vez. O processo fatorial permite avaliar a interação entre fatores. Em um experimento onde se testa um nível de cada fator por vez, não é possível analisar a interação entre fatores (ANDERSON, KRABER, 1999).

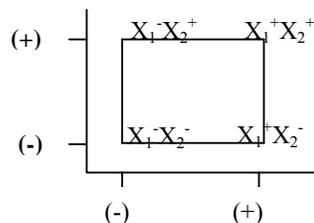


Figura 21 - Experimento fatorial envolvendo dois fatores

A Figura 21 apresenta um experimento fatorial que permite estudar o efeito conjunto de dois fatores na resposta Y. No experimento, ambos fatores são avaliados a dois níveis e todas

as possíveis combinações dos dois fatores através de seus níveis são contempladas no projeto. Geometricamente, os quatro testes formam as arestas do quadrado, formando o experimento fatorial 2^2 (com dois fatores testados a dois níveis). Os níveis dos fatores são designados (+) e (-). Uma análise dos dados coletados em cada combinação de níveis dos fatores permitirá então determinar quais variáveis têm efeito nas saídas do processo. Para estimar os efeitos individuais de cada fator (efeitos principais) e determinar se os fatores interagem, será necessário replicar rodadas experimentais.

A vantagem de experimentos fatoriais sobre experimentos onde um fator é testado a cada vez, é pronunciada ao se incluírem mais fatores. Por exemplo, com dois fatores, o projeto fatorial requer quatro testes (representado em forma de quadrado) e com três fatores, requer oito testes (representado geometricamente em forma de um cubo); no caso de uma estratégia OFAT, seis e dezesseis rodadas respectivamente seriam necessárias, para manter a mesma precisão conforme ilustrado na Figura 22.

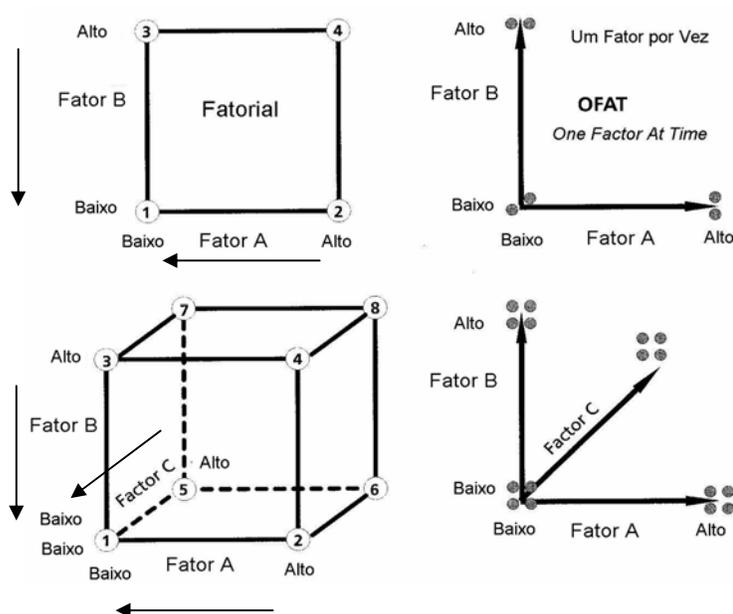


Figura 22 - Fatoriais de dois e três fatores a dois níveis versus OFAT
Fonte: ANDERSON ; WHITCOMB, 2000.

A estimativa dos efeitos é baseada nas médias de 2 e 4 rodadas para fatorial 2^2 e 2^3 respectivamente, conforme o sentido indicado pelas setas (ilustradas na Figura 22): direita para esquerda (fator A), cima para baixo (fator B) e do fundo para frente (fator C), seguindo a equação (13), onde n se refere ao número de pontos coletados em cada nível do fator.

$$Efeito = \frac{\sqrt{y_+}}{n_+} - \frac{\sqrt{y_-}}{n_-} \quad (13)$$

Um exemplo segue na Figura 23, onde existem oitotestes que proporcionam informação para cada variável (X_1 ou X_2) em cada nível escolhido (+) ou (-). Encontrando a diferença das médias nos resultados do experimento, tem-se a medida do efeito de mudar de um nível para outro, sobre a variável em avaliação:

$$a) Efeito_{X_1} = \frac{Y_1 + Y_2 + Y_3 + Y_4}{4} - \frac{Y_5 + Y_6 + Y_7 + Y_8}{4};$$

$$b) Efeito_{X_2} = \frac{Y_3 + Y_4 + Y_5 + Y_6}{4} - \frac{Y_1 + Y_2 + Y_7 + Y_8}{4};$$

$$c) Efeito_{da\ Interação\ X_1 - X_2} = \frac{Y_3 + Y_4 + Y_7 + Y_8}{4} - \frac{Y_5 + Y_6 + Y_1 + Y_2}{4}.$$

O resultado do experimento fatorial indicará qual variável ou interação possui um efeito mais pronunciado sobre a variável de resposta. Testes estatísticos podem ser usados para determinar se quaisquer dos efeitos diferem de zero.

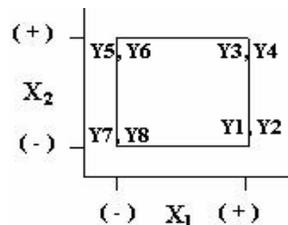


Figura 23 - Experimento fatorial 2^3 . Projeção em duas dimensões do cubo.

As aplicações de PAE, segundo Montgomery (2001), resumem-se em:

- caracterização do processo – através de experimentos usualmente fracionados para identificar os fatores críticos de processo, determinar a direção de ajuste dos fatores para reduzir o número de experimentos;
- otimização do processo – na fase da caracterização, o maior interesse é determinar quais variáveis afetam a resposta. Um próximo passo lógico é a otimização, que consiste em determinar a região nos fatores importantes que direciona para a melhor resposta possível.

3.1 PRINCÍPIOS BÁSICOS DO PAE

Os três princípios básicos do projeto de experimento, conforme Montgomery (2001), são a replicação, a randomização e o bloqueamento. Tais princípios são definidos na seqüência:

- a) **replicação**- trata-se da repetição do experimento básico. Pode apresentar, duas vantagens: a) permite ao experimentador obter uma estimativa do erro experimental. Esta estimativa de erro torna-se uma unidade básica de medida para determinar se as diferenças observadas nos dados são realmente estatisticamente diferentes; b) caso a média da amostra seja usada para estimar o efeito de um fator no experimento, a replicação permite ao experimentador obter uma estimativa mais precisa deste efeito. A réplica reflete fontes de variabilidade entre testes e dentro dos testes (MONTGOMERY, 2001). Replicação aumenta a probabilidade de detectar um efeito estatisticamente significativo, no meio da variação natural do processo (ruído) (ANDERSON, KRABER, 1999);
- b) **randomização** - trata-se da alocação do material do experimento e da determinação da ordem na qual os testes individuais devem ser realizados de forma aleatória (MONTGOMERY, 2001). A randomização evita a influência de variáveis não controláveis, por exemplo, temperatura ambiente e alterações na matéria-prima. Estas alterações que são comumente relacionadas à temperatura podem significativamente influenciar a resposta. Caso não randomizar a ordem dos experimentos, o PAE poderá indicar os efeitos de fatores que realmente são devido a variáveis não controláveis e que variam no momento do experimento (ANDERSON, KRABER, 1999);
- c) **bloqueamento** - é uma técnica de projeto usada para melhorar a precisão com as quais comparações entre os fatores de interesse são realizadas. Geralmente os blocos são utilizados para reduzir ou eliminar a variabilidade transmitida por fatores de distúrbios, que são fatores que podem influenciar a resposta experimental, mas sobre os quais não se tem interesse direto (MONTGOMERY, 2001).

Para usar o método estatístico de projeto e análise de experimentos é necessário que todos os envolvidos no experimento tenham uma idéia clara do que deve ser estudado, como

os dados devem ser coletados e, no mínimo, um entendimento qualitativo de como os dados coletados devem ser analisados (MONTGOMERY, 2001).

Através de todo o processo, é importante ter em mente que a experimentação é uma parte importante do processo de aprendizado, onde se formulam hipóteses iniciais sobre um sistema, realizam-se experimentos para investigar essas hipóteses e, com base nos resultados, formulam-se novas hipóteses. Isso sugere que a experimentação é iterativa.

A Figura 25 apresenta um quadro comparativo da seqüência proposta para o encaminhamento de um projeto de experimentos segundo diferentes autores. Montgomery (2001) sugere o uso de planilhas para condução do experimento, enquanto Echeveste e Ribeiro (1999) apresentam a Matriz de Otimização de Processos. Para o desenvolvimento do experimento apresentado no capítulo 4, será apresentada uma variação da Matriz de Otimização de Processos, segundo a proposta de planejamento de experimento da Figura 24 (CATEN; RIBEIRO, 2000).

Luftig e Jordan (1999) apresentam um modelo do processo de projeto de pesquisa organizado em termos do ciclo Plan, Do, Study, Act (PDSA), onde inclui a condução de experimentos, conforme as fases: **P** – refinar e desenvolver a descrição do problema, definir a estrutura de estudo da pesquisa, escrever as hipóteses e questões da pesquisa, definir e selecionar as variáveis dependentes e os critérios de medição, identificar e classificar os tratamentos, variáveis independentes e de ruído, criar o mais adequado e eficiente projeto de experimentos possível e disponível, desenhar o plano de amostragem, avaliar os instrumentos de coleta de dados; fase **D** – conduzir o estudo, executar o projeto de experimentos e coletar dados; fase **S** – projetar e selecionar um plano adequado para a análise estatísticas dos dados, analisar os dados; fase **A** – responder as questões da pesquisa e do teste de hipóteses, fornecer resultados, conclusões e recomendações para pesquisas futuras.

Ouvir a voz do cliente (O QUÊ):	Ouvir a voz do engenheiro (COMO):	Planejamento Final e Execução	Análise	Otimização
<p>-Pesquisa de mercado</p> <p>-Identificar Características de Qualidade (C.Q) de interesse</p> <p>-Identificar a importância relativa das C.Q. (pesos)</p>	<p>Definir:</p> <p>-Variáveis de resposta (VR) associadas às C.Q</p> <p>Identificar:</p> <p>-Outras variáveis de resposta de interesse</p> <p>- Parâmetros do processo (P.P)</p> <p>- Intervalo de variação dos P.P</p> <p>- Fatores controláveis (PP que podem afetar as VR)</p> <p>Definir:</p> <p>-Número de níveis para cada FC</p> <p>-Possíveis interações entre os FC</p> <p>Identificar restrições experimentais</p> <p>Escolher modelo estatístico</p>	<p>- Escrever a matriz experimental</p> <p>-Definir ordem dos ensaios (aleatorização)</p> <p>-Definir procedimentos de ensaios (uniformização)</p> <p>-Desenhar planilhas de coleta de dados</p> <p>- Executar o experimento e anotar o resultado</p>	<p>-Fazer ANOVA</p> <p>- Escrever uma tabela de médias</p> <p>- Fazer gráficos dos efeitos principais</p> <p>-Fazer gráficos das interações significativas</p> <p>- Fazer análise de regressão</p>	<p>-Modelar individualmente cada variável de resposta</p> <p>- Definir uma função objetivo</p> <p>- Otimizar, i.e, achar o ajuste dos FC que maximizam ou minimizam a função objetivo</p>

Figura 24 - Etapas de um experimento
 Fonte: CATEN; RIBEIRO, 2000

Montgomery (2001)	Hahn (2001)	Anderson et. al, (2000)	Knowlton (2001)
<i>Descrição e Reconhecimento do Problema</i>	<i>Reunir informações necessárias e documentação referente ao experimento</i>	<i>Definir objetivos</i>	<i>Definir a equipe de trabalho do experimento</i>
<i>Escolha dos Fatores e Níveis</i>	<i>Entender o modelo e as variáveis</i>	<i>Medir respostas quantitativamente</i>	<i>Escrever os objetivos do experimento</i>
<i>Seleção das Variáveis de Resposta</i>	<i>Acompanhar os experimentos ativamente</i>	<i>Replicação para reduzir variações não controláveis (ruídos)</i>	<i>Desenvolver um entendimento comum sobre o experimento</i>
<i>Escolha do Tipo de Experimento</i>	<i>Obter medições do erro experimental real</i>	<i>Randomização da ordem dos experimentos</i>	<i>Realizar brainstorming nos fatores e níveis</i>
<i>Realização do Experimento</i>	<i>Incluir condições de operação básica no plano experimental</i>	<i>Bloqueamento das fontes de Variação</i>	<i>Gerar as planilhas de dados e do experimento</i>
<i>Análise Estatística dos Dados</i>	<i>Considerar um plano de experimentação multi-estágio</i>	<i>Conhecimento de quais efeitos serão confundidos (caso ocorrer)</i>	<i>Realizar o experimento e analisar os resultados</i>
<i>Conclusões e Recomendações</i>	<i>Manter a simplicidade nos experimentos</i>	<i>Realizar a sequência de experimentos</i>	<i>Realizar experimento de follow-up e implementar a solução</i>
	<i>Revisar as propostas do experimento e prever os resultados possíveis</i>	<i>Criticar os resultados</i>	<i>Realizar o refinamento do experimento</i>
	<i>Documentar e protocolar o plano experimental</i>		
	<i>Preparar-se para as mudanças</i>		

Figura 25 - Quadro comparativo das propostas de seqüências de projetos de experimentos

3.2 EXPERIMENTOS COMPARATIVOS SIMPLES

Os experimentos comparativos simples também são chamados de tratamentos ou experimentos para comparar duas condições sendo testadas (MONTGOMERY, 2001). O número de fatores nos experimentos comparativos simples é um, conforme ilustrado no fluxograma da Figura 26 (ANDERSON;WHITCOMB, 2000).

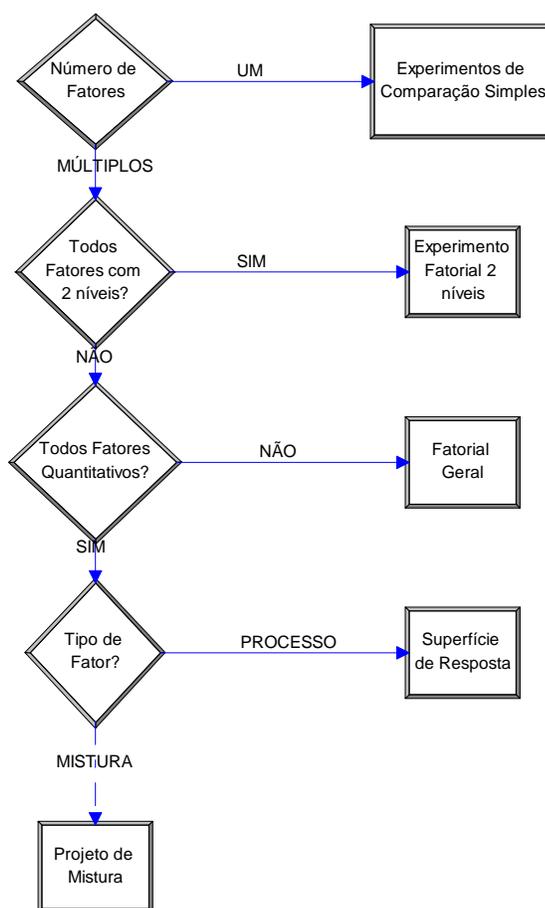


Figura 26 - Fluxo guia para projeto e análise de experimentos
Fonte: ANDERSON ; WHITCOMB, 2000

Os dados dos experimentos comparativos simples podem ser plotados em gráficos tipo diagrama de pontos (Figura 27) ou em *box plots* (Figura 28). O diagrama permite ao experimentador visualizar rapidamente a tendência central das observações e suas dispersões. O exemplo da Figura 27 mostra que as respostas do experimento (y_1 e y_2) nos dois níveis de um fator diferiram na média, porém apresentaram aproximadamente a mesma variação (MONTGOMERY, 2001).

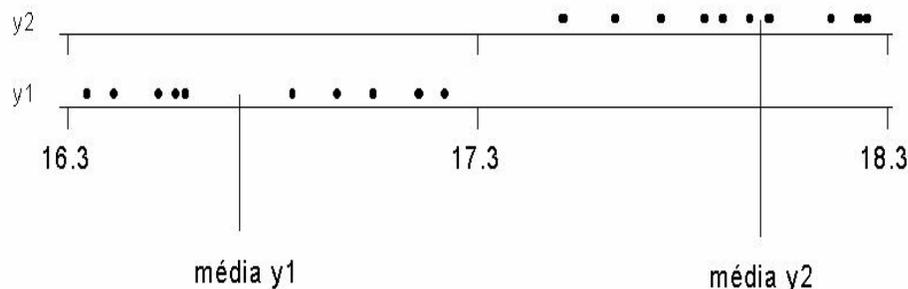


Figura 27 - Exemplo de diagrama de pontos
Fonte: MONTGOMERY, 2001.

O diagrama de pontos é útil para mostrar uma pequena quantidade de dados. Caso a quantidade de dados aumente, os pontos no diagrama de pontos tornam-se difíceis de distinguir, tornando o histograma uma melhor forma de visualização dos dados. O histograma mostra a tendência central, dispersão e um formato generalizado da distribuição dos dados.

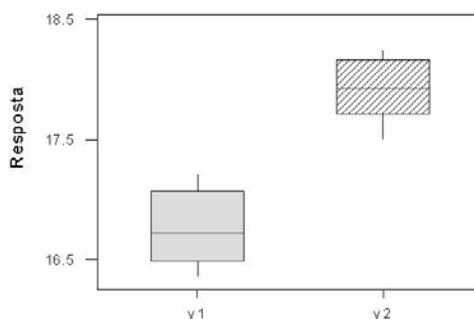


Figura 28 - Exemplo de gráfico box plot
Fonte: MONTGOMERY, 2001.

O gráfico de *box plot* Figura 28 mostra o mínimo e o máximo, os *quartis* mais baixos e mais altos (25 % e 75%, respectivamente) e a mediana (50%) dos dados, em uma caixa retangular alinhada horizontalmente ou verticalmente. A caixa se estende do primeiro ao quarto *quartil*, e uma linha central é a mediana da caixa. Linhas se estendem a partir da extremidade da caixa, para os valores mínimos e máximos. Existem muitas variações de *box plot* e diferentes regras para denotar os pontos extremos (MONTGOMERY, 2001).

Hoerl (2001) recomenda o ensino das ferramentas gráficas de melhoria, tais como gráficos de Pareto e histogramas, como predecessor, se não, substitutivo para análise estatística formal durante a Fase Analisar do ciclo DMAIC (capítulo 1), no encaminhamento dos projetos Seis Sigma.

Os dados do experimento comparativo simples podem ser analisados utilizando procedimentos de inferência estatística, como testes de hipótese (seção 3.5) e intervalos de confiança (seção 3.6), para comparar as médias de dois tratamentos (MONTGOMERY, 2001). O teste de hipóteses e intervalo de confiança são amplamente discutidos no programa Seis Sigma, com relação à inclusão e ênfase nos currículos de formação de *Black Belts* (HOERL, 2001).

Conforme Anderson e Whitcomb (2000), também pode ser utilizado o teste F simplificado derivado do teorema limite de limite central conforme equação (14). O teste F compara a variância entre as médias dos tratamentos versus a variância individual dentro de um tratamento específico.

$$F = \frac{ns^2_y}{s^2} \quad (14)$$

A fórmula assume que todas as amostras são de igual tamanho n . Pode se pensar o teste F, como uma relação de sinais (diferenças causadas pelo tratamento) versus ruído. A relação F aumenta com o aumento das diferenças dos tratamentos. Ela se torna mais sensível a uma diferença de tratamentos com o aumento do tamanho de amostra n . Assim se algo realmente difere, eventualmente será possível encontrar se mais dados forem coletados. Em contrapartida, a relação F decresce com o aumento da variação no processo ou ruído. É importante antes de iniciar o experimento, que se reduza às variações no processo através do CEP. Se os tratamentos não derem efeito, então a relação F, terá um valor próximo de um. Com o aumento da relação F, torna-se cada vez menos provável que as diferenças nos tratamento ocorram por acaso. É possível quantificar esta probabilidade. O teste F utiliza o quociente de variâncias como estatística do teste, portanto, o procedimento é chamado de análise de variância (Ver seção 3.6).

3.3 MODELO PARA OS DADOS

A representação das observações por um modelo estatístico facilita a compreensão dos testes de hipóteses (item 3.4) e das suposições associadas à análise de variância (item 3.6) (FLESCHE, 2001).

Os resultados do experimento podem ser representados por um modelo estatístico que descreve os dados conforme a equação (15):

$$y_{ij} = \mu_i + \varepsilon_{ij} \quad (15)$$

onde, y_{ij} é a $j^{\text{ésima}}$ observação do fator ao nível i , μ_i é a média da resposta ao $i^{\text{ésimo}}$ nível do fator e ε_{ij} é a variável aleatória normal associada com a observação y_{ij} . Assume-se que ε_{ij} segue uma distribuição normal e seja independente, ou seja, *Normal Independent Distribution* - NID $(0, \sigma_i^2)$, $i = 1, 2$. A variável ε_{ij} é conhecida como a componente de erro aleatório do modelo. Devido as médias μ_1, μ_2 serem constantes, a partir do modelo verifica-se que y_{ij} são NID (μ_i, σ_i^2) , $i = 1, 2$ (MONTGOMERY, 2001).

Uma forma alternativa de escrever a equação (15) é:

$$\mu_{ij} = \mu_i + \tau_i \quad i = 1, 2, \dots, k, \quad (16) \text{ para que a equação (15) torne-se}$$

$$y_{ij} = \mu_i + \tau_i + \varepsilon_{ij} \quad i = 1, 2, \dots, k / j = 1, 2, \dots, n \quad (17)$$

onde, μ é um parâmetro comum a todos os tratamentos, chamado de média global, τ_i é um parâmetro único ao tratamento i , chamado de efeito do $i^{\text{ésimo}}$ tratamento e ε_{ij} é o erro aleatório.

A equação (17) é chamada efeito do modelo (MONTGOMERY, 2001) ou modelo de análise de variância para um fator (item 3.8), por estar sendo investigado o efeito de um único fator sobre a variável de resposta de interesse (MONTGOMERY, 2001; WERKEMA, 1996).

Tanto a média do modelo quanto seu efeito são descritos por modelos estatísticos lineares, em que a variável de resposta y_{ij} é função linear dos parâmetros do modelo. O efeito do modelo é mais utilizado na literatura de projeto de experimentos. Há um entendimento intuitivo de que μ é constante e os efeitos dos tratamentos τ_i representam desvios desta constante, quando tratamentos específicos são aplicados (MONTGOMERY, 2001).

O objetivo do experimento é testar hipóteses apropriadas sobre os efeitos dos tratamentos e estimá-los. Além do teste de hipótese para médias, podem ser testadas hipóteses

sobre a variância de uma população, testes de hipóteses para índice de capacidade C_p , teste de hipótese para proporção p (WERKEMA, 1996).

3.4 TESTES DE HIPÓTESES

Uma hipótese estatística é uma afirmação sobre os parâmetros de uma distribuição de probabilidade ou parâmetros de um modelo (WERKEMA, 1996). Em um experimento, pode-se supor que as médias das variáveis de resposta (μ_1, μ_2) medidas em dois níveis de um fator sejam iguais. Isto pode ser escrito formalmente conforme abaixo (MONTGOMERY, 2001):

$$H_0 : \mu_1 = \mu_2 \text{ (hipótese nula);}$$

$$H_A : \mu_1 \neq \mu_2 \text{ (hipótese alternativa, verdadeira se } \mu_1 > \mu_2 \text{ ou } \mu_1 < \mu_2 \text{).}$$

As amostras são retiradas de duas populações normais independentes.

Assume-se a comparação de um fator a dois níveis, sendo, $y_{11}, y_{12}, \dots, y_{1n_1}$ as n_1 observações do primeiro nível do fator e $y_{21}, y_{22}, \dots, y_{2n_2}$ as n_2 observações do segundo nível do fator. Para testar uma hipótese, pode-se usar a seguinte seqüência de passos: a) observar uma amostra aleatória; b) computar uma estatística de teste apropriada; e c) rejeitar ou não a hipótese nula H_0 . Parte do procedimento é a especificação do conjunto de valores para o teste estatístico que leva a rejeição de H_0 . O conjunto de valores é chamado de região crítica ou região de rejeição para o teste (MONTGOMERY, 2001).

Dois erros podem emergir em um teste de hipóteses: a) erro Tipo I, quando a hipótese nula é rejeitada, apesar de ser verdadeira; b) erro Tipo II a hipótese nula não é rejeitada, apesar de ser falsa.

A probabilidade destes dois erros é representada por:

$\alpha = P(\text{Erro tipo I}) = P(\text{rejeitar } H_0 | H_0 \text{ é verdadeiro})$, probabilidade de rejeitar H_0 dado que H_0 é verdadeiro,

$\beta = P(\text{Erro tipo II}) = P(\text{falhar rejeitar } H_0 | H_0 \text{ é falso})$ probabilidade de falhar em rejeitar H_0 tal que H_0 é falso,

O procedimento geral no teste de hipóteses é especificar um valor de probabilidade para o erro Tipo I (α), freqüentemente chamado de nível de significância do teste, e então projetar

o procedimento do teste para que a probabilidade do erro tipo II (β) resulte pequena (MONTGOMERY, 2001).

3.5 INTERVALOS DE CONFIANÇA

Em muitos experimentos de Engenharia, o experimentador já sabe que μ_1 e μ_2 diferem, sendo neste caso mais importante conhecer o intervalo de confiança das diferenças de médias μ_1 e μ_2 (MONTGOMERY, 2001).

A definição de intervalo de confiança supõe que θ seja um parâmetro desconhecido. Para obter um intervalo de estimativa de θ , é necessário encontrar duas estatísticas, L e U, tal que a sentença de probabilidade $P(L \leq \theta \leq U) = 1 - \alpha$, seja verdadeira. O intervalo $L \leq \theta \leq U$ é chamado intervalo de $100(1 - \alpha)$ por cento de confiança para o parâmetro θ . A interpretação do intervalo, é que se, em amostras aleatórias repetidas, um grande número de tais intervalos são construídos, $100(1 - \alpha)$ por cento deles conterão o valor verdadeiro de θ .

As estatísticas L e U são chamadas os limites de confiança inferior e superior, respectivamente, e $1 - \alpha$ é chamado coeficiente de confiança. Se $\alpha = 0,05$, $L < \theta < U$ é um intervalo de confiança de 95 por cento para θ . O intervalo de confiança tem uma interpretação de frequência, onde sabe-se que o método usado para produzir intervalos de confiança proporciona as probabilidades corretas $100(1 - \alpha)$ por cento das vezes (MONTGOMERY, 2001).

Na prática, é extraído apenas uma amostra aleatória da população e construído um único intervalo de confiança para o parâmetro θ de interesse. Afirma-se, então, que θ pertence ao intervalo observado, com confiança de $100(1 - \alpha)$ por cento.

Um intervalo de confiança de $100(1 - \alpha)\%$ para a média μ pode ser obtido com base na distribuição da média amostral \bar{x} . A distribuição de \bar{x} será normal se a população for descrita por uma distribuição normal. Nesse caso, sabe-se que $z = \frac{x_i - \mu}{\sigma/\sqrt{n}}$, segue uma distribuição normal padronizada, isto é, $z \sim N(0,1)$.

Da distribuição normal, tem-se $P(-z_{\alpha/2} \leq z \leq z_{\alpha/2}) = 1 - \alpha$, que é equivalente a:

$$P(-z_{\alpha/2} \leq \frac{x - \mu}{\sigma/\sqrt{n}} \leq z_{\alpha/2}) = 1 - \alpha \Rightarrow P(x - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq x + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$$

Comparando $P(L \leq \theta \leq U)$ com a equação acima e trocando θ por μ , o intervalo de $100(1 - \alpha)$ % confiança é dado por $(x - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq x + z_{\alpha/2} \frac{\sigma}{\sqrt{n}})$. O desvio padrão da população σ não é conhecido; porém, em amostras de tamanho grande ($n > 30$), σ pode ser substituído pelo desvio padrão amostral s , tal que $x - z_{\alpha/2} s/\sqrt{n} \leq \mu \leq x + z_{\alpha/2} s/\sqrt{n}$.

Para construir o intervalo de confiança para a média de uma população a partir de uma amostra grande, ($n > 30$), pode-se seguir os seguintes passos: a) coletar uma amostra aleatória da população de interesse; b) calcular os valores \bar{x} e s ; c) escolher o valor do coeficiente de confiança $1 - \alpha$; d) determinar o valor de $z_{\alpha/2}$ a partir da tabela de distribuição normal padronizada; e) calcular os limites de confiança $\bar{x} \pm z_{\alpha/2} s/\sqrt{n}$; e (vi) interpretar o resultado.

Hoerl (2001) recomenda enfatizar intervalos de confiança em relação aos testes de hipóteses durante o treinamento das ferramentas do Seis Sigma no curso de formação de *Black Belts*. Abraham e MacKay (2001) suportam a mesma idéia. Para Hoerl, (2001) os testes de hipótese tendem a esconder o impacto do pequeno tamanho de amostra, levando a conclusão não apropriada que realmente não há diferença ou efeito. O efeito do aumento do tamanho de amostra no teste de hipóteses geralmente permite uma redução simultânea do nível de significância (α) e erro tipo II (β), pois quanto maior o tamanho de amostra, mais informações existem sobre o valor verdadeiro de μ (WERKEMA, 1996). Outro aspecto que Hoerl (2001) considera em relação ao teste de hipóteses é que a diferença conceitual entre aceitar a hipótese nula versus “falhar em rejeitar” a hipótese nula, não é fácil de transmitir, e freqüentemente não apresenta uma distinção clara para não estatísticos.

3.6 ANÁLISE DE VARIÂNCIA (ANOVA – ANALYSIS OF VARIANCE)

A análise de variância é utilizada para verificar se os efeitos principais dos fatores e os efeitos das interações em um experimento são significativos. A ANOVA permite concluir, com grau de confiança conhecido, se existem ou não diferenças entre as médias de mais de duas populações (WERKEMA, 1996). A variância σ^2 é uma medida de variabilidade da população. A Tabela 5 representa os dados de k tratamentos ou diferentes níveis de um fator.

A resposta observada para cada tratamento k , é uma variável aleatória. A média das médias

das observações é definida por $\bar{y}_{\dots} = \sum_{i=1}^k \sum_{j=1}^n \bar{y}_{ij}$.

Tabela 5 - Dados típicos de um experimento de fator simples.

Tratamento (nível)	Observações					Total	Médias
1	y_{11}	y_{12}	.	.	.	$y_{1\cdot}$	$\bar{y}_{1\cdot}$
2	y_{21}	y_{22}	.	.	.	$y_{2\cdot}$	$\bar{y}_{2\cdot}$
.
k	y_{k1}	y_{k2}	.	.	.	$y_{k\cdot}$	$\bar{y}_{k\cdot}$
						y_{\dots}	\bar{y}_{\dots}

Fonte: MONTGOMERY, 2001

O termo análise de variância se origina de particionar a variabilidade total em suas partes componentes para análise (BREYFOGLE, 1999).

Um exemplo a seguir descreve os passos para a aplicação de ANOVA para determinar se ocorrerão diferenças na dimensão de uma peça quando um ajuste específico for realizado em um processo considerando cinco diferentes níveis de ajustes (BREYFOGLE, 1999):

- a) descrever o problema utilizando a variável de resposta que corresponde a variável de saída do processo chave ou a característica medida da qualidade: problema - a dimensão da peça não atende a especificação;
- b) descrever a análise: determinar se existe diferença na dimensão da peça quando um ajuste determinado da máquina é alterado nos cinco níveis diferentes,
 - descrever as hipóteses:

$$H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu_5,$$

$$H_A : \mu_1 \neq \mu_2 \neq \mu_3 \neq \mu_4 \neq \mu_5,$$

onde μ_x é a média da dimensão da peça utilizando um ajuste x ,

- escolher uma amostra grande o suficiente e conduzir o experimento aleatoriamente,
- gerar a tabela de análise de variância (seção 3.8),

- testar a normalidade dos dados e igualdade das hipóteses da variância. (seções 3.7 e 3.11),
- fazer as decisões de hipótese sobre os fatores a partir da tabela ANOVA,
- calcule os ε^2 ,
- fazer a análise das médias, ANOM,
- traduzir as conclusões do experimento em necessidades do problema ou processo em questão.

3.7 TESTE DE HIPÓTESE PARA ANOVA *ONE-WAY*

A análise de variância avalia as diferenças entre amostras tomadas a diferentes níveis do fator para determinar se estas diferenças são grandes o suficiente relativo ao erro para concluir que em geral existe uma diferença significativa na resposta devido ao nível do fator (BREYFOGLE, 1999).

Para a análise de variância de um fator único, um modelo estatístico linear conforme equação (17), pode descrever as observações de um nível, com j observações tomadas sobre o nível i ($i = 1, 2, \dots, a; j = 1, 2, \dots, n$).

Para o teste de hipótese da análise de variância, os erros do modelo são considerados variáveis aleatórias independentes com distribuição normal, média igual a zero e variância σ^2 constante para todos os níveis do fator.

A expressão para o teste de hipótese das médias é:

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_a,$$

$$H_A : \mu_i \neq \mu_j \text{ para no mínimo um par } (i, j)$$

Quando H_0 é verdade, todos os níveis do fator tem uma média comum μ , que leva a expressão equivalente em termos de nível do efeito τ :

$$H_0 : \tau_1 = \tau_2 = \dots = \tau_a = 0,$$

$$H_A : \tau_i \neq 0, \text{ para no mínimo um } i,$$

Assim, o teste de análise de variância para um fator único, pode ser descrito pela igualdade das médias do nível ou se os efeitos do nível (τ_i) são zero (BREYFOGLE, 1999).

3.8 TABELA DE CÁLCULOS ANOVA

A soma dos quadrados totais dos desvios com relação à média global $\bar{y}_{..}$ descreve a variabilidade global dos dados conforme equação (18):

$$SQT = \sum_{i=1}^k \sum_{j=1}^n (y_{ij} - \bar{y}_{..})^2 \quad (18)$$

A expressão acima pode ser particionada como a soma de dois elementos conforme equação (19). O primeiro elemento é a soma dos quadrados das diferenças entre média do nível do fator e a média global (equação 20). O segundo elemento é a soma dos quadrados das diferenças das observações dentro do nível do fator com relação à média do nível do fator (equação 21). O primeiro elemento é uma medida da diferença entre as médias dos níveis, onde o segundo elemento é o erro aleatório.

$$SQT = n \sum_{i=1}^k (\bar{y}_i - \bar{y}_{..})^2 + \sum_{i=1}^k \sum_{j=1}^n (y_{ij} - \bar{y}_i)^2 \quad (19)$$

Simbolicamente esta relação é definida por $SQT = SQG_{\text{nível do fator}} + SQR_{\text{erro}}$, onde $SQG_{\text{nível do fator}}$, é a soma dos quadrados devido ao nível do fator (i.e., entre o nível do fator ou tratamentos). O termo mede a variação devido ao acaso quando as médias dos tratamentos forem iguais. Quando as médias forem diferentes, $SQG_{\text{nível do fator}}$ refletirá a variação entre as médias populacionais, além da variação devida ao acaso.

SQR_{erro} é a soma dos quadrados devido ao erro (i.e, dentro do nível do fator ou tratamento). O termo mede a variação devida ao acaso, isto é, a variação entre as observações dentro das amostras. SQR_{erro} capta a variação dos processos sem levar em conta o efeito da possível diferença entre as médias dos tratamentos.

$$SQG_{\text{nível do fator}} = n \sum_{i=1}^k (\bar{y}_i - \bar{y}_{..})^2 \quad (20)$$

$$SQR_{\text{erro}} = \sum_{i=1}^k \sum_{j=1}^n (y_{ij} - \bar{y}_i)^2 \quad (21)$$

Ao dividir pelo número respectivo de graus de liberdade estas somas de quadrados dão uma boa estimativa da variabilidade total, variabilidade entre níveis de fator, e variabilidade dentro dos níveis do fator (ou erro), conforme as expressões para as médias quadradas (22 e -23):

$$MQG_{\text{nível_do_fator}} = \frac{SQG_{\text{nível_do_fator}}}{k-1} \quad (22)$$

$$MQR = \frac{SQR_{\text{erro}}}{k(n-1)} \quad (23)$$

Se não houver diferenças na média dos tratamentos, as duas estimativas presumem ser similares. Se há diferença, suspeita-se que a diferença observada é causada pelas diferenças nos níveis do fator do tratamento. A hipótese nula que não há diferença nos níveis do fator é testada calculando-se a estatística de teste F, equação (24).

$$F_0 = \frac{MQG}{MQR} \quad (24)$$

Utilizando-se a tabela F (BREYFOGLE, 1999), deveria se rejeitar a hipótese nula e concluir que existem diferenças nas médias do tratamento, se $F_0 > F_{\alpha, k-1, k(n-1)}$. O procedimento de teste é resumido na Tabela 6:

Tabela 6 - Tabela de análise de variância para um fator

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Quadrado Médio	F0
Entre Tratamentos	$SQG_{\text{níveis do Fator}}$	$k-1$	$MQG_{\text{níveis do fator}}$	$F_0 = MQG / MQR$
Residual	SQR_{erro}	$k(n-1)$	MQR_{erro}	
Total	SQT	$kn-1$		

3.9 ANÁLISE DE VARIÂNCIA A DOIS FATORES (*TWO-WAY* ANOVA)

O experimento fatorial a dois fatores toma a forma da Tabela 7, onde o projeto é considerado completamente randomizado, porque as observações tomadas são aleatorizadas.

Tabela 7 - Arranjo geral para projeto fatorial de dois fatores

		Fator B			
		1	2	...	b
Fator A	1				
	2				
	...				
	a				

Fonte: BREYFOGLE, 1999.

Na Tabela 7 o fator A tem níveis variando de um até a, enquanto o fator B tem níveis variando de 1 até b, e as replicações vão de um até n. As respostas para as várias combinações do fator A com o fator B tomam a forma de y_{ijk} , onde i representa o nível do fator A, j descreve o nível do fator B e k representa o número das replicações. O número total de observações é então, a.b.n.

Uma descrição de um modelo linear de dois fatores é $\hat{Y}_{ijk} = \mu + \tau_i + \beta_j + (\tau\beta)_{ij} + \varepsilon_{ijk}$,

onde, μ é a média global, τ_i é o efeito do $i^{\text{ésimo}}$ nível de A, β_j é o efeito do $j^{\text{ésimo}}$ nível de B, $(\tau\beta)_{ij}$ é o efeito da interação e ε_{ijk} é o erro aleatório. Para o fatorial a dois níveis os tratamentos para os fatores A e B tem o mesmo valor.

O teste de hipótese para o fator A é:

$$H_0 : \tau_1 = \tau_2 = \dots = \tau_a = 0$$

$$H_A : \text{pelo menos um } \tau_i \neq 0,$$

O teste de hipótese para o fator B é:

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_b = 0$$

$$H_A : \text{pelo menos um } \beta_j \neq 0,$$

O teste de hipótese para a interação entre fator A e B é:

$$H_0 : (\tau\beta)_{ij} = 0, \text{ para todos valores de } i, j$$

$$H_A : \text{pelo menos um } (\tau\beta)_{ij} \neq 0,$$

Similar a análise de variância de um fator, a variabilidade total pode ser particionada no somatório da soma dos quadrados dos elementos do experimento, os quais podem ser representados por: $SQT = SQ_A + SQ_B + SQ_{AB} + SQR$, em que SQ_A é a soma dos quadrados do fator A, SQ_B é a soma dos quadrados do fator B, SQ_{AB} é a soma dos quadrados da interação do fator A com o fator B e SQR é a soma dos quadrados dos erros.

A soma destes quadrados tem os seguintes graus de liberdade conforme Tabela 8.

Tabela 8 - Graus de liberdade para experimento fatorial

Efeito	Graus de Liberdade
A	a-1
B	b-1
Interação AB	(a-1).(b-1)
Erro	ab(n-1)

Os cálculos do quadrado médio e F_0 são similares a ANOVA de um fator e estão descritos na Tabela 9.

Tabela 9- Tabela ANOVA *Two way* para modelo de efeitos fixos

Fonte de variação	Soma dos Quadrados	Graus de Liberdade	Médias Quadradas	F_0
Fator A	SQ_A	$a - 1$	$MQ_A = \frac{SQ_A}{a - 1}$	$F_0 = \frac{MQ_A}{MQR}$
Fator B	SQ_B	$b - 1$	$MQ_B = \frac{SQ_B}{b - 1}$	$F_0 = \frac{MQ_B}{MQR}$
Interação AB	SQ_{AB}	$(a - 1) \cdot (b - 1)$	$MQ_{AB} = \frac{SQ_{AB}}{(a - 1) \cdot (b - 1)}$	$F_0 = \frac{MQ_{AB}}{MQR}$
Erro	SQR	$ab(n - 1)$	$MQR = \frac{SQ_E}{ab(n - 1)}$	
Total	SQT	$abn - 1$		

A diferença entre a análise de variância de dois fatores e um projeto de blocos aleatórios em um fator é a consideração da interação (BREYFOGLE, 1999).

3.10 ANÁLISE DE RESÍDUOS

Antes que conclusões sejam tomadas a partir da análise de variância, a adequação do modelo deve ser verificada. A primeira ferramenta de diagnóstico é a análise residual (MONTGOMERY, 2001). A validade da análise depende também de suposições básicas. Uma suposição típica é que os erros seguem uma distribuição normal e independente, com média zero e uma variância constante desconhecida (NID $(0, \sigma^2)$). Para isto as amostras devem ser selecionadas com tamanho adequado e os experimentos realizados aleatoriamente. Após os dados terem sido coletados, rotinas de programas de computador podem ser utilizadas para testar as suposições (BREYFOGLE, 1999).

Um método importante para testar NID $(0, \sigma^2)$ de um experimento é a análise de resíduos. Um resíduo é a diferença entre o valor observado e o correspondente valor ajustado (ver equação 25) análise de resíduos é importante na investigação da adequação do modelo ajustado em detectar distorções do modelo,

$$e_{ij} = y_{ij} - \hat{y}_{ij} \quad (25)$$

onde \hat{y}_{ij} é uma estimativa da observação y_{ij} correspondente obtida conforme equação (26)

$$\begin{aligned}\hat{y}_{ij} &= \hat{\mu} + \hat{\tau}_i \\ \hat{y}_{ij} &= \bar{y}_{..} + (\bar{y}_{i.} - \bar{y}_{..}) \\ \hat{y}_{ij} &= \bar{y}_{i.}\end{aligned}\quad (26)$$

A equação 26 fornece um resultado intuitivo em que a estimativa de qualquer observação no i -ésimo tratamento é justamente a média do tratamento correspondente. Exame dos resíduos deveria ser uma parte automática da análise de variância. Se o modelo for adequado, os resíduos não devem ter nenhuma estrutura, isto é, não devem conter nenhum padrão óbvio. Através do estudo dos resíduos, muitos tipos de inadequações do modelo e violações das suposições podem ser descobertos (MONTGOMERY, 2001).

Técnicas de análise de resíduos incluem as seguintes verificações:

- a) normalidade através da plotagem de probabilidade normal e/ou histograma dos resíduos;
- b) correlação entre os resíduos através da plotagem dos resíduos em uma seqüência de tempo;
- c) correção do modelo através da plotagem dos resíduos versus os valores ajustados.

3.11 ANÁLISE DOS RESÍDUOS: AVALIAÇÃO DE NORMALIDADE

Se a premissa $NID(0, \sigma^2)$ é válida, uma plotagem do histograma dos resíduos deve-se parecer com a plotagem da distribuição normal. Esperam-se consideráveis distorções da normalidade quando o tamanho de amostra é pequeno. Uma plotagem de probabilidade normal dos resíduos pode ser realizada. Se a distribuição do erro é normal, a plotagem lembrará uma linha reta. Comumente uma plotagem dos resíduos mostrará um ponto que é muito maior ou menor que os outros. Este ponto é chamado de *outlier*. Um ou outro *outlier* podem distorcer a análise. Frequentemente os *outliers* são causados por erros nos registros das informações. Se não for o caso, mais análises devem ser realizadas. Talvez este ponto de dado possa trazer informação adicional para o que deve ser feito para melhorar o processo.

Para realizar uma verificação nos *outliers*, substitui-se o valor de erros residuais por $d_{ij} = e_{ij} / \sqrt{MQR_{erro}}$ e examina-se os valores residuais padronizados. Cerca de 68 % dos

residuais padronizados deverão estar dentro de um valor d_{ij} de ± 1 . Da mesma forma, cerca de 95 por cento dos residuais padronizados deverão estar dentro de um valor d_{ij} de ± 2 . Quase todos (99%) os valores residuais padronizados deverão estar dentro de um valor d_{ij} de ± 3 (BREYFOGLE, 1999).

3.12 ANÁLISE DOS RESIDUAIS: SEQUÊNCIA DE TEMPO

Uma plotagem dos resíduos na ordem de coleta dos dados ajuda a detectar correlação entre os resíduos. Uma tendência para rodadas positivas ou negativas de resíduos indica uma correlação positiva. Isto implica uma violação da suposição de independência. Um gráfico de individuais dos resíduos em ordem cronológica por número de observação pode verificar a independência dos erros. Autocorrelação positiva ocorre quando os residuais não trocam de sinais com a frequência que seria esperada, enquanto a autocorrelação negativa é indicada quando os residuais frequentemente trocam de sinais. Este problema pode ser muito sério e difícil de corrigir. É importante evitar o problema inicialmente. Um passo importante na obtenção de independência é conduzir a randomização adequada no início dos testes (BREYFOGLE, 1999).

3.13 ANÁLISE DOS RESIDUAIS: VALORES AJUSTADOS

Para um bom ajuste de modelo, a plotagem dos valores ajustados deverá ser distribuída randomicamente e não ter nenhum padrão. Discrepâncias comuns podem incluir (BREYFOGLE, 1999):

- a) pontos fora (*Outliers*), os quais aparecem como pontos que são muito alto ou muito baixo que os valores residuais normais. Estes pontos devem ser investigados. Talvez, alguns pontos coletados são errados, ou através da avaliação destas amostras, algum conhecimento adicional pode ser obtido levando a melhorias do processo;

- b) variância não constante, onde a diferença entre os valores residuais mais alto e mais baixo, ou aumenta ou decresce para um aumento nos valores ajustados. Isto pode ser causado pelo instrumento de medição, onde o erro é proporcional ao valor medido;
- c) ajuste pobre do modelo, onde, por exemplo, valores residuais parecem aumentar e então diminuem com um aumento no valor ajustado. Para a situação descrita, talvez um modelo quadrático seria um melhor ajuste que o modelo linear.

Os tipos de resposta de experimentos, como, contagem de defeitos, proporção de defeitos, tempo até falhar, não possuem constância de variância, rejeitando assim a premissa de variância constante para análise pelo método dos mínimos quadrados. Uma maneira de corrigir a variância não constante é aplicar uma transformação a variável de resposta (LEWIS *et al.*, 2000). A plotagem anormal dos residuais exibe uma relação de potência entre o desvio padrão da resposta y e a resposta média μ , simbolizada como: $\sigma_y \propto \mu^\alpha$. A Tabela 10 apresenta algumas possibilidades para esta relação juntamente com as transformações adequadas para alguns tipos de dados (ANDERSON; WHITCOMB, 2000).

Tabela 10 - Transformações de dados

Potência (α)	Transformação	Tipo de Resposta
0	Nenhuma	Normal
0,5	Raiz Quadrada	Contagem de defeitos
1	Logarítimo	Erro percentual cte
2	Inversa	Dados de taxa

Fonte: ANDERSON; WHITCOMB, 2000.

3.14 EFEITOS DE SIGNIFICÂNCIA E PLOTAGEM DE PROBABILIDADE

Outra técnica para checar significância é a plotagem em papel de probabilidade. Um efeito (principal ou interação) é dito significativo se sua magnitude é grande o suficiente com relação às outras colunas de contraste que podem ser determinadas no projeto de experimento. Quando a posição de plotagem de um efeito está além dos limites de uma linha reta através da coluna de contraste dos efeitos não significantes, este efeito é dito de ser significativo (BREYFOGLE, 1999). Uma alternativa a plotagem de probabilidade normal dos efeitos do fator é a plotagem meia-normal (*half normal plot*). É uma plotagem dos valores absolutos das estimativas de efeitos contra a probabilidade normal cumulativa (MONTGOMERY, 2001).

3.15 EXPERIMENTOS FATORIAIS 2^k COMPLETOS

Na execução de um fatorial completo, uma resposta é atingida para todas as combinações de todos os níveis dos fatores, conforme exemplo da Tabela 11. Na análise dos três fatores, oito testes são necessários (i.e. $2^3 = 8$). Ao realizar os testes, os fatores são ajustados nos níveis limites – e + sendo os valores de resposta anotados a cada teste.

Dentro do projeto de experimento, cada fator é executado no seu nível alto e baixo, um igual número de vezes. Pode-se notar que existe uma quantidade igual de sinais + e – em cada coluna. A melhor estimativa do efeito do fator pode ser avaliada, notando a diferença na média das saídas dos testes. O cálculo desta relação para o efeito do fator A da Tabela 11 é representado na equação 27.

Tabela 11 - Projeto fatorial completo com três fatores a dois níveis

Teste	A	B	C	Resposta	Exemplo
1	+	+	+	y_1	32
2	+	+	-	y_2	80
3	+	-	+	y_3	77
4	+	-	-	y_4	75
5	-	+	+	y_5	42
6	-	+	-	y_6	71
7	-	-	+	y_7	81
8	-	-	-	y_8	74
Efeito y	Efeito y_A	Efeito y_B	Efeito y_C	\bar{y}	66.5
Exemplo Efeito	-1.0	-20.5	-17		

Fonte: ANDERSON; WHITCOMB, 2000.

$$Efeito_{y_A} = [(\bar{x}_{A^+}) - (\bar{x}_{A^-})] = \frac{y_1 + y_2 + y_3 + y_4}{4} - \frac{y_5 + y_6 + y_7 + y_8}{4} \quad (27)$$

A diferença determinada pela equação é uma estimativa na mudança da resposta média a partir do nível alto para o nível baixo de A. Os outros efeitos dos fatores são calculados de maneira similar. No exemplo da Tabela 11, o impacto ou efeito dos fatores B (20,5) e C (17) são maiores que o fator A (1.0). Porém, antes de tomar alguma conclusão é necessário considerar os efeitos causados pela interação dos fatores.

Efeitos de interação são uma medida dos níveis dos fatores trabalhando juntos para afetar uma resposta. Exemplo, rendimento de um produto degrada quando a temperatura é alta em conjunção com a umidade sendo baixa. O fatorial completo 2^3 permite estimar todas as

interações de dois fatores, AB, AC e BC, além de uma interação de três fatores ABC. Incluindo os efeitos principais, causados por A, B e C, tem-se o total de sete efeitos, o máximo que se pode estimar de um projeto fatorial de oito testes, pois um grau de liberdade é utilizado para estimar a média global (Tabela 12). Colunas de interação são geradas na matriz multiplicando as colunas apropriadas e considerando o sinal resultante. A estimativa da interação BC, o maior efeito da Tabela 12 é determinado pela equação 28.

$$Efeito_{y_{BC}} = [(\overline{x_{BC^+}}) - (\overline{x_{BC^-}})] = \frac{y_1 + y_4 + y_5 + y_8}{4} - \frac{y_2 + y_3 + y_6 + y_7}{4} \quad (28)$$

Tabela 12 - Projeto de experimento fatorial completo considerando interações.

Testes ordem padrão	Efeitos Principais			Efeitos de Interação				Resposta	Exemplo
	A	B	C	AB	BC	AC	ABC		
1	+	+	+	+	+	+	+	y ₁	32
2	+	+	-	+	-	-	-	y ₂	80
3	+	-	+	-	-	+	-	y ₃	77
4	+	-	-	-	+	-	+	y ₄	75
5	-	+	+	-	+	-	-	y ₅	42
6	-	+	-	-	-	+	+	y ₆	71
7	-	-	+	+	-	-	+	y ₇	81
8	-	-	-	+	+	+	-	y ₈	74
Efeito y	-1.0	-20.5	-17.0	-0.5	-21.5	-6.0	-3.5	\bar{y}	66.5

Fonte: ANDERSON ; WHITCOMB, 2000.

Verifica-se através dos cálculos dos efeitos que o efeito da interação BC é maior que os feitos de B e C individualmente. É importante verificar no experimento fatorial se o efeito calculado é significativo relativo às diferenças causadas pelo erro experimental. Em uma escala absoluta de valores, os outros efeitos de interação variam de próximo a zero, para AB até 6 para a interação AC. Esta variação pode ter ocorrido aleatoriamente devido a variações normais o que pode ser verificado através da plotagem meia-normal (ver seção 3.15) dos efeitos para a variável y₁ da Tabela 13, conforme Figura 29 (ANDERSON; WHITCOMB, 2000).

Pontos	Efeitos	Valor absoluto do efeito	Probabilidade Cumulativa
1	AB	0.5	7.14%
2	A	1.0	21.43%
3	ABC	3.5	35.71%
4	AC	6.0	50.00%
5	C	17.0	64.79%
6	B	20.5	78.57%
7	BC	21.5	92.86%

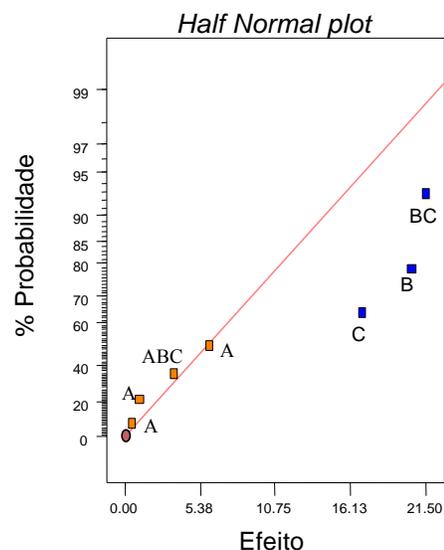


Figura 29 - Tabela de probabilidade e plotagem *half*-normal.

Da análise do gráfico da Figura 29 nota-se que os efeitos maiores BC, B e C estão fora da reta, sendo provavelmente os mais significativos. Os efeitos AC, ABC, A, e AB estão sobre a linha reta indicando uma distribuição normal. Estes efeitos são utilizados como estimativa de erro na análise de variância e no diagnóstico dos erros residuais para verificar as conclusões da plotagem *half*-normal.

Se a interação entre dois fatores for significativa, mais informações são determinadas sobre as interações, através de plotagens (ver Figura 30). Nota-se que existem quatro combinações dos níveis dos fatores BC (níveis BC: ++, +-, -+ e --). O valor médio para cada uma destas combinações é calculado primeiramente e então plotado. Por exemplo, o resultado dos experimentos um e cinco na Tabela 3.10 com os fatores B e C nos níveis ++ é 32 e 42 respectivamente. O efeito BC^+ é 37, $(y_1 + y_5/2)$.

Ordem padrão	B	C	Resposta y
1,5	+	+	37.0
2,6	+	-	75.5
3,7	-	+	79.0
4,8	-	-	74.5

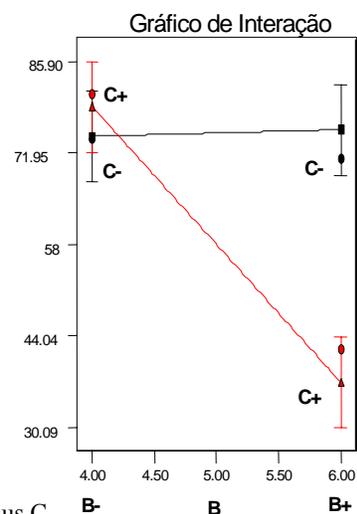


Figura 30 - Interação dos fatores B versus C

Na plotagem o efeito do fator B depende do nível do fator C. Quando o fator C está no nível baixo (-), a mudança na variável de resposta y é mínima, de 74,5 a 75,5. O sistema não é afetado pelo fator B. Porém quando o fator C é alto (+), a variável de resposta vai de 79 para 37, mostrando um impacto maior no efeito devido a um aumento no fator B. Os níveis destes fatores interagem para afetar o nível da resposta de saída. Se não ocorrer interação entre os fatores, as linhas na plotagem de interação serão paralelas.

Para a análise de variância, a soma dos quadrados (SQ) pode ser computada pela equação (29), válida para experimentos fatoriais a dois níveis balanceados (ANDERSON; WHITCOMB, 2000):

$$SQ = \frac{N}{4} Efeito^2 \quad (29)$$

onde N é o número testes, sendo $SQ_B = \frac{8}{4}(-20,5)^2 = 840,5$, $SQ_C = \frac{8}{4}(-17)^2 = 578$ e $SQ_{BC} = \frac{8}{4}(-21,5)^2 = 924,5$.

Ao serem somados, a resultante da soma dos quadrados formando o início da tabela ANOVA tem-se: $SQ_{modelo} = SQ_B + SQ_C + SQ_{BC} = 840,5 + 578 + 924,5 = 2343$. As somas dos quadrados dos efeitos menores do gráfico da Figura 30 serão somadas para estimar o erro chamado residual conforme:

$$SQ_{residual} = SQ_A + SQ_{AB} + SQ_{AC} + SQ_{ABC} = \frac{8}{4}(-1)^2 + \frac{8}{4}(-0,5)^2 + \frac{8}{4}(-6)^2 + \frac{8}{4}(-3,5)^2 = 99$$

Estes resultados são transportados para a tabela ANOVA conforme Tabela 13.

Tabela 13 - ANOVA para exemplo

Fonte	Soma dos Quadrados	Grau de liberdade	Quadrado médio	Valor F	Prob> F
Modelo	2343,0	3	781,0	31,5	<0,01
B	840,5	1	840,5	34,0	<0,01
C	578,0	1	578,0	23,3	<0,01
BC	924,5	1	924,5	37,3	<0,01
Residual	99,00	4	24,8		
Cor Total	2442,0	7			

O valor F da tabela comparado com a referência distribuição F para os graus de liberdade três (numerador) e quatro (denominador) de 6,591 asseguram que a variável de resposta do experimento é afetada significativamente por uma ou mais dos efeitos do modelo (ANDERSON; WHITCOMB, 2000).

3.16 EXPERIMENTOS FATORIAIS FRACIONADOS

Os experimentos fatoriais completos cobrem todas as combinações dos fatores, proporcionando informações valiosas sobre as interações. Entretanto, o número de rodadas experimentais aumenta rapidamente. Nos experimentos fatoriais fracionados podem ser estudados muitos fatores e manter o experimento a um tamanho razoável (ANDERSON; WHITCOMB, 2000). A Tabela 14 apresenta o relacionamento existente entre o número de fatores, número de ensaios, volume de informação que resulta de um experimento fatorial 2^k comparando com o número de ensaios em se realizar um experimento fatorial fracionado.

Tabela 14 – Fatorial 2^k versus fatorial fracionado.

Fatorial 2^k			Nº de interações sobre as quais é obtida informação					Nº ensaios Fatorial Fracionado	Redução
Nº de fatores	Nº de ensaios	Efeitos principais	Nº de fatores na interação						
K	2^k		2	3	4	5	6		
3	8	3	3	1	-	-	-	-	-
4	16	4	6	4	1	-	-	12	25%
5	32	5	10	10	5	1	-	16	50%
6	64	6	15	20	15	6	1	32	50%
7	128	7	21	35	35	21	7	32	75%
8	256	8	28	56	70	56	28	64	75%

Fonte: WERKEMA, 2000

Segundo Werkema (2000), as características dos experimentos fatoriais são:

- baseados em frações dos experimentos fatoriais completos;
- apropriados quando há um grande número de fatores a serem investigados sendo somente possível realizar um pequeno número de ensaios;
- permitem o equilíbrio entre o volume de informações necessárias à fase em que o experimento se encontra e o custo envolvido nas experimentações;
- utilizados nos estágios iniciais da experimentação (nível de conhecimento baixo ou moderado), principalmente nos experimentos exploratórios.

Usualmente haverá necessidade de experimentos adicionais e sempre haverá perda de informações sobre algumas interações. Os principais objetivos dos experimentos fatoriais fracionados são: priorizar fatores e determinar qual direção a seguir.

A construção do experimento fracionado segue a Tabela 14, onde os oito primeiros ensaios representam a fração principal 2^{4-1} equivalente a 2^3 ou $\frac{1}{2}$ fração do experimento fatorial completo 2^4 e os oito experimentos restantes (9 a 16) representam a fração complementar. Verificam-se os confundimentos dos fatores principais e interações conforme a Tabela 15, onde se confundiu a interação tripla ABC com a média geral e utilizam-se somente as linhas dos sinais positivos ou negativos para formar a fração principal. Ao realizar o experimento fatorial fracionado 2^{4-1} , abre-se mão de conhecer individualmente as interações de dois fatores e de três fatores.

Tabela 15 - Sinais algébricos para construção de um experimento 2^4

Ensaio	A	B	AB	C	AC	BC	ABC	D	AD	BD	ABD	CD	ACD	BCD	ABCD
1	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
2	+	+	+	-	-	-	-	-	-	-	-	-	-	-	-
3	+	-	-	+	+	+	+	+	+	+	+	+	+	+	+
4	-	+	-	-	+	+	+	-	-	-	-	-	-	-	-
5	+	-	-	-	-	+	+	+	+	+	+	+	+	+	+
6	-	+	-	-	+	-	+	+	-	+	-	-	+	-	+
7	-	-	+	+	+	-	+	+	-	-	+	+	+	-	+
8	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
9	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
10	-	+	-	-	+	-	+	-	+	-	+	+	-	+	-
11	-	-	+	-	-	-	+	-	+	+	-	-	+	+	-
12	+	+	+	+	+	+	+	-	-	-	-	-	-	-	-
13	-	-	+	-	+	+	-	+	-	-	+	-	+	+	-
14	+	+	+	-	-	-	-	+	+	+	+	-	-	-	-
15	+	-	-	+	+	-	-	+	+	-	-	+	+	-	-
16	-	+	-	+	-	+	-	+	-	+	-	+	-	+	-

Fonte: WERKEMA, 2000.

A estrutura de confundimentos para fatorial 2^{4-1} resolução IV da Tabela 16, conforme ilustrado pelas elipses, é $A + BCD$, $B + ACD$, $C + ABD$, $D + ABC$, $AB + CD$, $AC + BD$ e $AD + BC$.

A notação 2_R^{k-p} auxilia na identificação da estrutura dos confundimentos, onde: R é a resolução, k o número de fatores e p a fração. Os experimentos podem ser classificados conforme Resolução III, IV e V, sendo:

- resolução III – nenhum efeito principal é confundido com outro efeito principal. Efeitos principais são confundidos com interações de segunda ordem;
- resolução IV - nenhum efeito principal está confundido com outro efeito principal ou interações de segunda ordem. Interações de segunda ordem estão confundidas entre si;

- c) resolução V - nenhum efeito principal está confundido com outro efeito principal ou com interações de segunda e terceira ordem. Interações de segunda ordem estão confundidas com interações de terceira ordem.

A Tabela 16 apresenta opções de escolha de experimentos. Nem todos os experimentos de resolução IV são iguais. Alguns têm somente algumas poucas interações de dois fatores confundidas. Exemplo, o projeto de sete fatores, resolução IV, 32 ensaios (1/4 fração), possui 6 interações de dois fatores envolvendo D, E, F e G que estão confundidos conforme $DE = FG$, $DF = EG$, e $DG = EF$). Outras 15 interações de dois fatores estão confundidas com interações de três fatores ou mais. Portanto, devem-se ajustar fatores que possuem menor probabilidade de interagir com D, e, F ou G; e buscar fatores com maior probabilidade de interagir com fatores A, B e C. Também é possível optar por somente 16 ensaios para sete fatores e fração 1/8, pois também é resolução IV. Entretanto, através da estrutura de confundimento mostrada na Tabela 17, mesmo uma interação ativa pode causar confundimento. Exemplo, caso C e D interagirem, a interação pode ser confundida com AG (ver Tabela 17).

Tabela 16 - Resoluções para experimentos a dois níveis

Fatores	2	3	4	5	6	7	8
4 ensaios	completo	1/2 III	-	-	-	-	-
8	2 Rep	completo	1/2 IV	1/4 III	1/8 III	1/16 III	-
16	4 Rep	2 Rep	completo	1/2 V	1/4 IV	1/8 IV	1/16 IV
32	8 Rep	4 Rep	2 Rep	completo	1/2 VI	1/4 IV	1/8 IV
64	16 Rep	8 Rep	4 Rep	2 Rep	Completo	1/2 VII	1/4 V

Fonte: WERKEMA, 2000.

Tabela 17 - Estrutura de confundimento para sete fatores em 16 ensaios (somente interações de dois fatores).

Interação	Confundimento
AB	AB + CE + FG
AC	AC + BE + DG
AD	AD + CG + EF
AE	AE + BC + DF
AF	AF + BG + DE
AG	AG + BF + CD
BD	BD + CF + EG

Fonte: ANDERSON; WHITCOMB, 2000.

É importante investigar a estrutura de confundimento para as resoluções V para baixo. Os detalhes e cuidados na construção da fração adequada e o fornecimento de dados podem ser ajustados por *software*.

Emanuel e Palanisamy (2000) desenvolveram um procedimento seqüencial para experimentos fatoriais fracionados para seis e sete fatores, onde uma terceira matriz, além da

matriz principal Tabela 18 e matriz espelho Tabela 19 pode ser necessária para separar as interações de dois fatores confundidos. Neste procedimento, duas premissas são importantes: a) efeitos de interações de três ou mais fatores são negligenciáveis, b) efeitos de interações de dois fatores que contêm no mínimo um efeito principal não significativo são também negligenciadas. A razão destas premissas é conservar recursos gastos em informações pouco importantes, como interações de vários fatores que pouco contribuem para a resposta Y.

Tabela 18 - Matriz para fração principal de um projeto 2^{7-4} ou 2^{6-3}

Teste	A	B	C	D = AB	E = AC	F = BC	G = ABC	Resposta
1	-	-	-	+	+	+	-	Y ₁
2	+	-	-	-	-	+	+	Y ₂
3	-	+	-	-	+	-	+	Y ₃
4	+	+	-	+	-	-	-	Y ₄
5	-	-	+	+	-	-	+	Y ₅
6	+	-	+	-	+	-	-	Y ₆
7	-	+	+	-	-	+	-	Y ₇
8	+	+	+	+	+	+	+	Y ₈

Fonte: EMANUEL; PALANISAMY, 2000.

No procedimento proposto, defini-se a matriz principal, conjunto de oito experimentos, a qual é a fração $1/8$ para fatorial 2^6 e fração $1/16$ para fatorial 2^7 . Este projeto permitirá ao experimentador determinar se os fatores importantes foram incluídos no experimento, porém não permitirá a quantificação destes fatores, pois os efeitos principais e as interações de dois fatores serão confundidos.

Os geradores do experimento para a Tabela 18 são $I_1 = ABD$, $I_2 = ACE$, e $I_3 = BCF$, $I_4 = ABCG$. No caso do experimento 2^{6-3} , não se consideram os itens em negrito. A relação de definição completa é $I = ABD = ACE = BCF = ABCG = BCDE = ACDF = DCG = ABEF = BEG = AFG = DEF = ADEG = CEFG = ABCDEFG$. Desenvolvendo todo o conjunto de confundimentos e aplicando a premissa (i), a estrutura de confundimento torna-se $A + BD + CE + FG$, $B + AD + CF + EG$, $C + AE + BF + DG$, $D + AB + EF + CG$, $E + AC + DF + BG$, $F + BC + DE + AG$, e $G + DC + BE + AF$.

A matriz espelho é formada ajustando $D = -AB$, $E = -AC$, e $F = -BC$, $G = -ABC$, conforme Tabela 19.

A relação de definição para matriz espelho é $I = -ABD = -ACE = -BCF = ABCG = BCDE = ACDF = -DCG = ABEF = -BEG = -AFG = -DEF = ADEG = BDFG = CEFG = -ABCDEFG$. Eliminando as interações de três ou mais fatores, tem-se a seguinte estrutura de confundimentos: $A - BD - CE - FG$, $B - AD - CF - EG$, $C - AE - BF - DG$, $D - AB - EF - CG$,

E - AC - BG - DF, F - BC - DE - AG, e G - DC - BE - AF. Combinando os termos da fração espelho e principal, têm-se seis efeitos principais não confundidos, A, B, C, D, E, F e G e os remanescentes termos de interação a dois fatores confundidos entre si, BD + CE + FG, AD + CF + EG, AE + BF + DG, AB + EF + CG, AC + DF + BG, BC + DE + AG, e AF + BE + CD.

Tabela 19 - Matriz para fração espelho de um projeto 2^{7-4} ou 2^{6-3}

Teste	A	B	C	D = -AB	E = -AC	F = -BC	G = -ABC	Resposta
1	+	+	+	-	-	-	+	y_1
2	-	+	+	+	+	-	-	y_2
3	+	-	+	+	-	+	-	y_3
4	-	-	+	-	+	+	+	y_4
5	+	+	-	-	+	+	-	y_5
6	-	+	-	+	-	+	+	y_6
7	+	-	-	+	+	-	+	y_7
8	-	-	-	-	-	-	-	y_8

Fonte: EMANUEL; PALANISAMY, 2000.

O próximo passo é remover o confundimento através da combinação da matriz principal e matriz espelho para separar os efeitos principais das interações de dois fatores. Para os termos de interação que são significantes, rodadas adicionais podem ser necessárias para remover os confundimentos. O número necessário de rodadas adicionais dependerá de quantos efeitos principais são significantes. Como regra geral, quanto maior o número de efeitos principais não significativos, menor o número de rodadas adicionais necessárias. Pode-se generalizar os casos baseados no número de efeitos principais não significantes identificados no primeiro e segundo conjunto de experimentos: a) caso I, mais que dois efeitos principais não significativos, onde não serão necessárias rodadas adicionais; b) caso II, dois efeitos principais não significativos, onde podem ser necessárias rodadas adicionais; c) caso III, um efeito principal insignificante, onde rodadas adicionais serão necessárias, se quaisquer termos de interação de dois fatores confundidos forem significativos ; d) caso IV, sem efeito principal insignificante, quando as rodadas adicionais tornam-se importantes.

3.17 EXPERIMENTOS FRACIONADOS SATURADOS

Os experimentos mínimos com um fator a menos que o número de ensaios, por exemplo, sete fatores e oito ensaios, são considerados estarem “saturados” com fatores. Estes experimentos resolução III confundem efeitos principais com interações de DOIS fatores, um ponto negativo. Porém, podem ser uma opção na indisponibilidade de tempo ou recursos em conduzir o experimento. Caso os resultados apresentem significância, é preciso realizar mais experimentos – chamados de aumento do projeto (*design augmentation*). A método mais popular de *design augmentation* é a duplicação (*fold-over*). Adicionando um segundo bloco de ensaios com o sinal invertido em todos os fatores, pode-se quebrar o confundimento entre os efeitos principais e as interações de dois fatores (ANDERSON; WHITCOMB, 2000).

A Tabela 20 apresenta um experimento fatorial saturado. As colunas de interação calculadas são usadas para descrever os níveis dos quatro fatores adicionais, os quais agora perfazem o número total de considerações de fator a dois níveis (sete em oito testes, i.e., o projeto fatorial fracionado saturado, resolução III, fração 1/16).

Tabela 20 - Experimento fatorial fracionado saturado (interações selecionadas incluídas).

Teste	A	B	C	D AB	E AC	F BC	G ABC	AD	BE	BG	EG
1	+	+	-	+	-	-	-	+	-	-	+
2	+	+	+	+	+	+	+	+	+	+	+
3	+	-	-	-	-	+	+	-	+	-	-
4	-	+	+	-	-	+	-	+	-	-	+
5	+	-	+	-	+	-	-	-	-	+	-
6	-	-	+	+	-	-	+	-	+	-	-
7	-	+	-	-	+	-	+	+	+	+	+
8	-	-	-	+	+	+	-	-	-	+	-

Fonte: BREYFOGLE, 1999.

Existe confundimento das interações EG, BG e BE com os respectivos efeitos principais B, E e G. Todas as informações dos efeitos principais de sete fatores a dois níveis podem ser obtidos em somente oito testes. Existe uma preocupação que a significância de um fator possa afetar a decisão sobre outro fator. Para clarear esta dúvida, por exemplo, assume-se que E é o único fator significativo e que não há interações. Para verificar se o fator E pode afetar a decisão de ser o fator A significativo, um subconjunto da Tabela 20 é mostrado na Tabela 21, onde respostas de saída foram projetadas para fazer o fator E muito significantes.

Os efeitos médios dos fatores A e E são:

$$\begin{aligned}
 [(\overline{x_{E^+}}) - (\overline{x_{E^-}})] &= \frac{y_2 + y_5 + y_7 + y_8}{4} - \frac{y_1 + y_3 + y_4 + y_6}{4} \\
 &= \frac{500 + 500 + 500 + 500}{4} - \frac{0 + 0 + 0 + 0}{4} = 500
 \end{aligned}$$

$$\begin{aligned}
 [(\overline{x_{A^+}}) - (\overline{x_{A^-}})] &= \frac{y_1 + y_2 + y_3 + y_5}{4} - \frac{y_4 + y_6 + y_7 + y_8}{4} \\
 &= \frac{0 + 500 + 0 + 500}{4} - \frac{0 + 0 + 500 + 500}{4} = 0
 \end{aligned}$$

Tabela 21 - Exemplo de saída do projeto da Tabela 20.

Teste	A	E	Resposta Experimento
1	+	-	0
2	+	+	500
3	+	-	0
4	-	-	0
5	+	+	500
6	-	-	0
7	-	+	500
8	-	+	500

Fonte: BREYFOGLE, 1999.

Este exemplo ilustra que apesar de o fator E ser muito significativa, esta significância não afetou a decisão sobre não significância do fator A, os fatores B, C, D, F e G podem de forma similar ser mostrados como não significantes. O propósito deste exemplo é ilustrar que o efeito principal não será confundido com outro efeito principal neste projeto de experimento de sete fatores e oito testes. Entretanto, o experimentador, deve estar ciente que é possível que exista uma interação, (exemplo de BC), que poderia fazer o fator E parecer significativa apesar de os fatores B e C individualmente não serem determinados como significantes (BREYFOGLE, 1999).

A Tabela 22 apresenta o método de duplicação, onde se nota que os sinais das interações de dois fatores não foram trocados do bloco um (ensaios um a oito) para o bloco dois (ensaios nove a dezesseis). No bloco um os sinais da coluna E e BG são idênticos, porém no bloco dois eles diferem. Assim o experimento combinado não mais confunde E com BG. Porém a duplicação não elimina os confundimentos com os respectivos efeitos principais B, E e G.

Tabela 22 - Segundo bloco de ensaios duplicados (interações selecionadas)

Teste	A	B	C	D AB	E AC	F BC	G ABC	AD	BE	BG	EG
1	+	+	-	+	-	-	-	+	-	-	+
2	+	+	+	+	+	+	+	+	+	+	+
3	+	-	-	-	-	+	+	-	+	-	-
4	-	+	+	-	-	+	-	+	-	-	+
5	+	-	+	-	+	-	-	-	-	+	-
6	-	-	+	+	-	-	+	-	+	-	-
7	-	+	-	-	+	-	+	+	+	+	+
8	-	-	-	+	+	+	-	-	-	+	-
9	-	-	+	-	+	+	-	+	-	+	+
10	-	-	-	-	+	-	+	+	+	+	+
11	-	+	+	+	+	-	+	-	+	-	-
12	+	-	-	+	+	-	-	+	-	-	+
13	-	+	-	+	-	+	-	-	-	+	-
14	+	+	-	-	+	+	+	-	+	-	+
15	+	-	+	+	-	+	+	+	+	+	+
16	+	+	+	-	-	-	-	-	-	+	-

Fonte: BREYFOGLE,1999.

3.18 MODELAMENTO DA RESPOSTA ATRAVÉS DE REGRESSÃO

Os modelos testados através da análise de variância podem ser previstos por uma equação de regressão, conforme a equação (30) para somente um fator (ANDERSON; WHITCOMB, 2000).

$$\hat{Y} = \beta_0 + \beta_1 x_1 \quad (30)$$

onde \hat{Y} é a previsão da resposta, β_0 é o intercepto, β_1 é o coeficiente do modelo para o fator de entrada (x_1). A variável do fator x_1 é codificada em uma escala de -1 a $+1$ para os níveis altos e baixos do fator. A mudança do fator do nível baixo para alto causa um efeito medido na resposta conforme Figura 31. Onde, β_1 representa a declinação da reta, a qual é o aumento na resposta dividido pelo correspondente aumento no nível do fator (duas unidades codificadas). Portanto o coeficiente β_1 é a metade do efeito ($\beta_1 = \text{Efeito} / 2$) (ANDERSON; WHITCOMB, 2001). Quanto mais fatores são adicionados, o número de termos no modelo aumentam. O modelo fatorial para os dois fatores, ambos em dois níveis, torna-se conforme a equação (31):

$$\hat{Y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2 + \varepsilon \quad (31)$$

onde, β são os parâmetros a serem determinados, x_1 é a variável que representa fator A, x_2 é a variável que representa fator B e ε é termo do erro aleatório. As estimativas dos parâmetros no

modelo de regressão são relacionadas com as estimativas dos efeitos (MONTGOMERY, 2001).

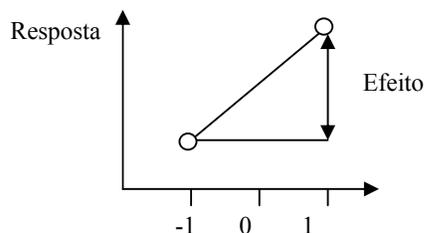


Figura 31: Gráfico da resposta versus nível do fator codificado
Fonte: ANDERSON; WHITCOMB, 2000.

A representação do modelo exemplo da seção 3.15 é visto na equação (32):

$$\hat{Y} = 66,5 + \frac{EfeitoB}{2}B + \frac{EfeitoC}{2}C + \frac{EfeitoBC}{2}BC$$

$$\hat{Y} = 66,5 - 10,25B - 8,50C - 10,75BC \quad (32)$$

O valor do intercepto (β_0) de 66,5 representa a média da resposta real. Os coeficientes podem ser comparados diretamente para avaliar o impacto relativo dos fatores. No caso o fator B (coeficiente $-10,25$) causa um impacto maior que o fator C (coeficiente $-8,50$).

Uma maneira de verificar o modelo é inserir os níveis dos fatores do projeto na equação 32 e gerar uma previsão (ver Tabela 23). Ao comparar o valor da previsão com valor observado (real), sempre se notará uma discrepância chamada de resíduo. Os resíduos são normalmente distribuídos e independentes com uma variância constante. Duas plotagens são recomendadas para verificar estas suposições estatísticas: plotagem normal dos resíduos e residuais versus nível de previsão. A Figura 32 apresenta as plotagens baseadas nos dados da Tabela 23.

Tabela 23 - Residuais para previsão

Teste	B	C	BC	Resposta Real	Previsão de Resposta	Residual
1	+	+	+	32	37	-5,0
2	+	-	-	80	75,5	-4,5
3	-	+	-	77	79,0	-2,0
4	-	-	+	75	74,5	0,5
5	+	+	+	42	37	5,0
6	+	-	-	71	75,5	-4,5
7	-	+	-	81	79,0	2,0
8	-	-	+	74	74,5	0,5

Na Figura 32 os resíduos são normalmente distribuídos, todos os pontos estão próximos ou sobre a linha reta. Caso ocorram padrões não lineares é possível transformar as respostas do experimento (ver seção 3.14). A plotagem dos resíduos *versus* previsão não apresenta um aumento dos residuais com o nível de previsão.

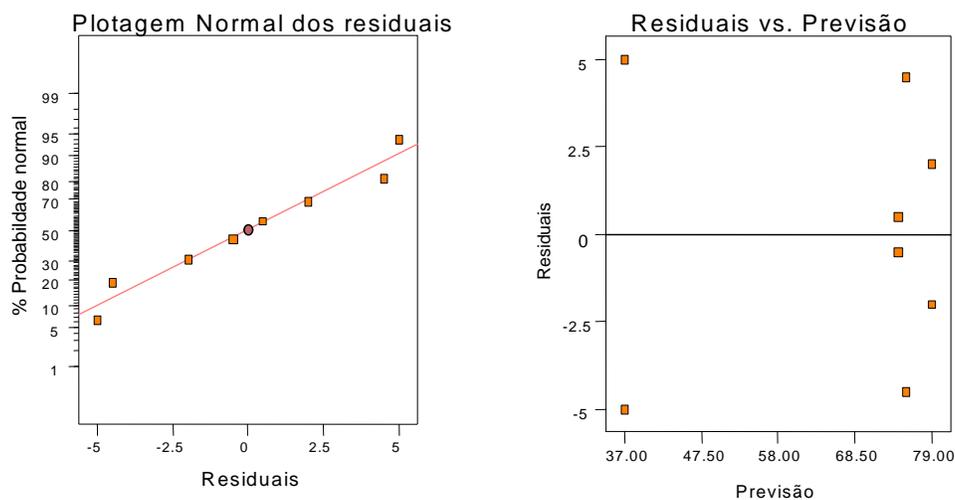


Figura 32 - Plotagem normal dos resíduos e residuais versus valores previstos

Os modelos de regressão podem ser lineares, quadráticos ou cúbicos. O termo de erro inclui as diferenças de outras variáveis como erros de medição, variações de material em uma operação de fabricação e material. Os erros são considerados com média zero e variância σ^2 desconhecida, sendo que não são correlacionados. Quando a magnitude do coeficiente de determinação (R^2) é grande, isto indica que o termo de erro para o modelo em questão é relativamente pequeno e o modelo se ajusta bem (ANDERSON; WHITCOMB, 2000).

Um primeiro propósito da análise de regressão é determinar os parâmetros desconhecidos no modelo de regressão (BREYFOGLE, 1999). Os coeficientes de regressão são determinados pelo método dos mínimos quadrados. Os quadrados mínimos minimizam os resíduos. Os coeficientes de regressão são definidos conforme equações (33) e (34):

$$\hat{\beta}_1 = \frac{S_{xy}}{S_{xx}} = \frac{\sum_{i=1}^n y_i x_i - \frac{(\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i)}{n}}{\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}} = \frac{\sum_{i=1}^n y_i (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (33)$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad (34)$$

A diferença entre o valor observado y_i e o valor correspondente ajustado \hat{y}_i é um residual conforme seção 3.10.

Testes de significância dos coeficientes de regressão envolvem distribuição t para a tabela dos coeficientes ou distribuição F para análise de variância. Uma hipótese nula é que β_0 é constante, e a hipótese alternativa é que não seja constante. Outra hipótese nula é que β_1 é zero, e a alternativa desta hipótese é de não ser zero.

Para a análise da tabela de variância, a variação total é dividida em partes descrita pela soma dos quadrados: $SQT_{total} = SQ_{regressão} + SQR_{erro}$, em que $SQT_{total} = \sum (y_i - \bar{y})^2$, $SQ_{regressão} = \sum (\hat{y}_i - \bar{y})^2$ e $SQR_{erro} = \sum (y_i - \hat{y}_i)^2$. Cada soma dos quadrados tem um número de graus de liberdades associados, sendo $n - 1$, 1 e $n - 2$ respectivos a SQT_{total} , $SQ_{regressão}$ e SQR_{erro} .

Quando divididos pelo número de graus de liberdade, a soma dos quadrados dá uma boa estimativa da fonte de variabilidade (i.e., total, regressão, e erro). Esta variabilidade é análoga ao cálculo de variância e é chamada de quadrado médio. Se não existir diferença nas médias dos tratamentos, as duas estimativas são presumidas serem similares. Se houver diferença, suspeita-se que a diferença observada é causada pelo regressor. A hipótese nula que não há diferença devido ao regressor é testada calculando-se a estatística F, $F_o = \frac{MQ_{regressão}}{MQ_{erro}}$.

Utilizando uma tabela F (BREYFOGLE, 1999), deve-se rejeitar a hipótese nula e concluir que há uma diferença causada pelo regressor se $F_o > F_{\alpha, 1, n-2}$

O coeficiente de determinação (R^2) é a razão entre a variação explicada e a variação total, conforme a equação (35):

$$R^2 = \frac{SQ_{regressão}}{SQ_{total}} = \frac{\sum (\hat{y}_i - y)^2}{\sum (y_i - y)^2} = 1 - \frac{SQ_{erro}}{SQ_{total}} \quad (35)$$

A multiplicação deste coeficiente por cem fornece o percentual de variação explicada pelo método dos quadrados mínimos. Um percentual maior indica um preditor melhor dos quadrados mínimos.

Se uma variável for adicionada a equação de regressão modelo, R^2 aumentará mesmo se a variável não tiver valor real. Uma compensação para isto é um valor ajustado, R^2 (ajustado), o qual tem uma aproximação estimada para o R^2 da população, conforme equação (36):

$$R^2(\text{ajustado}) = 1 - \frac{\left(\frac{SQ_{erro}}{n - p} \right)}{\left(\frac{SQ_{total}}{n - 1} \right)} \quad (36)$$

onde p é o número de termos na equação de regressão e n é o número total de graus de liberdade.

Caso R^2 (ajustado) e R^2 forem muito diferentes, então há uma indicação que foi incluído um número excessivo de variáveis preditoras na equação de regressão, ou seja, foram incluídas variáveis que não contribuem de modo significativo para melhorar a qualidade da equação ajustada (WERKEMA, 2000).

Wisnowski *et al.*, 2000 propõem o uso do método de árvore de regressão *Classification and regression trees* (CART) como complemento dos métodos gráficos na análise do PAE. A estrutura de árvores de regressão auxilia na identificação de condições de operação favoráveis e no direcionamento de futuros experimentos. A árvore de regressão pode ser representada conforme Figura 33(a), para prever a resposta em qualquer conjunto de fatores. O modelo de árvore de regressão da Figura 33 é baseado no exemplo da Tabela 24. Iniciam-se pelo topo da árvore ou nó raiz, seguindo-se para os nós subseqüentes baseados nas respostas a perguntas binárias sobre os fatores. A resposta esperada é baseada na partição do espaço fator conforme Figura 33(b). A árvore de regressão deve ser acompanhada da análise clássica e deve ser tratada como uma técnica exploratória.

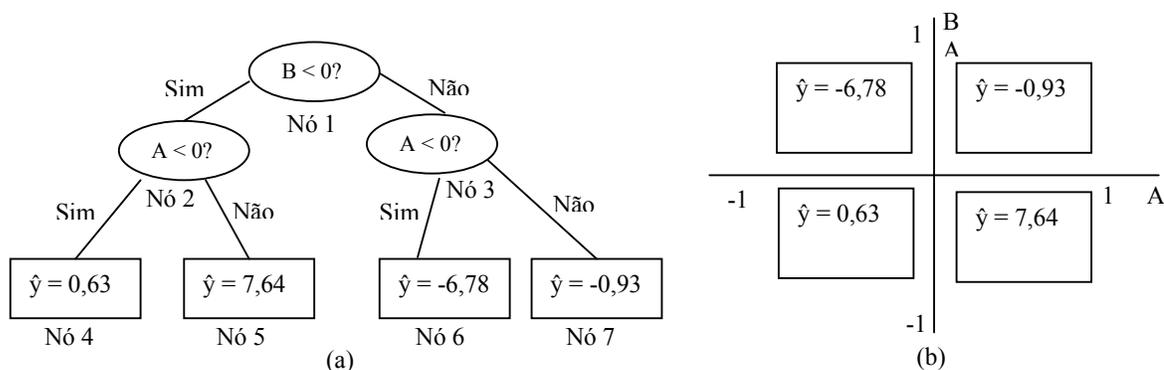


Figura 33 - (a) Representação em árvore do fatorial 2^3 , (b) Partição das respostas para o experimento 2^3 .

Fonte: WISNOWSKI *et al.*, 2000.

Tabela 24 - Dados exemplo $y = 3A - 4B + 0,25C + N(0,1)$ e $y^* = 3A - 4B + 3AB + 0,25C + N(0,1)$

A	B	AB	C	N(0,1)	y	y*
-	-	+	-	-0,05	0,70	3,70
+	-	-	-	1,40	8,15	5,15
-	+	-	-	0,98	-6,27	-9,27
+	+	+	-	0,84	-0,41	2,59
-	-	+	+	-0,69	0,56	3,56
+	-	-	+	-0,13	7,12	4,12
-	+	-	+	-0,55	-7,30	-10,30
+	+	+	+	-0,70	-1,45	1,55

Fonte: WISNOWSKI *et al.*, 2000.

Na Tabela 24, considerando a previsão de resposta para ajuste do fator A no nível alto, B no nível baixo, e C no nível alto (+1, -1, +1), a resposta para a primeira pergunta da árvore de regressão, no nó raiz (ver Figura 33), direciona para o nó dois. Como A está no nível alto, obtêm-se uma resposta esperada de 7,64 no nó cinco. Esta resposta é a média dos dois valores da Tabela 24 quando A é alto e B é baixo (8,15 e 7,12).

Analogamente ao procedimento de seleção de variáveis em uma análise clássica, o modelo de árvore não utiliza o fator C, devido ao seu mínimo efeito na resposta.

3.19 MÉTODO DE SUPERFÍCIE DE RESPOSTA PARA OTIMIZAÇÃO

A otimização se propõe a determinar a região nos fatores importantes que direcionam para a melhor resposta possível (MONTGOMERY, 2001) ou também determinar como os fatores importantes podem ser alterados para atingir a direção onde as maiores melhorias possam ser encontradas, ou seja, a direção de maior ascensão (*steepest ascent*) (BOX, 2000). Para exemplificar a otimização, segue um exemplo (MONTGOMERY, 2001) em que a variável de resposta é o rendimento de um processo químico e os resultados do experimento de caracterização indiquem que os fatores mais importantes do processo são temperatura de operação e tempo de reação. A Figura 34 mostra a região tempo x temperatura, onde é possível ver as linhas de rendimentos constantes conectadas formando um contorno de resposta, e as linhas de contornos para rendimentos 60, 70, 80, 90 e 95%. Estes contornos são projeções da região tempo x temperatura através das seções da superfície de rendimentos correspondentes aos percentuais de rendimento mencionadas.

A fim de localizar o ótimo, realiza-se um experimento fatorial variando tempo e temperatura. As respostas do experimento de otimização inicial estão nos quatro cantos do quadrado indicando ser necessário mover na direção de aumento de temperatura e diminuição do tempo de reação a fim de aumentar o rendimento. Alguns testes adicionais deveriam ser realizados nesta direção, e estes experimentos adicionais levar-nos-iam a região de rendimento máximo.

Uma vez encontrada a região de rendimento ótimo, um segundo experimento tipicamente é realizado. O objetivo do segundo experimento é obter uma estimativa mais precisa das condições de operação ótima para tempo e temperatura. Este método de otimização de processo é denominado de superfície de resposta.

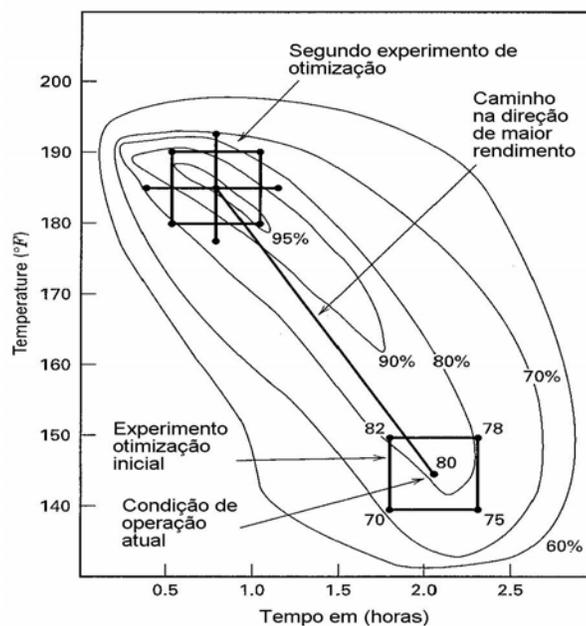


Figura 34 - Plotagem de contorno do rendimento como função do tempo e temperatura de reação.
 Fonte: MONTGOMERY, 2001.

O Método de Superfície de Resposta (MSR) deveria ser aplicado somente após completar as fases iniciais de experimentação: a) experimentos fracionados a dois níveis, os quais investigam os poucos fatores vitais dos muitos fatores triviais, b) fatoriais completos, os quais estudam os poucos fatores vitais em profundidade e definem uma região de interesse (ANDERSON; WHITCOMB, 2000)

Os experimentos fatoriais a dois níveis não podem detectar superfícies, porém podem detectar a presença de curvatura ao adicionar pontos centrais. Caso o efeito da Curvatura seja significativo na análise de variância, cria-se o projeto composto central através da inclusão de mais pontos ao longo dos eixos do espaço do fator que proporciona os fundamentos para o MSR (ANDERSON; WHITCOMB, 2000). O segundo experimento na Figura 34 é o projeto composto central, um dos mais importantes projetos de experimentos utilizados nos estudos de otimização de processo (MONTGOMERY, 2001). Box (2000) apresenta na Figura 35 o projeto composto central, mostrando os oito pontos originais do projeto fatorial 2^3 , indicado pelos círculos abertos e os sete pontos axiais adicionados mostrado pelos círculos preenchidos. Também é apresentada pelos círculos cruzados, a meia fração do experimento 2^3 .

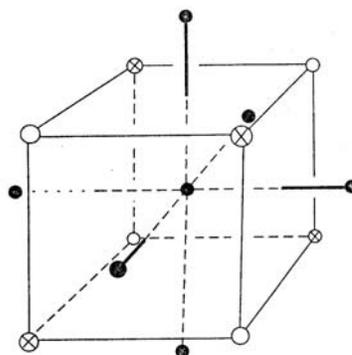


Figura 35 - Projeto composto para 3 fatores.

Fonte: BOX, 2000.

A construção do experimento composto central é realizada através da montagem seqüencial de experimentos (BOX, 2000). Uma seqüência apropriada conforme exemplo da Figura 35, seria: a) realizar uma meia fração do experimento 2^3 (quatro círculos cruzados). Caso as interações não sejam importantes, os quatro pontos permitirão estimar todos os efeitos principais e o ajuste de um modelo de primeiro grau. Pode-se também estimar a direção de maior ascensão (*steepest ascent*). Caso a realização de mais experimentos comprovarem o aumento, pode-se seguir esta direção e deslocar a localização de experimentos futuros; b) caso não ocorra um aumento, pode-se suspeitar de uma situação mais complexa, e um segundo bloco de rodadas experimentais pode ser realizados (experimentos marcados por círculos abertos na Figura 35), totalizando um experimento 2^3 . Se ainda, mais informações forem necessárias, c) podem ser incluídos pontos axiais e pontos centrais, para formar o experimento composto completo, tornando possível ajustar um modelo de segunda ordem.

Conforme o exemplo da Figura 36, os experimentos fatoriais a dois níveis e o método OFAT não mostram a direção de otimização. Nota-se também que o experimento fatorial pode não apresentar efeitos principais, porém pode mostrar grandes interações entre fatores, caso de aumentar a concentração e reduzir a temperatura conforme indica a seta. Na Figura 36 os X's apresentam as rodadas experimentais com o método OFAT, indicando falsamente um ponto P de máximo, e os círculos mostram o projeto fatorial 2^2 .

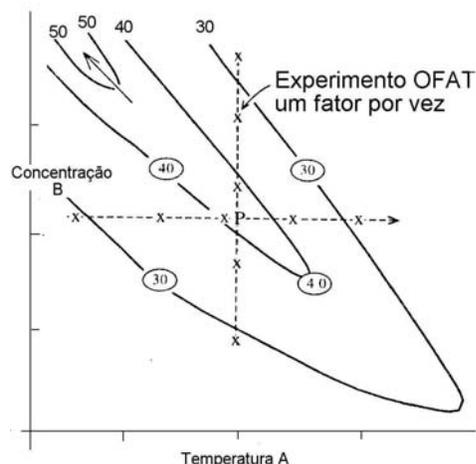


Figura 36 - Contornos de uma superfície entre temperatura e concentração de um determinado produto
 Fonte: BOX, 2000

Sieloff (2002) propõe o uso de Mapas Topográficos do Processo -*Process Topographic Maps* (PTM's) após a utilização do PAE, quando os novos padrões de operação são utilizados, para determinar ações corretivas em problemas que possam ocorrer. Os mapas identificam os locais atuais e desejados dos resultados, auxiliam os operadores na visualização que o processo está sob controle e indicam quais ajustes e em que direções devem ser feitos para assegurar a estabilidade do produto/processo. O operador pode entender como o processo opera em determinada região. Um exemplo da Figura 37 mostra duas condições em que a estabilidade do produto varia conforme o peso da peça. São gerados dois mapas que mostram ao operador como o equipamento responde ao mudar o avanço. Ao operar o processo no ponto A, com uma peça de peso menor (Figura 37 (a)), aumentando o avanço, aumenta-se a estabilidade objetiva do produto para duzentos. A mesma alteração realizada em um produto mais pesado não causa a mesma estabilidade (Ver Figura 37 (b)). No caso uma ação apropriada seria aumentar a temperatura do container para atingir o ponto C. Entretanto para a peça de peso vinte, um aumento no avanço requer uma diminuição na temperatura do container para manter a estabilidade do produto. Caso a temperatura do container seja cinquenta, o avanço três, e a estabilidade resultante de 190, deve-se checar primeiramente o peso da peça e verificar que seja vinte. Verificando o mapa da Figura 37 (a), para aumentar a estabilidade do processo por dez, é necessário aumentar a temperatura do container para 52 e o avanço para cinco.

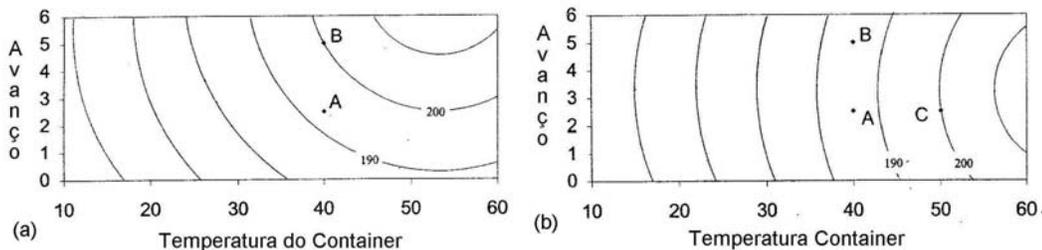


Figura 37 - Estabilidade do produto: (a) peso baixo da peça (20), (b) peso alto da peça (40).

A Figura 38 apresenta um conjunto de mapas que representam todos os produtos e as respectivas janelas de operação. Quando ocorrer problemas o operador identifica a posição no mapa apropriado e traça o curso de ação para atingir o objetivo, no caso a curva de estabilidade marcada em negrito no conjunto de mapas.

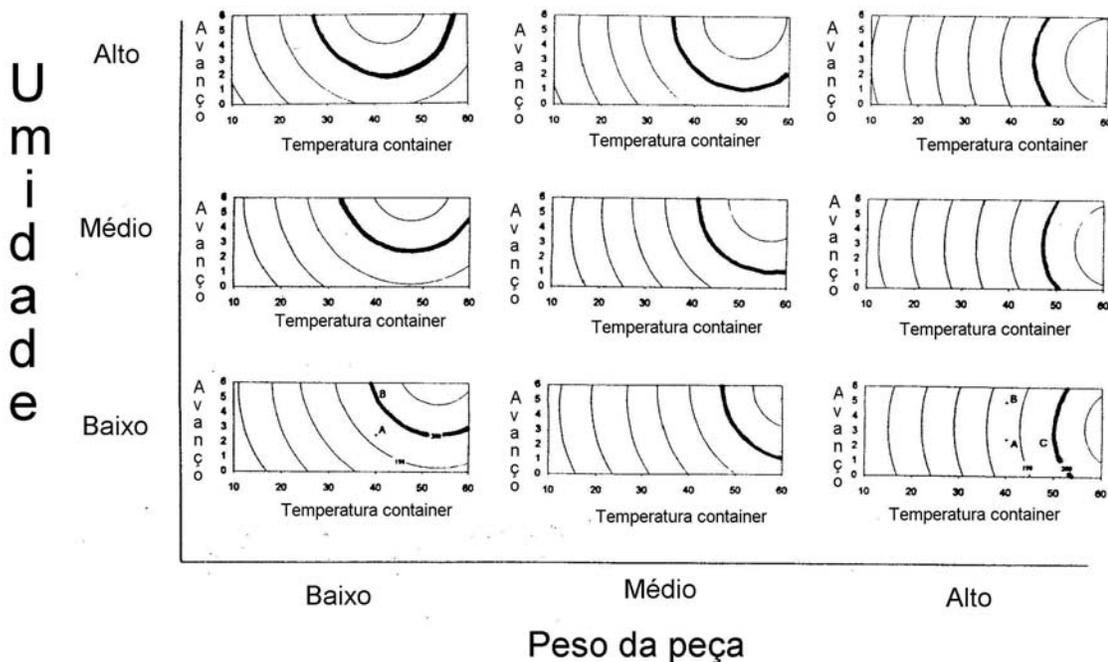


Figura 38 - Estabilidade do produto
 Fonte: SIELOFF, 2002.

4 ESTUDO DE CASO: EXEMPLO DE APLICAÇÃO DE PROJETO SEIS SIGMA UTILIZANDO PROJETO DE EXPERIMENTOS

O estudo de caso apresenta uma aplicação de um projeto Seis Sigma utilizando o ciclo PDCA. Trata-se de um projeto de certificação *Black Belt*, que contou com a monitoria de uma empresa consultora de treinamentos Seis Sigma e certificadora de *Black Belts*. O projeto teve início durante as semanas de treinamento do curso de formação de *Black Belts*. O projeto foi aplicado no setor de usinagem de uma linha de fabricação de blocos de motores a diesel. Usinagem é definida como o processo de fabricação de componentes através da remoção de material por ferramentas cortantes, processos químicos ou abrasão.

Atualmente, várias são as pressões e iniciativas de redução de custos e repasse de ganhos em produtividade promovidos pelas montadoras na cadeia de suprimentos do setor automotivo. Iniciativas como Manufatura Enxuta, com a utilização de Kaizens e Programa de Idéias, em que as montadoras disponibilizam veículos para seus fornecedores e solicitam idéias de redução de custo no produto, são comuns. Geralmente as melhorias ocorrem em relação a tempos de fabricação (*lead times*), redução de níveis de estoque, redução de área fabril e movimentação de materiais e redução de componentes com conseqüente redução de custos. Uma área praticamente inexplorada é a redução dos custos variáveis dos processos de fabricação, que incluem insumos perecíveis e semiperecíveis, como ferramental de desgaste e ferramental de uso prolongado. O foco deste estudo de caso é então direcionado para otimização dos parâmetros dos processos com a conseqüente redução dos custos variáveis de fabricação.

O objetivo principal do projeto em questão é a redução dos custos variáveis de produção da linha de usinagem de uma empresa fabricante de motores a diesel, localizada no estado do RS. A empresa, por pertencer à cadeia automotiva, é certificada na norma TS 16949 (antiga norma QS-9000) desenvolvida pelo *Automotive Industry Action Group (AIAG)* – (Grupo de Ação da Indústria Automotiva). Além das auditorias de certificação, a empresa tem seus processos de fabricação auditados pelos seus clientes sempre que ocorrer lançamento de um produto ou alterações nos processos de fabricação, como mudanças de layout, aumento de produção com inclusão de turnos de trabalho. As auditorias seguem os manuais de referência da TS 16949, que incluem manuais de CEP, FMEA e Análise dos Sistemas de Medição. A

principal ferramenta estatística utilizada neste estudo de caso é o Projeto e Análise de Experimentos (PAE) na otimização da vida útil do ferramental. Este objetivo também atende a uma demanda do AIAG, de aplicar técnicas estatísticas nos parâmetros do processo (item 3.1). A metodologia do programa Seis Sigma é utilizada em todo o desdobramento do projeto.

Durante o desenvolvimento do projeto foram identificados custos excessivos de ferramental em duas operações da linha de fabricação, denominadas de operação vinte e oitenta. A operação vinte apresentou uma grande variação de vida útil de ferramental, principalmente devido a problemas de manutenção. Um grande percentual de peças era retrabalhado após a operação para garantir a especificação. Foram desenvolvidos, juntamente com a equipe de processos e operadores, o mapa de processo e o planejamento do experimento da operação vinte. O experimento não foi realizado devido a problemas no equipamento que poderiam atuar como ruído durante os testes.

Em contrapartida, a operação oitenta apresentou uma vida útil constante de ferramenta, ou seja, foi estipulada uma quantidade fixa de peças produzidas até a troca da ferramenta, sugerindo assim a possibilidade de aumentá-la. O experimento realizado nesta operação serviu como um modelo de teste de otimização de ferramental para todas as máquinas da linha. A simplicidade do experimento foi um fator importante para disseminar a ferramenta PAE na empresa, buscando entendimento e comprometimento das equipes de processo e do chão-de-fábrica.

4.1 VIDA ÚTIL DA FERRAMENTA

A vida útil de uma ferramenta de corte é dada pelo tempo que a mesma trabalha efetivamente (deduzidos os tempos passivos), até perder sua capacidade de corte, dentro de um critério previamente estabelecido. Atingido este tempo à ferramenta deve ser reafiada ou substituída (DINIZ *et al.*, 2001). A equação da vida útil da ferramenta é definida por Taylor (FERRARESI, 1986), sendo:

$$T = K.V_c^{-x} \quad (37)$$

onde T é a vida útil em minutos, V_c é a velocidade de corte e K e x são constantes do material para determinadas condições de usinagem. A equação da vida útil foi desenvolvida por

Frederik Taylor através da realização de 50.000 experimentos de usinagem e consumindo o equivalente a 356.000 kg de aço (GEORGIU, 2001).

Na determinação da vida útil é verificado o tempo até atingir o desgaste no flanco frontal da ferramenta (Figura 39), após o qual ocorrerão defeitos no acabamento superficial da peça, não manutenção da tolerância, podendo até atingir a quebra catastrófica da ferramenta com a conseqüente parada do equipamento de produção.

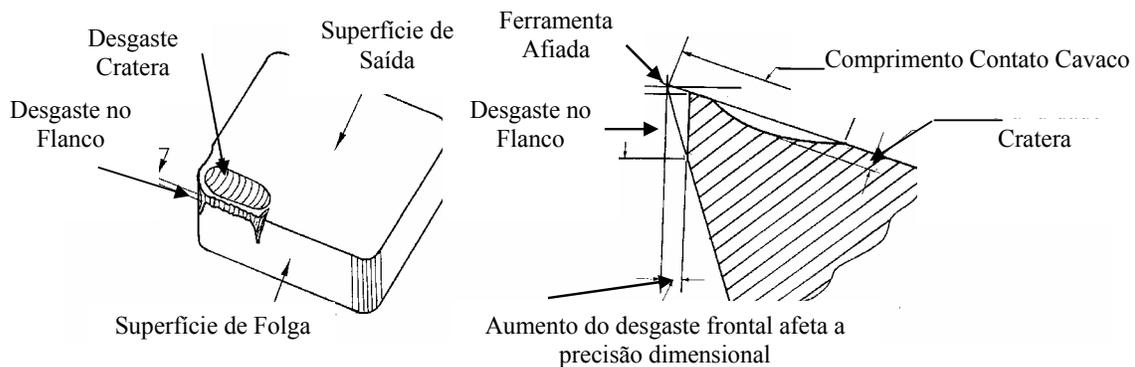


Figura 39 - Geometria e seção transversal de uma ferramenta desgastada

Convencionou-se medir os desgastes no plano ortogonal da ferramenta, distinguindo-se os desgastes na superfície de saída e superfície de folga. O desgaste no flanco, denominado de VB é o valor médio de desgaste medido na superfície de folga enquanto o desgaste na superfície de saída é medido através da profundidade de cratera (KT), (DINIZ *et al.*, 2001).

O estudo do PAE no projeto Seis Sigma propôs a alteração nos parâmetros de usinagem, velocidade de corte (V_c) e avanço da ferramenta (f_n), a fim de prolongar a vida útil da ferramenta, ou seja, diminuir o efeito do desgaste do flanco (VB) e manter a dimensão da peça por um tempo maior (T), postergando a troca do gume de corte.

4.2 PROJETO SEIS SIGMA

A meta geral inicialmente proposta pela alta gerência para o projeto Seis Sigma reportado neste estudo de caso foi à redução do custo variável de produção da linha de usinagem do bloco de motor em U\$ 50.000,00 por ano até o final do ano corrente (o projeto

foi realizado no ano de 2001). A meta proposta foi baseada na exigência de ganho por projeto Seis Sigma para certificação de *Black Belts*.

4.2.1 Metodologia utilizada no experimento

A metodologia utilizada foi o ciclo PDCA, estruturado através do Mapa de Raciocínio (Figuras 40, 41, 44, 45, 48, 49, 52), onde as perguntas e respostas, comprovações de dados e passagem entre etapas do ciclo PDCA estão claramente identificadas. Foram utilizadas as ferramentas gráficas de Pareto, gráfico de controle e, por fim, o projeto e análise de experimentos no estudo de otimização da vida útil de ferramental de usinagem, permitindo prolongar o uso e reduzindo o gasto com a reposição de ferramentas.

4.2.2 Etapa planejamento do ciclo PDCA (P)

A etapa de Planejamento, representada através do mapa de raciocínio, inclui as sub-etapas de Identificação do Problema (Figura 40), Análise de Fenômeno (Figuras 41, 44, 45, 48, 52), Análise de Processo (Figura 49) e Estabelecimento do Plano de Ação; ver seção 1.2. Os resultados e os desdobramentos da etapa Planejamento do projeto Seis Sigma são apresentados nas seções 4.2.2.1 a 4.2.2.4.

4.2.2.1 Identificação do problema

O objetivo desta sub-etapa é identificar e avaliar o problema. O mapa de raciocínio inicia com a descrição da meta geral, seguido de perguntas e respostas e comprovação das respostas através de documentos ou coletas de dados, na expectativa de definir ou focar melhor o problema. Os resultados da sub-etapa de identificação do problema no estudo de caso são apresentados na Figura 40.

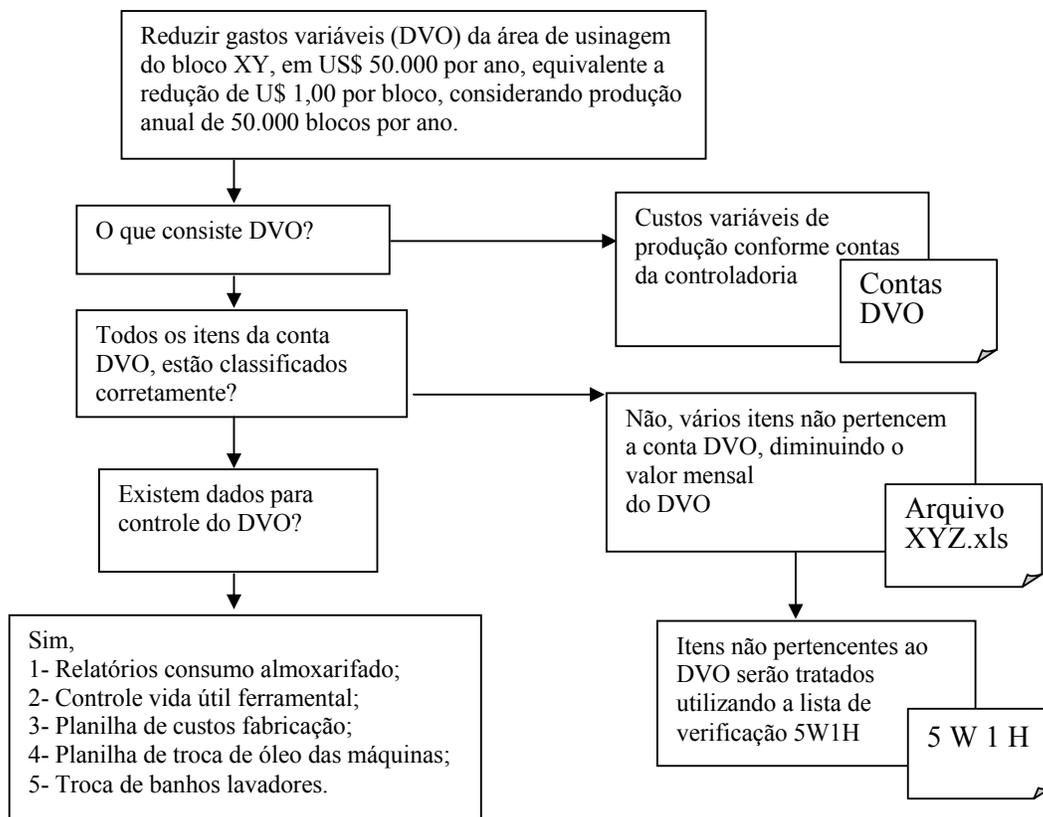


Figura 40 - Mapa de raciocínio – sub-etapa identificação do problema

A sub-etapa Identificação do Problema continua através do mapa de raciocínio. É evidenciado que existem controles para os gastos das contas de DVO. O próximo passo é identificar como ocorrem estes gastos. Pode-se dizer que o problema está identificado, sendo possível passar para a fase de Análise do Fenômeno ainda dentro da etapa de Planejamento do Ciclo PDCA.

4.2.2.2 Análise do Fenômeno

Nesta etapa, busca-se conhecer as características mais importantes do problema e focá-lo. Os resultados da análise do fenômeno no estudo de caso vêm apresentados na Figura 41.

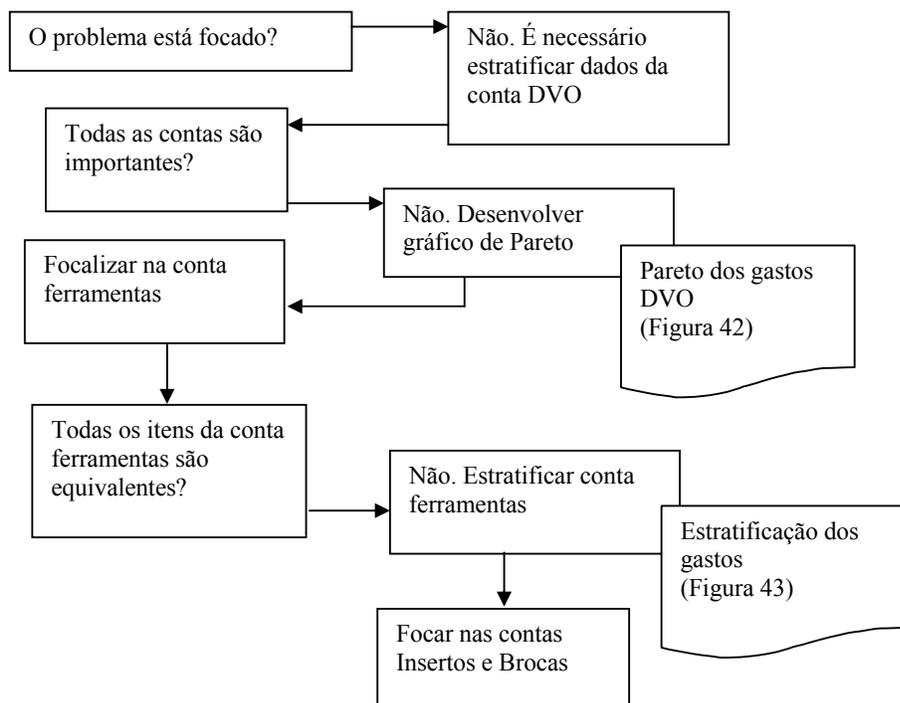


Figura 41 - Mapa de raciocínio – análise do fenômeno

Na busca da focalização do problema para descobrir quais contas são mais importantes nos gastos variáveis, utilizou-se o gráfico de Pareto, conforme apresentado na Figura 42.

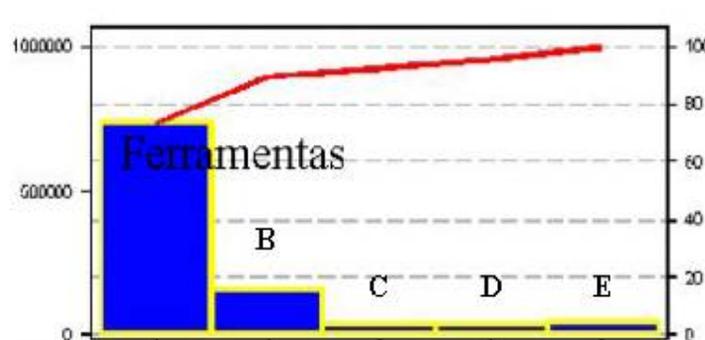


Figura 42 - Gráfico de Pareto dos gastos DVO

Verifica-se que a conta Ferramentas é responsável por 73,4% dos gastos variáveis de produção. As demais contas, não explicitadas na Figura 42, são: gases, óleos e inflamáveis

(B), material de manutenção (C), material de escritório (D), tintas, solventes e material de limpeza (E).

Estratificou-se, assim, a conta Ferramentas, identificando-se os seus maiores gastos; são eles: insertos, brocas e alargadores. Devido ao maior gasto ser o de insertos e brocas (ver gráfico na Figura 43), a investigação prosseguirá no estudo dos processos de gasto de insertos e brocas.

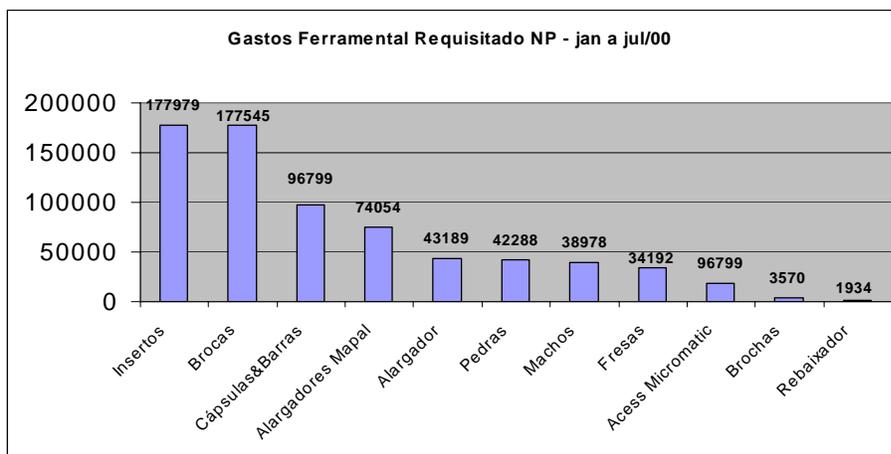


Figura 43 - Estratificação dos maiores gastos da conta ferramenta

As Figuras 44 e 45 apresentam o mapa de raciocínio investigando como ocorrem os gastos de insertos. Os dados primeiramente são extraídos do histórico das contas da contabilidade. É importante conhecer o processo e identificar fontes de variação dos gastos de inserto. Busca-se, também nesta fase, delinear uma meta específica para a resolução do problema. Considera-se que o problema é um resultado indesejado do processo e que as metas são estabelecidas sobre o resultado do mesmo (CAMPOS, 1996). O projeto Seis Sigma, conforme o mapa de raciocínio na Figura 40, inicia com uma meta geral, seguindo um desdobramento onde se busca estabelecer metas específicas. Na Figura 43, verifica-se que o estabelecimento de metas e planos de ações de redução de consumo nas ferramentas inserto e brocas pode, potencialmente, viabilizar o atendimento da meta geral do projeto.

Apesar de existirem dados contábeis acerca do consumo de ferramental de desgaste, as informações não são suficientes para identificar as causas de consumo excessivo do mesmo. É necessário identificar uma métrica ou indicador que demonstre as variações nos gastos. Um bom indicador seria a quantidade de blocos ou peças produzidas até efetuar a troca de ferramenta, ou seja, o controle de vida útil da ferramenta por máquina (ver Figura 46). Com

este indicador, é realizado um gráfico de controle da troca de ferramentas por máquinas, indicando como se comporta a variação de gastos e em quais equipamentos eles ocorrem. As Figuras 46 e 47 demonstram a variação mensal do indicador “número de blocos produzidos entre intervalos de troca de ferramenta” para cada lado do equipamento usado na operação 20.

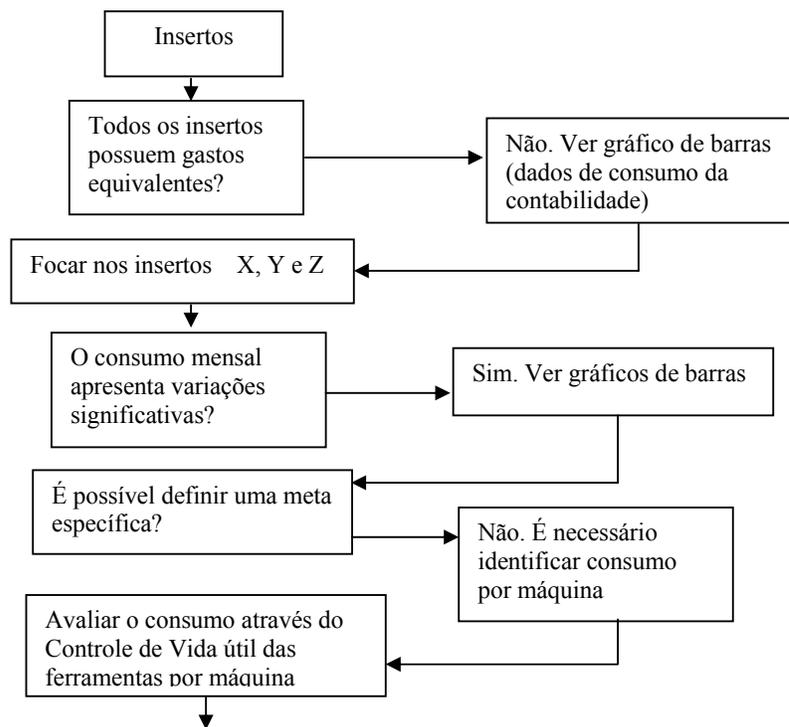


Figura 44 - Mapa de raciocínio -análise do fenômeno

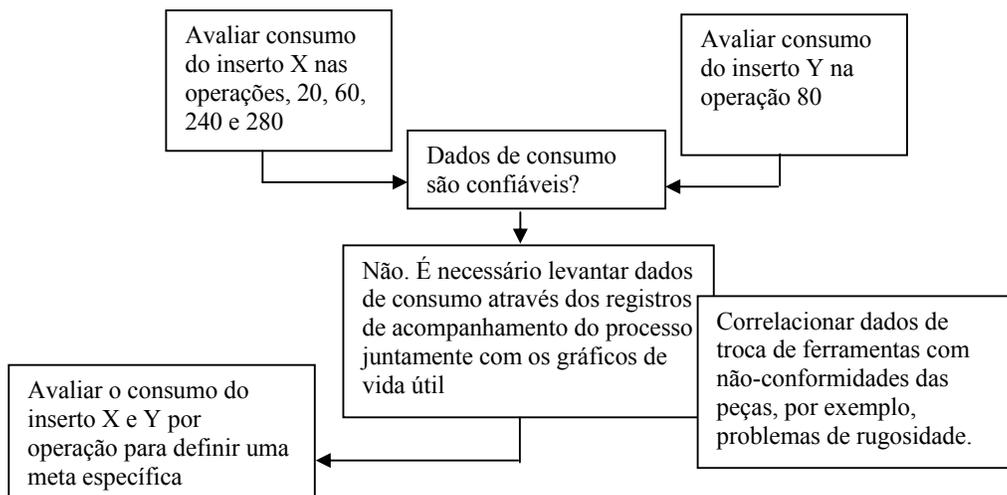


Figura 45 - Mapa do raciocínio - análise do fenômeno

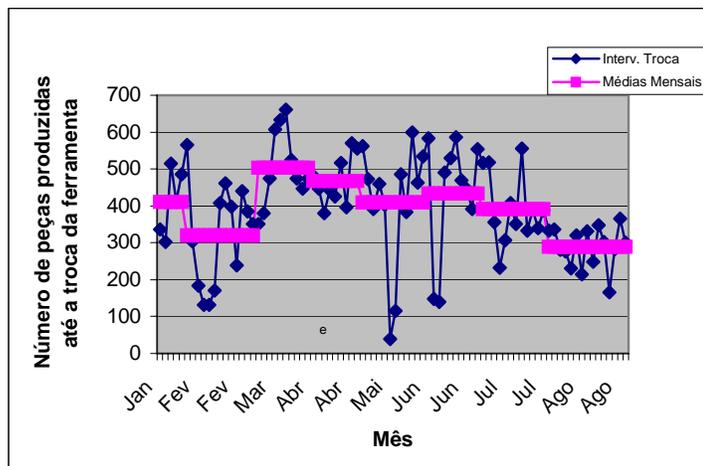


Figura 46 - Gráfico consumo de ferramentas do lado esquerdo da máquina, operação 20.

A média das médias do gráfico da Figura 46 é de 392 blocos produzidos por troca e o desvio padrão é igual a 134. Percebe-se muita variação no consumo de ferramentas. O equipamento apresentou causas especiais que provocaram uma média de troca baixa em alguns meses, sendo que algumas destas causas estão explicitadas no mapa de processo (ver Figuras 50 e 51) desenvolvido com a equipe de operação do equipamento.

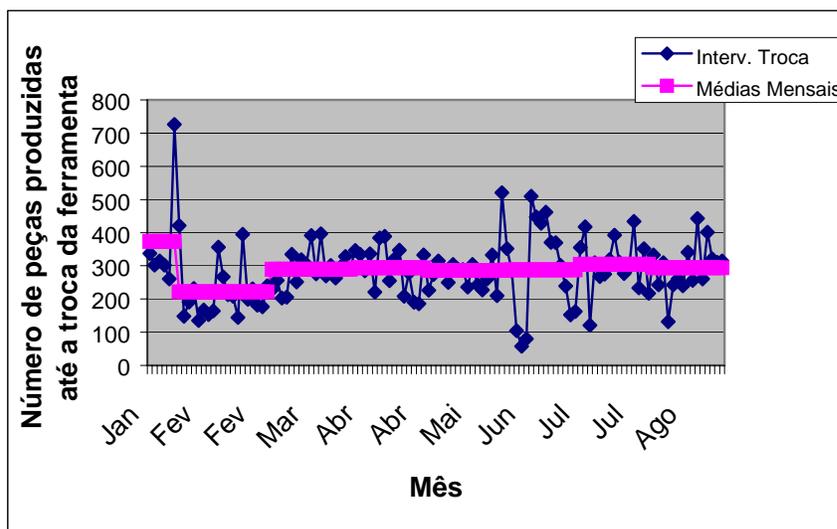


Figura 47 - Gráfico do consumo de ferramentas do lado direito da máquina, operação 20

Analisando o consumo do lado direito da máquina, verifica-se que a variabilidade é bem menor. Nesta etapa do mapa de raciocínio é definida uma meta específica para ambos os lados

da máquina. Após a definição das metas (ver Figura 48) é possível passar para a fase de Análise do Processo, ainda dentro da etapa de Planejamento do ciclo PDCA.

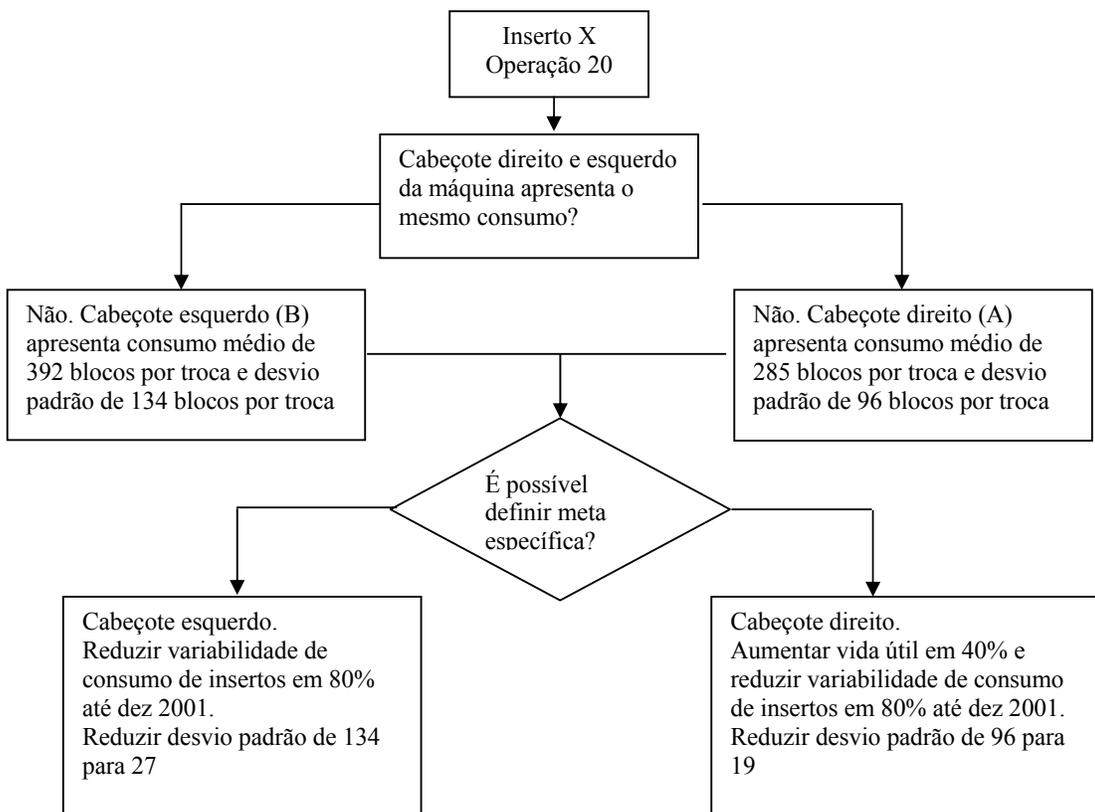


Figura 48 - Mapa de raciocínio - análise do fenômeno

4.2.2.3 Análise do processo

A Figura 49 apresenta o mapa de raciocínio típico da etapa Análise do Processo. No estudo de caso foi utilizado o fluxo apresentado em **negrito**. Nesta sub-etapa, busca-se conhecer as causas que geram o problema específico no processo. Para visualizar o processo podem ser utilizados fluxogramas e o mapa de processo. Caso o processo não for bem definido, pode ser utilizado *brainstorming*, diagrama de causa e efeito, diagrama de árvore, ou diagrama de afinidades (Ver Anexo A) para só então mapear o processo. Muitas vezes será preciso quantificar como as causas se relacionam com os efeitos do processo através de Cartas de Controle, Projeto e Análise de Experimentos e Análise de Regressão, ou entender melhor o processo para conhecer as causas, através do Mapa do Processo (item 2.4.3).

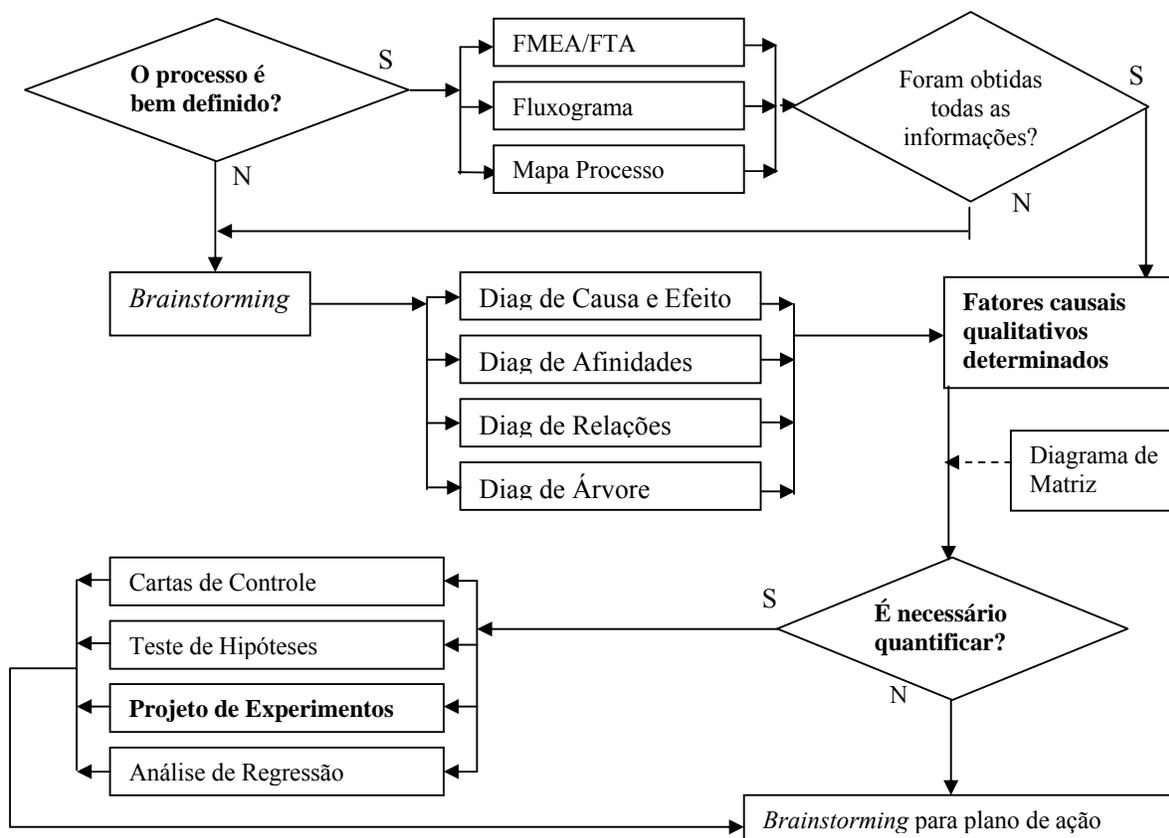


Figura 49 - Mapa de raciocínio - análise do processo
Fonte: WERKEMA, 2000.

O mapa de processo elenca as causas principais ou variáveis do processo que podem ser utilizadas no planejamento do experimento. O mapa de processo desenvolvido para a operação 20 (Figuras 50 e 51), apresentou muitas variáveis de controle, identificadas por (C) e variáveis de ruído (R), além de problemas no equipamento. O próximo passo seria o desenvolvimento de um projeto de experimento para otimizar o tempo de troca de ferramentas. Muitos blocos da operação 20 eram retrabalhados em outros equipamentos do setor ferramentaria para corrigir erros de planicidade, perpendicularismo e rugosidade, que são as cotas finais ou especificações de desenho para a operação vinte e estão identificadas no mapa das Figuras 50 e 51 por Y, sendo y o sub-produto de cada etapa do processo. Devido à incapacidade do processo, a empresa optou por dividir o processo da operação 20 em duas etapas, investindo em um segundo equipamento para realizar o passe de acabamento (ver Figura 51). A investigação através da metodologia Seis Sigma prosseguiu com a operação 80, também identificada como grande fonte de gasto de ferramentas. Desta forma, foi dado prosseguimento no mapa de raciocínio para estudar o consumo de ferramentas na operação 80, conforme Figura 52.

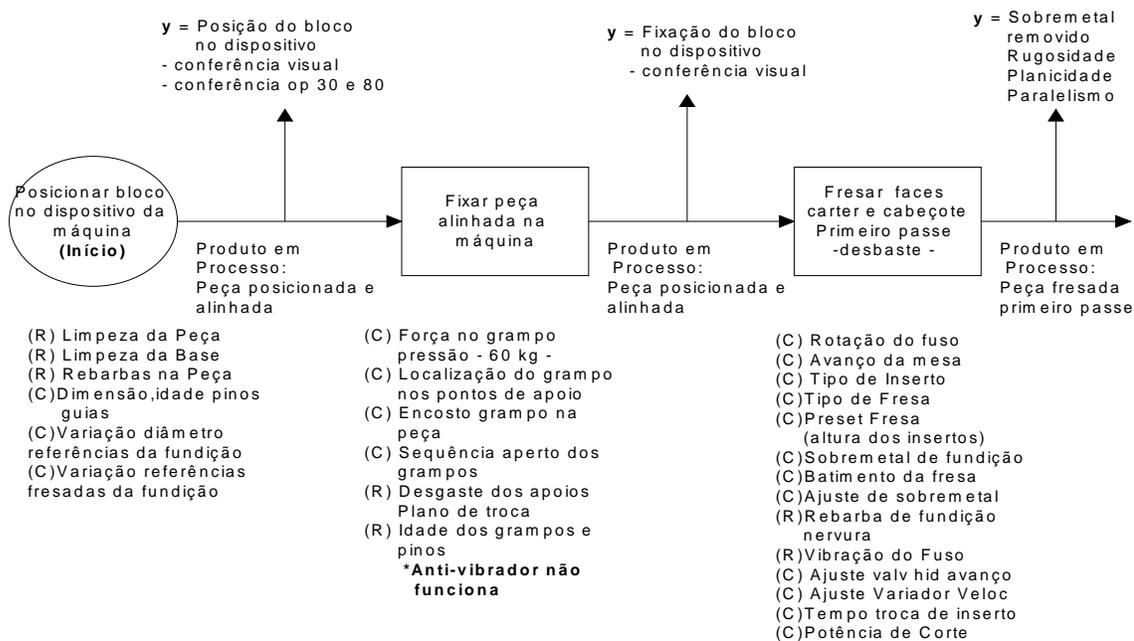


Figura 50 - Mapa de processo da operação 20, primeiro estágio da máquina.

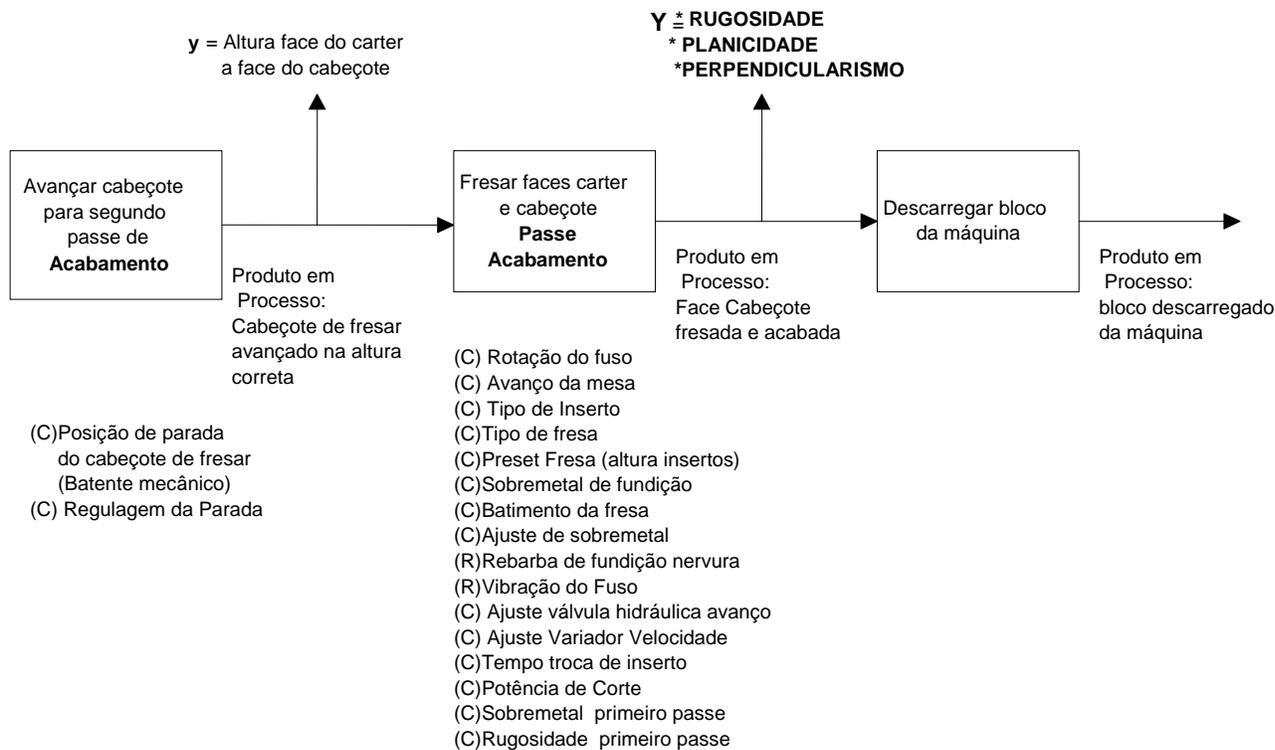


Figura 51 - Mapa do processo da operação 20, segundo estágio da máquina

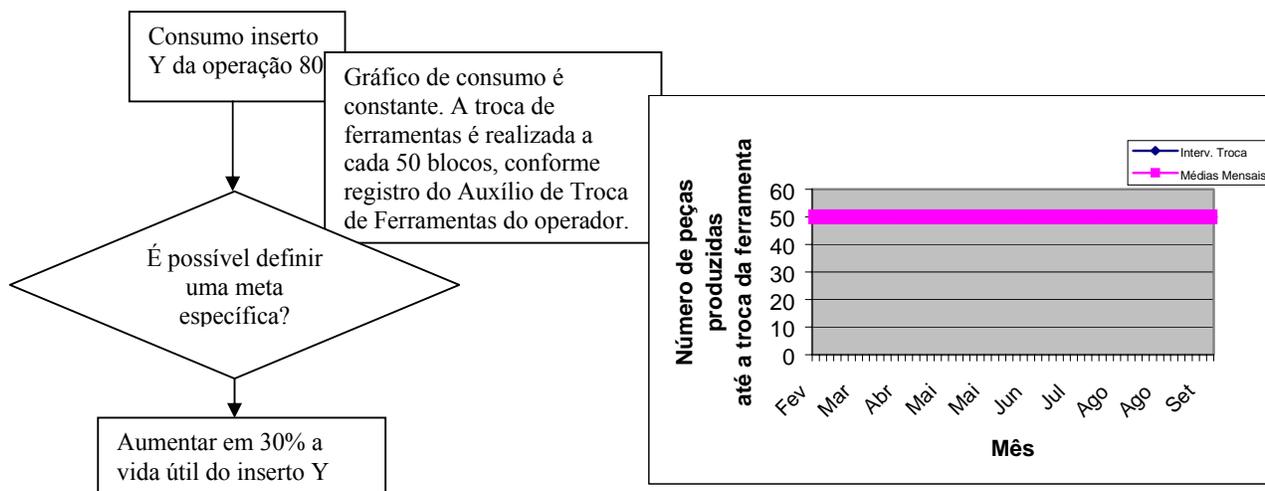


Figura 52 - Mapa de raciocínio etapa análise do fenômeno

Após a determinação da meta específica (ver Figura 52), a construção do mapa de processo, apresentado na Figura 53 auxilia na identificação dos fatores no planejamento dos experimentos.

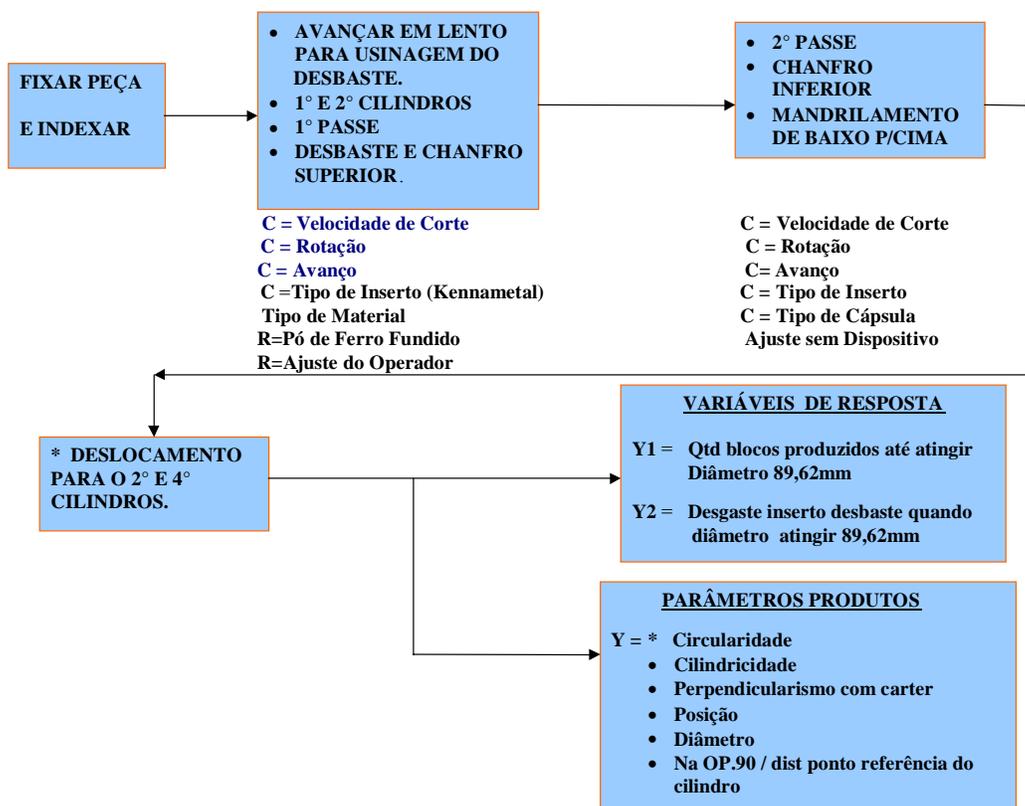


Figura 53 - Mapa de processo de usinagem do bloco na mandriladora

A mandriladora vertical da operação 80 é composta de dois cabeçotes com a função de mandrilar o diâmetro de quatro cilindros do bloco do motor. Durante esta operação são usadas dez ferramentas de corte, sendo oito para desbaste e duas para acabamento ou medida final, ambas específicas para ferro fundido, que é o material principal do bloco do motor. A operação de desbaste é realizada na direção vertical, sentido de cima para baixo, enquanto que a operação de acabamento é realizada no sentido de baixo para cima, quando do retorno do cabeçote e da ferramenta.

Conforme o histórico de estudos de capacidade realizados pela equipe técnica, foi definido que a vida útil para cada aresta de corte da ferramenta, seria de cinquenta blocos, sendo que a ferramenta de desbaste deveria ser trocada simultaneamente com a ferramenta de acabamento ao atingir a dimensão 89,62mm referente ao limite inferior de controle do processo (LIC). Os parâmetros de corte do estudo de capacidade não foram registrados.

Para cada troca de duas ferramentas de acabamento é necessário trocar oito ferramentas de desbaste, sendo que as ferramentas de desbaste ainda possuem vida útil remanescente para continuar no processo, o que resulta em desperdício. A proposta do experimento consistiu em estudar a influência do desgaste das ferramentas de desbaste na ferramenta de acabamento a fim de prolongar os períodos de troca de ferramentas, otimizando seu uso.

O experimento consistiu em promover modificações nos parâmetros de usinagem, conforme descritos no mapa de processo da Figura 53 realizado em conjunto com os técnicos e operadores da máquina. No mapa foram descritos os fatores controláveis (C) e os fatores não controláveis, considerados como ruído (R).

A partir do mapa do processo da mandriladora, foi planejado o experimento utilizando-se a planilha de Planejamento da Otimização Experimental de Produtos e Processos proposta por Caten e Ribeiro (2000) que é uma variação da Matriz de Otimização de Processos proposta por Echeveste e Ribeiro (1999). A seguir é apresentada a planilha através das Tabelas 24 a 36. A importância das planilhas de planejamento é mencionada no capítulo 3.

Tabela 25 - Descrição do título, objetivos do projeto, equipe e local de trabalho

TÍTULO DO ESTUDO
Otimização de ajustes da Máquina XXXX de fabricação de blocos de motores
Objetivos do Estudo
Determinar os ajustes da máquina XXXXX para que se obtenha o menor consumo de insertos, respeitando-se os parâmetros de qualidade do produto.
Equipe de Trabalho – Luis, Antonio, Operador 1, Operador 2
Local e data – Motores <i>Corporation</i>

O conteúdo da Tabela 25 é similar a Carta de Projeto proposta por Eckes (2003), Werkema (2001) na condução dos projetos Seis Sigma. Os objetivos da Carta de Projeto conforme Werkema (2001) são: a) apresentar claramente o que é esperado em relação à equipe; b) manter a equipe alinhada aos objetivos prioritários; c) formalizar a transição do projeto das mãos do *Black Belt* para a equipe; d) manter a equipe dentro do escopo definido para o projeto.

A inserção da voz do cliente, demandas de qualidade na condução do planejamento do experimento é realizada através da Tabela 26. A definição das variáveis de resposta para atingir as demandas da qualidade, como especificação e custo são desenvolvidos na Tabela 27.

Tabela 26 - Levantamento das características de qualidade importantes ao cliente

Demanda de Qualidade	Importância
Custo reduzido de produção	1
Tolerâncias de forma (concentricidade, cilindridade) dentro dos limites	1
Tolerâncias dimensionais dentro dos limites	1

Tabela 27 - Variáveis de respostas elencadas pela equipe técnica

Variáveis de Resposta	Tipo	Alvo (unidades)	Especificações		Importância
			Min	Max	
Y1: Desgaste dos insertos	Menor é melhor	0,25	0	0,25	1
Y2: Quantidade produzida por conjunto de insertos	Maior é melhor	70	55	70	2

As demandas da qualidade da Tabela 26 referem-se ao produto final e são atendidas na operação final ou de acabamento dos cilindros denominada de brunimento. O experimento proposto refere-se à primeira operação de desbaste do cilindro, seguindo-se um segundo desbaste, e um acabamento final. O cumprimento das demandas atende ao desempenho técnico do produto, bem como o repasse de ganhos de produtividade ou redução de custo, estipulados no contrato de fornecimento do produto. A variável de resposta Y2 (quantidade de peças produzidas por insertos) da Tabela 27 foi estipulada como a quantidade de blocos produzidos até atingir o diâmetro de 89,62mm, referente ao LIC. Esta condição de processo garante a estabilidade do processo nas operações subseqüentes conforme estudo de capacidade do processo realizado pela equipe técnica. A variável de resposta Y1 (desgaste de inserto) foi medida ao atingir o diâmetro de 89,62mm. Uma análise do desgaste do inserto mostrou que o mesmo poderia prosseguir a usinagem fazendo-se uma regulagem na cápsula porta-inserto para compensar o desgaste ocorrido. Esta condição foi descartada pela equipe

técnica devido à possibilidade de erros de ajustes acarretando variações nas operações seguintes, conforme experiência anterior.

Caso a equipe técnica detenha todo o conhecimento do processo, não sendo necessário mapeá-lo, os parâmetros do processo e fatores de ruído para atingir as variáveis de resposta podem ser definidos diretamente pelas Tabelas 28 e 29 respectivamente. A intensidade das relações entre variáveis de resposta e parâmetros do processo (ver Tabela 31) e as interações entre os parâmetros do processo (ver Tabela 32) podem ser ajustadas utilizando os pesos da Tabela 30.

Tabela 28 - Parâmetros do processo (fatores) selecionados pela equipe técnica

Parâmetro Do processo	Ajuste Atual	Ajuste Sugerido	Intervalo MIN	Intervalo MAX	Facilidade de ajuste
X1: Velocidade de corte	147	155	147	160	1
X2: Avanço de corte	400	450	400	487	1
X3: Posição do cabeçote	-	-	Esquerdo	Direito	1
X4: Fabricante de Inserto	-	-	Kenametal	Sandvik	1

O parâmetro de controle rotação registrado no mapa de processo da Figura 53 está inserido no parâmetro velocidade de corte (X1), da Tabela 28.

Na Tabela 28 não foram incluídos os fatores fluido de corte, pois a configuração do equipamento é para usinagem a seco devido ao material do bloco ser de ferro fundido e a operação de mandrilamento ser de desbaste. Somente é utilizado fluido de corte na operação de acabamento brunimento. Foram escolhidos insertos de mesma geometria e classes de material, porém de diferentes fabricantes. Não foram testados geometrias diferentes. O interesse da equipe técnica foi de estudar as combinações de velocidade de corte e avanço, pois estudos de capacidade realizados anteriormente definiram uma vida útil de 50 peças, considerando ajustes de Velocidade de Corte e Avanço nos níveis mínimos conforme a coluna Ajuste Atual da Tabela 28.

Tabela 29 - Fatores de ruído no experimento

Fatores de ruído
Z1: Excesso de sobremetal de fundição
Z2: Variação de dureza do material
Z3: Deslocamento de parede do bloco

Foi estipulada uma folha de verificação padrão para a operação do equipamento, durante o experimento instruindo o operador quanto ao manuseio das peças e anotação das quantidades produzidas, mantendo assim a influência do operador constante.

Tabela 30 - Atribuição das interações e relações

Intensidade das relações e interações	Valor numérico
Inexistente	0
Fraca	1
Moderada	2
Forte	4

Tabela 31 - Atribuição das relações entre fatores e variáveis de resposta

	R _{ij} = Relações XiY _j				
	Im. Rel.	X1	X2	X3	X4
Y1 = Desgaste	1	4	2	1	1
Y2 = Qtd Blocos	1	4	2	1	1
IPP _j		8	4	2	2

Tabela 32 - Atribuição das interações entre fatores

	I _{ij} = Interações XiX _j			
	X1	X2	X3	X4
X1 = Vel. Corte	-	4	0	0
X2 = Avanço	4	-	0	0
X3 = Pos. Cabeçote	0	0	-	0
X4 = Fabr. Inserto	0	0	0	-
	4	4	0	0

A priorização dos parâmetros do processo (ver Tabela 33) é feita em função de três aspectos: grau de interação dos parâmetros do processo (K1); efeito dos parâmetros do processo sobre as variáveis resposta (K2); facilidade de ajuste (FA).

O formulário para os cálculos segue:

$$K1(x_j) = \sum_i R_{ij} \times IE_i \quad (39)$$

$$K2(x_j) = (\sum_i I_{ij}) / P \quad (40)$$

$$PR(x_j) = [K1(x_j) + K2(x_j)] \times FA_j \quad (41)$$

onde: P número de parâmetros do processo;

I_{ij} índice de interação entre os parâmetros do processo i e j;

R_{ij} relação entre a variável de resposta i e o parâmetro do processo j;

IE_i índice de importância para a variável de resposta i;

FA_j Facilidade de ajuste para o parâmetro de processo j.

Tabela 33 - Priorização dos parâmetros do processo

		Iij = Interações XiXj			
		X1	X2	X3	X4
K1	32	8	4	2	2
K2	2	4	4	0	0
FA	-	1	1	1	1
PR =		2,64	1,36	0,64	0,64

Os fatores controláveis do processo e seus níveis estão resumidos na Tabela 34. Embora o mapa de processo da Figura 53 apresente mais fatores, foram priorizados para investigação os fatores velocidade de corte X1 e avanço X2. Os níveis dos fatores e sua amplitude foram escolhidos baseados no campo de potência da máquina e na disponibilidade de ajustes, sem comprometer a produção. Tentou-se incluir no experimento o fator X4, Fabricante do Inserto, para testar dois fornecedores: Kenametal e Sandvik. Os primeiros testes com o fabricante Kenametal apresentaram um desempenho inesperado, com quebra dos insertos e indisponibilizando a quantidade de amostras necessárias para realizar o experimento, que seria um experimento fatorial 2^3 .

Tabela 34 - Fatores controláveis do experimento

Fatores controláveis	PR	Níveis reais	Níveis codificados
X1 - Velocidade de corte	2,64	147 e 160 m/min	-1 e 1
X2 - Avanço de corte	1,36	400 a 487 mm/min	-1 e 1

As vantagens na utilização da planilha de planejamento da otimização experimental de produtos e processos (CATEN; RIBEIRO, 2000) em relação a definir os parâmetros do experimento diretamente do mapa de processo da Figura 53, estão na priorização dos fatores controláveis do experimento, na possibilidade de visualizar possíveis interações entre os fatores, na simplicidade de utilização e principalmente no questionamento e visualização das relações entre possíveis fatores e variáveis de resposta.

O planejamento do experimento pode ser resumido conforme Tabelas 35, 36 e 37.

Tabela 35 – Descrição das variáveis de resposta

Variáveis de Resposta	Método de Medição
Y1 = Desgaste no flanco dos insertos de desbaste	Lupa graduada – medição do desgaste de flanco na aresta de corte do inserto
Y2 = Quantidade de blocos produzidos até a dimensão de 89,62 mm	Intramés – medição do diâmetro do cilindro em 2 eixos X e Y

Tabela 36 – Descrição das variáveis de ruído

Variáveis de Ruído	Método de Controle
Sobremetal de fundição	Medição de sobremetal antes da usinagem
Matéria-prima	Anotação da série da corrida de fundição
Erros de deslocamento no bloco usinado	Enviar blocos usinados a metrologia (medição de perpendicularismo) Cortar um bloco por teste e medir parede
Assentamento incorreto do bloco	Limpeza dos pontos de apoio após cada peça
Controle da quantidade de blocos produzidos até dimensão de 89,62mm	Uso de Carta de Controle, anotações em planilha.

O experimento fatorial 2^2 com quatro réplicas foi aleatorizado (usando o software Minitab). A planilha com lista das 16 rodadas experimentais é apresentada na Tabela 37. O experimento foi dividido em dois blocos para reduzir a variabilidade entre turnos de operação.

Tabela 37 - Planilha do experimento

Ordem Padrão	Ordem dos Testes	Blocos	Vel Corte	Avanço	Desgaste do Inserto	Quantidade de Blocos
6	1	1	160	400	0,25	50
5	2	1	147	400	0,15	50
4	3	1	160	487	0,15	78
2	4	1	160	400	0,24	50
8	5	1	160	487	0,13	78
1	6	1	147	400	0,14	50
3	7	1	147	487	0,14	49
7	8	1	147	487	0,16	49
11	9	2	147	487	0,21	61
9	10	2	147	400	0,18	60
14	11	2	160	400	0,25	72
15	12	2	147	487	0,14	61
10	13	2	160	400	0,11	72
13	14	2	147	400	0,20	60
12	15	2	160	487	0,16	61
16	16	2	160	487	0,13	61

O experimento durou um período de dez dias. O correram variações de desgaste de insertos (Y2) devido possivelmente a variações de sobremetal de fundição, como irregularidades, carepas, devido o diâmetro de entrada na mandriladora ser bruto de fundição.

A análise dos resultados foi feita utilizando o *software* Minitab. Iniciou-se uma avaliação visual dos resultados através da plotagem do gráfico de Pareto (ver Figura 54).

A análise do gráfico de Pareto indica que o fator de controle velocidade de corte tem maior efeito sobre a variável resposta quantidade de blocos produzidos, conforme apresentado na Figura 54. A linha vertical vermelha indica que qualquer efeito que se estender além da linha é significativo a um nível de significância (α) de 0,05. No caso o fator de controle velocidade de corte (A) é significativo, enquanto o fator de controle avanço (B) e a interação dos fatores de controle velocidade de corte e avanço (AB) não são significativos.

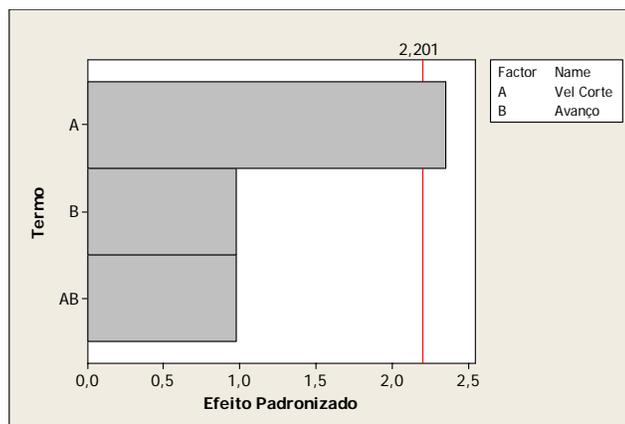


Figura 54 - Gráfico de Pareto dos fatores de controle para variável quantidade de blocos.

Na seqüência, a Figura 55 traz uma ilustração gráfica do efeito do fator de controle, velocidade de corte sobre a variável de resposta quantidade. O gráfico indica que velocidade de corte a um nível maior faz com que a ferramenta produza uma maior quantidade de blocos até atingir a dimensão 89,62mm.

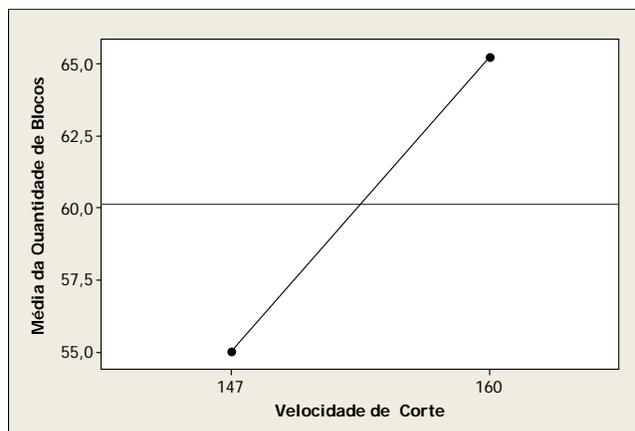


Figura 55 - Gráfico do efeito do fator de controle velocidade de corte sobre a variável de resposta quantidade de blocos produzidos.

A análise visual dos resultados do experimento foi refinada através de uma análise de variância, visualizada na Tabela 38.

Tabela 38- Análise de variância para quantidade

Fonte	Graus de Liberdade	SS	MS	F	P
Vel. Corte	1	420,3	420,3	4,96	0,046
Avanço	1	72,2	72,2	0,85	0,374
Interação	1	72,2	72,2	0,85	0,374
Erro	12	1017	84,8		
Total	15	1581,7			

A uma nível de significância de 5% ($\alpha = 0,05$), pode-se concluir que o fator de controle velocidade de corte é significativo pois o valor de probabilidade é menor que 0,05 e $F_0 > F_{0,05; 12} = 4,75$. A adequação do modelo pode ser verificada através da plotagem dos seus resíduos no papel de probabilidade da Normal, conforme Figura 56. Observam-se resíduos normalmente distribuídos, próximos da linha diagonal do gráfico.

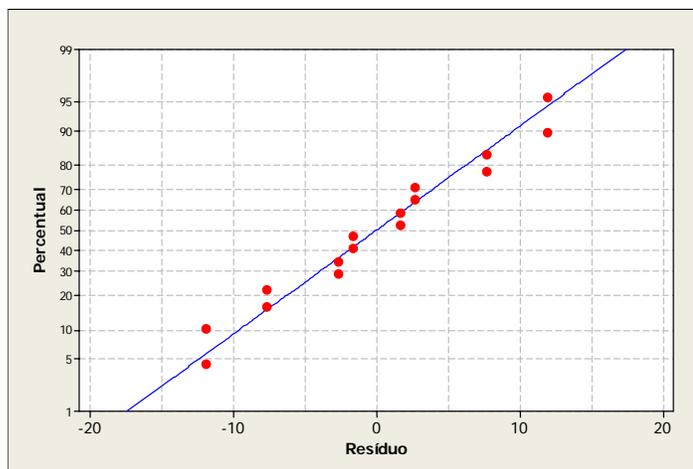


Figura 56 - Plotagem de probabilidade normal para variável de resposta quantidade

A análise do gráfico de Pareto indica que o fator de controle avanço tem o maior efeito, conforme ilustrado na Figura 57. Como nenhum fator ultrapassa a linha de significância, pode-se concluir que os fatores de controle não apresentam efeito significativo na variável de resposta desgaste.

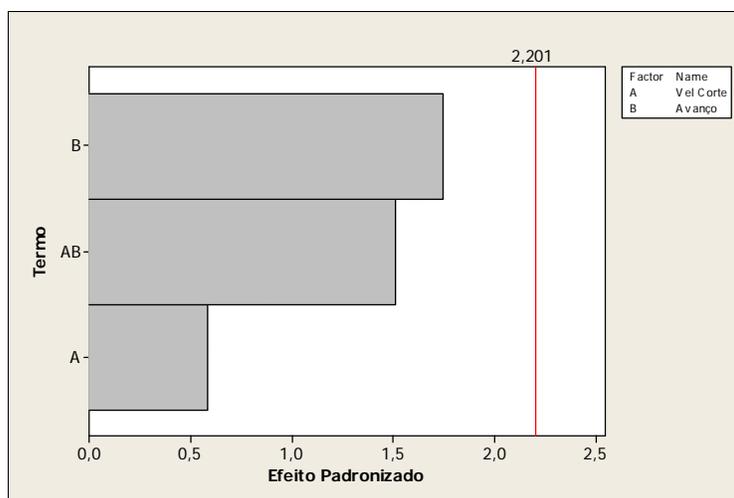


Figura 57 - Gráfico de Pareto dos fatores para variável desgaste

A análise de variância que confirma a análise visual em termos analíticos para a variável de resposta desgaste é apresentada na Tabela 39. A análise de variância não aponta efeito significativo dos fatores de controle sobre a variável de resposta desgaste, a uma significância de 5%, pois a probabilidade é maior que 0,05 e $F_0 < F_{0,05; 1,12} = 4,75$.

Tabela 39 - Análise de variância para desgaste

Fonte	Graus de Liberdade	SS	MS	F	P
Veloc Corte	1	0,00062	0,00062	0,37	0,555
Avanço	1	0,00562	0,00562	3,33	0,093
Interação	1	0,00422	0,00422	2,50	0,140
Erro	12	0,02030	0,00169		
Total	15	0,03078			

4.2.3.4 Estabelecimento do plano de ação

A última sub-etapa dentro da etapa Planejamento (P) do ciclo PDCA é o Plano de Ação. As ações propostas para o processo foram regular a máquina com os níveis altos dos fatores de controle velocidade de corte (160 m/min) e avanço (487 mm/min). Apesar de o avanço resultar em não significativo, foi tomada a decisão de ajustá-lo no nível mais alto, visto que um avanço maior permite que a ferramenta fique menos tempo em contato com a peça do que um avanço menor, o que resultará em menor desgaste do gume de corte. Com isso, a vida útil da ferramenta passou para um valor médio de 70 blocos produzidos até a troca do gume de corte da ferramenta, com uma dispersão de 10 blocos. O experimento serviu de aprendizado e modelo para implementar o projeto de experimentos nos testes de ferramentas a fim de otimizar o processo nas demais 32 máquinas da linha de usinagem.

O ganho obtido de 40% de vida útil, passando de 50 para 70 blocos produzidos até a troca de ferramenta, é expressivo, considerando que não houve investimento por parte da empresa; apenas a regulagem ótima dos fatores produziu o efeito. O Projeto e Análise de Experimentos mostra-se uma ferramenta poderosa na otimização dos processos. É necessário difundir seu uso e buscar alternativas de implantação da ferramenta de uma forma direta para o chão-de-fábrica.

Os testes de novas ferramentas realizados anteriormente (previamente à utilização do PAE), levavam em conta parâmetros de velocidade de corte e avanço, recomendados pelo fabricante por catálogo ou experiência própria. Não era utilizada uma metodologia de teste, nem eram testados diferentes níveis dos fatores. A variável resposta era a quantidade de peças produzidas com os ajustes recomendados por catálogo de fabricante de ferramentas. A ferramenta que produzia mais peças no teste era implantada, sendo que muitas vezes não se sustentava o resultado com o tempo.

Após a fase Estabelecimento do Plano de Ação seguiram-se as etapas Execução do Plano (DO), Verificação dos Resultados (CHECK – C) e Ação (A) finalizando o projeto. A execução do plano consistiu de incorporar os novos parâmetros testados no projeto e análise de experimentos. Para a verificação foi realizado um novo estudo de capacidade do equipamento e a ação seguiu-se com a padronização do procedimento de testes de insertos, incorporando o projeto e análise de experimentos como metodologia de testes.

O projeto apresentou um pequeno ganho financeiro, comparado ao potencial de ganho com aumento da vida útil de ferramental no restante da linha de usinagem (32 máquinas). Contudo o ganho foi considerado expressivo, pois foi possível um aumento de 30% em vida útil do ferramental, somente com a regulagem ótima dos parâmetros de usinagem.

O estudo de caso aqui reportado foi apresentado ao comitê da qualidade da empresa, onde todos os candidatos a *Black Belts* apresentaram seus projetos a fim de promover a troca de experiências e sedimentar o uso da metodologia Seis Sigma na resolução dos problemas. Foi a primeira utilização da ferramenta PAE na empresa. As dificuldades encontradas no desenvolvimento dos projetos Seis Sigma foram associadas ao nível de envolvimento dos participantes nos projetos *Black Belt*. A empresa optou por uma dedicação parcial dos candidatos aos projetos Seis Sigma, o que dificultou no acompanhamento dos experimentos, na continuidade dos trabalhos e no prazo de conclusão dos projetos.

Em contato posterior com a empresa, a mesma realizou investimento adquirindo novos motores elétricos para a mandriladora, permitindo assim testar velocidades de corte mais elevadas, conforme sugeriam os resultados do experimento. Atualmente a vida útil da ferramenta na operação 80 é de 90 blocos produzidos por troca de ferramenta e os ajustes dos parâmetros de controle são velocidade de corte 344 m/min e avanço 462 mm/min.

5 CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS

Esta dissertação analisou a aplicação da metodologia Seis Sigma em um estudo de caso parte de um projeto de certificação de *Black Belt* na indústria automotiva. Na abordagem foram enfocados o desdobramento da metodologia Seis Sigma e suas ferramentas a fim de obter um resultado prático e mensurável. Os resultados atualmente obtidos em implantações de projetos Seis Sigma são citados por Montgomery et al. (2001) como uma das vantagens e razões de sucesso do programa, frente a várias outras iniciativas para melhoria da qualidade e redução de variabilidade testadas no passado, tais como Total Quality Management – Gestão da Qualidade Total (TQM) Zero Defeito e Engenharia de Valor.

O estudo de caso serviu à empresa como projeto piloto para avaliar a sedimentação do treinamento dos *Black Belts* e adoção da metodologia Seis Sigma nos projetos, bem como o conhecimento do potencial de ganho dos projetos Seis Sigma e o tempo para atingir os resultados, incluindo tempo de dedicação dos funcionários nos projetos, além das necessidades de treinamentos de *Green Belts*.

Outro aspecto do trabalho é a utilização de uma metodologia amplamente conhecida teoricamente, como PDCA, porém não muito utilizada na prática. A apresentação e desdobramento do estudo de caso através do ciclo PDCA e a utilização das técnicas estatísticas inseridas em cada fase do ciclo auxiliaram o entendimento e utilização da metodologia Seis Sigma definindo um caminho (*roadmap*) para atingir os objetivos propostos do projeto.

O estudo de caso permitiu atingir os objetivos de aplicação da metodologia e ferramentas Seis Sigma no desenvolvimento do projeto e utilização da ferramenta PAE na otimização de parâmetros de usinagem, com conseqüente redução dos custos variáveis de fabricação através do aumento da vida útil do ferramental da seguinte forma:

- a) desdobramento do projeto e problema de pesquisa através do ciclo PDCA, identificando a passagem entre cada fase e utilização adequada das ferramentas estatísticas e não estatísticas, e comprovação dos dados registrando a evolução do projeto no mapa de raciocínio;
- b) mapeamento do fluxo do processo identificando causas de variação em cada etapa do processo, e identificação dos fatores controláveis para o planejamento do projeto de experimentos;

- c) planejamento do experimento através da planilha de planejamento da otimização experimental de produtos e processos (CATEN e RIBEIRO, 2000). A utilização da planilha simplifica a identificação dos fatores controláveis para o projeto de experimento, além de identificar a relação entre os fatores;
- d) execução do PAE analisando dados visualmente através de gráficos de Pareto e analiticamente através da ANOVA;
- e) criação de um modelo de teste de otimização de vida útil de ferramental. Os experimentos fatoriais tipo 2^2 permitem testar as combinações dos parâmetros velocidade de corte e avanço em dois níveis. Os experimentos fatoriais 2^3 permitem a inclusão de um terceiro fator, como tipo de fabricante ou tipo de tecnologia de ferramenta. A análise dos dados obtidos a partir de ambos os projetos experimentais permite identificar quais ajustes dos parâmetros dos processos aumentam a vida útil do ferramental. Apesar de serem experimentos simples de realizar, as empresas de manufatura de usinagem comumente utilizam a estratégia de teste de ferramentas ajustando um fator por vez.

Em uma primeira determinação de níveis dos fatores experimentais, foi possível obter um ganho de 40% na vida útil da ferramenta (passou-se de 50 peças produzidas por troca de ferramenta para 70 peças). O primeiro experimento sinalizou a necessidade de verificação de níveis adicionais para os fatores experimentais. Dessa segunda verificação, obteve-se um aumento de 80% na vida útil da ferramenta (passou-se de 50 peças produzidas por troca de ferramenta para 90 peças). A aplicação de PAE nas demais 32 máquinas da linha de usinagem permitirá uma redução de custo de ferramental considerável. Tal redução é extremamente importante, pois as cotações para venda do produto na indústria automotiva possuem planilha aberta, isto é, o custo variável de produção de ferramental é conhecido e discutido com o cliente, que na maioria das vezes possui linhas de fabricação de processo similares ou até mesmo fabrica o mesmo produto.

Um dos fatores escolhidos no experimento, velocidade de corte (V_c), tem relação com a vida útil da ferramenta descrita pela equação (37). O experimento permitiu definir os níveis adequados de V_c para atingir um aumento de vida útil. A utilização do PAE pode trazer outros resultados de maior complexidade, conforme sugestões para trabalhos futuros na seção 5.2. Contudo, para difundir a metodologia na indústria automotiva, é válida a iniciativa de desenvolver experimentos mais simplificados, com dados de fácil análise.

Um fato extremamente importante na aplicação de novas metodologias é o sucesso da implantação. A indústria automotiva é, na maioria das vezes, pioneira na introdução de novas ferramentas. Sendo assim, a expectativa de sucesso, a resistência de implantação e o imediatismo das novas soluções são fatores a serem vencidos para conquistar espaço e implantar uma cultura de experimentos a fim de se obter a otimização dos processos.

O estudo de caso aplicou a metodologia Seis Sigma e o PAE na otimização dos parâmetros do processo. Para investigações futuras, sugere-se ampliar o uso das ferramentas do Seis Sigma para aplicação no produto através do DFSS (*Design for Six Sigma*) além de:

- a) ampliar fatores a pesquisar e definir uma estratégia de experimentação específica para o caso usinagem. A usinagem geralmente compreende interações complexas entre materiais da peça, da ferramenta, fluido e condições de corte. A melhoria em usinagem pode ser caracterizada por: aumento da vida da ferramenta, maior taxa de remoção de material (produtividade), melhoria do acabamento superficial, melhor controle do cavaco e diminuição das forças de corte. Sendo assim, a aplicação da metodologia *Response Surface Technology* (RSM) com os gráficos de linhas de contorno e superfície de resposta e a superposição de contornos das variáveis de resposta auxiliam na escolha dos melhores fatores para otimização dos resultados (RAMOS *et al.*, 2004);
- b) desenvolver e aplicar os mapas topográficos do processo propostos por Sieloff (2002) após a aplicação do PAE, auxiliando o operador na monitoração do processo, e na manutenção dos resultados obtidos;
- c) investigação sistemática de otimização dos resultados de experimentos, através da análise da função perda proposta por Taguchi;
- d) aplicar PAE no projeto de tolerâncias analíticas do produto. A tolerância dos componentes para produtos montados é freqüentemente ajustada com o auxílio da fórmula de transmissão de erros. Este método geralmente requer o uso de derivadas parciais da relação funcional entre as dimensões dos componentes e as características de qualidade do produto montado. O uso combinado do PAE e do projeto em computador CAD pode ser usado para obter as derivadas parciais da relação funcional sem a necessidade de conhecer a expressão matemática explícita desta relação, podendo assim usar a fórmula de transmissão de erro para estabelecer as tolerâncias funcionais (BISGAARD; GRAVES; SHIN, 2000);

- e) no caso de projeto empírico de tolerâncias, o PAE e a função perda de Taguchi, podem ser utilizados conforme seqüência de projeto de tolerância proposta por Creveling, Slutsky e Antis (2001) para otimizar as tolerâncias, baseado na redução dos desvios padrões dos componentes:
- definir parâmetros do projeto de engenharia ou processo de manufatura a ser avaliado,
 - desenvolver a função perda de qualidade para a variável de resposta,
 - definir o desvio padrão ($1s$) de montagem ou manufatura, acima e abaixo do ponto de ajuste médio para cada parâmetro sob avaliação,
 - selecionar um arranjo ortogonal adequado com graus de liberdade suficientes para facilitar a avaliação do efeito de um desvio padrão dos pontos de ajuste para cada parâmetro na variável de resposta medida,
 - alinhar os fatores de ruído com o arranjo ortogonal do experimento, (vi) realizar o experimento,
 - conduzir a análise de variância,
 - calcular a perda de qualidade total para o projeto base,
 - quantificar a perda de qualidade devido a cada parâmetro no projeto base,
 - calcular o percentual que cada parâmetro contribui para a variabilidade total na resposta,
 - calcular a capacidade do processo (C_p) para o projeto,
 - construir a equação de variância,
 - utilizar os novos valores de variância do parâmetro inferior para calcular os novos valores perda inferiores,
 - acordar com a equipe de processo o aumento no custo dos componentes associado com a redução de variância em cada parâmetro,
 - refazer o experimento nos novos limites de desvio padrão, conforme definido na redução das variâncias dos parâmetros,
 - calcular o novo C_p dos limites de tolerância dos clientes e o desvio padrão do experimento de verificação;

- f) aplicar RSM na análise de planeza de superfícies metrológicas de máquinas de medição por coordenadas. A curva do RSM se aproxima dos pontos da planicidade medidos em uma superfície, podendo o método RSM representar estatisticamente a planeza da superfície (LIMA JR.; SILVA, 2004).

REFERÊNCIAS

ABRAHAM, B.; MACKAY, J. Discussion on HOERL, Roger. Six Sigma Black Belts: what do they need to know? **Journal of Quality Technology**. Milwaukee, Wi.: ASQ, v. 33, n. 4, p. 410-413, oct. 2001.

AGUIAR, S. **Integração das Ferramentas da Qualidade ao PDCA e ao Programa Seis Sigma**. Belo Horizonte: Desenvolvimento Gerencial, 2002.

ANDERSON, M. J; KRABER, S. L. Eight Keys to Successful DOE. **Quality Digest**. [S.l.]:[s.n.], jul.1999.

ANDERSON, M.; WHITCOMB, P. **DOE Simplified**: Practical tools for effective experimentation. Portland: Productivity, 2000.

AIAG - AUTOMOTIVE INDUSTRY ACTION GROUP. **Statistical Process Control**: reference manual. Michigan: AIAG, 1995.

BAYLEY, S. P. Discussion on HOERL, Roger. Six Sigma Black Belts: what do they need to know? **Journal of Quality Technology**. Milwaukee, Wi, v. 33, n. 4, p. 426-428, oct. 2001.

BISGAARD, S.; FREIESLEBEN, Johannes. Economics of Six Sigma. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.13, n.2, p. 325-331, 2000-01.

BISGAARD, S.; GRAVES, S.; SHIN, G. Tolerancing Mechanical Assemblies With CAD and DOE. **Journal of Quality Technology**. Milwaukee, Wi, v. 32, n. 3, p. 231-240, july.2000.

BOX, G.; LUCENÑO, A. Six Sigma, Process Drift, Capability Indices, and Feedback Adjustment. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.12, n.3, 297-302, 2000.

BOX, G. The Invention of Composite Design. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.12, n.1, p. 119-122, 1999-2000.

BREYFOGLE III, Forrest W. **Implementing Six Sigma**. New York John Wiley & Sons, 1999.

BUCHAIM, J.G. **Confiabilidade de Sistemas**. São Paulo: QPB Consultoria e Treinamento, 1994.

BREYFOGLE III, F. W; ENCK, D; MEADOWS, B. Discussion on HOERL, Roger. Six Sigma Black Belts: what do they need to know? **Journal of Quality Technology**. Milwaukee, Wi, v. 33, n. 4, p.424- 425, oct. 2001.

CAMPOS, Vicente Falconi. **Gerenciamento pelas Diretrizes**. Belo Horizonte: Fundação Cristiano Ottoni, Escola de Engenharia da UFMG, 1996.

CREVELING, C.M.; SLUTSKY, J.L.; ANTIS, D. **Design for Six Sigma in Technology and Product Development**. New Jersey: Prentice Hall, 2003.

DINIZ, A. E.; MARCONDES, F.C.; COPPINI, N.L. **Tecnologia da Usinagem dos Materiais**. São Paulo: Artliber, 2001.

ECHEVESTES, M.; RIBEIRO, J. L. **Planejando a Otimização de Processos**. Porto Alegre: PPGE, UFRGS, 1999.

ECKES, George. **Six Sigma for Everyone**. New York: John Wiley & Sons, 2003.

EMANUEL, J. T.; PALANISAMY, M. Sequential Experimentation Using Two-Level Fractional Factorials. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.12, n.3, p.335-346, 2000.

FERRARESI, D. **Fundamentos da Usinagem dos Metais**. São Paulo: Blücher, 1977.

FLESCHE, G. **Projeto de Experimentos**. Dissertação (Mestrado Profissional), PPGE, UFRGS, 2001.

GEORGIU, G. Tool Life Math. In: COMPACTED GRAPHITE IRON MACHINABILITY SEMINAR, 2001, Warren, Michigan, EUA. **Anais...**Michigan, EUA: [s.n.], 2001.

GRAVES, Spencer. Six Sigma Rolled Throughput Yield. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.14, n.2, p. 257-266, 2001-02.

HAHN, Gerald; DOGANAKSOY, Necip. HOERL, Roger, The Evolution of Six Sigma **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v. 12, n.3, p. 317- 326, 2000.

HAHN, G. J. *et al.* The Impact of Six Sigma Improvement: a glimpse into the future of statistics. **The American Statistician**. Washington: American Statistical Association, v.53, n. 1, p.8,1999.

HARRY, Michel; SCHROEDER, Richard. **Six Sigma**: the breakthrough management strategy revolutionizing the world's top corporations. New York: Currency, 2000.

HILD, C.R.; SANDERS, D.; ROSS, B. The Thought Map. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.12, n.1, p. 21-27,1999-2000.

HILL, W. J. Discussion on HOERL, Roger. Six Sigma Black Belts: what do they need to know? **Journal of Quality Technology**. Milwaukee, Wi, v. 33, n. 4, p. 421- 423, oct.2001.

HILSDORF, W.C. A Estratégia Seis Sigma para Melhoria da Qualidade: uma análise crítica das métricas utilizadas. **Revista Pesquisa e Tecnologia FEI**. São Paulo, n. 23, p. 35-39, outubro, 2002.

HOERL, Roger. Six Sigma Black Belts: what do they need to know? **Journal of Quality Technology**. Milwaukee, Wi, v. 33, n. 4, p.391- 406, oct. 2001.

HOLANDA, V. B.; RICCIO, E.D. A Utilização da Pesquisa Ação para Perceber e Implementar Sistemas de Informações Gerenciais. **Artigo Internet USP**, 2000. Disponível em: www.tecsi.fea.usp.br/riccio/tac/pdf/art-pesacao.pdf. Acesso em: janeiro 2002.

INGLE, S; ROE, W. Six Sigma Black Belt Implementation. **TQM Magazine**, York, Inglaterra, GB : Mcb University Press, v. 13, n. 4, p. 273 – 280, 2001.

JURAN, J. M. **Juran on Leadership for Quality**: an executive handbook. New York: The Free Press, 1989.

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

KNOWLTON, J; KEPPINGER, R. The Experimentation Process. **Quality Progress**. Milwaukee, WI.: ASQ, p. 43-47, feb.1993.

LAFRAIA, J. R. B. **Manual de Confiabilidade, Manutenibilidade e Disponibilidade**. Rio de Janeiro: Qualitymark, 2001.

LEWIS, S; MONTGOMERY, D.; MYERS, R.H. Examples of Designed Experiments With Non-normal Responses. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v. 33, n. 3, p. 265- 291, jul. 2001.

LIMA Jr., J.C de; SILVA, J.B. de A. Métodos de Regressão para Determinar a Planeza de Superfícies Metrológicas. **Máquinas e Metais**. São Paulo: Aranda, n. 460, p.140-157, maio, 2004.

LUFTIG, J.T.; JORDAN, V.S. **Design of Experiments in Quality Engineering**. New York: McGraw-Hill, 1998.

MONTGOMERY, D.C. **Design and Analysis of Experiments**. 5.ed. New York: John Wiley & Sons, 2001.

MONTGOMERY, D.C. *et al.* Discussion on HOERL, Roger. Six Sigma Black Belts: what do they need to know? **Journal of Quality Technology**. Milwaukee, Wi, v. 33, n. 4, p.407- 409, oct. 2001.

PANDE, P.S.; NEUMAN, R.P.; CAVANAGH, R.R. **Estratégia Seis Sigma**. Rio de Janeiro: Qualitymark, , 2000.

PYZDEK, T. Discussion on HOERL, Roger. Six Sigma Black Belts: what do they need to know? **Journal of Quality Technology**. Milwaukee, Wi, v. 33, n. 4, p. 418-420, oct.2001.

RAMOS, C.A.D.*et al.* Usinabilidade de Aço Inoxidável Martensítico no Fresamento de Topo. **Máquinas e Metais**. São Paulo: Aranda, n. 462, p.76-92, julho, 2004.

REID, R. A.; KOLJONEN, E. L; BUELL, J. B. The Deming Cycle Provides a Framework for Managing Environmentally Responsible Process Improvements. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker,v.12, n.2, p.199-209,1999-2000.

- SANDERS, D; HILD, C.R. Common Myths About Six Sigma. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.13, n. 2, p. 269-276, 2000-01.
- SIELOFF, R. Creating Process Topographic Maps to Improve Quality and Reduce Scrap. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.14, n. 3, p. 331-333, 2001-2002.
- SIQUEIRA CAMPOS, M. Seis Sigma – Presente e Futuro. **Artigo internet**. POA, 2003. Disponível em: http://www.siqueiracampos.com/art_jan_03.htm. Acesso em: julho 2003.
- SNEE, R. D. Discussion on HOERL, Roger. Six Sigma Black Belts: what do they need to know? **Journal of Quality Technology**. Milwaukee, Wi, v. 33, n. 4, p.414- 417, oct. 2001.
- TEN CATEN, C.; RIBEIRO, J. L. D. **Material de Suporte, Projeto de Experimentos**. (Mestrado Profissional), Engenharia de Produção, PPGEP, UFRGS, 2000.
- THIOLLENT, Michel. **Metodologia da Pesquisa-Ação**. São Paulo Cortez, 2002.
- WERKEMA, Cristina. **Criando a Cultura Seis Sigma**. Rio de Janeiro: Qualitymark, 2001.
- WERKEMA, M. C. C. **Seis Sigma**: treinamento para *Black Belt*. Belo Horizonte: Fundação de Desenvolvimento Gerencial, 2000. Sessões 1,2,3 e 4.
- WERKEMA, M.C.; AGUIAR, S. **Planejamento e Análise de Experimentos**: como identificar as principais variáveis influentes no processo. Belo Horizonte: Universidade Federal de Minas Gerais, Fundação Cristiano Ottoni, 1996.
- WERKEMA, M.C. **Como Estabelecer Conclusões com Confiança**: entendendo inferência estatística. Belo Horizonte: Universidade Federal de Minas Gerais, Fundação Cristiano Ottoni, 1996.
- WISNOWSKI, J. W.; RUNGER, G. C.; MONTGOMERY, D. C. Analyzing Data from Designed Experiments: a Regression Tree Approach. **Quality Engineering**. Monticello, N.Y.: Marcel Dekker, v.12, n.2, p. 185-197, 1999-2000.

APÊNDICE A - Ferramentas da qualidade utilizadas no programa Seis Sigma

Algumas considerações gerais sobre ferramentas utilizadas no programa Seis Sigma, seguem:

Diagrama de Afinidades: utiliza a similaridade entre dados não numéricos para facilitar o entendimento, de forma sistemática, da estrutura de um problema. Esta ferramenta é utilizada para mostrar a direção adequada a ser seguida em um processo de solução de problemas, organizar as informações disponíveis para a solução de um problema e organizar idéias provenientes de alguma avaliação (WERKEMA, 2000). É um método para converter um conceito vago em específico através do uso da linguagem e diagramas (JURAN, 1989).

Diagrama de Relações: apresenta estrutura das relações de causa e efeito de um conjunto de dados numéricos, permitindo a organização do conhecimento disponível sobre o problema analisado. É utilizado quando o problema é complexo, de modo que a visualização das relações de causa e efeito não é fácil e a seqüência correta das ações é crítica para o alcance dos objetivos (WERKEMA, 2000).

Diagrama de Árvore: empregado na definição qualitativa das causas de um problema e na elucidação da essência (ponto principal) de uma área a ser melhorada (WERKEMA, 2000). É utilizado no formato de árvore de falhas. É iniciado com um resultado final a ser obtido ou evitado, onde se identificam os fatores que contribuem para o resultado. O diagrama pode se estender a múltiplos níveis de análise (JURAN, 1989).

Diagrama de Matriz: consiste no arranjo dos elementos que constituem um evento ou problema de interesse nas linhas e colunas de uma matriz, de forma que a existência ou as forças das relações entre os elementos é mostrada por meios de símbolos nas intersecções das linhas e colunas. É utilizado na visualização de um problema como um todo, deixando claras as áreas nas quais o problema está concentrado. Esta ferramenta permite a exploração de um problema sob mais de um ponto de vista e a construção de uma base multidimensional para sua solução, a distribuição de tarefas entre as diversas equipes de trabalho disponíveis e a identificação de gargalos e pontos críticos (WERKEMA, 2000).

ANEXO A - Conversão de processos para escala seis sigma

Harry e Schroeder (2000) apresentam um exemplo de classificação de processos na escala sigma, conforme Tabela 40 e Tabela 41:

Tabela 40 - Capacidade sigma dos processos.

Aproximação da capacidade sigma dos processos			
Passo	Ação	Equações	Cálculos
1	Processo a considerar	-----	Cobrança
2	Unidades colocadas no processo	-----	1.283
3	Unidades OK no processo	-----	1.138
4	Rendimento do processo (Yield)	= (passo 3) / (passo 2)	0,8870
5	Taxa de defeito	= 1 – passo 4	0,113
6	Número de características possíveis de criar defeito	CTQ's – características críticas para a qualidade	24
7	Taxa de defeitos por CTQ's	= (passo 5 / (passo 6))	0,0047
8	Defeitos por milhão de oportunidades (DPMO)	= (passo 7) x 1.000.000	4.709
9	Conversão de DPMO em valor Sigma utilizando Tabela Anexo A2	-----	4,1

Tabela 41 - Tabela de Conversão Sigma

Tabela de Conversão Sigma									
Valor de Sigma	Defeitos por milhão de oportunidades	Valor de Sigma	Defeitos por milhão de oportunidades	Valor de Sigma	Defeitos por milhão de oportunidades	Valor de Sigma	Defeitos por milhão de oportunidades	Valor de Sigma	Defeitos por milhão de oportunidades
0.00	933,193	1.20	382,088	2.40	184,060	3.60	17,865	4.80	483
0.05	926,471	1.25	401,294	2.45	171,056	3.65	15,778	4.85	404
0.10	919,243	1.30	420,740	2.50	158,655	3.70	13,904	4.90	337
0.15	911,492	1.35	440,382	2.55	146,859	3.75	12,225	4.95	280
0.25	903,199	1.40	460,172	2.60	135,666	3.80	10,724	5.00	233
0.20	894,350	1.45	480,061	2.65	125,072	3.85	9,378	5.05	193
0.30	884,930	1.50	500,000	2.70	115,070	3.90	8,198	5.10	159
0.35	874,928	1.55	480,061	2.75	105,650	3.95	7,143	5.15	131
0.40	864,334	1.60	460,172	2.80	96,800	4.00	6,210	5.20	108
0.45	853,141	1.65	440,382	2.85	88,508	4.05	5,386	5.25	89
0.50	841,345	1.70	420,740	2.90	80,757	4.10	4,661	5.30	72
0.55	828,944	1.75	401,294	2.95	73,529	4.15	4,024	5.35	59
0.60	815,940	1.80	328,088	3.00	66,807	4.20	3,467	5.40	48
0.65	802,338	1.85	363,169	3.05	60,571	4.25	2,980	5.45	39
0.70	788,145	1.90	344,578	3.10	54,799	4.30	2,555	5.50	32
0.75	773,373	1.95	326,355	3.15	49,471	4.35	2,186	5.55	26
0.80	758,036	2.00	308,537	3.20	44,565	4.40	1,866	5.60	21
0.85	742,154	2.05	291,160	3.25	40,059	4.45	1,589	5.65	17
0.90	274,253	2.10	274,253	3.30	35,930	4.50	1,350	5.70	13
0.95	291,160	2.15	257,846	3.35	32,157	4.55	1,144	5.75	11
1.00	308,537	2.20	241,964	3.40	28,717	4.60	968	5.80	9
1.05	326,355	2.25	226,627	3.45	25,588	4.65	816	5.85	7
1.10	344,578	2.30	211,856	3.50	22,750	4.70	687	5.90	5
1.15	363,169	2.35	197,663	3.55	20,182	4.75	577	5.95	4
								6.00	3

Nota: Esta tabela inclui deslocamento de 1,5 sigma para todos os valores de z