

**Universidade Estadual de Campinas
Instituto de Matemática, Estatística e
Computação Científica**

**ESTUDO COMPARATIVO DE TÉCNICAS PARA IDENTIFICAR
FATORES DE RUÍDO EM EXPERIMENTOS FATORIAIS**

Leonardo Silva de Andrade

Orientador: Prof. Dr. Ademir José Petenate

CAMPINAS

2003


**UNICAMP
BIBLIOTECA CENTRAL
SEÇÃO CIRCULANTE**

200326156

**ESTUDO COMPARATIVO DE TÉCNICAS PARA IDENTIFICAR FATORES DE
RÚIDO EM EXPERIMENTOS FATORIAIS**

Este exemplar corresponde à redação final da dissertação devidamente corrigida e defendida por Leonardo Silva de Andrade e aprovada pela comissão julgadora.

Campinas, 28 de março de 2003



Prof. Dr. Ademir José Petenate

Banca Examinadora

1. Prof. Dr. Ademir José Petenate
2. Prof. Dr. Reinaldo Charnet
3. Prof. Dr. Valdério Anselmo Reisen

Dissertação apresentada ao Instituto de Matemática, Estatística e Computação Científica, UNICAMP, como requisito parcial para a obtenção do Título de MESTRE em ESTATÍSTICA

UNIDADE	BE
Nº CHAMADA	UNICAMP
	An24e
V	
ISSUE	54917
REV	16-124103
PREÇO	R\$ 11,00
DATA	02/08/03
Nº CPD	

CM00187026-0

BIB ID 295523

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA DO IMECC DA UNICAMP

Andrade, Leonardo Silva de


An24e Estudo comparativo de técnicas para identificar fatores de ruído em experimentos fatoriais / Leonardo Silva de Andrade -- Campinas, [S.P. :s.n.], 2003.

Orientador : Ademir José Petenate


Dissertação (mestrado) - Universidade Estadual de Campinas, Instituto de Matemática, Estatística e Computação Científica.

1. Taguchi, Método de (Controle de qualidade). 2. Relação de sinal para ruído. 3. Planejamento experimental. I. Petenate, Ademir José. II. Universidade Estadual de Campinas. Instituto de Matemática, Estatística e Computação Científica. III. Título.


**Dissertação de Mestrado defendida em 28 de março de 2003 e aprovada pela Banca
Examinadora composta pelos Profs. Drs.**



Prof (a). Dr (a). ADEMIR JOSÉ PETENATE



Prof (a). Dr (a). REINALDO CHARNET



Prof (a). Dr (a). VALDÉRIO ANSELMO REISEN

Aos meus pais

MEUS AGRADECIMENTOS

À minha mãe, pelo seu amor incondicional, incentivo perene e formação do meu caráter, sem os quais não seria possível a finalização deste trabalho.

Ao meu pai, pelas lições extraídas da sua própria vida, de determinação e vontade de superação.

À Márcia, pelo enorme carinho, apoio e, sobretudo, paciência com que me ajudou a superar os momentos mais críticos desta jornada.

Ao meu orientador, Prof. Dr. Ademir Petenate, pela sempre cordial disponibilidade em recomençar e, principalmente, por não ter deixado que eu abandonasse este caminho.

Aos colegas de mestrado Celeste, Maristela, Marcelo, Silvestre e Sirlei, que através de suas dificuldades me deram mais força para concluir este trabalho; e à Dani, pela valiosa ajuda na preparação para os exames de qualificação.

À CAPES, pelo suporte financeiro.

RESUMO

A melhoria da qualidade na indústria tem merecido cada vez mais atenção da comunidade científica pelo diferencial competitivo que pode proporcionar. Um dos pioneiros nesta área, o engenheiro japonês Genichi Taguchi, apresentou no início da década de 1960 uma metodologia baseada em uma idéia inovadora: a de que se obtém melhoria de qualidade através da redução de variabilidade. Através de experimentos realizados fora da linha de produção, essa metodologia visa identificar fatores que possam ser ajustados adequadamente, de forma a reduzir a variabilidade do processo industrial. Um elemento importante desta metodologia é a estatística, também chamada de medida de *performance*, utilizada na análise desses experimentos. Abordando tanto aspectos teóricos como aplicados, esse texto faz um estudo comparativo entre a medida de *performance* proposta por Taguchi (chamada razão sinal-ruído) e algumas alternativas propostas na literatura. Palavras-chave: Métodos de Taguchi, Razão Sinal-Ruído, Qualidade Industrial, Fator de Ruído, Experimentos Fatoriais

ABSTRACT

Quality improvement in industry deserves an increasing attention from the scientific community for the competitive differential it may bring. One of the pioneers in this area, the Japanese engineer Genichi Taguchi, presented in the beginning of the 1960's a novel methodology, based in the fact that variability reduction results in quality improvement. Through off-line experiments, this methodology seeks to find process factors that can be readjusted in order to reduce variability. A key component of this methodology is the statistic, also known as performance measure, to be used in the experiment analysis. Focusing both theoretical and applied aspects, this text makes a comparative study between the performance measure proposed by Taguchi (called signal-to-noise ratio) and some alternatives proposed in the literature.

Keywords: Parameter Design, Taguchi Methods, Signal-To-Noise Ratio, Industrial Quality

SUMÁRIO

	Introdução.....	1
1	Métodos de Taguchi.....	3
1.1	Histórico.....	3
1.2	Definição.....	5
1.3	Característica de Qualidade.....	6
1.4	Estrutura de Fatores.....	8
1.5	Plano Experimental.....	9
1.6	Função Perda.....	11
1.7	Razão Sinal-Ruído (SN).....	14
1.8	Otimização do Processo em 2 Estágios.....	15
2	Análise de Efeitos de Dispersão.....	17
2.1	Análise de Efeitos de Dispersão em Experimentos Sem Replicações.....	17
2.1.1	Identificação dos Efeitos de Dispersão Ativos...	19
2.2	Análise de Efeitos de Dispersão em Experimentos Com Replicações.....	20
2.2.1	Estudo e Extensão de SN.....	21
2.2.2	Proposta de Montgomery.....	26
2.2.3	O Uso de Transformações.....	27
2.2.4	A Prática de Pooling na ANOVA.....	29
2.2.5	Avaliação das Mudanças Efetuadas no Processo....	30
3	Análise de Experimentos Simulados	35
3.1	Descrição dos Experimentos Com e Sem Replicações.....	38
3.2	Análise do Experimento Com 3 Replicações.....	40
3.3	Análise do Experimento Sem Replicações.....	56

4	Estudo de Capacidade - Estudo Comparativo dos Experimentos.....	64
4.1	Característica de Qualidade Comprimento.....	65
4.2	Característica de Qualidade Rugosidade.....	73
5	Conclusões.....	81
	Bibliografia.....	84

Introdução

A percepção de que a redução da variabilidade em processos industriais é ponto chave para a melhoria da qualidade deve-se a Genichi Taguchi, engenheiro japonês, um dos grandes responsáveis pelo renascimento da indústria do Japão após a 2ª Guerra Mundial. A fim de obter redução de variabilidade, Taguchi propôs uma metodologia de fácil compreensão e aplicação por parte dos engenheiros de processo industriais.

O principal objetivo deste trabalho é traçar um estudo comparativo entre a metodologia de Taguchi e algumas das críticas feitas a ela, tanto do ponto de vista teórico quanto do prático, no que se refere à estatística utilizada para medir a variabilidade na análise dos experimentos. Em grande parte, os autores destas críticas foram estatísticos que, ao se debruçarem sobre o assunto, identificaram oportunidades para refinamento da metodologia de Taguchi.

O trabalho é constituído de três blocos principais: (i) o estudo da validade das medidas propostas por Taguchi (razão sinal-ruído: SN), apontando as situações em que são apropriadas; (ii) apresentação das diversas propostas sugeridas a partir da década de 1980 para contornar os problemas existentes e não resolvidos pelo uso de SN; (iii) comparar SN com essas novas propostas através da análise de conjuntos de dados gerados via simulações.

O público alvo, para o qual esta tese foi escrita, são as indústrias e seus engenheiros, interessados em reduzir a variabilidade de seus processos, utilizando planejamento de experimentos.

A estrutura desta dissertação é a seguinte: os Métodos de Taguchi são apresentados no capítulo 1; o capítulo 2 é dedicado à análise de efeitos de dispersão; as simulações e as análises associadas encontram-se no capítulo 3; o estudo de capacidade comparativo entre as diversas alternativas propostas será feito no capítulo 4; e, no capítulo 5, estão apresentadas as conclusões.

Capítulo 1

Métodos de Taguchi

1.1 Histórico

Nas décadas que sucederam a 2ª Guerra Mundial, a indústria japonesa estava destruída e sem condições de competir com uma indústria americana forte e saudável, vinda de um grande desenvolvimento ocorrido durante a guerra. O Japão tinha que lidar com problemas sérios, como falta de matéria-prima de qualidade e maquinário obsoleto. Nesse ambiente, a indústria japonesa encontrou um conjunto de técnicas desenvolvidas nos EUA durante a guerra, chamadas de Controle Estatístico de Processos. A utilização dessas técnicas não só impulsionou as indústrias, tornando-as competitivas, como também iniciou a formação e o desenvolvimento de profissionais altamente qualificados e voltados à melhoria de processos. Em seguida, novas metodologias foram criadas - em grande parte baseadas em técnicas estatísticas - com o objetivo de fabricar produtos competitivos e de alta qualidade, ainda que baratos. A chave para obtenção de produtos com tais características é a redução e o controle da variabilidade do processo associado.

Um importante personagem nesse processo de transformação da indústria japonesa em uma indústria competitiva e de alta qualidade é Genichi Taguchi (1987, introdução). Na busca pela redução de variabilidade, Taguchi foi quem primeiro despertou para o fato de que se deve procurar o ajuste dos fatores de que se tem controle para que o processo se torne robusto às variações impostas por fatores não controláveis (ou seja, fontes de

variação não controláveis, que na maioria das vezes nem são identificáveis), em contraposição à abordagem em voga na época, de tentar "domar" os fatores não controláveis. Observe-se que obter um processo robusto sob o aspecto descrito acima significa dizer que a variabilidade será reduzida (ou, idealmente, minimizada), pois o processo estará "imune" aos efeitos dos fatores não controláveis, que provocam o aumento de variabilidade.

Para dar conta deste problema utilização de experimentação é natural, com o objetivo de que sejam determinadas as condições ótimas para a operação do processo, pois diversas condições devem ser testadas, a fim de se estudarem os efeitos dos diversos fatores nele envolvidos. Daí a utilização da técnica estatística conhecida como Planejamento de Experimentos para estudar a relação entre os fatores envolvidos no processo de fabricação e sua variabilidade.

Os Métodos de Taguchi, que serão definidos na próxima seção, possuem forte caráter prático, podendo facilmente ser absorvidos pelos engenheiros responsáveis por implementar mudanças que resultam em melhorias da qualidade. Diversas empresas de grande porte se beneficiaram do uso de sua metodologia no Japão e nos Estados Unidos.

À medida que os chamados Métodos de Taguchi se popularizaram, também despertaram a atenção da comunidade estatística, que passou a estudá-los em profundidade a partir de meados da década de 1980 (o painel de discussão editado por Nair (1992), em uma das publicações mais conceituadas do mundo acadêmico nesta área, mostra a importância que o assunto ganhou). Esse foi o ponto de partida para que esses métodos começassem a ser mais bem

compreendidos e também melhorados - por que não também eles? Entre os diversos elementos dos Métodos de Taguchi discutidos e criticados pela comunidade científica, um tem merecido atenção especial e sido alvo de grande debate nos últimos anos: a razão sinal-ruído (SN, *signal-to-noise ratio*), que nada mais é do que a estatística utilizada para medir a variabilidade do processo, também chamada de *medida de performance*, utilizada na identificação dos efeitos de dispersão. Esta estatística, em particular, será o alvo de nossos estudos, ainda que os principais elementos da metodologia de Taguchi sejam apresentados no próximo capítulo.

É, ainda, muito importante observar que ao longo dessas duas décadas o princípio básico proposto por Taguchi (1987) permaneceu intacto: o de que se deve criar um processo robusto à variabilidade através do ajuste apropriado dos fatores controláveis.

1.2 Definição

Os Métodos de Taguchi, como definidos por Taguchi (1987) e discutidos em Nair (1992), serão entendidos nesse texto como sendo um conjunto de ações que têm por objetivo a redução de variabilidade da característica de qualidade de interesse (seção 1.3). E que esse conjunto de ações é compreendido por: seleção de fatores controláveis e não-controláveis para fazer parte de um experimento (seção 1.4), escolha do plano experimental, a partir de arranjos ortogonais (seção 1.5), análise do experimento, utilizando como variável resposta a razão sinal-ruído (seção 1.7) e utilização do procedimento de otimização em dois estágios (seção 1.8) a fim de obter a configuração dos fatores que permita a minimização da função perda (seção 1.6) e, conseqüentemente, a

minimização de variabilidade. Nesse texto, quando a visão de Taguchi for exposta, o conjunto de referências (compostos dessa dissertação e dos textos indicados no início do parágrafo) contém o assunto abordado, excetuando-se os casos em que uma referência é explicitada.

Em outras palavras, a metodologia de Taguchi consiste em tomar algumas variáveis do processo, no jargão estatístico chamadas fatores, e realizar um experimento com o processo de fabricação, para que a partir dele sejam determinados novos níveis de operação dos fatores controláveis envolvidos, em que a variabilidade do processo seja menor. Nesse sentido, dizemos que o processo foi *otimizado*. Na obtenção de um processo ótimo, precisamos, em primeiro lugar, detectar quais são os fatores influentes na dispersão do processo e, em seguida, ajustar esses fatores nos níveis em que produzam menor dispersão. O experimento permite, também, definir quais são os fatores influentes no nível do processo, de forma a ajustá-los de uma maneira tal, que sua *performance* seja a melhor possível frente as especificações do processo.

Serão apresentados a seguir os principais elementos envolvidos na implementação do Método de Taguchi e suas definições, de forma a permitir um melhor entendimento de nosso ponto central de estudo, a razão sinal-ruído.

1.3 Característica de Qualidade

Define-se como característica de qualidade a característica de um produto pela qual é possível determinar se um produto atende ou não às especificações do cliente. Tanto no experimento quanto na

elaboração das cartas de controle, essa será a característica do produto medida. Um mesmo produto pode apresentar diversas características de qualidade. No capítulo 3, onde apresentamos a simulação de operação de uma fábrica de tijolos de metal, há interesse em que o comprimento do tijolo e sua rugosidade sejam controlados e melhorados simultaneamente, pois o comprador dos tijolos avalia os fornecedores disponíveis no mercado segundo essas 2 características.

As características de qualidade podem ser estáticas ou dinâmicas. Características de qualidade estáticas são aquelas cujo valor alvo é fixo. Exemplos de características de qualidade desse tipo são: diâmetro do eixo de um certo tipo de caminhão, viscosidade de um lubrificante, etc. As características de qualidade dinâmicas são mais complexas e resultam em diferentes valores, dependendo do valor de entrada. Um exemplo típico é a temperatura de um ambiente controlada através de um aparelho de ar condicionado. Regula-se o termostato no valor desejado, e espera-se que a temperatura do ambiente atinja este valor. Um aparelho de ar condicionado é tão melhor quanto mais próximas forem as temperaturas ajustadas das temperaturas reais, independente dos níveis desejados. Em outras palavras, o aparelho deve responder aos estímulos de entrada de forma precisa, atingindo, para cada valor de entrada, um diferente valor de saída. A otimização de características de qualidade do tipo dinâmico não será estudada nesse texto por se tratar de problema explorado na literatura apenas por Taguchi (1987), o que inviabiliza um estudo comparativo.

Quanto ao objetivo de otimização, as características de qualidade estáticas podem se apresentar de três formas:

- *Nominal-the-best* (no alvo é o melhor): a especificação, neste caso, exige que se atinja um determinado valor alvo. Por exemplo, a cremosidade de um sorvete ou a largura das ranhuras de um pneu.
- *Smaller-the-better* (quanto menor, melhor): o alvo, neste caso, não é fixo. É apenas desejável que a característica apresente o menor valor possível, idealmente nulo. Exemplos são: tempo decorrido até que saia a primeira cópia de uma máquina copiadora, defeitos na imagem de uma televisão e corrosão de metais.
- *Larger-the-better* (quanto maior, melhor): esse caso é o inverso do anterior. Alguns exemplos são: capacidade de tração de um pneu, rendimento de uma reação química ou resistência corrosiva da pintura de um carro.

1.4 Estrutura dos Fatores

Existem duas categorias de fatores associados a um processo industrial: controláveis e não-controláveis. Os Métodos de Taguchi dedicam-se ao estudo dos fatores controláveis, pois esses são os que efetivamente serão manipulados durante o processo de fabricação. Quanto aos não-controláveis, eles podem, quando possível, ser controlados durante o experimento para avaliação de seu impacto no processo. Um exemplo de fator não-controlável pode ser a temperatura do ambiente de uma linha de produção, que eventualmente permite controle no ambiente experimental, mas que, normalmente apresenta custos elevadíssimos para seu controle no ambiente de produção.

Os fatores controláveis podem ser subdivididos em:

- **Fatores de Ruído:** esses fatores, quando variados, induzem no processo alteração na sua dispersão. Isso significa que, quando identificados, procuraremos ajustá-los nos níveis em que produzem a menor dispersão do processo. Eventualmente esses fatores podem atuar também sobre a locação do processo. Em caso de conflito na determinação do nível ótimo, a definição do nível a ser ajustado depende do tipo de característica de qualidade. Por exemplo, no caso de *nominal-the-best*, o nível do fator será aquele em que minimiza a dispersão - neste caso, o ajuste da locação deverá ser feito por outro(s) fator(es) de locação. Já no caso de *smaller-the-better* e *larger-the-better* deve-se priorizar o ajuste pelo seu efeito na locação do processo.
- **Fatores de Sinal:** têm influência somente sobre a locação da característica de qualidade medida.
- **Fatores de custo :** não influenciam a dispersão nem a locação em que o processo opera. Portanto, podem ser ajustados nos níveis em que sejam mais baratos, reduzindo assim os custos de fabricação do produto.

1.5 Plano Experimental

O plano experimental proposto por Taguchi é, na prática, uma composição de dois planos experimentais distintos, descritos a seguir: o primeiro plano experimental contém apenas os fatores controláveis do experimento e é chamado *arranjo interno*. O segundo plano contém apenas fatores não-controláveis e é chamado *arranjo externo*.

A escolha de planos fatoriais é natural, pois há uma típica estrutura de fatores. No entanto, freqüentemente o engenheiro

está interessado em estudar um grande número de fatores, cujo número de combinações entre eles pode chegar à casa dos milhares. Por isso é muito comum a utilização de planos fatoriais fracionados nas aplicações industriais de que tratamos aqui. Para referência sobre planos fatoriais e planos fatoriais fracionados, veja Box, Hunter e Hunter (1987, capítulo 12).

Para dar forma aos arranjo interno e externo, Taguchi utiliza os arranjos ortogonais (para referência veja Montgomery (1991)), que formam uma categoria de planos fatoriais e fatoriais fracionados. O plano experimental completo é uma união entre os arranjos externo e interno, em que cada subexperimento do arranjo interno é executado com todas as combinações do arranjo externo. Os arranjos ortogonais são usualmente denotados por L_i , em que i corresponde ao número de corridas experimentais (ou subexperimentos). Para um experimento do tipo L_i é possível estimar até $(i-1)$ efeitos principais sem confundimento com outros efeitos principais.

Abaixo segue um exemplo de plano experimental, em que o arranjo interno é um plano do tipo L_8 , e neste caso contém os fatores de A a G; o arranjo externo é um plano do tipo L_4 , e contém os fatores de H a J. Note-se que os dois arranjos ortogonais são planos fatoriais fracionados saturados (Box, Hunter e Hunter (1987), pág. 398).

Tabela 1.1. Exemplo de combinação entre os arranjos interno e externo utilizados por Taguchi (dados hipotéticos)

Arranjo Interno (L_8)							Arranjo Externo (L_4)			
							(H, I, J)			
A	B	C	D	E	F	G	(-, -, -)	(-, +, +)	(+, -, +)	(+, +, -)
-	-	-	-	-	-	-	1.2	<u>1.5</u>	1.9	1.4
-	-	-	+	+	+	+	2.3	1.8	1.6	1.5
-	+	+	-	-	+	+	1.9	2.1	1.4	1.7
-	+	+	+	+	-	-	1.3	2.3	1.5	1.9
+	-	+	-	+	-	+	2.1	1.7	1.4	1.8
+	-	+	+	-	+	-	2.1	1.4	1.7	2.3
+	+	-	-	+	+	-	1.9	2.1	1.4	1.7
+	+	-	+	-	-	+	1.8	1.6	1.5	1.4

Fonte: Dados fictícios

Em cada linha da tabela acima foram realizadas quatro corridas experimentais, mas estas não são replicações das combinações dos fatores de A a G, pois são resultado de quatro diferentes combinações dos fatores de H a J. Ou seja, o valor 1.5, sublinhado na tabela, tem diferente combinação dos fatores de H a J do que o valor 1.2, imediatamente à sua esquerda.

Os arranjos ortogonais possuem algumas características interessantes, expostas abaixo:

- i. No caso de experimentos fatoriais fracionados saturados, os arranjos ortogonais são planos de efeitos principais, ou seja, estimam-se os efeitos principais sem confundimento com outros efeitos principais.

- ii. Nenhum fator é beneficiado, pois em cada par de colunas todas as combinações de fatores ocorrem; e elas ocorrem o mesmo número de vezes.
- iii. As somas de quadrados correspondentes a cada fator são independentes sob as hipóteses usuais da análise de variância (normalidade e homocedasticidade).
- iv. As estimativas dos efeitos principais podem ser utilizadas para realizar previsões da resposta para qualquer combinação de níveis dos fatores. Um fato importante é que a variância do erro de previsão é a mesma para qualquer combinação do plano fatorial completo.

Para maior discussão da eficiência desses planos e propostas alternativas para melhor escolha do plano experimental, consulte Montgomery (1991, pág. 538).

1.6 Função Perda

Para Taguchi, o conceito de qualidade está associado, quantitativamente, à perda imposta à sociedade causada pelo produto ou serviço, cuja *performance* é abaixo das expectativas. Em outras palavras, são as perdas sofridas pela sociedade (cliente, fabricante ou outro), quando um produto não atinge o desempenho esperado (por exemplo, quando um produto é enviado para reparo no período da garantia ou o incômodo sentido pelo cliente ao, freqüentemente, levar seu carro novo ao conserto).

Assim, podemos definir a função perda como sendo a medição da perda associada à ausência de qualidade (ou desempenho fora do valor alvo) para cada um dos valores possíveis da característica de qualidade.

Para quantificar a função perda, Taguchi utiliza uma aproximação por série de Taylor de segunda-ordem em torno do valor alvo t . Logo, a expressão da função perda tem a seguinte forma:

$$L(y) \cong L(t) + \frac{L'(t)(y - t)}{1!} + \frac{L''(t)(y - t)^2}{2!}, \quad (1.1)$$

onde L é a função perda e y é a medida da característica de qualidade.

No entanto, $L(t)=0$, pois quando a *performance* atinge o valor alvo, a perda é nula, pela própria definição de função perda. E, também, $L'(t)=0$, por ser mínimo local, também pela definição da função perda.

Então temos:

$$L(y) \cong \frac{L''(t)(y - t)^2}{2!} = k_1(y - t)^2, \quad (1.2)$$

onde $k_1 = \frac{L''(t)}{2!}$ é uma constante econômica, que varia conforme o processo e as características do produto, também chamada de coeficiente de perda de qualidade.

Segundo Taguchi, há vantagens na especificação de um critério para definir a perda associada à falta de qualidade, pois faz com que o problema de reduzir a variabilidade fique mais objetivo, além de promover uma base de comparação para a variação de diferentes características de qualidade.

De todo modo, a quantificação dessa perda é difícil, porque um mesmo produto pode ser usado por pessoas diferentes, em diferentes aplicações, em ambientes completamente distintos.

Conceitualmente, a minimização da função perda (equação 1.2) associada ao processo é o objetivo do método proposto por Taguchi. No entanto, na prática, a função perda não é utilizada, e sim alguma medida que represente a variabilidade do processo, como veremos no próximo capítulo. Na seção 2.2.1, analisaremos os casos em que há relação entre a função perda e a estatística que mede a variabilidade, propostas por Taguchi. No entanto, devido à complexidade em se determinar a função perda (lembre-se que a equação 1.2 é apenas uma aproximação e podem existir outras formas possíveis, conforme as características do processo de interesse) e seu apelo pouco prático, sua utilização fica restrita e sujeita a diversas críticas.

De toda forma, é importante observar que a introdução do conceito e a importância dada à *proximidade do alvo* é originada da idéia de minimização da função perda; e que esta foi uma importante evolução do conceito, já obsoleto, de que basta que o produto esteja dentro das especificações para que ele tenha boa qualidade.

1.7 Razão Sinal-Ruído (SN)

O conceito de razão sinal-ruído tem sua origem na engenharia elétrica, especificamente, na área de comunicações. Na transmissão de dados e, em particular, no módulo receptor, é importante fazer a melhor distinção possível entre a mensagem transmitida (sinal) e a variação aleatória própria do sistema (ruído), que faz com que o sinal seja erroneamente interpretado pelo módulo receptor. A quantidade SN é definida como a razão entre a potência média do sinal e a potência média do ruído. Assim, o sistema é tão melhor quanto maior for sua razão sinal-ruído, pois de forma mais clara é possível separar a mensagem do ruído.

Taguchi adaptou esse conceito e o introduziu em sua metodologia, a fim de atingir seu objetivo de determinar quais são os fatores de ruído e seus níveis ótimos, maximizando SN. A razão sinal-ruído é calculada para cada linha do arranjo ortogonal. Existem diversas fórmulas propostas para a razão sinal-ruído (veja Taguchi (1987), capítulos 22 a 25), e a escolha de uma delas depende do objetivo do experimento no que se refere à característica de qualidade.

Para sistemas estáticos, temos, para cada tipo de característica de qualidade, as seguintes formas mais comuns para SN (Taguchi (1988), pág. 10, 11):

$$\text{Nominal-the-Best: } SN_T = 10 \log \left(\frac{\bar{Y}^2}{S^2} \right), \quad (1.3)$$

$$\text{Smaller-the-Better: } SN_s = -10 \log \left(\frac{\sum y^2}{n} \right) \quad (1.4)$$

$$\text{Larger-the-Better: } SN_L = -10 \log \left(\sum (1/y^2) / n \right) \quad (1.5)$$

Nas equações acima $\bar{y}$ é a média aritmética das observações em uma combinação dos fatores do plano experimental, s é o desvio-padrão dessas mesmas observações e n é o número de subexperimentos disponíveis.

1.8 Otimização do Processo em Dois Estágios

A otimização do processo, conforme proposta por Taguchi, tem a interessante característica de ser facilmente assimilada pelos engenheiros do processo, pois contém forte apelo intuitivo e simples aplicação. A otimização do processo se dá em dois estágios e está descrita abaixo:

Procedimento 1.1

1. Determinar os fatores cujos efeitos são estatisticamente significantes sobre a razão sinal-ruído através do uso da Análise de Variância de SN. Esses fatores são os de ruído ativos e devem, portanto, ser ajustados nos níveis onde SN é máximo.
2. Dentre todos os fatores que possuem efeitos significantes sobre a média, escolher aquele cujo efeito sobre SN seja o menor. Esse fator será determinado como o de sinal, e que idealmente não deve ter efeito sobre SN. Ele, portanto, será responsável pelo ajuste da média ao valor apropriado, dependendo da característica de qualidade envolvida. Os

fatores restantes são os fatores de custo, podendo ser ajustados nos níveis em que são mais baratos.

Como dito anteriormente, Taguchi não minimiza a função perda quadrática, mas, sim, maximiza SN. Veremos mais adiante em que circunstâncias a maximização de SN leva à minimização da função perda quadrática.

Capítulo 2

Análise de Efeitos de Dispersão

2.1 Análise de Efeitos de Dispersão em Experimentos Sem Replicações

A metodologia proposta por Taguchi permite que, para cada combinação do arranjo interno, seja calculada a razão sinal-ruído ou outra medida de variabilidade. No entanto, como discutido por Montgomery (1991), a combinação dos arranjo interno e externo demanda um número elevado de sub-experimentos, nem sempre à disposição do engenheiro ou pesquisador responsável pelo experimento que, principalmente nos estágios iniciais de experimentação, tem interesse em incluir um grande número de fatores no plano experimental.

Assim, surge a necessidade de se realizar experimentos sem replicações. É importante que se observe que com a utilização da expressão "sem replicações", queremos dizer que neste experimento não é possível calcular a razão sinal-ruído ou outra medida de variabilidade para cada linha do plano experimental. Esperamos, neste ponto, eliminar qualquer tipo de confusão que possa advir do fato do plano experimental de Taguchi também não possuir replicações genuínas.

Box e Meyer (1986) apresentam uma metodologia de identificação dos efeitos de dispersão em duas etapas. Na primeira etapa, os efeitos de locação são identificados e os resíduos deste ajuste são calculados. Na segunda etapa, analisam-se os resíduos com o objetivo de identificar os efeitos de dispersão. Como se vê, a

identificação dos efeitos de dispersão está diretamente ligada à identificação dos efeitos de locação. Por isso, corre-se o risco de se obter uma análise de efeitos de dispersão viesada em decorrência da má identificação dos efeitos de locação (para uma discussão mais profunda veja Brenneman e Nair (2001)).

Apresentaremos a seguir a metodologia de Box e Meyer (1986), baseada no princípio de Pareto, segundo o qual a *maior parte dos efeitos é devida a uma pequena parcela de fatores*. O princípio pode ser utilizado tanto na identificação de efeitos de locação como de dispersão. A análise do experimento é iniciada com a remoção dos efeitos de locação através de ajuste de regressão pelo método de mínimos quadrados. Em seguida, sobre os resíduos desta regressão, faz-se uso de técnicas exploratórias apenas, para a identificação dos efeitos de dispersão, pois não é possível a realização de testes de significância na ausência de estimativas para o erro-padrão dos efeitos. Box e Meyer (1986) propõem, então, a utilização de ferramentas gráficas, de onde são identificados os fatores cujos efeitos são significantes quanto à dispersão. Uma vez detectados esses fatores significantes, os demais são eliminados da análise, gerando assim pseudo-replicações para o experimento, de onde é possível calcular a ANOVA correspondente para tais fatores.

Para esta fase exploratória, Box e Meyer (1986a) sugerem a utilização do gráfico de Daniel (1959), também conhecido como gráfico de probabilidades normais, juntamente com o gráfico de probabilidades posteriores de Bayes para a identificação dos fatores cujos efeitos são significantes. Este texto fará uso apenas do gráfico de Daniel (1959), pois se trata da ferramenta mais amplamente aceita e de mais fácil utilização, sendo encontrada em qualquer *software* estatístico existente no mercado.

2.1.1. Identificação dos Efeitos de Dispersão Ativos

Os seguintes passos devem ser seguidos na identificação de efeitos de dispersão ativos em experimentos sem replicação:

1. Identificação dos fatores de locação ativos através dos métodos usuais (ver Montgomery(1991))
2. Ajustar, pelo método de mínimos quadrados, o modelo identificado no passo 1 e calcular os resíduos produzidos por esse ajuste.
3. A partir dos resíduos encontrados, calcular para cada fator i a seguinte estatística:

$$\dot{F}_i = \frac{s^2(i+)}{s^2(i-)}, \quad (2.1)$$

onde $s(i+)$ é o desvio-padrão do i -ésimo fator no nível $+1$ e $s(i-)$ é calculado de forma análoga para o nível -1 . $\dot{F}_i$ denota que os desvios-padrão são calculados sobre os resíduos do ajuste por mínimos quadrados no passo 2.

4. Observar no gráfico de probabilidades normais se algum dos $\ln \dot{F}_i$ apresenta-se desalinhado dos demais pontos. Os pontos que estiverem desalinhados são os efeitos de dispersão ativos.

O objetivo da remoção dos efeitos de locação antes da identificação dos efeitos de dispersão é evitar que esta última contenha viés originado de uma eventual relação entre locação e dispersão no processo em questão.

Em outras palavras, ajusta-se o modelo de efeitos de locação por mínimos quadrados e, a partir dos resíduos, calculam-se $s^2(i+)$ e $s^2(i-)$, o desvio-padrão dos resíduos da i -ésima coluna cujos níveis são $+1$ e -1 respectivamente.

A utilização do gráfico de Daniel (1959) é simples e se baseia na hipótese nula de que todos os efeitos são inativos e normalmente distribuídos, com média 0 e variância σ^2 . Assim, os fatores inativos estarão alinhados nesse gráfico, enquanto os fatores ativos estarão posicionados fora da reta, nas suas extremidades.

2.2 Análise de Efeitos de Dispersão em Experimentos com Replicações

O estudo desenvolvido neste capítulo será estritamente direcionado ao problema de otimizar características de qualidade do tipo *nominal-the-best*, onde utilizaremos a notação SN_T para a razão sinal-ruído associada a este problema. A otimização de processos *smaller-the-better* e *larger-the-better* não demanda estudo tão aprofundado, por se tratar de problema essencialmente de locação, já vastamente estudado na literatura. Para efeito de ilustração, no entanto, este problema será abordado de forma prática no capítulo 3. É importante ressaltar que, neste texto, o termo "com replicações" representa a possibilidade de cálculo de alguma medida de variabilidade. Por vezes, como comentado anteriormente, podemos ter um plano experimental, resultado da combinação entre os arranjos interno e externo, em que as medidas geradas para o arranjo interno não são replicações verdadeiras.

Os primeiros estudos desenvolvidos por estatísticos, a fim de compreender mais profundamente os métodos de Taguchi, começaram em meados da década de 1980. Atenção especial foi dedicada à medida de *performance* utilizada na identificação e estimação dos efeitos de dispersão, a razão sinal-ruído (SN_T), pois como não há, por parte de Taguchi, justificativa teórica para seu uso, era

importante conhecer o que essa medida realmente representava no contexto de otimização do processo.

O artigo de León et al (1987) formaliza o contexto em que SN_T tem validade teórica e vai além, sugerindo um método para elaboração de medidas de *performance* para identificação de efeitos de dispersão de maneira geral, mas sempre utilizando a característica de qualidade em sua métrica original. Montgomery (1991) simplifica bastante a questão ao propor a utilização de $\log(s)$ (onde s é o desvio-padrão) como medida de *performance*. A seção 2.2.3 aborda a proposta de Box (1988), em que ele generaliza a proposta de Montgomery (1991), sugerindo, em primeiro lugar, a eliminação da dependência entre média e desvio-padrão através do uso de transformações, para, a partir da variável transformada, realizar a análise de efeitos de dispersão com a medida $\log(s)$.

As três abordagens serão discutidas a seguir.

2.2.1 Estudo e Extensão de SN_T

A demonstração da validade de SN_T a seguir deve-se a Leon et. al (1987), que estabeleceram um método geral para a determinação de uma medida de *performance* que seja independente de ajustes, batizada pelos autores de PerMIA (*Performance Measures Independent of Adjustment*). A exposição do método segue abaixo.

Seja $\mathbf{x}$ o vetor de fatores do plano experimental (que pode ser fatorial completo ou fracionado) e que contém os diversos níveis incluídos no experimento. Esse vetor pode ser subdividido em duas partes, tal que $\mathbf{x}=(\mathbf{x}_1, \mathbf{x}_2)$, onde $\mathbf{x}_1$ representa os fatores de ruído e seus níveis no experimento e $\mathbf{x}_2$ os fatores de sinal e

seus níveis no experimento. Mostraremos a seguir que somente na situação em que a média e o desvio-padrão da característica de qualidade do processo sob estudo são proporcionais e, além disso, que a função perda é do tipo quadrática, é que a maximização de SN_T através da escolha adequada dos níveis de $\mathbf{x}_1$ induz à minimização dessa função perda.

É importante observar que, quando buscamos a minimização da função perda ou a maximização de SN_T , estamos na busca pela seleção dos níveis dos fatores que proporcionam tal otimização, pois os fatores do experimento já estão fixados. Por isso, estamos diante de um exercício de detectar fatores (dentre os fatores incluídos no experimento) cujo os efeitos são ativos com respeito a uma medida (nesse caso, a razão sinal-ruído), associado à seleção dos níveis em que esses fatores devem ser ajustados de forma a proporcionar a maximização desta mesma medida.

Seja y a característica de qualidade medida no experimento e t o alvo a ser atingido. Sabendo-se que a média e o desvio-padrão são proporcionais, podemos escrever y através de uma fatoração de duas funções $\mu(\cdot)$ e $\varepsilon(\cdot)$, da seguinte forma:

$$y = \mu(\mathbf{x}_1, \mathbf{x}_2) \varepsilon(\mathbf{N}, \mathbf{x}_1), \quad (2.2)$$

onde $E(y) = \mu(\mathbf{x}_1, \mathbf{x}_2)$ é uma função estritamente monótona nos níveis de cada fator de sinal do vetor $\mathbf{x}_2$ para cada fator de dispersão do vetor $\mathbf{x}_1$. $\mathbf{N}$ é a componente aleatória que representa o ruído. A fatoração de y nas funções $\mu(\cdot)$ e $\varepsilon(\cdot)$ é feita de tal forma, tal que $E(y) = \mu(\mathbf{x}_1, \mathbf{x}_2)$, implicando imediatamente em $E[\varepsilon(\mathbf{N}, \mathbf{x}_1)] = 1$.

A prova constará da apresentação de um procedimento alternativo (procedimento 2.1) ao de Taguchi (procedimento 1.1), baseado na equação 2.2 e na função de perda quadrática (equação 1.2), e da posterior demonstração de que tanto o procedimento 1.1 quanto o procedimento 2.1 são equivalentes.

Define-se a função $P(\mathbf{x}_1)$ como sendo $P(\mathbf{x}_1) = \min_{\mathbf{x}_2} R(\mathbf{x}_1, \mathbf{x}_2)$, onde a função $R(\mathbf{x}_1, \mathbf{x}_2)$ é a função risco, ou seja,

$$R(\mathbf{x}_1, \mathbf{x}_2) = E[L(Y)] = k_1 E(y-t)^2, \quad (2.3)$$

e também se reconhece $R(\mathbf{x}_1, \mathbf{x}_2)$ como sendo o erro quadrático médio (EQM). Como mencionado anteriormente, $P(\mathbf{x}_1)$ sendo o mínimo em $\mathbf{x}_2$ da função risco representa a escolha dos níveis dos fatores que compõem $\mathbf{x}_2$ de tal maneira que $R(\mathbf{x}_1, \mathbf{x}_2)$ seja mínimo. Assim, $P(\mathbf{x}_1)$ tem a seguinte forma:

$$P(\mathbf{x}_1) = \min_{\mathbf{x}_2} [k_1 (y-t)^2] \quad (2.4)$$

Em seguida, definimos um novo procedimento, da seguinte forma:

Procedimento 2.1

Passo 1. Achar $\mathbf{x}_1^*$ que minimize $P(\mathbf{x}_1) = \min_{\mathbf{x}_2} R(\mathbf{x}_1, \mathbf{x}_2)$.

Passo 2. Achar $\mathbf{x}_2^*$ que minimize $R(\mathbf{x}_1^*, \mathbf{x}_2)$.

É sempre possível encontrar um par $(\mathbf{x}_1^*, \mathbf{x}_2^*)$, pois esse par representa os níveis dos fatores do experimento que minimizarão $P(\mathbf{x}_1)$ e $R(\mathbf{x}_1^*, \mathbf{x}_2)$, respectivamente. No pior caso, o par $(\mathbf{x}_1^*, \mathbf{x}_2^*)$ produzirá resultados equivalentes nas funções $P(\mathbf{x}_1)$ e $R(\mathbf{x}_1^*, \mathbf{x}_2)$, (o que representa que possuem efeitos nulos) e então as funções

já se apresentarão em seu mínimo. Caso contrário (pelo menos um fator cujo efeito seja significativo), é possível escolher o nível desse(s) fator(es) que permite(m) a minimização das funções $P(\mathbf{x}_1)$ e $R(\mathbf{x}_1^*, \mathbf{x}_2)$. Portanto, aplicando o procedimento 2.1, temos:

$$\begin{aligned} R(\mathbf{x}_1, \mathbf{x}_2) &\geq \min_{\mathbf{x}_2} R(\mathbf{x}_1, \mathbf{x}_2) \\ &\geq \min_{\mathbf{x}_2} R(\mathbf{x}_1^*, \mathbf{x}_2) \quad (\text{pelo passo 1.}) \\ &= R(\mathbf{x}_1^*, \mathbf{x}_2^*) \quad (\text{pelo passo 2.}) \end{aligned} \quad (2.5)$$

Mostraremos a seguir a equivalência entre os procedimentos 1.1 e 2.1 sob perda quadrática. Para tanto, basta mostrar que $P(\mathbf{x}_1)$ é uma função decrescente da equação 1.3, sob perda quadrática.

Sob o modelo dado pela equação 2.2, temos a seguinte função risco:

$$R(\mathbf{x}_1, \mathbf{x}_2) = E[\mu(\mathbf{x}_1, \mathbf{x}_2)\varepsilon(\mathbf{N}, \mathbf{x}_1) - t]^2 = \mu^2(\mathbf{x}_1, \mathbf{x}_2)\sigma^2(\mathbf{x}_1) + [\mu(\mathbf{x}_1, \mathbf{x}_2) - t]^2, \quad (2.6)$$

onde $\sigma^2(\mathbf{x}_1) = \text{var}[\varepsilon(\mathbf{N}, \mathbf{x}_1)]$, conforme a equação 2.2, e $k_1=1$ na função perda quadrática, por conveniência. Assim, a fim de minimizar a função risco em relação aos níveis do conjunto de fatores $\mathbf{x}_2$, temos:

$$\frac{\partial R(\mathbf{x}_1, \mathbf{x}_2)}{\partial \mathbf{x}_2} = \frac{2\partial \mu(\mathbf{x}_1, \mathbf{x}_2)}{\partial \mathbf{x}_2} \{ \mu(\mathbf{x}_1, \mathbf{x}_2)[1 + \sigma^2(\mathbf{x}_1)] - t \}. \quad (2.7)$$

Igualando a zero a expressão acima para obtenção do mínimo, e considerando que $\frac{\partial \mu(\mathbf{x}_1, \mathbf{x}_2)}{\partial \mathbf{x}_2} \neq 0$, pois $E(y)$ é função estritamente monótona em $\mathbf{x}_2$, temos:

$$\mu(\mathbf{x}_1, \mathbf{x}_2^*(\mathbf{x}_1)) = \frac{t}{1 + \sigma^2(\mathbf{x}_1)}, \quad (2.8)$$

onde $\mathbf{x}_2^*(\mathbf{x}_1)$ é definido por $R(\mathbf{x}_1, \mathbf{x}_2^*(\mathbf{x}_1)) = \min_{\mathbf{x}_2} R(\mathbf{x}_1, \mathbf{x}_2)$.

Substituindo a equação 2.8 na equação 2.6, temos:

$$P(\mathbf{x}_1) = \min_{\mathbf{x}_2} R(\mathbf{x}_1, \mathbf{x}_2) = \frac{t^2}{(1 + \sigma^2(\mathbf{x}_1))^2}. \quad (2.9)$$

Note-se, porém, que a razão sinal-ruído de Taguchi para características de qualidade "no alvo é melhor" (equação 1.3) pode ser escrita como função de $\sigma^2(\mathbf{x}_1)$, da seguinte forma:

$$\begin{aligned} SN_T &= 10 \log[E^2(Y)/\text{var}(Y)] \\ &= 10 \log[\mu^2(\mathbf{x}_1, \mathbf{x}_2)/\mu^2(\mathbf{x}_1, \mathbf{x}_2)\sigma^2(\mathbf{x}_1)] \\ &= -10 \log \sigma^2(\mathbf{x}_1) \end{aligned} \quad (2.10)$$

E, ainda, como temos que $\frac{\partial P(\mathbf{x}_1)}{\partial \sigma^2(\mathbf{x}_1)} = \frac{t^2}{[1 + \sigma^2(\mathbf{x}_1)]^2} > 0$, podemos dizer que

a função $P(\mathbf{x}_1)$ é função monótona crescente em $\sigma^2(\mathbf{x}_1)$, e logo, função monótona decrescente em SN_T . Como consequência, quando se obtém a minimização de $P(\mathbf{x}_1)$ atinge-se a maximização de SN_T . Concluimos então que existe equivalência entre os procedimentos propostos por Taguchi e por León et. al (1987) quando a média é proporcional à variância e a função perda é do tipo quadrático. Nesse caso, pode-se intercambiar o uso de SN_T e de $P(\mathbf{x}_1)$ como medida de *performance*.

Pode-se generalizar a utilização desse método para diversos tipos de função perda e de relações de dependência entre média e variância. A desvantagem desse método é que ele pressupõe que não só a forma funcional da característica de qualidade, mas também a forma da função perda sejam conhecidas. Como já discutido, são raros os casos em que essas duas funções podem ser definidas com clareza.

2.2.2 Proposta de Montgomery

A primeira proposta alternativa à metodologia de Taguchi é a encontrada no livro de Montgomery (1991, pág. 110). Por meio das replicações é possível calcular o desvio-padrão (s) para cada linha do plano experimental. A medida de *performance* utilizada é $\log(s)$, com o objetivo de obter uma distribuição mais suave para o desvio-padrão e poder fazer uso do gráfico de probabilidades normais. Se todos os valores de s estiverem entre 0 e 1, pode-se utilizar $-\log(s)$ como medida de *performance*. A transformação logarítmica é recomendada por, usualmente, ser capaz de eliminar a assimetria da distribuição do desvio-padrão.

A análise dos fatores ativos com relação aos efeitos de dispersão deve ser feita inicialmente através do gráfico de probabilidades normais. Uma vez detectados os efeitos ativos, esses poderão ser estimados por meio da ANOVA com as pseudo-replicações geradas a partir da eliminação dos efeitos não ativos.

A questão nesse caso é se admitir se, em qualquer processo industrial, a média não apresenta dependência com a variância. Talvez realmente esta seja a realidade em grande parte dos casos estudados, mas há ainda clara necessidade de se evoluir para uma metodologia em que cada experimento utilize os seus próprios

dados para estimar a forma da dependência entre média e desvio-padrão, produzindo assim medidas de *performance* para identificação dos efeitos de dispersão apropriadamente adaptadas às características do processo em estudo. A próxima seção busca exatamente essa generalização.

2.2.3 O Uso de Transformações

Este capítulo é baseado nos artigos de Box (1988) e Nair e Pregibon (1986), autores que, na essência, perseguem a mesma idéia de Taguchi, mas a implementam de maneira diferente. A discussão em torno da utilização de transformações é mais profunda no texto de Box (1988). Por outro lado, a metodologia sugerida por Nair e Pregibon (1986) tem apelo intuitivo mais forte e é de mais fácil implementação - por isso será ela a apresentada neste texto. Ambos os artigos fazem críticas analíticas e filosóficas à utilização da metodologia de Taguchi. A principal crítica filosófica refere-se à busca de um tipo de análise mais flexível, adaptada a cada processo em que é aplicada, ao invés de utilizar medidas de *performance* pré-estabelecidas.

Na seção 2.2.2 concluímos que, ao contrário do que pensava Taguchi, SN_T não remove a dependência entre média e variância para qualquer processo. Portanto, efeitos de dispersão podem ser detectados com viés se a relação de dependência entre média e variância não forem proporcionais. Box (1988) e Nair e Pregibon (1986) advogam que o desvio-padrão ou uma função monótona dele (como a variância ou $\log(s)$, onde s é o desvio-padrão das replicações para uma combinação de fatores do experimento) deve ser usado como medida de *performance*, pois é estatística suficiente para medir a variabilidade, e o uso de qualquer outra

estatística seria menos eficiente. No entanto, um cuidado deve ser tomado antes do cálculo da medida de *performance*: o de remover, por meio de uma transformação adequada da característica de qualidade, a relação de dependência entre média e desvio-padrão, quando ela existir.

A classe de transformações sugerida por Nair e Pregibon (1986), extraída de Bartlett (1947), é a seguinte:

$$Y = \begin{cases} Y^{1-\frac{k_2}{2}}, & \text{se } k_2 \neq 2 \\ \log Y, & \text{se } k_2 = 2 \end{cases} \quad (2.11)$$

onde Y é a nova variável transformada e y é a variável original.

Os tipos mais comuns de transformações, de acordo com o valor de k_2 , são:

Tabela 2.1. Coeficiente k_2 para as transformações mais comuns

k_2	0	1	2	4
Transformação	y	$\sqrt{y}$	Log y	1/y

O problema chave, nessa nova abordagem, é determinar a transformação a ser aplicada na característica de qualidade (que se traduz na escolha do k_2 adequado), pois, com a escolha adequada da transformação elimina-se a dependência entre média e desvio-padrão e, assim, identificam-se corretamente os efeitos de dispersão através de $\log(s)$. Segundo Nair e Pregibon (1986), a determinação de k_2 pode ser feita com um gráfico de média contra desvio-padrão na escala log-log. A utilização de um gráfico na escala log-log é recomendada por facilitar a determinação de k_2 ,

pois a inclinação da reta no gráfico nessa escala é uma estimativa do próprio k_2 .

Em resumo, a abordagem de Taguchi conduz a solução do problema para uma definição da melhor medida de *performance* disponível, para que, ao mesmo tempo, se elimine a dependência entre média e desvio-padrão e se reduza a variabilidade. Box (1988) e Nair e Pregibon (1986), ao invés de buscarem formas funcionais, pretendem privilegiar que os dados "falem" por si mesmos, extraíndo informação do próprio experimento para determinar uma transformação que elimine a dependência entre média e desvio-padrão e fazendo uso de uma só medida de *performance*: o desvio-padrão.

2.2.4 A Prática de *pooling* na ANOVA

Em experimentos para redução da variabilidade com replicações, os efeitos de dispersão são efetivamente identificados e estimados em planos experimentais sem replicações, pois para cada combinação de fatores calcula-se uma só medida de variabilidade.

Uma prática muito comum na análise de experimentos sem replicações é o *pooling* da ANOVA, em que as somas de quadrados dos fatores de menor efeito são somadas, dando origem a uma pseudo-soma de quadrados dos erros, permitindo, assim, o cálculo das estatísticas F de cada um dos fatores e os respectivos testes de significância. É sabido que esses testes são apenas aproximados e apresentam viés.

Para justificar o *pooling* na ANOVA, normalmente se argumenta que se por acaso algum fator for considerado como significativo erroneamente, isso não comprometerá a otimização, pois um fator inativo será eventualmente ajustado a outro nível, cujo efeito

também é inerte. A primeira consequência indesejável da adoção de tal prática é que eventualmente se pode perder uma oportunidade de redução de custos. A segunda, mais difícil de se quantificar, mas não menos danosa, é discutida a seguir. O processo de experimentação é contínuo, ou seja, as informações de um experimento alimentam o planejamento do próximo. Portanto, podem haver desvios do melhor caminho a se seguir no aprendizado contínuo sobre o processo se adotam-se conclusões extraídas de análises viesadas.

A utilização de métodos exploratórios, como o gráfico de probabilidades normais, é recomendada para situações como essa. O uso de gráficos, nessa fase da análise do experimento, tem a vantagem adicional de ter maior apelo intuitivo aos engenheiros de processo.

A utilização de técnicas estatísticas deve estimular a criatividade de engenheiros e pesquisadores, ao invés de substituí-la. Por isso deve-se procurar associar todas as técnicas disponíveis, mesmo que simples e informais, para prover informações adequadas à correta análise do experimento.

2.2.5 Avaliação das Mudanças Efetuadas no Processo

A identificação de fatores de ruído através da análise de um experimento, na maior parte das vezes, nos leva a soluções de ajuste dos fatores do processo em níveis diferentes dos utilizados antes da análise do experimento. Isto significa dizer que temos uma oportunidade de melhoria do processo, que só ocorre se operarmos sobre ele uma mudança. Mudanças desta ordem normalmente geram insegurança tanto para a equipe que as propõe (experimentadores) tanto para a equipe que efetivamente responde

pelo processo, e que passará a operá-lo de maneira diferente. Para que estes dois grupos ganhem confiança nas mudanças que se deseja implementar e garantir que os resultados obtidos pelo experimento podem ser reproduzidos na linha de produção, as mudanças devem ser testadas. Assim, é possível obter a confirmação de que as mudanças sugeridas pela análise do experimento efetivamente resultam em melhoria do processo.

O Método de Taguchi sugere que sejam realizados novos experimentos, chamados experimentos confirmatórios, a fim de checar a eficácia da(s) mudança(s), testando o papel dos fatores no processo e seus efeitos.

Uma alternativa à realização de experimentos confirmatórios é a comparação entre a performance do processo nas condições anteriores ao experimento e a performance do processo nas condições sugeridas pela análise do experimento. A vantagem de se testar apenas uma nova condição de operação é que ela tem implementação mais simples. Além disso, quase sempre consumirá menos recursos do que a realização de um novo experimento.

Mas como se mede a performance do processo tal como é operado antes da realização do experimento para comparar com a performance do processo após feitas as mudanças sugeridas pelo experimento? Sugerimos neste texto a utilização do gráfico de controle (Mittra(1986), capítulo 6) associado à análise dos índices de capacidade C_p , C_{pk} e C_{pm} (Mittra(1986), capítulo 9 ou Montgomery(1991, capítulo 9)).

O gráfico de controle é uma ferramenta exploratória que permite a monitoração da atividade de um processo. As medidas de uma característica de qualidade são coletadas e representadas no eixo

vertical, enquanto o eixo horizontal representa amostras individuais ou sub-grupos (em ordem cronológica) dos quais se amostrou a característica de qualidade. Amostras de um certo tamanho (4 ou 5 observações, por exemplo) são selecionadas sequencialmente, e uma estatística baseada na característica de qualidade (por exemplo, comprimento) é calculada com base no número de observações na amostra (por exemplo, média). Essas estatísticas são então colocadas no gráfico na ordem em que as amostras foram retiradas.

Quando dados são coletados do processo nas duas condições que desejamos confrontar (recomenda-se a seleção de pelo menos dez indivíduos ou sub-grupos para cada condição) é possível observar eventuais alterações no processo, que esperamos que sejam melhorias, no nível e/ou na variabilidade da característica de qualidade. O gráfico de controle também tem um papel muito importante no que se refere à avaliação da estabilidade do processo nos dois momentos em questão.

Diz-se que um processo é estável se não há alterações no seu nível durante o período de observação. É importante observar que a magnitude da variabilidade não está relacionada à estabilidade do processo. Em outras palavras, um processo estável é um processo que está sob a ação de causas comuns de variação apenas.

Para propormos uma mudança ao processo, é necessário que este se encontre estável antes da mudança, pois de outra forma não teremos certeza de que foi a mudança introduzida no processo a responsável pela melhoria observada. Igualmente importante é a avaliação da estabilidade do processo após as mudanças sugeridas pelo experimento, pois é a garantia de que houve impacto

duradouro sofrido pela característica de qualidade no processo sob estudo.

Mas não é suficiente observarmos apenas a estabilidade do processo antes e depois das mudanças efetuadas. Temos que avaliar ainda se as mudanças efetuadas causaram também impacto positivo na característica de qualidade - sugerimos duas maneiras, que devem ser usadas em conjunto, para fazer isto.

A primeira delas é feita pelo confronto, no mesmo gráfico de controle, das observações feitas antes da mudança e após a mudança sugerida pela análise do experimento. Visualmente, deveremos ser capazes de enxergar forte alteração na média do processo e/ou forte redução na amplitude dos limites de controle.

A segunda é através da análise de capacidade do processo, onde os índices de capacidade avaliam a performance do processo utilizando como referência os limites de especificação definidos pelo cliente, comparando-os com os limites de variação do processo. A análise de capacidade somente pode ser feita em processos que se encontram sob controle. Quando a variabilidade do processo é menor do que a variabilidade aceita pelo cliente, o processo é dito capaz. Há também índices de capacidade que levam em consideração a locação do processo para avaliar sua capacidade. Mas qualquer que seja o índice, se ele for maior do que 1, o processo é dito capaz.

Os índices C_p (índice de capacidade potencial) e C_{pk} (índice de capacidade efetiva) são os mais populares. Também utilizaremos neste texto, ao longo da análise dos experimentos simulados, no capítulo 3, o índice de capacidade de Taguchi (C_{pm}).

O índice de capacidade potencial, C_p , tem a seguinte forma:

$$C_p = \frac{LSE - LIE}{6\sigma}, \quad (2.12)$$

onde LSE denota o limite superior de especificação, LIE o limite inferior de especificação e σ é o desvio-padrão do processo. O índice C_p compara a variabilidade do processo com a variabilidade especificada pelo cliente.

O índice C_{pk} incorpora informação sobre a média do processo, e deve ser utilizado quando o nível do processo não está no alvo. A fórmula de C_{pk} é:

$$C_{pk} = \min\{CPS, CPI\}, \quad (2.13)$$

onde $CPS = \frac{LSE - \mu}{3\sigma}$ (índice de capacidade superior) e $CPI = \frac{\mu - LIE}{3\sigma}$ (índice de capacidade inferior). LSE e LIE são respectivamente os limites superiores e inferiores de especificação, μ é a média do processo e σ seu desvio-padrão.

O índice de capacidade de Taguchi, C_{pm} , também incorpora a locação do processo, medindo a variabilidade em torno do valor alvo t . Sua forma está descrita abaixo

$$C_{pm} = \frac{LSE - LIE}{6\tau}, \quad (2.14)$$

onde LSE e LIE são respectivamente os limites superiores e inferiores de especificação, e τ é o desvio-padrão em torno do alvo t , e é dado pela fórmula:

$$\tau^2 = E[(X - t)^2] = E[(X - \mu)^2] + (\mu - t)^2 = \sigma^2 + (\mu - t)^2, \quad (2.15)$$

onde μ é a média do processo e σ^2 é sua variância.

Mitra(1986, capítulo 9) contém um estudo comparativo destes índices em diversas situações, onde descreve suas características e avalia suas vantagens e desvantagens.

Capítulo 3

Análise de Experimentos Simulados

O objetivo deste capítulo é avaliar as metodologias estudadas nos capítulos anteriores, simulando situações reais enfrentadas por um pesquisador interessado em reduzir a variabilidade de um processo industrial.

Utilizaremos o programa simulador *Mid-State Brick Factory* (veja referência na bibliografia) para gerar os dados. Esse programa simula o funcionamento de uma fábrica de tijolos de metal, onde concentraremos nossa atenção no processo de corte dos blocos.

O programa simulador permite a geração de dados para quatro diferentes características de qualidade referentes aos blocos de metal: comprimento, rugosidade da superfície, número de entalhes e a existência ou não de rebarbas, das quais utilizaremos, para efeito de experimentação, apenas as duas primeiras. Na geração dos dados, pode-se escolher os intervalos de tempo entre coletas de amostras e o número de unidades a serem amostrados de cada vez.


É possível manipular doze fatores no total, divididos em três categorias. Os nomes dos fatores estão entre parênteses:

- i) Sistemas de medição: pode-se selecionar diferentes sistemas de medição para o comprimento (*length gage*) e para a rugosidade (*micro gage*).
- ii) Fornecedores: pode-se selecionar diferentes fornecedores para as barras (*brick vendor*) que, quando cortados,

originarão os blocos, e para a serra (*saw blade supplier*) que corta os blocos.

- iii) Ajuste da máquina: pode-se controlar sete fatores da máquina que corta os blocos. Estes fatores são: velocidade da serra (*length*), velocidade de aproximação da serra (*speed*), pressão do grampo de fixação da barra (*clamp pressure*), pressão do líquido refrigerante da serra (*coolant pressure*), concentração do líquido refrigerante da serra (*coolant conc.*), ajuste da guia da serra (*guide setting*), posição da barra (*part position*) e frequência de mudança da serra (*blade chg/freq.*)

Abaixo segue a tela do programa *Mid-State Brick Factory* que possibilita o ajuste dos fatores descritos acima.



The screenshot shows a 'Change Settings' dialog box with the following fields and options:

- Speed:** 1100
- Feed Rate:** 4
- Clamp Pressure:** 29.5
- Coolant Pressure:** 68
- Coolant Conc.:** 0.5
- Guide Setting:** 0.02
- Part Position:** Side (dropdown menu)
- Blade Chg/Freq:** 1200
- Saw Blade Supplier:** Brite (dropdown menu)
- Brick Vendor:** A1GA01 (dropdown menu)
- Length Gage:** GC-012 (dropdown menu)
- Micro gage:** GM-015 (dropdown menu)
- Parts in Bin:** 500
- Buttons:** Ok, Cancel, Chg. Saw Blade (checkbox)

Figura 3.1. Tela de ajuste dos fatores da etapa de corte dos blocos no processo de fabricação de tijolos do *software Mid-State Brick Factory*

Utilizaremos sete dos doze fatores disponíveis para realizar os experimentos. Estes fatores estão listados abaixo juntamente com suas regiões de variação:

Tabela 3.1. Fatores utilizados no experimento acompanhados de seus valores máximos e mínimos para operação da máquina

Fator	Valor Mínimo	Valor Máximo
Velocidade da serra (<i>speed</i>)	50	600
Velocidade de aproximação da serra (<i>feed rate</i>)	2	6
Pressão do fixador do bloco (<i>clamp pressure</i>)	10	50
Pressão líq. Refrigerante (<i>coolant pressure</i>)	-	68
Concentração líq. Refrigerante (<i>coolant conc.</i>)	-	10
Guia da serra (<i>guide setting</i>)	0,01	0,03
Posição da barra (<i>part position</i>)	FLAT	SIDE

Analisaremos um experimento com 3 replicações e um outro sem replicações. Este último foi derivado do primeiro conjunto de dados, pois se tomou a primeira replicação para montar os dados do experimento. Serão otimizadas duas características de qualidade simultaneamente: o comprimento (*length*) e a rugosidade (*micro*) dos tijolos. O comprimento é uma característica de qualidade do tipo *nominal-the-best*, com valor alvo 4 e especificação variando entre 3,97 e 4,03. A rugosidade é uma característica de qualidade do tipo *smaller-the-better* e seu valor não pode ultrapassar 250. Portanto, a otimização do processo para o comprimento será baseada na análise de efeitos de dispersão, enquanto para a rugosidade será feita análise de locação.

Os 5 fatores fixos no experimento e os respectivos níveis estão descritos abaixo:

Blade Chg / Freq : 200

Saw Blade Supplier : TOUGHY

Brick Vendor: WRIGHT01

Length Gage : ACME

Micro Gage: GM015

O capítulo está estruturado da seguinte forma: a seção 3.1 apresenta o experimento e as variáveis envolvidas. A seção 3.2 analisa o experimento com replicações; e, na seção 3.3 o experimento sem replicações é analisado.

3.1. Descrição do Experimento Com e Sem Replicações

Os 7 fatores incluídos no experimento, acompanhados dos níveis em que serão testados e da condição atual do processo, estão apresentados na tabela a seguir:

Tabela 3.2. Condições iniciais de operação da máquina e níveis utilizados na experimentação

Fatores	Níveis do Experimento		Condições Iniciais
	-1	+1	
<i>Speed</i>	100	600	100
<i>Feed Rate</i>	2	6	4
<i>Clamp Pressure</i>	10	50	29.5
<i>Coolant Pressure</i>	30	68	68
<i>Coolant Conc.</i>	0,5	2,8	0,5
<i>Guide Setting</i>	0,01	0,03	0,02
<i>Part Position</i>	FLAT	SIDE	SIDE

O experimento será conduzido seguindo um plano experimental fatorial fracionado 2_{III}^{7-4} , com a seguinte estrutura de confundimento: D = AB E = AC F = BC G = ABC. Note-se que alguns efeitos principais se confundem com interações de 2ª ordem.

A escolha do plano descrito acima em detrimento da utilização dos arranjos interno e externo combinados se dá por duas razões principais: (i) Montgomery (1991, pág. 538) discute a eficiência de planos simples em comparação com o cruzamento de dois planos diferentes. É possível concluir a partir do texto que, com o consumo dos mesmos recursos, ou unidades experimentais, somos capazes de ganhar mais informação a cerca do processo quando utilizamos planos fatoriais ou fatoriais fracionados usuais; (ii) A elaboração de um só plano fatorial fracionado permite comparação de resultados obtidos pelas diversas técnicas e também pelos experimentos executados com e sem replicações.

A ordem de coleta foi aleatorizada através de sorteio e depois os dados foram coletados, um a um, em intervalos de 30 minutos, ou seja, foram registradas, no total, 24 corridas experimentais para cada uma das características de qualidade em questão. O plano experimental, acompanhado das medidas coletadas para o comprimento e rugosidade, está apresentado abaixo.

Tabela 3.3. Dados experimentais para o experimento com 3 replicações

Ordem Exp.	Speed	Feed Rate	Clamp Pressure	Coolant Pressure	Coolant Conc.	Guide Setting	Part Position	Comprimento			Rugosidade		
1	100	2	10	68	2.8	0.03	SIDE	3.9926	4.0050	3.9927	199.18	209.82	200.24
2	600	2	10	68	0.5	0.01	FLAT	3.9729	4.0098	4.0143	177.99	165.89	178.61
3	100	6	10	30	0.5	0.03	FLAT	4.0016	4.0153	3.9702	236.62	258.46	245.55
4	600	6	10	30	2.8	0.01	SIDE	4.0155	3.9964	4.0150	171.53	204.84	181.69
5	100	2	50	30	2.8	0.01	FLAT	3.9956	3.9930	3.9994	190.81	181.29	213.67
6	600	2	50	30	0.5	0.03	SIDE	3.9906	3.9985	4.0000	173.74	180.32	170.41
7	100	6	50	68	0.5	0.01	SIDE	3.9903	3.9926	3.9948	240.51	238.35	247.02
8	600	6	50	68	2.8	0.03	FLAT	3.9894	3.9943	4.0064	183.95	164.33	178.41

Os dados do experimento sem replicações são extraídos da tabela acima, tomando-se a primeira coluna à esquerda de cada característica de qualidade como sendo a única replicação disponível.

Após a coleta dos dados, a análise completa do experimento foi realizada no software Minitab13 (veja referência na bibliografia). As análises seguem sempre um mesmo roteiro, apresentando, nessa ordem, (i) o gráfico de efeitos principais, (ii) o gráfico de probabilidades normais, (iii) a tabela de estimativa dos efeitos e (iv) a tabela de análise de variância (ANOVA) dos efeitos determinados como significantes através da análise das ferramentas de (i) a (iii). A sequência de menus utilizado em cada um deles é:

(i) Gráfico de Efeitos Principais: Stat > DOE > Factorial > Factorial Plots > Main Effects Plot

(ii) Gráfico de Probabilidades Normais: Stat > DOE > Factorial > Analyze Factorial Design > Graphs > Normal Effects Plot

(iii) Tabela de Estimativa dos Efeitos: Stat > DOE > Factorial > Analyze Factorial Design

(iv) Tabela de Análise de Variância: Stat > DOE > Factorial > Analyze Factorial Design

3.2 Análise do Experimento Com 3 Replicações

O experimento com replicações será analisado segundo as três diferentes abordagens da seção 2.2 para a variável comprimento: (i) utilizando SN_T de Taguchi; (ii) utilizando $\log(s)$, o logaritmo do desvio padrão, na variável original e (iii) aplicando uma transformação para eliminar a dependência entre média e desvio-padrão para utilizar o mesmo $\log(s)$ do item anterior sobre a variável transformada - em conjunto com a análise de dispersão para o comprimento, analisaremos também os seus efeitos de locação para um ajuste apropriado ao alvo. Para a variável rugosidade faremos uma comparação entre a utilização de SN_s (equação 1.4) e $\bar{y}$ (média aritmética das replicações de uma combinação dos fatores do experimento) como variáveis-resposta do experimento.

Iniciamos a análise do experimento pelo gráfico da distribuição dos dados experimentais. O gráfico abaixo mostra que a variável comprimento possui efeitos de dispersão mais marcantes do que os efeitos de locação, pois as barras apresentam amplitudes bem variadas, enquanto seus centros não apresentam forte desalinhamento.



Figura 3.2. Gráfico da distribuição das unidades experimentais da variável comprimento

A variável rugosidade, por sua vez, apresenta mais claramente efeitos de locação, pois há algumas barras cujas linhas centrais estão em um patamar bem superior ao de outras barras.




Figura 3.3. Gráfico da distribuição das unidades experimentais da variável rugosidade

3.2.1 Análise de Dispersão Para o Comprimento

A) Razão Sinal-Ruído de Taguchi (SN_T)

A variável comprimento é do tipo *nominal-the-best*. Já vimos na seção 1.7 que a medida de *performance* a ser utilizada é:

$$SN_T = 10 \log \left(\frac{\bar{Y}^2}{s^2} \right).$$

Para cada linha do experimento (ou combinação de fatores) será possível calcular a medida SN_T . O gráfico abaixo, chamado gráfico de efeitos principais (Box, Hunter e Hunter, 1987)), apresenta os sete fatores do experimento, onde em cada ponto do gráfico é apresentada a média de SN_T para as observações cujo os níveis estão indicados. Por exemplo, o primeiro ponto à esquerda do gráfico corresponde ao cálculo da média de SN_T para as linhas do experimento onde o fator *speed* se apresenta em seu nível 100. Assim, pela comparação da média de SN_T quando *speed* é 100 contra a média de SN_T quando *speed* é 600 é possível determinar o efeito sobre SN_T quando variamos *speed* de 100 para 600. Se esse efeito for significativo sobre SN_T , dizemos que este é um fator de dispersão para o comprimento e escolheremos, para a nova configuração da máquina, o nível de *speed* que produz o maior valor de SN_T , visando assim, a maximização da razão sinal-ruído, e conseqüente redução de variabilidade.

O gráfico de efeitos principais abaixo sugere a existência de três fatores de ruído: *speed*, *clamp pressure* e *part position*.

Gráfico de Efeitos Principais (médias) para SN(T) de Comprimento




Figura 3.4. Gráfico de efeitos principais para SN_T do comprimento

O gráfico a seguir, chamado de gráfico de probabilidades normais ou gráfico de Daniel (1959), é construído tomando-se, para cada fator, a média de SN_T nos níveis +1 e -1, respectivamente denotados por $\overline{SN_T(+1)}$ e $\overline{SN_T(-1)}$ (observe que esses são os valores expressados no gráfico de efeitos principais acima) e então fazendo a diferença $e_i = \overline{SN_T(+1)} - \overline{SN_T(-1)}$ para cada fator i do experimento. As quantidades e_i são chamadas efeitos do i -ésimo fator e são apresentadas no gráfico abaixo. O gráfico revela os efeitos ativos sobre SN_T através dos pontos desalinhados. Em concordância com o gráfico de efeitos principais, temos os seguintes três efeitos ativos: *speed*, *clamp pressure* e *part position*.

Gráfico de Probabilidades Normais para os Efeitos: SN(T) de Comprimento




Figura 3.5. Gráfico de probabilidades normais para os efeitos sobre a variável SN_T do comprimento

A tabela 3.4 contém a estimativa dos efeitos ativos, cujos fatores estão destacados na figura 3.5. A tabela abaixo também apresenta os coeficientes do modelo de regressão ajustado para os níveis dos fatores codificados, ou seja, as variáveis independentes se apresentam apenas na forma +1 e -1. Esta regressão é calculada pelo método de mínimos quadrados.

Observe que os três fatores *speed*, *clamp pressure* e *part position* apresentam efeitos significantes ao nível de 10%.

Tabela 3.4 Estimativas dos efeitos e coeficientes para SN_T do comprimento (níveis codificados)

Fator	Efeito	Coef.	E.P. Coef.	T	P
Intercepto		54.247	1.009	53.79	0.000
Speed	-4.797	-2.398	1.009	-2.38	0.076
Clamp Pr.	10.515	5.258	1.009	5.21	0.006
Part Pos.	6.127	3.063	1.009	3.04	0.039

A tabela 3.5 apresenta a análise de variância (ANOVA) para o modelo contendo apenas os três fatores significantes, já discutidos nas figuras 3.4 e 3.5 e também na tabela 3.4. O valor-p de 1,4% leva à conclusão de que o modelo é significativo a 5%.

Tabela 3.5 Análise de variância para SN_T do comprimento (níveis codificados)

Fonte	GL	SQ	SQ Aj.	QM Aj.	F	P
Efeitos Principais*	3	342.22	342.22	114.075	14.02	0.014
Resíduos	4	32.55	32.55	8.137		
Total	7	374.77				

* Fatores incluídos no modelo: *speed*, *clamp pressure* e *part position*

Conclusão Para Análise de SN_T de Comprimento:

Após a identificação dos fatores de ruído, nos voltamos para o gráfico de efeitos principais (figura 3.4), a fim de determinar o nível em que esses fatores devem ser ajustados para que SN_T seja máximo (ou a variabilidade seja mínima). A análise do gráfico revela que devemos ajustar da seguinte forma os fatores de ruído (os respectivos níveis estão entre parênteses): *speed* (100), *clamp pressure* (50) e *part position* (SIDE).

B) Log(s) - Montgomery

Analisaremos agora a primeira alternativa ao uso de SN_T : a utilização de $\log(s)$ como variável resposta do experimento. O gráfico de efeitos principais abaixo sugere a existência de três fatores de ruído: *speed*, *clamp pressure* e *part position*.

Gráfico de Efeitos Principais para o log(s) do Comprimento




Figura 3.6. Gráfico de efeitos principais para a variável log(s) do comprimento

O gráfico de probabilidades normais a seguir também aponta como fatores de ruído *speed*, *clamp pressure* e *part position*.

Gráfico de Probabilidades Normais para os Efeitos: log(s) do Comprimento




Figura 3.7. Gráfico de probabilidades normais para a variável log(s) do comprimento

A tabela de estimativa dos efeitos abaixo revela que os três fatores sugeridos pelos métodos gráficos como fatores de ruído são significantes a 10%.

Tabela 3.6 Estimativas dos efeitos e coeficientes para log(s) do comprimento (níveis codificados)

Fator	Efeito	Coef.	E.P. Coef.	T	P
Intercepto		-4.860	0.1159	-41.93	0.000
Speed	0.553	0.277	0.1159	2.39	0.075
Clamp Pr.	-1.212	-0.606	0.1159	-5.23	0.006
Part Pos.	-0.705	-0.352	0.1159	-3.04	0.038

E a tabela ANOVA abaixo também revela modelo significativo a 5%.

Tabela 3.7 Análise de variância para log(s) do comprimento (níveis codificados)

Fonte	GL	SQ	SQ Aj.	QM Aj.	F	P
Efeitos Principais*	3	4.5433	4.5433	1.5144	14.09	0.014
Resíduos	4	0.4300	0.4300	0.1075		
Total	7	4.9732				

* Fatores incluídos no modelo: *speed*, *clamp pressure* e *part position*

Uma vez identificados os fatores de ruído, voltamos ao gráfico de efeitos principais para log(s) e buscamos os níveis em que esses fatores apresentam log(s) mínimo.

Conclusão Para Análise de log(s) do Comprimento:

Após a identificação dos fatores de ruído, nos voltamos para o gráfico de efeitos principais (figura 3.6), a fim de determinar o nível em que esses fatores devem ser ajustados para que log(s) seja mínimo. A análise do gráfico revela que devemos ajustar da seguinte forma os fatores de ruído (os respectivos níveis estão

entre parênteses): *speed* (100), *clamp pressure* (50) e *part position* (SIDE).

C) Uso de Transformações

Segundo a metodologia proposta por Nair e Pregibon (1986), devemos avaliar a necessidade de efetuar uma transformação estabilizadora da variância, eliminando a dependência entre média e desvio-padrão. O gráfico sugerido para fazer tal avaliação vem a seguir:




Figura 3.8. Gráfico da média vs. desvio-padrão do comprimento (escala log-log)

Observe-se que o gráfico de média versus desvio-padrão na escala log-log não revela haver forte dependência entre eles. Portanto, não há necessidade de se fazer transformação sobre a variável original.

Conclusão Para Análise Via Uso de Transformações:

Como essa metodologia consiste em utilizar como variável resposta $\log(s)$ da variável transformada, e que nesse caso não houve

necessidade de transformação, a análise é equivalente àquela feita na seção anterior. Portanto, concluímos que, para obter redução de variabilidade, os ajustes a serem feitos nos fatores de ruído são: *speed* (100), *clamp pressure* (50) e *part position* (SIDE).

3.2.2 Análise de Locação Para o Comprimento

A análise de locação para o comprimento será baseada na média da variável comprimento. O objetivo da análise é utilizar um eventual efeito de locação para ajustar a média ao alvo especificado.

O gráfico de efeitos principais para o comprimento não apresenta nenhum fator cujo efeito se destaque em relação aos demais.

Gráfico de Efeitos Principais para o Comprimento




Figura 3.9. Gráfico de efeitos principais para a variável comprimento

A tabela de estimativa dos efeitos é fornecida abaixo a fim de confirmar a inexistência de efeitos de locação para o comprimento.

Tabela 3.8 Estimativas dos efeitos e coeficientes para o comprimento (níveis codificados)

Fator	Efeito	Coef.	E.P. Coef.	T	P
Intercepto		3.99776	0.002639	1514.72	0.000
Speed	0.00500	0.00250	0.002639	0.95	0.358
Feed Rate	0.00145	0.00072	0.002639	0.27	0.787
Clamp Pr.	-0.00470	-0.00235	0.002639	-0.89	0.386
Coolant Pr.	-0.00300	-0.00150	0.002639	-0.57	0.578
Coolant Conc.	0.00370	0.00185	0.002639	0.70	0.493
Guide Set.	-0.00275	-0.00138	0.002639	-0.52	0.610
Part Pos.	-0.00182	-0.00091	0.002639	-0.34	0.735

Observe-se que o valor-p do modelo completo é 87,3% na ANOVA abaixo. Portanto, não há como ajustar, por meio dos fatores testados, o alvo da especificação.

Tabela 3.9 Análise de variância para o comprimento (níveis codificados)

Fonte	GL	SQ	SQ Aj.	QM Aj.	F	P
Efeitos Principais*	7	0.00049647	0.00049647	0.00007092	0.42	0.873
Resíduo	16	0.00267485	0.00267485	0.00016718		
Erro Puro	16	0.00267485	0.00267485	0.00016718		
Total	23	0.00317132				

* Todos os fatores fazem parte deste modelo

Há que se considerar soluções de engenharia para fazer os ajustes, se necessários, que são perfeitamente aplicáveis à característica em questão, como, por exemplo, submeter os tijolos a um segundo corte caso seu comprimento esteja muito acima da especificação.

3.2.3 Análise de Locação Para a Rugosidade

A) Razão Sinal-Ruído de Taguchi (SN_s)

A variável rugosidade é do tipo *smaller-the-better*, ou seja, os fatores significantes para SN_s são fatores de sinal. Portanto, faremos uso da equação 1.4 como variável resposta do experimento, que tem a seguinte forma:

$$SN_s = -10 \log \left(\frac{\sum y^2}{n} \right).$$

O gráfico de efeitos principais abaixo sugere a existência de três fatores de sinal de significantes: *speed*, *feed rate* e *coolant conc.*

Gráfico de Efeitos Principais para SN(S) da Rugosidade




Figura 3.10. Gráfico de efeitos principais para a variável SN_s da rugosidade

O gráfico de probabilidades normais confirma a identificação dos mesmos três fatores de sinal para SN_s da rugosidade.

Gráfico de Probabilidades Normais para os Efeitos: $SN(S)$ da Rugosidade




Figura 3.11. Gráfico de probabilidades normais para a variável SN_s da rugosidade

A seguinte tabela de estimativa dos efeitos mostra serem os três fatores identificados nas figuras 3.10 e 3.11 como sendo fatores de sinal como sendo significantes a 1%.

Tabela 3.10 Estimativas dos efeitos e coeficientes para SN_s da rugosidade (níveis codificados)

Fator	Efeito	Coef.	E.P. Coef.	T	P
Intercepto		-45.94	0.07953	-577.66	0.000
Speed	1.88	0.94	0.07953	11.83	0.000
Feed Rate	-1.04	-0.52	0.07953	-6.57	0.003
Cool. Conc.	0.73	0.36	0.07953	4.57	0.010

A tabela ANOVA abaixo confirma a significância do modelo, apresentando valor-p inferior a 1%.

Tabela 3.11 Análise de variância para SN_s da rugosidade (níveis codificados)

Fonte	GL	SQ	SQ Aj.	QM Aj.	F	P
Efeitos Principais*	3	10.3215	10.3215	3.44050	68.00	0.001
Resíduo	4	0.2024	0.2024	0.05059		
Erro Puro	4	0.2024	0.2024	0.05059		
Total	7	10.5239				

* Fatores que fazem parte do modelo: *speed*, *feed rate* e *coolant conc.*

Após a identificação dos fatores significantes para SN_s da Rugosidade, voltamos nossa atenção ao gráfico de efeitos principais (Figura 3.10), a fim de avaliar em que nível os fatores identificados devem ser ajustados para promover redução no nível da rugosidade - os níveis escolhidos são aqueles em que SN_s da rugosidade é maior, a fim de maximizar a razão sinal-ruído.

Conclusão Para Análise de SN_s :

Os fatores de sinal e os respectivos níveis em que SN_s da rugosidade devem ser ajustados são: *speed* (600), *feed rate* (2) e *coolant conc.* (2,8).

B) Modelagem Através da Média

A modelagem através da média da rugosidade resulta no seguinte gráfico de efeitos principais, que sugere a existência dos mesmos três fatores de sinal: *speed*, *feed rate* e *coolant conc.*




Figura 3.12. Gráfico de efeitos principais para a variável rugosidade

O gráfico de probabilidades normais abaixo confirma o diagnóstico: são três os fatores de sinal: *feed rate*, *speed* e *coolant conc.*

Gráfico de Probabilidades Normais para os Efeitos Padronizados: Rugosidade




Figura 3.13. Gráfico de probabilidades normais para a variável rugosidade

A tabela de estimativa dos efeitos a seguir revela que os três fatores de sinal identificados através das figuras 3.12 e 3.13 são significantes a 1%.

Tabela 3.12 Estimativas dos efeitos e coeficientes para a rugosidade (níveis codificados)

Fator	Efeito	Coef.	E.P. Coef.	T	P
Intercepto		199.72	2.111	94.62	0.000
Speed	-44.15	-22.08	2.111	-10.46	0.000
Feed Rat	25.77	12.89	2.111	6.11	0.000
Cool. Co	-19.48	-9.74	2.111	-4.61	0.000

O modelo contendo apenas os três fatores assinalados acima é significativo, segundo a tabela ANOVA a seguir:

Tabela 3.13 Análise de variância para a rugosidade (níveis codificados)

Fonte	GL	SQ	SQ Aj.	QM Aj.	F	P
Efeitos Principais*	3	17957.5	17957.5	5985.8	55.98	0.000
Resíduo	20	2138.5	2138.5	106.9		
Erro Puro	20	2138.5	2138.5	106.9		
Total	23	20095.9				

* Fatores que fazem parte do modelo: *speed*, *feed rate* e *coolant conc.*

Conclusão Para Análise de $\bar{y}$:

Através da análise da figura 3.12, os fatores de sinal e os respectivos níveis em que a média é mínima são: Speed (600), Feed Rate (2) e Coolant Conc (2,8).

3.2.4 Análise Conjunta Para Comprimento e Rugosidade

O quadro abaixo resume o resultado das análises para cada uma das características de qualidade no experimento com replicações.

Todas as metodologias, em cada uma das variáveis, foram concordantes nos resultados. No entanto, há conflito no nível sugerido para o fator *Speed*. Nessa situação, um critério não estatístico deve ser utilizado na eliminação do conflito, como, por exemplo, a escolha da característica mais importante para o comprador dos tijolos.

Tabela 3.14. Resultado do experimento para cada variável resposta e resultado final para ajuste da máquina

Fatores	Comprimento (dispersão)	Rugosidade (locação)	Resultado
Speed	100	600	100
Feed Rate		2	2
Clamp Pressure	50		50
Coolant Pressure			68*
Coolant Conc.		2,8	2,8
Guide Setting			0,02*
Part Position	SIDE		SIDE

* Ajuste do fator de acordo com a configuração original da máquina

Consideraremos, nesse caso, que interessa mais ao comprador que ocorra redução de variabilidade do comprimento em comparação com a redução no nível de rugosidade dos tijolos. Assim, o fator *speed* será ajustado em 100.

3.3 Análise do Experimento Sem Replicações

Já vimos que o experimento sem replicações vai fazer uso da primeira replicação para cada corrida experimental do conjunto de dados original. Os objetivos mantêm-se os mesmos. Iniciaremos

pela análise dos efeitos de dispersão para o comprimento e, em seguida, nos voltaremos à análise dos efeitos de locação para a rugosidade.

A tabela com os dados utilizados segue abaixo:

Tabela 3.15. Dados experimentais para o experimento sem replicações

Ordem Exp.	Speed	Feed Rate	Clamp Pressure	Coolant Pressure	Coolant Conc.	Guide Setting	Part Position	Comprimento	Rugosidade
1	100	2	10	68	2.8	0.03	SIDE	3.9926	199.18
2	600	2	10	68	0.5	0.01	FLAT	3.9729	177.99
3	100	6	10	30	0.5	0.03	FLAT	4.0016	236.62
4	600	6	10	30	2.8	0.01	SIDE	4.0155	171.53
5	100	2	50	30	2.8	0.01	FLAT	3.9956	190.81
6	600	2	50	30	0.5	0.03	SIDE	3.9906	173.74
7	100	6	50	68	0.5	0.01	SIDE	3.9903	240.51
8	600	6	50	68	2.8	0.03	FLAT	3.9894	183.95

3.3.1 Análise de Locação para o Comprimento

Como visto no capítulo 3, começamos a análise do experimento sem replicações pela remoção dos efeitos de locação.

O gráfico de efeitos principais para a média do comprimento segue abaixo:

Gráfico de Efeitos Principais para o Comprimento




Figura 3.14. Gráfico de efeitos principais para a variável comprimento

São 4 os fatores de maior efeito: *feed rate*, *coolant pressure*, *coolant conc.* e *part position*. O gráfico de probabilidades normais aponta serem os mesmos quatro fatores significantes.

Gráfico de Probabilidades Normais para os Efeitos: Comprimento
(nível de significância = .10)




Figura 3.15. Gráfico de probabilidades normais para a variável comprimento

Segundo a tabela de estimativa dos efeitos, os quatro fatores diagnosticados como fatores de sinal nas figuras 3.15 e 3.16 são significantes a 10%. Todos esses fatores serão considerados significativos com o objetivo de remover, da melhor forma possível, os efeitos de locação existentes.

Tabela 3.16 Estimativas dos efeitos e coeficientes para o comprimento (níveis codificados)

Fator	Efeito	Coef.	E.P. Coef.	T	P
Intercepto		3.99356	0.001472	2713.78	0.000
Feed Rat	0.01127	0.00564	0.001472	3.83	0.031
Cool.Pre	-0.01453	-0.00726	0.001472	-4.94	0.016
Cool.Con	0.00943	0.00471	0.001472	3.20	0.049
Part Pos	0.00738	0.00369	0.001472	2.51	0.087

A tabela ANOVA abaixo confirma a significância do modelo.

Tabela 3.17 Análise de variância para o comprimento (níveis codificados)

Fonte	GL	SQ	SQ Aj.	QM Aj.	F	P
Efeitos Principais*	4	0.00096265	0.00096265	0.00024066	13.89	0.028
Resíduos	3	0.00005197	0.00005197	0.00001732		
Total	7	0.00101462				

* Fatores incluídos no modelo: *feed rate*, *coolant pressure*, *coolant conc.* e *part position*

3.3.2 Análise de Dispersão para o Comprimento

Uma vez o modelo ajustado através do método de mínimo quadrados, dele são extraídos os resíduos do ajuste. A partir desses resíduos, foram calculadas as variâncias amostrais para cada um dos fatores nos dois níveis existentes no experimento. O resultado encontra-se no quadro abaixo:

Tabela 3.18. Logaritmo da razão entre as variâncias nos níveis (+) e (-)

	Speed	Feed Rate	Clamp Pressure	Coolant Pressure	Coolant Conc.	Guide Setting	Part Position
$s^2(-) \cdot 10^6$	4.40	8.52	8.66	4.40	8.66	8.54	16.80
$s^2(+) \cdot 10^6$	4.52	8.54	8.66	4.52	8.66	8.52	0.52
$\ln [s^2(+)/s^2(-)]$	0.03	0.00	0.00	0.03	0.00	0.00	-3.47

O valor da estatística $\hat{F}$ para o fator *part position* é discrepante em relação aos demais. No gráfico a seguir pode-se observar a diferença de variabilidade entre os níveis dos fatores.




Figura 3.16. Gráfico dos efeitos da variância do comprimento

Part position desempenha o papel de fator de ruído para o comprimento, devendo ser ajustado ao nível SIDE, pois é o nível de menor variância.

3.3.3 Análise de Locação para a Rugosidade

O gráfico de efeitos principais para a rugosidade indica que existem três fatores de sinal: *speed*, *feed rate* e *coolant conc.*

Gráfico de Efeitos Principais para a Rugosidade




Figura 3.17. Gráfico dos efeitos principais da variável rugosidade

O gráfico de probabilidades normais é concordante em apontar os mesmos três fatores como fatores de sinal para a rugosidade.

Gráfico de Probabilidades Normais para os Efeitos: Rugosidade

(nível de significância = .10)




Figura 3.18. Gráfico de probabilidades normais da variável rugosidade

A tabela de estimativa dos efeitos a seguir confirma a significância dos fatores diagnosticados como fatores de sinal nas figuras 3.17 e 3.18.

Tabela 3.19 Estimativas dos efeitos e coeficientes para a rugosidade (níveis codificados)

Fator	Efeito	Coef.	E.P. Coef.	T	P
Intercepto		196.79	2.006	98.11	0.000
Speed	-39.98	-19.99	2.006	-9.97	0.001
Feed Rat	22.72	11.36	2.006	5.66	0.005
Cool.Con	-20.85	-10.42	2.006	-5.20	0.007

E a ANOVA atesta a significância do modelo quando retirados os fatores inertes.

Tabela 3.20 Análise de variância para a rugosidade (níveis codificados)

Fonte	GL	SQ	SQ Aj.	QM Aj.	F	P
Efeitos Principais*	3	5098.26	5098.26	1699.42	52.80	0.001
Resíduo	4	128.75	128.75	32.19		
Erro Puro	4	128.75	128.75	32.19		
Total	7	5227.02				

* Fatores que fazem parte do modelo: *speed*, *feed rate* e *coolant conc.*

Assim, concluímos a existência de três fatores de locação para a rugosidade que, para que tenha sua média seja minimizada, faz uso do seguinte ajuste da máquina: *speed* (600), *feed rate* (2) e *coolant conc.* (2,8).

3.3.4 Análise Conjunta das Características de Qualidade Comprimento e Rugosidade No Experimento Sem Replicações

O quadro abaixo resume o resultado das análises para cada uma das características de qualidade. Não houve divergência em nenhum dos métodos aplicados para a mesma característica de qualidade nem entre as características.

Tabela 3.21 Análise conjunta das características de qualidade, segundo a análise do experimento sem replicações

Fatores	Comprimento	Rugosidade	Resultado
Speed		600	600
Feed Rate		2	2
Clamp Pressure			29,5*
Coolant Pressure			68*
Coolant Conc.		2,8	2,8
Guide Setting			0,02*
Part Position	SIDE		SIDE

* Ajuste do fator de acordo com a configuração original da máquina

Capítulo 4

Estudo de Capacidade - Estudo Comparativo dos Resultados Obtidos

O estudo de capacidade a seguir foi realizado a partir de três diferentes condições de operação da fábrica de tijolos: a primeira delas é a configuração original da máquina, também chamada de condição inicial; as outras duas configurações referem-se aos resultados obtidos pelo experimento sem replicações e pelo experimento com 3 replicações. Conforme o capítulo anterior, as três configurações estão descritas abaixo:

Tabela 4.1. Três configurações a serem comparadas no estudo de capacidade

Fatores	Condição Inicial	Sem Replicações	Com 3 Replicações
Speed	100	600	100
Feed Rate	4	2	2
Clamp Pressure	29,5	29,5*	50
Coolant Pressure	68	68*	68*
Coolant Conc.	0,5	2,8	2,8
Guide Setting	0,02	0,02*	0,02*
Part Position	SIDE	SIDE	SIDE

* Fatores ajustados nos níveis iniciais por não serem fatores de ruído nem de sinal

Os dados utilizados para medir a *performance* do processo nas configurações acima foram capturados sempre da seguinte forma: 6 (seis) unidades amostrais foram coletadas a cada 30 minutos, por dois dias inteiros de operação. Em cada uma das três coletas a

fábrica foi reinicializada, para que os dados coletados fossem referentes aos dias 1 e 2 da fábrica, eliminando o efeito de deterioração de *performance* que ocorre com o passar dos dias.

Para as duas características de qualidade a análise se dará da seguinte forma: em primeiro lugar avaliaremos a estabilidade do processo na sua condição inicial e nas condições propostas, a fim de garantir a validade do estudo de capacidade. Em seguida, os histogramas contendo os índices C_p , C_{pk} e C_{pm} serão apresentados para avaliação do impacto na mudança na configuração da máquina. E por último serão mostrados, lado a lado, os gráficos de controle na condição inicial e nas condições de cada um dos resultados propostos, qual sejam: experimento sem e com 3 replicações.

4.1 Característica de Qualidade Comprimento

Na apresentação feita do *software Mid-State Brick Factory*, feita no capítulo 3, vimos que os limites de tolerância para o comprimento são $4 \pm 0,03$. O gráfico de controle para o processo ajustado na sua configuração inicial está apresentado abaixo:




Figura 4.1. Gráfico de controle do processo na configuração inicial para o comprimento

A análise do gráfico revela que o processo encontra-se estável e que, portanto, pode-se prosseguir à análise de capacidade.

O histograma contendo os mesmos dados do gráfico de controle anterior, acompanhado dos índices de capacidade, está apresentado abaixo.

Análise de Capacidade para Comprimento

Condição Inicial




Figura 4.2. Histograma e estatísticas de capacidade para o comprimento na condição inicial

Na condição inicial, a capacidade potencial do processo (C_p) é 1,02, o que significa que o processo é capaz. No entanto, o índice C_{pk} , que representa a capacidade efetiva do processo em estudo, é 0,86. Isso indica que, apesar de o processo potencialmente ser capaz de produzir unidades dentro das especificações exigidas, não é isso que se observa nas condições atuais de operação. O gráfico é bem claro em demonstrar que é necessário fazer um ajuste no nível do processo para cima, elevando a média do processo para o valor alvo. O índice de capacidade de Taguchi (C_{pm}) é 0,94, maior do que C_{pk} . Isso indica que a variabilidade em torno da média foi capaz de compensar o afastamento da média, produzindo um índice C_{pm} mais próximo de C_p .

Analisaremos agora o gráfico de controle do processo após o ajuste segundo a análise do experimento sem replicações.




Figura 4.3. Gráfico de controle do processo para a variável comprimento segundo ajuste proposto pela análise do experimento sem replicações

A análise do gráfico revela que o processo encontra-se estável e que, portanto, pode-se prosseguir à análise de capacidade.

O histograma contendo os mesmos dados do gráfico de controle anterior, acompanhado dos índices de capacidade, está apresentado abaixo.

Análise de Capacidade para Comprimento Experimento Sem Replicações




Figura 4.4. Histograma e estatísticas de capacidade para a variável comprimento após mudanças sugeridas pela análise do experimento sem replicações

O índice de capacidade potencial do processo aumentou de 1,02 para 1,17. Ou seja, houve leve redução na variabilidade do processo. A performance efetiva do processo sofreu pequena melhora, com o índice C_{pk} indo de 0,86 para 0,95. Esta leve melhora também foi refletida no índice C_{pm} , que foi de 0,94 para 0,97.

Abaixo encontra-se o gráfico de controle comparativo do processo antes e depois das modificações provocadas pela análise do experimento sem replicações.




Figura 4.5. Gráfico comparativo de X-barra/R para a variável comprimento antes e após mudanças sugeridas pela análise do experimento sem replicações

As condições propostas pela análise do experimento sem replicações não resultaram em expressiva redução na variabilidade. Algumas observações importantes são necessárias: o único fator identificado como fator de ruído no experimento sem replicações é concordante com os fatores de ruído encontrados no experimento com 3 replicações. No entanto, esse fator (*part position*), não teve sua configuração alterada em relação à configuração original, pois a máquina já estava ajustada no nível *SIDE* para este fator. Portanto, apesar de, nesse caso específico, não termos obtido redução de variabilidade, pudemos constatar que a informação produzida pela análise do experimento é confiável, e que houve ganho de aprendizado na execução do experimento, pois sabe-se que o bloco não pode ser cortado na

posição *FLAT* sob pena de aumento na variabilidade do processo para o comprimento.

Analisaremos agora o gráfico de controle do processo após o ajuste segundo a análise do experimento com 3 replicações.




Figura 4.6. Gráfico de controle do processo para a variável comprimento após mudanças sugeridas pela análise do experimento com 3 replicações

A análise do gráfico revela que o processo encontra-se estável e que, portanto, pode-se prosseguir à análise de capacidade.

O histograma contendo os mesmos dados do gráfico de controle anterior, acompanhado dos índices de capacidade, está apresentado abaixo.

Análise de Capacidade para Comprimento Experimento Com 3 Replicações




Figura 4.7. Histograma e estatísticas de capacidade para a variável comprimento após mudanças sugeridas pela análise do experimento com 3 replicações

Nesse caso, o índice C_p apresentou aumento expressivo, indo de 1,02 para 1,74, demonstrando forte redução na variabilidade do processo. O índice C_{pk} seguiu a mesma tendência, indo de 0,86 para 1,41. Esse ajuste resultou em um processo com capacidade potencial melhor, além de ter tornado a *performance* efetiva capaz de produzir unidades dentro das especificações - o índice de não-conformidade fica abaixo de 0,007%. A redução de variabilidade também provocou aumento no índice C_{pm} (de 0,94 para 1,23), apesar do ainda existente ligeiro afastamento da média do processo do alvo em relação à condição inicial de operação.

É importante notar que ainda há oportunidades em se melhorar o processo através do adequado ajuste no nível do processo.

Os gráficos de controle abaixo reforçam os comentários anteriores, mostrando forte redução de variabilidade, refletida tanto pelos limites de controle do gráfico de X-barra quanto pelos limites de controle de R.




Figura 4.8. Gráfico comparativo de X-barra/R para a variável comprimento antes e após mudanças sugeridas pela análise do experimento com 3 replicações

4.2 Característica de Qualidade Rugosidade

No que tange aos limites de especificação da variável rugosidade, a única exigência é de que ela seja menor que 250, não havendo valor alvo definido neste caso. O gráfico de controle para o processo ajustado na sua configuração inicial está apresentado abaixo:




Figura 4.9. Gráfico de controle do processo na configuração inicial para a variável rugosidade

A análise do gráfico revela que o processo encontra-se estável e que, portanto, pode-se prosseguir à análise de capacidade.

O histograma contendo os mesmos dados do gráfico de controle anterior, acompanhado dos índices de capacidade, está apresentado abaixo.

Análise de Capacidade para Rugosidade Condição Inicial




Figura 4.10. Histograma e estatísticas de capacidade para a variável rugosidade na condição inicial

Os índices (C_p e C_{pk}) são coincidentes nesse caso, pois não temos valor alvo definido. O valor dos dois índices é 0,99, mostrando um processo quase capaz. Não há sentido em se calcular o índice C_{pm} quando não existe alvo definido.

Analisaremos agora o gráfico de controle do processo após o ajuste segundo a análise do experimento sem replicações.




Figura 4.11. Gráfico de controle do processo para a variável rugosidade após mudanças sugeridas pela análise do experimento sem replicações

A análise do gráfico revela que o processo encontra-se estável e que, portanto, pode-se prosseguir à análise de capacidade.

O histograma contendo os mesmos dados do gráfico de controle anterior, acompanhado dos índices de capacidade, está apresentado abaixo.

Análise de Capacidade para Rugosidade Experimento Sem Replicações




Figura 4.12. Histograma e estatísticas de capacidade para a variável rugosidade após mudanças sugeridas pela análise do experimento sem replicações

Diferente da análise para a variável comprimento, em que o experimento sem replicações não apresentou resultados expressivos, a análise para a variável rugosidade melhorou a capacidade do processo de maneira acentuada, elevando os índices C_p e C_{pk} de 0,99 para 2,68.

O gráfico de controle abaixo ratifica o comentário anterior, mostrando de forma acentuada como o nível do processo sofreu forte queda.

Gráfico de X-barra/R para Rugosidade




Figura 4.13. Gráfico comparativo de X-barra/R para a variável rugosidade antes e após mudanças sugeridas pela análise do experimento sem replicações

Analisaremos agora o gráfico de controle do processo após o ajuste segundo a análise do experimento com 3 replicações.




Figura 4.14. Gráfico de controle do processo para a variável rugosidade após mudanças sugeridas pela análise do experimento com 3 replicações

A análise do gráfico revela que o processo encontra-se estável e que, portanto, pode-se prosseguir à análise de capacidade.

O histograma contendo os mesmos dados do gráfico de controle anterior, acompanhado dos índices de capacidade, está apresentado abaixo.

Análise de Capacidade para Rugosidade Experimento Com 3 Replicações




Figura 4.15. Histograma e estatísticas de capacidade para a variável rugosidade após mudanças sugeridas pela análise do experimento com 3 replicações

O experimento com 3 replicações melhora a capacidade do processo e leva os índices C_p e C_{pk} de 0,99 para 2,72. Para a variável rugosidade, ambos os experimentos promoveram resultados contundentes - lembrando que esta é uma característica de qualidade em que a melhora de qualidade se traduz em um problema de efeitos de locação.

O gráfico de controle comparativo, abaixo, aponta a expressiva redução no nível do processo após o ajuste segundo as recomendações feitas pela análise do experimento com 3 replicações.

Gráfico X-barra/R para Rugosidade




Figura 4.16. Gráfico comparativo de X-barra/R para a variável rugosidade antes e após mudanças sugeridas pela análise do experimento com 3 replicações

Capítulo 5

Conclusões

Taguchi (1987) foi pioneiro na busca da redução de variabilidade como forma de melhorar processos industriais. A base de sua teoria continua sendo amplamente utilizada não só pelos engenheiros de processo que fazem uso de seus métodos, mas também pelos cientistas, hoje, debruçados em resolver o mesmo problema. No entanto, seus métodos têm sofrido várias críticas (Box (1988), Box e Meyer (1986), León et. al (1987) e Nair e Pregibon (1986) são alguns exemplos), principalmente por se apresentarem na forma de "receita de bolo", não estimulando à busca das características próprias do processo para sua melhoria.

No aspecto teórico, vimos que podem existir situações em que a maximização da razão sinal-ruído não leva à otimização do processo, e isto porque a razão sinal-ruído elimina a dependência entre média e desvio-padrão apenas no caso em que eles são proporcionais. Nair e Pregibon (1986) e Box (1988) atacam o ponto central deste problema, propondo a utilização de transformações para eliminar a dependência entre média e desvio-padrão. Eliminada esta dependência, deve-se utilizar o próprio desvio-padrão (ou uma função monótona dele) para avaliar a variabilidade. Os ganhos na utilização desta metodologia aparecem de duas maneiras: não só ela é mais geral e, portanto, tem aplicação mais ampla, como também conduz o experimentador a conhecer melhor o processo sob sua gestão.

Quanto ao aspecto prático, além da comparação entre metodologias, uma outra discussão interessante é a da utilização de replicações nos experimentos.

Começamos pela comparação dos resultados encontrados nas análises dos experimentos sem e com replicações. No caso da variável comprimento, onde temos um problema de identificação de efeitos de dispersão, o experimento sem replicações foi menos informativo, como esperado, do que o experimento com 3 replicações. No entanto, produziu informações importantes sobre o processo, de maneira confiável. Quando da identificação de efeitos de locação (para a variável rugosidade), o experimento sem replicações foi tão efetivo quanto o experimento com 3 replicações para reduzir o nível do processo. Os experimentos sem replicações revelaram-se menos informativos, mas sem por isso deixarem de ter importância, principalmente em ambientes onde os recursos disponíveis para a experimentação são escassos. Esta é a razão pela qual as linhas mais recentes de pesquisa (Brenneman e Nair (2001), por exemplo), têm procurado desenvolver metodologias mais eficientes para análise de experimentos deste tipo, procurando extrair maior quantidade de informações.

A comparação entre as diversas metodologias apresentadas nesta dissertação, do ponto de vista prático, revelou não haverem divergências na identificação dos efeitos de dispersão do processo, ou seja, todos os métodos utilizados sugeriram exatamente o mesmo ajuste do processo de fabricação de tijolos após as análises dos experimentos. Mas é importante notar que, de acordo com León et al. (1987), a maximização de SN_T funciona quando a média e desvio-padrão forem proporcionais. Apesar de este não ter sido o caso com a variável comprimento, SN_T foi

capaz de otimizar o processo da mesma forma, mostrando sua robustez ao desvio da situação teórica ideal.

Essa pode ser uma razão pela qual os Métodos de Taguchi, tal qual foram propostos inicialmente, continuam populares - grande parte dos processos encontrados na prática têm solução similar com aquelas obtidas através das alternativas propostas mais recentemente por renomados estatísticos, mostrando a robustez do método na prática.

No entanto, os argumentos de que se deve sempre procurar acumular conhecimento acerca da estrutura dos processos, e que esses conhecimentos são de grande utilidade na experimentação seqüencial sobre um processo, são fortes demais para que nos acomodemos e apliquemos uma receita pré-fabricada, ainda que ela funcione.

Essa é a razão pela qual este estudo sugere aos engenheiros de processo que busquem o conhecimento estrutural dos processos sob sua gestão, e, desta maneira, conduzam a análise do experimento segundo a prática de Taguchi apenas como uma forma de validar os resultados obtidos.

Alguns tópicos envolvendo melhoria de processos industriais através da utilização de planejamento de experimentos e que podem servir de objeto para futuras pesquisas são: identificação de fatores de ruído em experimentos sem replicações, identificação de fatores de ruído através do uso de modelos lineares generalizados ou através do uso de superfícies de resposta.

Bibliografia

BARTLETT, M.S. (1947) **The Use of Transformations**, Biometrics, 3, 33-52.

BOX, G. E. P. (1988) **Signal-to-Noise Ratios, Performance Criteria, and Transformations**, Technometrics, 30, 1-39.

BOX, G. E. P.; HUNTER, W. G.; HUNTER, J. S. (1987) **Statistics for Experimenters**, New York: John Wiley.

BOX, G. E. P.; MEYER, R. D. (1986) **An Analysis For Unreplicated Fractional Designs**, Technometrics, 28, 11-18.

BOX, G. E. P.; MEYER, R. D. (1986a) **Dispersion Effects from Fractional Designs**, Technometrics, 28, 19-27.

BRENNEMAN, W. A.; NAIR, V. N. (2001) **Methods for Identifying Dispersion Effects in Unreplicated Factorial Experiments: A Critical Analysis and Proposed Strategies**, Technometrics, 43, 388-405.

DANIEL, C. (1959) **Use of Half-Normal Plots in Interpreting Factorial Two-Level Experiments**, Technometrics, 1, No.4, 311-342.

LEÓN, R. V.; SHOEMAKER, A. C. ; KACKER, R. N. (1987) **Performance Measures Independent of Adjustment: An Explanation and Extension of Taguchi's Signal-to-Noise Ratio**, Technometrics, 29, 253-285.

MID-STATE BRICK FACTORY. Disponível em
www.virtualchaos.com/MidStateBrick.html. Acesso em 14 de
fevereiro de 2003.

MINITAB STATISTICAL SOFTWARE RELEASE 13.32. Disponível em www.minitab.com. Acesso em 19 de maio de 2003.

MITRA, A. (1998) **Fundamentals of Quality Control and Improvement**, 2nd ed., New Jersey: Prentice Hall.

MONTGOMERY, D. C. (1991) **Introduction to Statistical Quality Control**, New York: John Wiley.

MONTGOMERY, D. C. (1997) **Design and Analysis of Experiments**, 5th ed., New York: John Wiley

NAIR, N. V.; PREGIBON, D. (1986) **A Data Analysis Strategy for Quality Engineering Experiments**, AT & T Technical Journal, 73-84.

NAIR, N. V. (1992) **Taguchi's Parameter Design: A Panel Discussion**, Technometrics, 34, 127-161.

TAGUCHI, G. (1980) **Introduction to Off-line Quality Control**, Japan: Central Japan Quality Control Association.

TAGUCHI, G. (1986) **Introduction to Quality Engineering: Designing Quality into Products and Processes**, White Plains, NY: Kraus International Publications.

TAGUCHI, G. (1987) **System of Experimental Design**, vol. 1 and 2, White Plains, NY: Kraus International Publications

TAGUCHI, G. (1989) **Taguchi Methods: Proceedings of the 1988 European Conference**, Edited by Tony Bendell, Essex: Elsevier Science Publishers Ltd.