

## **CADERNOS DO IME – Série Estatística**

Universidade do Estado do Rio de Janeiro - UERJ  
Rio de Janeiro - RJ - Brasil  
ISSN 1413-9022 / v. 31 p. 31 - 45, 2011

# **GESTÃO DE PARÂMETROS CRÍTICOS NO PROCESSO DE DESENVOLVIMENTO DE PRODUTOS POR MEIO DE SIMULAÇÃO E MODELAGEM ESTATÍSTICA**

Karla Faccio  
UNISINOS  
kfaccio@unisinos.br

Márcia Elisa Soares Echeveste  
Departamento de Estatística – IM - UFRGS  
Programa de Pós-Graduação em Engenharia de Produção - UFRGS  
echeveste@producao.ufrgs.br

Danilo Marcondes Filho  
Departamento de Estatística – IM - UFRGS  
Marcondes.filho@ufrgs.br

### **Resumo**

*A gestão de parâmetros críticos (CPM, do inglês Critical Parameters Management) estuda a conversão das demandas dos clientes em especificações críticas para o produto, permitindo que a equipe de desenvolvimento concentre os esforços nas características mais relevantes do produto desde as fases iniciais do Processo de Desenvolvimento de Produto (PDP). A definição das especificações críticas do produto nas suas fases preliminares de desenvolvimento resultará num PDP mais consistente e, por sua vez, em um produto final com menos chance de reparos em seu projeto. O objetivo desse artigo é a proposição de uma abordagem utilizando simulação e análise de regressão para identificação dos parâmetros críticos na fase preliminar à construção do protótipo do produto, isto é, quando existem poucas informações sobre o produto. Esta abordagem será apresentada a partir de um estudo de caso envolvendo um novo produto sob desenvolvimento.*

**Palavras-chave:** *Gestão de Parâmetros Críticos, Análise de Regressão, PDP.*

## 1. Introdução

Desenvolver um produto consiste em um processo pelo qual uma organização transforma as informações de oportunidades de mercado e de possibilidades técnicas em dados para a fabricação de um produto comercial (CLARK e FUJIMOTO, 1991). O processo de desenvolvimento de produtos (PDP) contempla um fluxo de informações entre os diversos setores funcionais envolvidos. Estabelecer a comunicação entre estes setores ao longo do desenvolvimento de produtos envolve uma série de práticas e ferramentas. As ferramentas são vistas como facilitadores, por meio delas as organizações podem reestruturar seu processo de desenvolvimento de produtos (ARAUJO, 1997).

As informações sobre atributos demandados do produto são estudadas na gestão de requisitos. O entendimento dos requisitos prioritários no produto apresenta o primeiro passo para uma boa execução do projeto de um produto, uma vez que associa as necessidades dos clientes com as especificações do produto e metas de desempenho (VRINAT, 2007). Entende-se por requisito do produto o atributo necessário do produto que tenha valor e utilidade para o cliente (YOUNG, 2003). A gestão dos requisitos parte da estratégia da empresa até o conceito do produto e, quando detalhados, os requisitos desdobram-se em parâmetros, assim, aqueles que têm impacto significativo nos requisitos do produto são denominados de parâmetros críticos.

No entanto, o acompanhamento dos parâmetros críticos ao longo do projeto de desenvolvimento é um desafio em face da crescente complexidade no PDP diante das novas tecnologias, novos materiais, novas e mais sofisticadas soluções em produtos. Além disso, manter o controle sobre esses requisitos próximos de seus respectivos valores metas ao longo do PDP apresenta a meta da gestão de parâmetros críticos (CPM - *Critical Parameters Management*).

Desse modo, o CPM é uma abordagem revolucionária para a gestão de desenvolvimento de produtos, uma vez que alinha as decisões estratégicas e modelos matemáticos na mesma ferramenta, estudando a conversão das demandas do mercado em especificações críticas para a funcionalidade do produto. Contudo, o maior desafio para a implementação do CPM é realizar uma mensuração das informações a cerca do produto, buscando a relação matemática de quais parâmetros críticos impactam no produto final (CREVELING *et al.*, 2003; JUDD, 2005; VRINAT, 2007).

O emprego do CPM pode iniciar ainda na fase de geração do conceito do produto, uma vez que fornece suporte para o mapeamento dos SSC's (Sistema, Subsistemas e Componentes) do produto. Desta forma, permite que a equipe de desenvolvimento concentre esforços nas características mais relevantes do produto desde as fases iniciais do desenvolvimento de um produto (CREVELING *et al.*, 2003; ROZENFELD *et al.*, 2006). Verifica-se que o CPM é um assunto atual na comunidade de desenvolvimento de produtos e envolve inclusive técnicas, ferramentas e métodos clássicos utilizados no PDP, como o QFD (*Quality Function Deployment*) e o DOE (*Design of Experiments*) (ROZENFELD *et al.*, 2006; VRINAT, 2007).

Percebe-se que no desenvolvimento de novos produtos, na fase de conceituação, a equipe não tem o produto físico para condução de testes. A primeira representação física do produto ocorre em geral no protótipo. Contudo, o protótipo é uma das soluções possíveis de um produto, definido por meio de um método de seleção de conceito (ULRICH e EPPINGER, 2000; JUDD, 2005). Autores defendem que quanto mais à montante o conhecimento dos parâmetros e de sua interferência no produto final, maior é o ganho de tempo e qualidade no produto e no projeto (ECHEVESTE, 2003). Sabe-se que o quanto antes forem definidas as especificações críticas do produto, isso resultará num PDP mais consistente e por sua vez, em um produto final com menos chance de reparos em seu projeto.

Por essa razão, este artigo realiza uma simulação estatística para os valores dos parâmetros do produto com base nas suas especificações-meta e opinião de especialistas. A intenção é maximizar as informações identificadas nas fases iniciais de desenvolvimento do produto sobre os requisitos por meio da geração de um banco de dados multivariado. Assim, o objetivo deste artigo é a proposição de uma abordagem utilizando simulação e análise de regressão para identificação dos parâmetros críticos na fase preliminar à construção do protótipo do produto, isto é, quando existem poucas informações sobre o produto.

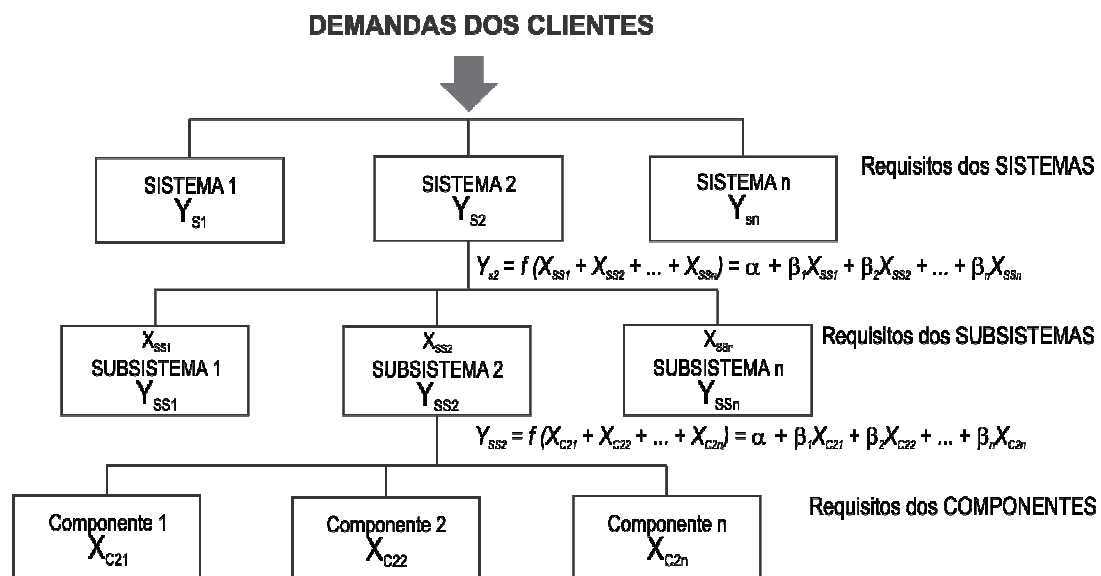
## **2. Gestão de Parâmetros Críticos (CPM)**

Um método de organização dos requisitos em parâmetros críticos proposto por Creveling *et al.* (2003) é o DFSS (*Design for Six Sigma*). O DFSS é uma metodologia baseada em ferramentas analíticas para auxiliar no desenvolvimento de novos produtos.

Esta metodologia considera as exigências do mercado e dos clientes, e verifica quantitativamente o quanto as especificações estão sendo atendidas. Desta forma, Creveling *et al.* (2003) apresentam o CPM como uma nova visão para a gestão de requisitos em um contexto de DFSS. O CPM é uma dimensão do DFSS que concentra esforços nas características críticas do produto que, quando controladas e ajustadas, poderão garantir melhorias no produto final. Para Judd (2005) a gestão de parâmetros críticos é um método de suporte ao PDP. Cada fase do CPM tem como entrada e saída variáveis mensuráveis que representam os parâmetros. Os parâmetros podem ser definidos como variáveis mensuráveis que caracterizam os SSC's do produto. Os sistemas são influenciados por variáveis dos componentes.

A Figura 1 ilustra o desdobramento dos SSC's de um produto genérico, na qual as exigências partem das demandas do mercado, que são aquelas características que geralmente são percebidas pelos clientes. Essas demandas são convertidas em requisitos do cliente que são medidas por meio de requisitos do produto. Nesse caso, os requisitos do produto são variáveis representadas por  $Y$ , isto é, as variáveis resposta que são dependentes das variáveis explicativas ( $X$ 's) (independentes) dos subsistemas.

Figura 1 – Gestão de Parâmetros Críticos



O relacionamento entre essas variáveis é dado pela função de transferência sistema/subsistema, que estuda matematicamente as relações entre as variáveis

$Y_{Si} = f(X_{SS1}, X_{SS2}, X_{SS3}, \dots, X_{SSi})$  e o mesmo ocorre com os subsistemas/componentes, isto é,  $Y_{Ssi} = f(X_{C1}, X_{C2}, X_{C3}, \dots, X_{Ci})$ . Onde,  $i = 1, \dots, k$ ;  $k$ : número de variáveis;  $Si$ : sistema  $i$ ;  $SSi$ : subsistema  $i$ ;  $Ci$ : componente  $i$ ;  $Y_{Si}$ : variável resposta do sistema  $i$ ,  $Y_{Ssi}$ : variável resposta do subsistema  $i$ ;  $X_{SSi}$ : variável explicativa do subsistema  $i$  e  $X_{Ci}$ : variável explicativa do componente  $i$ . Em um primeiro nível, as variáveis resposta ( $Y_{Si}$ 's) dos sistemas são influenciados por variáveis explicativas dos subsistemas ( $X_{SSi}$ 's). Em outro nível, mais abaixo, as variáveis resposta ( $Y_{Ssi}$ 's) dos subsistemas são influenciados pelas variáveis explicativas dos componentes ( $X_{Ci}$ 's). Dos componentes, chega-se às exigências do processo de manufatura (CREVELING *et al.*, 2003).

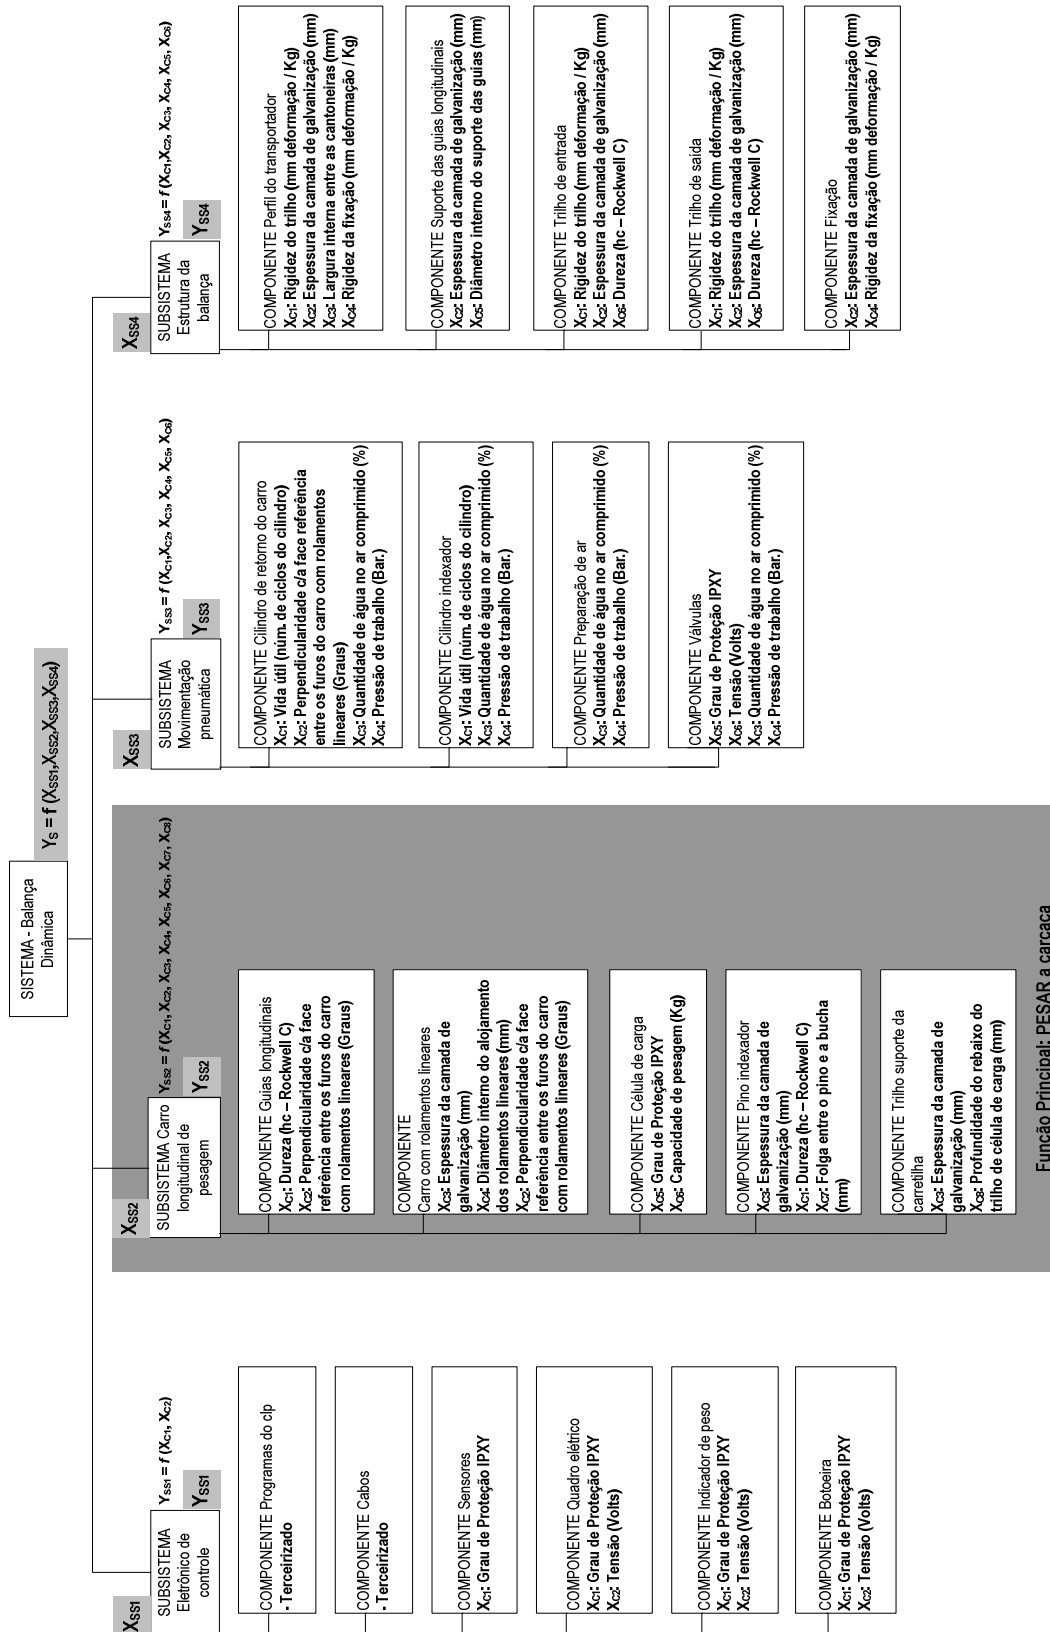
Uma técnica estatística que pode ser útil para auxiliar na gestão dos parâmetros críticos no PDP é a Análise de Regressão. A análise de regressão é uma ferramenta utilizada para estudar as relações entre duas ou mais variáveis, e prever o valor de uma variável resposta (dependente -  $Y$ ) por meio de um conjunto de variáveis explicativas (independentes  $X$ 's) (MONTGOMERY e RUNGER, 2007). A análise de regressão é utilizada para criar uma equação ou função de transferência a partir das medições das entradas e saídas dos sistemas (CREVELING *et al.*, 2003; VRINAT, 2007). A Equação 1 é o caso de regressão linear múltipla com efeito aditivo e sem efeito de interação (GUJARATI, 2000; MONTGOMERY, 2006).

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_i X_i + \varepsilon \quad (1)$$

Onde:  $Y$  é a variável resposta (dependente);  $\alpha$  é a constante (intercepto entre a reta e o eixo ortogonal);  $i = 1, \dots, k$ ;  $k$  é o número de variáveis;  $\beta$ 's são os parâmetros (coeficientes da regressão);  $X_i$ 's são as variáveis explicativas (independentes) e  $\varepsilon$  é o erro ou resíduo.

Com base na figura 1 pode-se verificar que a função de transferência pode ser estimada por técnicas de regressão. As variáveis explicativas ( $X_{SSi}$ 's) dos subsistemas irão prever as variáveis resposta ( $Y_{Si}$ 's) dos sistemas, uma vez que as variáveis ( $X_{Ci}$ 's) dos componentes predizem as variáveis resposta ( $Y_{Ssi}$ 's) dos subsistemas, enfatizando quais são os parâmetros críticos de um determinado produto. Vale salientar que os coeficientes ( $\beta$ 's) da regressão associados aos  $X_i$ 's representam o impacto destas variáveis na variável resposta ( $Y$ ).

Figura 2 - Desdobramento das variáveis associadas aos SSC's



### 3. Fases e aplicação de uma abordagem para identificação dos parâmetros críticos

Esta seção apresenta um exemplo do desenvolvimento de um novo produto eletrônico denominado balança dinâmica de carcaças pertencente a uma empresa de grande porte e líder.

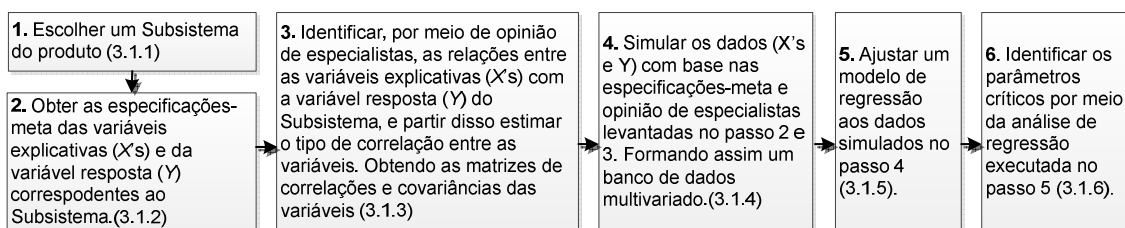
A Figura 2 ilustra o desdobramento dos SSC's da balança dinâmica de carcaças relacionadas com as variáveis correspondentes. Este relacionamento é derivado da aplicação da Matriz das Características das Partes do QFD, a qual relaciona os componentes do produto com as variáveis de qualidade correspondentes, porém, esta matriz não será apresentada neste artigo pelo limitado número de páginas. Desta forma, definem-se quais são as variáveis de qualidade relacionadas com os componentes do produto e seus subsistemas e sistema.

Assim, observando a Figura 2, em um primeiro nível, o sistema é influenciado por variáveis ( $X_{SSI}$ 's) dos subsistemas (eletrônico de controle; carro longitudinal de pesagem; movimentação pneumática e estrutura da balança). Em outro nível, os subsistemas são influenciados pelas variáveis  $X_{Ci}$ 's dos componentes.

#### 3.1 Desenvolvimento de uma abordagem para identificar os parâmetros críticos

Esta fase realiza-se na fase de detalhamento do projeto do PDP e será uma aplicação da abordagem apresentada na Figura 3, sendo responsável por avaliar os SSC's e entender a relação entre os parâmetros críticos dos componentes.

Figura 3 - Procedimento para identificar os parâmetros críticos por meio de modelagem estatística



A abordagem apresentada na Figura 3 é aplicada a um exemplo de desenvolvimento de um novo produto em que as variáveis serão amostradas por meio de simulação estatística com base nas suas especificações-meta e opinião de especialistas, uma vez que inexistente o protótipo do produto em estudo. Pode-se afirmar que a abordagem mostrada na Figura 3 é para o exemplo em se estuda um subsistema por vez.

### 3.1.1 Escolher um subsistema do produto

Escolheu-se um subsistema, neste caso, o Carro Longitudinal de Pesagem, que está destacado na Figura 2 e possui a função fundamental do produto em estudo, ou seja, de pesar a carcaça, no intuito de verificar quais são os parâmetros críticos para o correspondente subsistema. O próximo passo é definir as especificações-meta das variáveis dos componentes relacionadas ao subsistema em estudo.

### 3.1.2 Obter as especificações-meta das variáveis explicativas ( $X_{Ci}$ 's) e da variável resposta ( $Y_{SS2}$ ) correspondentes ao subsistema escolhido

As especificações-meta das variáveis explicativas ( $X_{Ci}$ 's) e da variável resposta ( $Y_{SS2}$ ) relacionadas ao correspondente subsistema foram definidas com base em normas, neste exemplo, uma fonte importante foi uma norma do Inmetro (OIML R51-1 / 2006) (Figura 4). Essas especificações-meta serão consideradas para se realizar a simulação de um banco de dados das variáveis explicativas e da variável resposta relacionadas ao subsistema.

Figura 4: Especificações-meta das variáveis explicativas e da variável resposta

Variáveis explicativas ( $X_{Ci}$ 's) correspondentes ao Subsistema Carro Longitudinal de Pesagem	Tipo de Variável	Valor Mínimo	Valor Máximo
$X_{C5}$ : Grau de proteção IPXY	Atributo	95% com IP67	IP67
$X_{C1}$ : Dureza (Hc)	Nominal	45 Hc	55 Hc
$X_{C2}$ : Perpendicularidade com a referência entre os furos do carro com os rolamentos lineares (Graus)	Norminal	89,9°	90,1°
$X_{C6}$ : Capacidade de pesagem (Kg)	Nominal	2 Kg	300 Kg
$X_{C3}$ : Espessura da camada de galvanização (mm)	Nominal	0,07 mm	0,1 mm
$X_{C7}$ : Folga entre o pino e a bucha (mm)	Nominal	0,02 mm	0,05 mm
$X_{C8}$ : Profundidade do rebaixo do trilho da célula de carga (mm)	Nominal	2 mm	4 mm
$X_{C4}$ : Diâmetro interno do alojamento dos rolamentos lineares (mm)	Nominal	75 mm	75,025 mm
Variável Resposta ( $Y_{SS2}$ )	Tipo	Valor Mínimo	Valor Máximo
Precisão de pesagem (Gramas)	Nominal	0 g	100 g

Ressalta-se que, o conhecimento da equipe utilizado para identificar as especificações e a relação entre as variáveis deve estar apoiado, além de Normas regulamentatórias em: relatórios técnicos, publicações científicas relacionadas à tecnologia e aos princípios de solução mecânico, químico-físico importantes para o atendimento às funções demandadas do produto ou em produtos similares. Uma vez identificadas as especificações-metas das variáveis correspondentes ao subsistema em estudo, a próximo passo é identificar as relações entre essas variáveis.



### 3.1.3 Identificar as relações entre as variáveis explicativas ( $X_{Ci}$ 's) e com a variável resposta ( $Y_{SS2}$ ) do subsistema escolhido por meio de uma opinião de especialistas

Por meio de entrevistas com especialistas verificou-se que o relacionamento das variáveis explicativas ( $X_{Ci}$ 's) dos componentes, sendo  $i = 1, \dots, 8$ , com a variável resposta precisão de pesagem ( $Y_{SS2}$ ) relacionadas ao subsistema carro longitudinal de pesagem é linear. Esta constatação partiu de um questionamento com estes especialistas, o qual investigou a relação de cada  $X_{Ci}$ , sendo  $i = 1, \dots, 8$ , na precisão de pesagem dentro do intervalo de especificações-meta das respectivas variáveis. Deste modo, o questionamento partiu das especificações-meta dos  $X_{Ci}$ 's e do  $Y_{SS2}$  solicitando-se aos especialistas qual seria o comportamento do  $Y_{SS2}$  aumentando ou diminuindo os valores de cada variável ( $X_{Ci}$ ) relacionados com o subsistema em estudo dentro dos seus intervalos de especificações. Deste modo, tornou-se possível desenhar/construir um possível modelo que demonstrasse como cada  $X_{Ci}$  se relaciona com o  $Y_{SS2}$ .

Constata-se que as variáveis explicativas que mais influenciam na precisão de pesagem são (Figura 4):  $X_{C1}$ ,  $X_{C2}$ ,  $X_{C3}$ ,  $X_{C4}$ ,  $X_{C5}$ ,  $X_{C6}$ ,  $X_{C7}$  e  $X_{C8}$ . Esta constatação partiu de uma conversa com os especialistas, que informaram, pelos seus conhecimentos a cerca do assunto, as variáveis que mais poderiam influenciar na precisão de pesagem. Para o prosseguimento do estudo serão utilizadas as cinco variáveis mais importantes, segundo os especialistas, para a precisão de pesagem, são elas (Figura 4):  $X_{C1}$ ,  $X_{C2}$ ,  $X_{C6}$ ,  $X_{C8}$  e  $X_{C4}$ . Assim, o número de variáveis relacionadas ao subsistema em estudo que serão simuladas serão cinco e não oito como indica na Figura 2, pois foram consideradas as variáveis explicativas mais importantes para a variável resposta.

Outro questionamento realizado aos especialistas foi em relação à importância de cada variável explicativa ( $X_{Ci}$ ) na precisão de pesagem ( $Y_{SS2}$ ), por conseguinte, estas importâncias foram transformadas em correlações entre as variáveis, auxiliando no preenchimento da Matriz de Correlações mostrada na sequência. Procedeu-se também com uma investigação do relacionamento entre as variáveis explicativas ( $X_{Ci}$ 's) por meio do preenchimento, pelos especialistas, de uma matriz de relacionamentos a fim de finalizar o preenchimento da Matriz de Correlações (Figura 5). Estes relacionamentos entre os  $X_{Ci}$ 's também foram transformados em correlações entre as variáveis  $X_{Ci}$ 's.

Assim, realizou-se uma análise das correlações entre as variáveis explicativas ( $X_{Ci}$ 's), sendo  $i = 1, 2, 4, 6, 8$ , e a variável resposta ( $Y_{SS2}$ ) precisão de pesagem por meio de entrevistas com os especialistas, resultando em uma Matriz de Correlações (Figura

5). Portanto, por meio dos questionamentos descritos anteriormente, estimaram-se as correlações lineares entre as cinco variáveis mais importantes e a precisão de pesagem.

Figura 5 - Matriz de Correlações das variáveis a serem simuladas

$$r = \begin{matrix} & Y_{SS2} & X_{C1} & X_{C2} & X_{C6} & X_{C8} & X_{C4} \\ \begin{matrix} Y_{SS2} \\ X_{C1} \\ X_{C2} \\ X_{C6} \\ X_{C8} \\ X_{C4} \end{matrix} & \begin{bmatrix} 1 & 0,6 & 0,7 & 0,8 & 0,8 & 0,5 \\ 0,6 & 1 & 0 & 0,6 & 0 & 0 \\ 0,7 & 0 & 1 & 0 & 0 & 0,3 \\ 0,8 & 0,6 & 0 & 1 & 0 & 0 \\ 0,8 & 0 & 0 & 0 & 1 & 0 \\ 0,5 & 0 & 0,3 & 0 & 0 & 1 \end{bmatrix} \end{matrix}$$

Com base na suposição de Normalidade das variáveis em estudo estimaram-se as variâncias das mesmas, para tal considerou-se  $6\sigma$  de desvio dentro da amplitude das especificações-meta de cada variável. Assim, as variâncias de cada variável foram estimadas, ou seja, a diagonal principal da Matriz de Covariâncias foi preenchida. E invertendo a fórmula do coeficiente de correlação linear (Equação 2) chegou-se na fórmula da covariância (Equação 3), a qual forneceu os valores das covariâncias entre as variáveis, completando assim a Matriz das Covariâncias (Figura 6), a qual servirá de informação de entrada para a simulação dos dados na fase posterior.

$$r = \frac{Cov(X,Y)}{\sqrt{S_X^2} \times \sqrt{S_Y^2}} \quad (2)$$

$$Cov(X,Y) = r \times \sqrt{S_X^2} \times \sqrt{S_Y^2} \quad (3)$$

Onde r: coeficiente de correlação linear;  $Cov(X,Y)$ : covariância entre X e Y;  $S_X^2$ : variância do X e  $S_Y^2$ : variância do Y. Note que estes cálculos foram realizados para o  $Y_{SS2}$ ,  $X_{C1}$ ,  $X_{C2}$ ,  $X_{C6}$ ,  $X_{C8}$  e  $X_{C4}$ , formando assim a Matriz de Correlações e a Matriz de Covariâncias das cinco variáveis em estudo e da variável resposta precisão de pesagem.

Figura 6 - Matriz de Covariâncias das variáveis a serem simuladas

$$Cov = \begin{matrix} & Y_{SS2} & X_{C1} & X_{C2} & X_{C6} & X_{C8} & X_{C4} \\ \begin{matrix} Y_{SS2} \\ X_{C1} \\ X_{C2} \\ X_{C6} \\ X_{C8} \\ X_{C4} \end{matrix} & \begin{bmatrix} 277,78 & 16,67 & 0,39 & 662,22 & 4,44 & 0,03 \\ 16,67 & 2,78 & 0 & 49,67 & 0 & 0 \\ 0,39 & 0 & 0,001 & 0 & 0 & 4,167E-05 \\ 662,22 & 49,67 & 0 & 2466,78 & 0 & 0 \\ 4,44 & 0 & 0 & 0 & 0,11 & 0 \\ 0,03 & 0 & 4,167E-05 & 0 & 0 & 1,736E-05 \end{bmatrix} \end{matrix}$$

Essas matrizes e as demais informações coletadas com os especialistas serão utilizadas para a realização da simulação e análise das variáveis.

### **3.1.4 Simular os dados ( $X_{Ci}$ 's e $Y_{SS2}$ ) com base nas informações levantadas nos passos 2 e 3**

Os dados foram simulados com base nas especificações-meta (FIGURA 4) e na opinião de especialistas, considerou-se: a Matriz de Covariâncias entre as variáveis explicativas e entre a variável resposta e o relacionamento das variáveis explicativas com a variável. O resultado é um banco de dados normal multivariado de tamanho 100 formado por cinco variáveis relacionadas ao subsistema carro longitudinal de pesagem.

Algumas suposições foram consideradas nessas simulações: (a) As variáveis explicativas ( $X_{Ci}$ 's) têm distribuição Normal; (b) A variável resposta ( $Y_{SS2}$ ) tem distribuição Normal; (c) As variáveis  $X_{Ci}$ 's e  $Y_{SS2}$  têm distribuição Multinormal com as variâncias e covariâncias obtidas no passo 3, sendo  $i = 1, 2, 4, 6, 8$ . A suposição de normalidade das variáveis  $X_{Ci}$ 's (a) foi considerada para atingir aos objetivos deste trabalho, visto que se espera que a balança seja utilizada pelos animais com medidas (pesos) apresentando variações em igual proporção acima ou abaixo de seus valores-alvo. Adicionalmente, essa justificativa pode ser estendida para a variável  $Y_{SS2}$  (b) sendo pertinente assumir que a precisão de pesagem tenha variações proporcionais acima e abaixo do seu valor médio. Conseqüentemente, é razoável supor que este conjunto de variáveis pertença à distribuição multivariada Multinormal (d), uma vez que a distribuição univariada destas variáveis é supostamente Normal (JURAN; GRYNA, 1993). Além disso, técnicas do controle estatístico da qualidade baseiam-se na aproximação para a distribuição normal, pois conforme Montgomery (2004), esta distribuição é considerada, com frequência, como o modelo probabilístico apropriado para variáveis do setor industrial.

Os dados foram simulados com auxílio do *software R 2.6.0* e com base nas suposições anteriormente descritas.

### **3.1.5 Ajustar um modelo de regressão aos dados simulados no passo 4**

O modelo de regressão linear múltipla ajustado para os dados simulados no passo 4, a 1%, é apresentado na Equação 4 e pode ser visualizado também na Figura 7. O modelo ajustado foi gerado no *software R 2.6.0*.

$$Y_{SS2} = 10270 + 1,949Dureza + 0,2355CapacidadePesagem + 18,49Profundidade \quad (4)$$

Figura 7- Modelo de regressão estimado para os dados simulados

Modelo de Análise de Regressão estimado para os dados simulados				
Variáveis	Coefficientes estimados	Erro padrão	Valor t	Pr(> t )
Intercepto	10270	4636	2,214	0,0292 *
Dureza ( $X_{C1}$ )	1,949	0,4234	4,604	0,000013 ***
Perpendicularidade com a referência entre os furos do carro com rolamentos lineares ( $X_{C2}$ )	-22,68	12,41	-1,827	0,0708 .
Capacidade de pesagem ( $X_{C6}$ )	0,2355	0,01419	16,58	< 2e-16 ***
Profundidade do rebaixo do trilho da célula de carga ( $X_{C8}$ )	18,49	1,523	12,136	< 2e-16 ***
Diâmetro interno ( $X_{C4}$ )	-167,1	115,4	-1,448	0,1508

Significativos: 0 \*\*\*\* 0,001 \*\*\* 0,01 \*\* 0,05 \* 0,1 . 1

O modelo estimado apresenta um  $R^2=0,9126$ , isto é, 91,26% da variabilidade da precisão de pesagem pode ser explicada pelo conjunto de variáveis utilizadas no modelo, ou seja, pela  $X_{C6}$ ,  $X_{C1}$  e  $X_{C8}$ . Pela análise de variância verifica-se que o modelo está bem ajustado aos dados (Estatística F = 196,4 e p-valor < 0,001).

Por meio de uma análise adicional verificou-se que os pressupostos do modelo de regressão são atendidos. Assim, o ajuste linear foi adequado, as variâncias são constantes, não há autocorrelação entre os resíduos e os resíduos são normais (Teste de Normalidade *Lilliefors* D = 0,0413 e p-valor = 0,9442), este p-valor indica aderência dos resíduos à normalidade. Mostrando assim, que a Equação 4 é eficaz na predição da variável resposta precisão de pesagem, uma vez que os pressupostos do modelo de regressão linear múltipla foram atendidos.

Cabe comentar que as interações entre as variáveis explicativas não foram consideradas na elaboração do modelo por motivos de simplificação do mesmo. Para estudos futuros sugere-se considerar as interações possíveis, por meio de entrevistas com especialistas a fim de prospectar sobre o tipo de relacionamento entre os  $X_{Ci}$ 's.

### 3.1.6 Identificar os parâmetros críticos por meio da análise de regressão executada no passo 5

Uma vez identificado o modelo estatístico para os dados simulados, procede-se com a identificação dos parâmetros críticos. Segundo o modelo apresentado na Figura 7 e na Equação 4 verifica-se que os parâmetros mais críticos para a precisão de pesagem (g) do produto em estudo são a profundidade do rebaixo do trilho da célula de carga (mm), a dureza (Hc) e a capacidade de pesagem (Kg). Sendo assim, importante monitorar e atuar nestes parâmetros a fim de obter o melhor produto para o mercado.

#### 4. Conclusões

O objetivo deste artigo foi propor de uma abordagem utilizando simulação e análise de regressão para identificação dos parâmetros críticos na fase preliminar à construção do protótipo do produto. Através de um estudo de caso envolvendo uma balança dinâmica de carcaças pôde-se ilustrar a abordagem descrita nesse artigo, utilizando um subsistema do produto como referência.

A abordagem proposta utilizou o conhecimento explícito publicado na literatura e relatórios técnicos de produtos similares e o conhecimento tácito de especialistas na tecnologia e funcionamento do produto para atribuir o relacionamento entre as variáveis relacionadas às partes (SSC's) e estas ao produto final. A partir disto, os graus de relacionamento foram convertidos em correlações entre as variáveis e, mediante suposições, amostras foram simuladas para estimar os pesos das variáveis explicativas sob a variável resposta por meio de um modelo de regressão.

Importante destacar que esta proposta permitiu estimar as variáveis mais influentes na resposta (características demandadas do produto) na fase anterior à construção do protótipo. A análise dos dados seguindo o método proposto neste artigo pode ser replicada com os dados de desempenho do protótipo, estimando novamente os parâmetros da regressão, assim como na etapa do teste do lote piloto do produto. Desta forma é possível monitorar os parâmetros críticos ao longo do PDP e aferir o quanto o modelo estimado com base em dados simulados teve adesão aos modelos estimados com base em dados reais de experimentos com o produto físico.

Portanto, a aplicação desta abordagem proposta capacita aos desenvolvedores de produtos o monitoramento das características críticas da qualidade ao longo das fases do PDP.

#### Referências

- ARAUJO, C. S. Avaliação e seleção de ferramentas de desenvolvimento de produtos. In: XVII ENEGEP - Encontro Nacional de Engenharia de Produção. **Anais...**, Gramado, 1997.
- BACK, N.; OGLIARI, A.; DIAS, A.; DA SILVA, J. C. **Projeto Integrado de Produtos: Planejamento, concepção e modelagem**. 1 ed. Manole: São Paulo, 2008.
- CLARK, K. B.; FUJIMOTO, T. **Product Development Performance: strategic, organization and management in the world auto industry**. Boston-Mass.: Harvard Business School Press, 1991.
- CREVELING, C. ;SLUTSKY, J. ; ANTIS, D. **Design for Six Sigma in Technology and Product Development**. Prentice Hall: New Jersey, 2003.

ECHEVESTE, M. E. S. **Uma Abordagem para Estruturação e Controle do Processo de Desenvolvimento de Produtos**. 2003. 225 f. Tese (Doutorado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2003.

GUJARATI, D. **Econometria Básica**. 3 ed. Makron Books: São Paulo, 2000.

JUDD T. C. Program Level Design for Six Sigma. **Cognition Corporation and SAE International**, 05M-373, 2005.

JURAN, J. M.; GRZYNA, F. M. **Controle da Qualidade: Métodos Estatísticos Clássicos aplicados à Qualidade**. 6 ed. Makron Books: São Paulo, 1993.

MONTGOMERY, D. C. **Introdução ao Controle Estatístico da Qualidade**. 4 ed. LTC: Rio de Janeiro, 2004.

MONTGOMERY, D. C. **Introduction to Linear Regression Analysis**. 4 ed. Wiley-Interscience, 2006.

MONTGOMERY, D. C.; RUNGER, G. **Applied Statistics and Probability for Engineers**. 4 ed. John Wiley and Sons, 2007.

ROZENFELD, H.; FORCELLINI, F.; AMARAL, D. ; SILVA, S.; ALLIPRADINI, D. e SCALICE, R. **Gestão de Desenvolvimento de Produtos: Uma referência para melhoria do processo**. 1 ed. Editora Saraiva, 2006.

ULRICH, K. T.; EPPINGER, S. D. **Product Design and Development**. 2 ed. McGraw-Hill, New York, 2000.

YOUNG R. **The Requirements Engineering Handbook**. Norwood, MA, USA: Artech House. 2003.

VRINAT, M. **Driving Product Development with Critical Parameters: Cognition delivers active requirements management for full product lifecycle**, 2007. CPDA – Collaborative Product Development Associate. Disponível em: <[http://cpd-associates.com/index.cfm?content=subpage&file=include\\_RPPage.cfm&ID=72404138&DOC=194759626](http://cpd-associates.com/index.cfm?content=subpage&file=include_RPPage.cfm&ID=72404138&DOC=194759626)>. Acesso em: 2008.

# **PROPOSAL OF CRITICAL PARAMETERS MANAGEMENT IN DEVELOPMENT OF PRODUCTS TROUGH SIMULATION AND STATISTICAL MODELING**

## **Abstract**

*The management of critical parameters (CPM) is studying the conversion of customer demands in critical specifications for the product allowing the development team to concentrate efforts on the most relevant characteristics of the product since the early stages of Product Development Process (PDP). It is known that as soon as they are defined the critical specifications of the product, this will result in a PDP more consistent and turn into a final product with less chance of repairs in your project. The aim of this paper is to propose an approach using simulation and regression analysis to identify the critical parameters in the preliminary phase before the construction of the prototype product, ie when there is little information about the product. This approach will be presented from a case study involving a new product under development.*

**Key-words:** *Critical Parameters Management, Regression Analysis, PDP.*