

# UMA ESTRATÉGIA PARA ANALISAR RESULTADOS DE UM PROJETO DE EXPERIMENTOS

Viviane Leite Dias de Mattos  
Universidade Católica de Pelotas  
[vldm@atlas.ucpel.tche.br](mailto:vldm@atlas.ucpel.tche.br)

Pedro Alberto Barbetta  
Universidade Federal de Santa Catarina  
[barbetta@inf.ufsc.br](mailto:barbetta@inf.ufsc.br)

Robert Wayne Samohyl  
Universidade Federal de Santa Catarina  
[samohyl@eps.ufsc.br](mailto:samohyl@eps.ufsc.br)

Débora Gomes Machado  
Universidade Católica de Pelotas  
[deboragm@hotmail.com](mailto:deboragm@hotmail.com)

## RESUMO

Cada vez mais, exige-se que as empresas desenvolvam sua tecnologia, visando a obtenção de produtos de qualidade ao menor custo possível. Para tal, o planejamento estatístico projeto de experimentos é uma metodologia extremamente poderosa, identificando os fatores que afetam a média (*efeitos de locação*) e os fatores que afetam a variabilidade (*efeitos de dispersão*) da resposta. O presente trabalho apresenta uma estratégia para analisar resultados de projetos fatoriais do tipo  $2^k$  ou  $2^{k-p}$ , aplicando-a aos resultados de um experimento realizado para avaliar o comportamento da resistência à compressão de concretos moldados com adição de cinza de casca de arroz.

Palavras-chave: Qualidade; Projeto de Experimentos; Efeitos de Locação; Efeitos de Dispersão.

## ABSTRACT

More and more, it is demanded that the companies develop his technology. They may obtain quality products at the lowest possible cost. Project of experiments is a powerful statistical tool, identifying the factors that affect the average (location effects) and the factors that affect the variability (dispersion effects) of the answer. The present work presents a strategy to analyze a  $2k$  or  $2k-p$  factorial designs, applying it to the results of an experiment accomplished to evaluate the behavior of concrete compressive strength with rice husk ash as a mineral admixture. The strategy was evaluated for simulations of Monte Carlo. It showed to be efficient.

Key Words: Quality; Design of Experiments; Location Effects; Dispersion Effects

## 1 INTRODUÇÃO

A busca pela melhoria da qualidade de produtos e processos é uma tarefa freqüentemente executada pelo engenheiro da qualidade que tem, na experimentação estatística, uma de suas principais ferramentas. Segundo Box *et al.* (1986b), uma das causas mais importantes do êxito das empresas japonesas em alcançar alta qualidade com custos compatíveis, são os inúmeros programas experimentais implementados durante a fase de projeto e desenvolvimento de um

produto. Esta metodologia permite avaliar simultaneamente não apenas os efeitos de vários fatores sobre as características funcionais do produto, bem como os efeitos das interações entre estes fatores.

As técnicas clássicas de projeto experimental priorizavam suas ações em fatores controláveis do processo, dando grande importância à média e ao valor-alvo, ou seja, focavam sua análise apenas no valor médio da resposta. Entretanto, o desenvolvimento da Engenharia da Qualidade, alavancado por Taguchi, mostrou que ajustar um valor médio a um valor-alvo é insuficiente para a obtenção dos chamados *sistemas robustos*: sistemas insensíveis a qualquer fonte de variação; existe também a necessidade de diminuir a variabilidade em torno do valor-alvo. Dentro desse enfoque, ao analisar resultados de um experimento, é necessário identificar os fatores que afetam a média (*efeitos de locação*) e os fatores que afetam a variabilidade (*efeitos de dispersão*) da resposta. Diz-se que um fator afeta a média da resposta e, portanto, apresenta *efeito de locação ativo*, quando o valor esperado da resposta for diferente nos níveis estudados desse fator. Um fator afeta a variabilidade da resposta, apresentando *efeito de dispersão ativo*, quando possui variâncias diferentes nas respostas obtidas nos seus diferentes níveis.

A otimização de um sistema produtivo pode ser obtida fazendo com que fatores com efeitos de locação ativos sejam aferidos de forma a aproximar ao máximo a resposta média do valor-alvo; fatores com efeitos de dispersão ativos sejam alocados em níveis que minimizam a variabilidade em torno do valor-alvo; e fatores sem efeitos de locação e de dispersão sejam aferidos nos níveis mais econômicos.

Experimentos fatoriais com dois níveis, completos ou fracionados, incluindo fatores de controle e fatores de ruído, são muito usados em estudos preliminares de programas de qualidade, pois, nesta fase, existe grande quantidade de fatores a serem estudados. Os fatores com maior interferência no processo devem ser selecionados para investigação mais detalhada em etapas posteriores. Assim, nesta fase, é necessário identificar os fatores com efeitos de locação ativos e fatores com efeitos de dispersão ativos.

O presente artigo apresenta uma estratégia, definida a partir de simulações de Monte Carlo, para analisar resultados de projetos fatoriais do tipo  $2^k$  ou  $2^{k-p}$ , com poucas replicações. A estratégia proposta é aplicada aos resultados de um experimento realizado para avaliar o comportamento da resistência à compressão de concretos moldados em betoneiras basculantes, com adição de cinza de casca de arroz.

## 2 FUNDAMENTAÇÃO TEÓRICA

De acordo com Carrol e Ruppert (1988), as técnicas para identificar e analisar fatores com efeitos de locação já foram muito discutidas e apresentam uma teoria consagrada.

Na análise dos resultados de um *experimento com replicações*, a identificação dos fatores ou interações com efeitos de locação *ativos* pode ser realizada por meio de técnicas estatísticas formais, como o teste  $F$  da análise de variância. Estas técnicas exigem, entretanto, que os erros sejam variáveis aleatórias independentes, com distribuição normal, valor esperado nulo e variância constante. Em *experimentos não-replicados*, quando não se conhece a verdadeira variância, é comum utilizar métodos menos formais, como o gráfico de Pareto e o gráfico de probabilidade normal, pois não existe uma estimativa confiável da variância do erro experimental. Nesses processos gráficos, são identificados os efeitos aparentemente significativos. Em ambos os casos, é aconselhável realizar de uma análise exploratória de dados para avaliar a possibilidade de alteração da métrica da variável-resposta.

Para identificar fatores com efeitos de dispersão ativos, vários métodos, envolvendo gráficos, testes de significância e construção de modelos foram propostos nos últimos anos. Em geral, esses métodos medem a variabilidade empregando variâncias amostrais calculadas sobre as replicações (considerando experimentos com replicações); já em experimentos não-replicados, a análise geralmente se baseia nos resíduos quadráticos de um modelo ajustado aos dados.

Os métodos existentes para *experimentos com replicações* são comprovadamente eficientes apenas se existirem muitas replicações, razão pela qual se tornam dispendiosos e, em algumas situações, até inviáveis para o setor industrial, que busca, permanentemente, a redução dos custos de manufatura. Por este motivo, a indústria valoriza os *experimentos não-replicados* que, embora reduzam custos, são superficiais no estudo da variabilidade. Em tal situação, a avaliação da variabilidade é feita pelo *erro residual* (abrange efeitos dos fatores que não entram no modelo da média) e não pelo *erro puro*, razão pela qual o desempenho dos métodos depende muito da qualidade do modelo da média.

### 3 ESTRATÉGIA PARA IDENTIFICAÇÃO DOS EFEITOS ATIVOS

Mattos (2004) propõe uma estratégia para identificar efeitos de locação e de dispersão em experimentos do tipo  $2^k$ , com poucas replicações (duas a quatro). A adoção de projeto experimental com poucas replicações se justifica em função dos custos. O método mais simples para identificar os efeitos de dispersão ativos é através da análise dos logaritmos das variâncias calculadas sobre as replicações, porém, a adequação da análise sobre esta estatística só ocorre em projetos experimentais com mais de cinco replicações, conforme o artigo clássico de Bartlett e Kendall (1946). Por outro lado, o uso de projetos experimentais não-replicados, pode comprometer a identificação correta de efeitos de dispersão ativos.

A estratégia de Mattos (2004) consiste em, inicialmente, identificar os efeitos de locação significativos e ajustar um modelo para a média por meio do método dos mínimos quadrados ordinários (MQO), avaliando a qualidade deste por meio do gráfico de probabilidade normal e a possibilidade de utilização de transformações matemáticas.

Se for possível encontrar um modelo de locação bem ajustado aos dados, estimam-se os efeitos de dispersão pelo método de Box e Meyer (1986), que aqui será denominado de BM. Originalmente este método foi proposto para projeto de experimentos não-replicados. Em Nair e Pregibon (1988) e em Mattos (2004) o método de Box e Meyer foi adaptado para projeto de experimentos com replicações. Por este método, cada efeito de dispersão é estimado pelo logaritmo do quociente entre a média aritmética dos resíduos quadráticos dos ensaios com sinal + e a média aritmética dos resíduos quadráticos dos ensaios com sinal – do projeto  $2^k$ , sendo a identificação dos efeitos ativos feita pelo gráfico de probabilidade normal. Se forem encontrados mais de um efeito de dispersão, situação em que o método BM pode não ser válido (Brenneman e Nair, 2001), refaz-se a análise pelo método aqui denominado de H (baseado em Harvey, 1976), segundo o qual os efeitos de dispersão são estimados por meio do logaritmo de quociente entre médias geométricas de resíduos quadráticos, identificando os ativos também pelo gráfico de probabilidade normal. Os estimadores dos efeitos, pelo método H, correspondem aos coeficientes que se obtém quando se aplica o método dos mínimos quadrados sobre os logaritmos dos resíduos quadráticos.

Se houver dúvidas quanto à adequação do modelo de locação, estimam-se os efeitos de dispersão com base em variâncias amostrais (calculadas sobre as replicações). Inicialmente é utilizado o método R (Nair e Pregibon, 1988), que é baseado no logaritmo do quociente entre médias aritméticas de variâncias amostrais (similar ao método de Box e Meyer). Se forem encontrados mais de um efeito de dispersão, refaz-se a análise pelo método S (Nair e Pregibon, 1988), que é baseado no logaritmo do quociente entre médias geométricas de variâncias (similar ao método de Harvey).

Quando forem identificados efeitos de dispersão ativos, o modelo de locação pode ser aprimorado com o método de estimação dos mínimos quadrados generalizados (MQG), usando o inverso da variância como peso em cada parcela da soma de quadrados.

### 4 ESTUDO DE CASO

A estratégia foi aplicada em um experimento planejado na forma de um projeto fatorial completo com cinco fatores (*A*, *B*, *C*, *D* e *E*), ensaiados em dois níveis (-1 e +1), sintetizados na Tabela 1. A amostra foi composta por 96 ensaios, pois, em cada uma das 32 condições

experimentais, foram realizadas três replicações.

Espera-se que uma menor quantidade de água ( $A=-1$ ), a utilização da adição de cinza de casca de arroz ( $B=1$ ), um maior tempo de mistura ( $C=1$ ) desde que não ultrapasse 3 minutos e o adensamento mecânico ( $D=1$ ) aumentem a resistência média do concreto. Também se espera que, aos 28 dias ( $E=1$ ), o concreto apresente maior resistência média.

**TABELA 1** – Descrição dos fatores e níveis utilizados no experimento.


Fatores		Nível inferior (-1)	Nível superior (1)
Relação água/aglomerante	<i>A</i>	0,35	0,60
Quantidade de adição (%)	<i>B</i>	0	10
Tempo de mistura (segundos)	<i>C</i>	100	300
Tipo de adensamento	<i>D</i>	manual	mecânico
Idade (dias)	<i>E</i>	03	28

Inicialmente, buscou-se identificar os efeitos de locação ativos para ajustar um modelo, por meio do método MQO, aplicado aos valores da resistência à compressão, sendo consideradas interações de até terceira ordem. Um teste *F* identifica os fatores *A*, *D* e *E*, além das interações *AE* e *BCD*, como apresentando efeitos significativos. O modelo de locação obtido por mínimos quadrados foi:

$$\hat{\mu}_y = 42,422 - 10,488A - 2,330D + 1,842E + 1,456AE - 1,292BCD. \quad (1)$$


com coeficiente de determinação  $R^2 = 0,849$ . A significância desse modelo foi verificada pelo teste *F* ( $F = 101,63$ ;  $df_1 = 5$ ;  $df_2 = 90$ ;  $valor-p < 0,0001$ ). Como o experimento apresenta replicações, também foi aplicado um teste de falta de ajuste ( $F = 1,56$ ;  $df_1 = 26$ ;  $df_2 = 64$ ;  $valor-p = 0,0754$ ), mostrando que a falta de ajuste não é significativa ao nível de significância de 5%. Embora os resultados dos testes foram satisfatórios, no teste de falta de ajuste o *valor-p* foi muito baixo, perto do ponto de corte.

A análise foi complementada pela construção de dois gráficos: um gráfico de resíduos, relacionando estimativas de resíduos com os correspondentes valores preditos (gráfico (a) da Figura 1) e um de probabilidade normal desses resíduos (gráfico (b) desta mesma figura). O gráfico (a) sugere a existência de maior variabilidade entre os resíduos correspondentes a maiores valores preditos, enquanto o gráfico (b) sugere que esses resíduos seguem aproximadamente uma distribuição normal.



**FIGURA 1** – Diagrama de dispersão de valores preditos e resíduos e gráfico de probabilidade normal dos resíduos do modelo descrito na equação 1.

De acordo com Nair e Pregibon (1986), antes de identificar os fatores que apresentam efeitos ativos, é necessário definir o quanto a variância depende da média, porque, se existir dependência, a variabilidade do processo é completamente definida pela proximidade da média ao valor alvo e nada pode ser feito para minimizá-la. Um diagrama de dispersão, relacionando as médias aritméticas e os desvios padrões em cada condição experimental (calculados sobre as replicações) sugere a existência de correlação positiva entre estas duas estatísticas (Figura 2), confirmada pelo coeficiente de correlação de Pearson ( $R = 0,447$ ;  $\text{valor-}p = 0,010$ ). Nessas condições, a qualidade de um modelo ajustado pode ser melhorada se a métrica da resposta for alterada por uma transformação matemática que estabilize a variância, o que deve ocorrer usando a transformação logarítmica.



**FIGURA 2** – Diagrama de dispersão entre as médias e os desvios padrões, calculados sobre as replicações dos dados originais.


Após a transformação dos dados, um teste  $F$  é novamente aplicado, considerando as interações de até terceira ordem, sendo identificados como significativos, além dos efeitos principais de  $A$ ,  $D$  e  $E$ , os efeitos das interações  $AE$ ,  $BC$  e  $BCD$ . Aplicando MQO, obtém-se o seguinte modelo de locação:

$$\hat{\mu}_{\ln y} = 3,706 - 0,253A - 0,055D + 0,053E + 0,023AC - 0,051AE + 0,022BC - 0,022BCD \quad (2)$$


com coeficiente de determinação  $R^2 = 0,882$ . O modelo ajustado é altamente significativo ( $F = 94,25$ ;  $df_1 = 7$ ;  $df_2 = 88$ ;  $\text{valor-}p < 0,0001$ ) e não há falta de ajuste se considerar nível de significância de 5% ( $F = 1,41$ ;  $df = 24$ ;  $df_2 = 64$ ;  $\text{valor-}p = 0,1379$ ). Comparando com os resultados do modelo anterior, nota-se ligeira melhoria, o que também se verifica comparando os gráficos da Figura 3 com os da Figura 2.

Entre os modelos analisados, o de melhor qualidade parece ser o representado pela equação 2, razão pela qual a análise é realizada com dados transformados. Entretanto, embora este modelo tenha apresentado resultado satisfatório no teste de significância, o valor- $p$  associado ao teste de falta de ajuste ainda está próximo do nível usual de significância: 5%. Como a inferência sobre efeitos de dispersão é muito influenciada pela qualidade do modelo de locação ajustado, optou-se por avaliá-los por meio de métodos que se baseiam em variâncias amostrais.

Seguindo a estratégia utilizada, a identificação dos efeitos de dispersão é feita pelo método  $R$  que os estima a partir de quocientes entre médias aritméticas de variâncias amostrais. Os resultados encontrados, mostrados no gráfico de probabilidade normal na Figura 4, sugerem a existência de apenas um efeito de dispersão: o efeito da interação  $AB$ .



**FIGURA 3** – Diagrama de dispersão de valores preditos e resíduos, e gráfico de probabilidade normal dos resíduos, com base no modelo ajustado da equação 2.



**FIGURA 4** – Gráfico de probabilidade normal das estimativas dos efeitos de dispersão: método *R*.

A Figura 4 indica claramente que a interação *A\*B* deve ser considerada com efeito de dispersão ativo. Fazendo a modelagem do logaritmo neperiano das variâncias amostrais das variáveis transformadas (aplicando MQO), resulta no seguinte modelo ajustado para a variância:

$$\hat{\sigma}_{\ln y}^2 = \exp\{-5,47 + 0,49AB\} \tag{3}$$

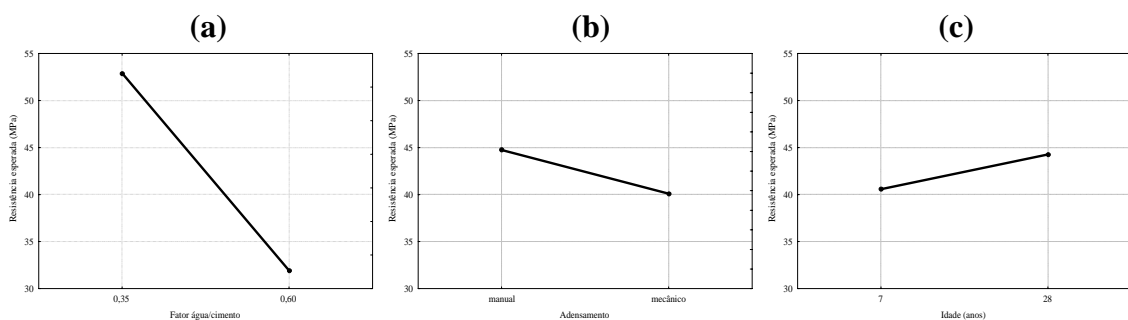
Essa equação permite prever a variância em cada uma das 32 condições experimentais. Agora, o modelo de locação pode ser refinado pelo método dos mínimos quadrados generalizados (*MQG*), sendo estimado um novo modelo para a média em que os coeficientes são estimados pela minimização de uma soma de quadrados dos erros, cujos termos são ponderados pelos inversos das variâncias preditas pelo modelo 3. Na construção deste novo modelo, a interação de terceira ordem deixa de ser significativa, o que é interessante em termos práticos. O novo modelo da média, ajustado por *MQG*, é:

$$\hat{\mu}_{\ln y} = 3,706 - 0,253A - 0,055D + 0,053E + 0,023AC - 0,051AE + 0,022BC \tag{4}$$

A análise permitiu identificar que a resistência à compressão do concreto está relacionada com o fator água/cimento (Fator *A*), com a forma de adensamento (Fator *D*) e com sua idade (Fator *E*), conforme evidenciam os gráficos (a), (b) e (c) da Figura 5. Maiores valores são esperados aos 28 dias para corpos-de-prova moldados com menor quantidade de água e adensados manualmente.

Os resultados encontrados para a quantidade de água e idade estão dentro do previsto. Apenas o resultado relativo ao adensamento não foi o esperado: o adensamento mecânico, teoricamente, deveria fornecer melhores resultados. Isto talvez se deva ao fato de, no ensaio, o adensamento ser realizado em um corpo-de-prova de tamanho pequeno, mais adequado ao tamanho do soquete metálico. O tamanho do vibrador de imersão torna a execução do adensamento mais difícil.


Também é constatado que o fator A (água/cimento) interage com os fatores C (tempo de mistura) e E (idade), conforme os gráficos (a) e (b) da Figura 6. O gráfico (a) dessa figura mostra que, quando é utilizada menor quantidade de água (Fator A no nível -1), um tempo de mistura menor fornece um resultado melhor, o mesmo não acontecendo se for utilizada maior quantidade de água (Fator A no nível +1). O gráfico (b) evidencia que, quando é utilizada menor quantidade de água (Fator A no nível -1), o concreto enrijece mais rapidamente, adquirindo, aos sete dias, uma resistência quase igual à resistência aos vinte e oito dias, o mesmo não acontecendo ao ser utilizada maior quantidade de água (Fator A no nível +1).




**FIGURA 5** – Efeito principal dos fatores A, D e E sobre a resistência à compressão.

O fator B (utilização da adição), foco deste estudo, interage com o fator C (tempo de mistura), conforme mostra o gráfico (c) da Figura 6. Quando a adição não é utilizada (Fator B no nível -1), menos tempo de mistura fornece maior resistência, o mesmo não acontecendo quando a adição é utilizada (Fator B no nível +1).

A variabilidade da resistência à compressão é influenciada apenas pela interação AB (fator água/cimento e uso de adição), conforme mostra o gráfico da Figura 7. Quando é usado o fator água/cimento 0,35 (Fator A no nível -1), a variabilidade é menor nos corpos-de-prova que utilizaram adição (Fator B no nível +1), enquanto que quando é usado o fator água/cimento 0,60 (Fator A no nível +1), a variabilidade é menor nos corpos-de-prova que moldados sem adição (Fator B no nível -1). Isto talvez ocorra em função dos efeitos pozolânico e *microfiller* decorrentes do uso da adição na mistura ficarem mais evidentes quando uma menor quantidade de água é utilizada.



**FIGURA 6** – Efeito das interações A\*C, A\*E e B\*C sobre a resistência à compressão.



**FIGURA 7** – Efeito da interação  $A*B$  sobre a variabilidade nos resultados da resistência à compressão.

## 5 CONSIDERAÇÕES FINAIS

Este artigo apresenta uma estratégia para identificar efeitos de locação e dispersão em dados oriundos de experimentos com poucas replicações, incluindo a construção de modelos para a média e a variância de um processo.

A metodologia utilizada inicia com a identificação de efeitos de locação pelos métodos clássicos. Após a avaliação da qualidade do modelo encontrado, feita por meio de técnicas formais e técnicas gráficas, é avaliada a necessidade de mudança da métrica da resposta. No estudo de caso aqui descrito, a transformação logarítmica mostrou-se adequada. Após a transformação dos dados, como o modelo ainda não se ajustou muito bem aos dados, a existência de efeitos de dispersão é avaliada por meio do método  $R$ , proposto por Nair e Pregibon (1988). Realiza-se, então, o refinamento do modelo de locação por meio do método dos mínimos quadrados generalizados ( $MQG$ ).

Na literatura são descritas metodologias mais avançadas para os mesmos propósitos, como a que se baseia em modelos lineares generalizados conjuntos (*joint GLMs*), conforme descrito em Lee e Nelder (2003) e Robinson (2006). Contudo, são procedimentos mais complexos e dependem de pacotes computacionais específicos.

O principal objetivo da realização do experimento com concretos, descrito na seção 4, foi avaliar o desempenho do concreto moldado com a adição de cinza de casca de arroz, bem como relacioná-lo com alguns parâmetros de seu processo produtivo. A análise dos resultados mostrou que a hipótese de esta adição aumentar a resistência à compressão do concreto não é comprovada, mas que ela interage com o tempo de mistura, interferindo no resultado médio esperado da resistência à compressão, e com o fator água/cimento, interferindo na variância esperada da resistência à compressão. Quando é utilizada a adição cinza de casca de arroz, o tempo de mistura do concreto deve ser maior para obtenção de uma maior resistência. A utilização desta adição traz maiores benefícios à mistura, propiciando o aparecimento de maior homogeneidade quando é utilizada menos água na preparação da mistura.

Esse estudo mostrou a importância do conhecimento do comportamento da variabilidade e sua interferência no comportamento da média, além de evidenciar o benefício de utilização de transformações matemáticas em uma análise estatística de dados para obtenção de resultados mais fidedignos. O fato de não ter sido possível encontrar um modelo de boa qualidade para a média talvez possa ser atribuído ao fato de não existência de um modelo linear relacionando os fatores considerados no experimento e sua resposta.

## 6 BIBLIOGRAFIA

- [1] Barbetta PA, Ribeiro JLD, Samohyl RW. Variance regression models in experiments with few replications. *Quality and Reliability Engineering International*, 2000 **16**: 397- 404.
- [2] Bartlett MS, Kendall, DJ. The statistical analysis of variance-heterogeneity and the logarithmic transformation. *Journal of the Royal Statistical Society, Ser B*, 1946 **8**: 128-138.



- [3] Brenneman WA, Nair VN. Methods for identifying dispersion effects in unreplicated factorial experiments: A critical analysis and proposed strategies. *Technometrics*, 2001 **43**: 388 - 405.
- [4] Box GEP, Meyer RD. Dispersion effects from fractional design. *Technometrics*, 1986 **28**:19-27.
- [5] Box GEP, Meyer RD. An analysis for unreplicated fractional factorial. *Technometrics*, v.28, n1, p.11-18, 1986b.
- [6] Carrol, R.J.; Ruppert, D. *Transformation and weighting in regression*. USA: Chapman and Hall, 1988. 245p.
- [7] Harvey AC. Estimating regression models with multiplicative heteroscedasticity. *Econometrica*, 1976 **44**(3): 461- 465.
- [8] Lee, Y. e Nelder, J. A. – Robust design via generalized linear models. *Journal of Quality Technology*, 2003, v. 35, n. 1.
- [9] Mattos VLD. Identificação de efeitos de dispersão em experimentos com poucas replicações. Tese (Engenharia de Produção). Universidade Federal de Santa Catarina, Florianópolis, 2004. [www.inf.ufsc.br/~barbetta/publicacoes.html](http://www.inf.ufsc.br/~barbetta/publicacoes.html).
- [10] Mattos VLD; Barbetta, P.A.; Samohyl, R.W. Identificação de efeitos de dispersão em experimentos fatoriais  $2^k$  e  $2^{k-p}$ . *Produção*, v.14, n2, 2004. 36-46.
- [11] Montgomery DC. *Design and analysis of experiments*, 6 ed., John Wiley: New York, 2005.
- [12] Nair VN, Pregibon D. A data analysis strategy for quality engineering experiments. *AT&T Technical Journal*, 1986: **65**: 73-84.
- [13] Nair VN, Pregibon D. Analysing Dispersion Effects from Replicated Factorial Experiments. *Technometrics*, 1988 **30**: 247-257.
- [14] Nair VN, Pregibon D. A Data Analysis Strategy for Quality Engineering Experiments. *TAT&T Technical Journal*, 1986 **30**: 247-257.
- [15] Robinson, T. J.; Wulff, S. S.; Montgomery, D. C. e Khuri, A. I. – Robust parameter design using generalized linear mixed models. *Journal of Quality Technology*, 2006, v. 38, n. 1.