



28 · 29 · 30  
de OUTUBRO

**XII SEGET**  
SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA  
TEMA 2015  
Otimização de Recursos e Desenvolvimento



# Gráfico $T^2$ de Hotelling com esquema especial de amostragem para processos bivariados e autocorrelacionados

Roberto Campos Leoni  
rleoni@yahoo.com.br  
AEDB

**Resumo:** Este artigo propõe o emprego do gráfico de  $T^2$  com a estratégia de amostragem composta para o monitoramento do vetor de médias de processos bivariados com observações autocorrelacionadas. O emprego da estratégia de amostragem composta consiste em reagrupar elementos dos dois últimos subgrupos racionais selecionados do processo. O objetivo principal da técnica proposta é reduzir o efeito negativo da autocorrelação no desempenho do gráfico de controle de  $T^2$ . Quando as duas variáveis são autocorrelacionadas, a estratégia de amostragem composta sempre melhora o desempenho do gráfico de  $T^2$ , contudo, a estratégia não é recomendada para processos em que apenas uma das variáveis é autocorrelacionada e robusta a presença de causas especiais.

**Palavras Chave:** Gráfico de controle -  $T^2$  de Hotelling - Autocorrelação - Amostragem - Processos bivariados



## 1. INTRODUÇÃO

Métodos estatísticos desempenham um papel central no monitoramento da variabilidade de características de qualidade relacionadas a processos de manufatura ou serviços. Na década de 30, Shewhart (1931) lançou as bases para emprego dos gráficos de controle e, ainda naquela época, reconheceu a necessidade de monitorar processos considerando o controle multivariado.

Quando os gráficos de controle foram criados, destinavam-se à indústria de partes discretas e não havia praticamente nenhum grau de automação (COSTA; EPPRECHT; CARPINETTI, 2005; MONTGOMERY, 2009).

Uma das hipóteses básicas para uso de gráficos de controle é a independência entre observações ao longo do tempo. Quando essa hipótese é violada, tem-se um processo com observações autocorrelacionadas. Processos contínuos e por batelada são extremamente frequentes na indústria química e metalúrgica. Tais processos raramente produzem observações independentes (COSTA; EPPRECHT; CARPINETTI, 2005).

A violação da hipótese de independência não se restringe a processos contínuos ou por batelada. Processos discretos altamente automatizados também costumam apresentar observações autocorrelacionadas (COSTA; EPPRECHT; CARPINETTI, 2005).

A hipótese de independência entre as observações de uma variável pode ser violada pelas altas taxas de amostragem empregadas na seleção de elementos que compõem a amostra segundo o instante de fabricação, ou seja, quando as medidas das observações são realizadas em um curto espaço de tempo (KIM; JITPITAKLERT; SUKCHOTRAT, 2010).

Alguns trabalhos sugeriram a adoção de estratégias de amostragem para reduzir o efeito negativo da autocorrelação no desempenho do gráfico de controle de  $\bar{X}$ .

Costa e Castagliola (2011) empregaram a estratégia de amostragem em que os elementos da amostra são coletados de forma sistemática da linha de produção. Eles mostraram que o efeito da autocorrelação pode ser reduzido selecionando itens não vizinhos de acordo com o instante em que são produzidos.

Franco et al. (2013) introduziram a estratégia de amostragem composta. Nesta estratégia os elementos das amostras são oriundos de dois subgrupos racionais vizinhos. Os resultados comprovaram que a estratégia de amostragem composta é superior a estratégia de amostragem sistemática quando há alto grau de autocorrelação na variável. Recentemente, Franco et al. (2014) também investigaram o projeto econômico-estatístico para o gráfico de  $\bar{X}$  com a estratégia de amostragem sistemática.

Em todos esses trabalhos, as observações das características de qualidade  $X$  são descritas por um modelo autoregressivo de primeira ordem AR (1).

Neste artigo, considerou-se o uso do gráfico de  $T^2$  para controle do vetor de médias de processos bivariados cujas observações são representadas pelo modelo multivariado autoregressivo de primeira ordem - VAR (1). Para reduzir o efeito negativo da autocorrelação no desempenho do gráfico de  $T^2$ , propomos o emprego da estratégia de amostragem composta.

A próxima seção apresenta o modelo VAR (1) e a matriz de variância-covariância do vetor de médias amostrais quando as amostras são selecionadas de acordo com o princípio de formação de subgrupos racionais. Na seção 3, obteve-se a matriz de variância-covariância do vetor de médias amostrais com a estratégia de amostragem composta. As propriedades estatísticas do gráfico de  $T^2$  e o efeito da autocorrelação no desempenho do gráfico de  $T^2$  são



apresentados nas seções 4 e 5. Na seção 6, descreve-se um exemplo ilustrativo e algumas conclusões e considerações finais são apresentadas na seção 7.

## 2. O MODELO VAR (1) E A MATRIZ DE VARIÂNCIA-COVARIÂNCIA DO VETOR DE MÉDIAS AMOSTRAIS

A hipótese de independência é violada em muitos processos de manufatura. Nesse caso, vetores autoregressivos de primeira ordem – VAR (1) são usados para modelar processos multivariados com correlação temporal entre observações de uma mesma variável e correlação entre observações de diferentes características de qualidade (ARKAT; NIAKI; ABBASI, 2007; BILLER; NELSON, 2003; HUANG; BISGAARD; XU, 2013; HWRANG; WANG, 2010; ISSAM; MOHAMED, 2008; JARRETT; PAN, 2007; KALGONDA; KULKARNI, 2004; KALGONDA, 2012; KIM; JITPITAKLERT; SUKCHOTRAT, 2010; MASTRANGELO; FORREST, 2002; NIAKI; DAVOODI, 2009).

O modelo autoregressivo multivariado de primeira ordem, VAR(1), é dado por:

$$\mathbf{X}_t - \boldsymbol{\mu} = \Phi(\mathbf{X}_{t-1} - \boldsymbol{\mu}) + \mathbf{e}_t \quad (1)$$

sendo  $\mathbf{X}_t = (x_{1t}, \dots, x_{pt})^T$  o vetor de dados de ordem  $p \times 1$ ;  $\boldsymbol{\mu}_0 = (\mu_{01}, \dots, \mu_{0p})^T$  o vetor de médias de ordem  $p \times 1$ ,  $\Phi$  uma matriz com os parâmetros autoregressivos de ordem  $p \times p$  e  $\mathbf{e}_t = (e_{1t}, \dots, e_{pt})^T$  são vetores de erros aleatórios independentes de ordem  $p \times 1$  com distribuição normal multivariada de média zero e matriz de variância-covariância  $\Sigma_e$ .

De acordo com Kalgonda and Kulkarni (2004), a matriz de variância-covariância de  $\mathbf{X}_t$  é obtida por:

$$\Gamma = \Phi \Gamma \Phi^T + \Sigma_e \quad (2)$$

Considerou-se neste trabalho o caso particular em que  $p=2$  para estudar o efeito da correlação e da autocorrelação no desempenho do gráfico  $T^2$  de Hotelling. Quando  $p=2$ , os elementos de  $\Phi$  e  $\Sigma_e$  são representados por:

$$\Phi = \begin{pmatrix} a & c \\ d & b \end{pmatrix} \quad (3)$$

$$\Sigma_e = \begin{pmatrix} \sigma_{e_x}^2 & \sigma_{e_{xy}} \\ \sigma_{e_{xy}} & \sigma_{e_y}^2 \end{pmatrix} = \begin{pmatrix} \sigma_{e_x}^2 & \rho \sigma_{e_x} \sigma_{e_y} \\ \rho \sigma_{e_x} \sigma_{e_y} & \sigma_{e_y}^2 \end{pmatrix} \quad (4)$$

sendo  $\rho$  a correlação entre X e Y.

Quando  $\Phi = \text{diag}(a, b)$ , segue das equações (2) e (4) a relação:

$$\Gamma = \begin{pmatrix} \sigma_X^2 & \sigma_{XY} \\ \sigma_{XY} & \sigma_Y^2 \end{pmatrix} = \begin{pmatrix} (1-a^2)^{-1} \sigma_{e_x}^2 & (1-ab)^{-1} \sigma_{e_{xy}} \\ (1-ab)^{-1} \sigma_{e_{xy}} & (1-b^2)^{-1} \sigma_{e_y}^2 \end{pmatrix} \quad (5)$$

Leoni, Machado e Costa (2014) obtiveram a matriz de variância-covariância  $\Gamma_{\bar{X}}$  do vetor de médias amostrais  $\bar{X}$  quando os elementos das amostras são selecionados de acordo com o conceito de subgrupos racionais:



$$\Gamma_{\bar{X}} = \begin{pmatrix} \zeta_{\bar{X}}^2 & \zeta_{\bar{X}Y} \\ \zeta_{\bar{X}Y} & \zeta_{\bar{Y}}^2 \end{pmatrix} = \begin{pmatrix} \frac{\sigma_{\bar{X}}^2}{n} \left[ 1 + \frac{2}{n} \sum_{j=1}^{n-1} (n-j)a^j \right] & \frac{\sigma_{\bar{X}Y}}{n} \left[ 1 + \frac{1}{n} \sum_{j=1}^{n-1} (n-j)a^j + \frac{1}{n} \sum_{j=1}^{n-1} (n-j)b^j \right] \\ \frac{\sigma_{\bar{X}Y}}{n} \left[ 1 + \frac{1}{n} \sum_{j=1}^{n-1} (n-j)a^j + \frac{1}{n} \sum_{j=1}^{n-1} (n-j)b^j \right] & \frac{\sigma_{\bar{Y}}^2}{n} \left[ 1 + \frac{2}{n} \sum_{j=1}^{n-1} (n-j)b^j \right] \end{pmatrix} \quad (6)$$

sendo  $n$  o tamanho das amostras.

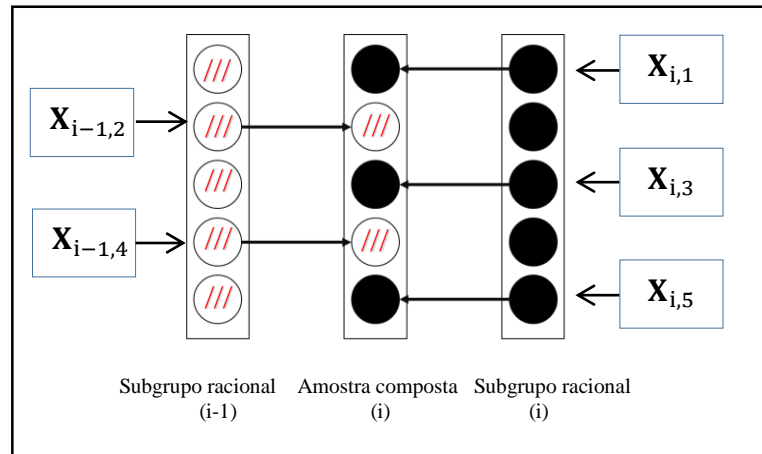
A equação (6) é função de  $\Phi$ ,  $n$  e  $\Sigma_e$ . Para um processo bivariado,  $\Gamma_{\bar{X}}$  pode ser generalizado por:

$$\Gamma_{\bar{X}} = \begin{pmatrix} \zeta_{\bar{X}}^2 & \zeta_{\bar{X}Y} \\ \zeta_{\bar{X}Y} & \zeta_{\bar{Y}}^2 \end{pmatrix} = \frac{1}{n^2} \left\{ (\sum_{i=0}^{n-1} \Phi^i) \Gamma (\sum_{i=0}^{n-1} \Phi^i)^T + \sum_{k=1}^{n-1} \left[ (\sum_{i=1}^k \Phi^{i-1}) \Sigma_e (\sum_{i=1}^k \Phi^{i-1})^T \right] \right\} \quad (7)$$

É bem conhecido que a autocorrelação gera um impacto negativo no desempenho do gráfico de controle de  $\bar{X}$ ; Leoni, Machado e Costa (2014) provaram que a autocorrelação também reduz o poder do gráfico de  $T^2$  na sinalização de causas especiais que atuam no vetor de médias de um processo. A partir de  $\Gamma_{\bar{X}}$  é possível avaliar o real efeito da autocorrelação no desempenho do gráfico de controle de  $T^2$ .

### 3. ESTRATÉGIA DE AMOSTRAGEM COMPOSTA

A estratégia de amostragem composta consiste em selecionar unidades de dois subgrupos racionais consecutivos (FRANCO et al., 2013). Para ilustrar o emprego desta técnica, considere a Figura 1 que apresenta dois subgrupos racionais consecutivos de tamanho 5 ( $n=5$ ) e a amostra composta. Uma amostra composta  $i$  é formada com unidades do subgrupo racional  $i$  (primeiro, terceiro e quinto elementos de acordo com o instante em que os elementos são selecionados da linha de produção) e unidades do subgrupo racional anterior  $i-1$  (segundo e quarto elementos). Os elementos restantes do subgrupo racional corrente, isto é, segundo e quarto elementos, são utilizados para formar a próxima amostra composta  $i+1$  e assim por diante.



**Figura 1:** Amostra composta.

**Fonte:** Adaptado de Franco et al. (2013)

O vetor de médias da amostra composta  $i$  é dado por:

$$\bar{\mathbf{M}}_i = \frac{n_e}{n} \cdot \underbrace{\frac{1}{n_e} \sum_{t=1}^{n_e} \mathbf{X}_{i-1,2t}}_{\bar{\mathbf{Y}}_{i-1}} + \frac{n_o}{n} \cdot \underbrace{\frac{1}{n_o} \sum_{t=1}^{n_o} \mathbf{X}_{i,2t-1}}_{\bar{\mathbf{Z}}_i} \quad (8)$$

sendo:  $\mathbf{X}_{k,l}$  o  $l$ -ésima vetor com observações do  $k$ -ésimo subgrupo racional;  $\bar{\mathbf{Y}}_{i-1}$  o vetor de médias das unidades de ordem par selecionadas do subgrupo racional  $i-1$ , e  $\bar{\mathbf{Z}}_i$  o vetor de



médias das unidades de ordem ímpar selecionadas do subgrupo racional  $i$ . Quando  $n$  é par,  $n_e = n_o = n/2$ , e quando  $n$  é ímpar,  $n_e = (n - 1)/2$  e  $n_o = (n + 1)/2$ .

Admitindo-se que  $\bar{Y}_{i-1}$  e  $\bar{Z}_i$  são independentes, a matriz de variância-covariância  $\Gamma_{\bar{M}}$  do vetor de médias da amostra composta  $\bar{M}$  é dada por:

$$\Gamma_{\bar{M}} = \begin{pmatrix} \zeta_X^2 & \zeta_{XY} \\ \zeta_{XY} & \zeta_Y^2 \end{pmatrix} = \left(\frac{n_e}{n}\right)^2 \cdot \Gamma_{\bar{Y}} + \left(\frac{n_o}{n}\right)^2 \cdot \Gamma_{\bar{Z}} \quad (9)$$

sendo  $\Gamma_{\bar{Y}}$  e  $\Gamma_{\bar{Z}}$  são, respectivamente, a matriz de variância-covariância do vetor de médias das amostras selecionadas do subgrupo racional  $i-1$  e subgrupo racional  $i$ . De acordo com o modelo VAR (1):

$$\Gamma_{\bar{Z}} = \frac{1}{n_o^2} \left\{ \left( \sum_{l=0}^{n_o-1} \Phi^{2l} \right) \Gamma \left( \sum_{l=0}^{n_o-1} \Phi^{2l} \right)^T + \sum_{k=1}^{n_o-1} \left\{ \sum_{j=1}^2 \left[ \left( \sum_{l=1}^k \Phi^{2l-j} \right) \Sigma_e \left( \sum_{l=1}^k \Phi^{2l-j} \right)^T \right] \right\} \right\} \quad (10)$$

e

$$\Gamma_{\bar{Y}} = \frac{1}{n_e^2} \left\{ \left( \sum_{l=0}^{n_e-1} \Phi^{2l+1} \right) \Gamma \left( \sum_{l=0}^{n_e-1} \Phi^{2l+1} \right)^T + \left( \sum_{l=0}^{n_e-1} \Phi^{2l} \right) \Sigma_e \left( \sum_{l=0}^{n_e-1} \Phi^{2l} \right)^T + \sum_{k=1}^{n_e-1} \left\{ \sum_{j=1}^2 \left[ \left( \sum_{l=1}^k \Phi^{2l-j} \right) \Sigma_e \left( \sum_{l=1}^k \Phi^{2l-j} \right)^T \right] \right\} \right\} \quad (11)$$

Para ilustrar como se obtém a matriz  $\Gamma_{\bar{M}}$  considere o caso em que  $n=5$ ,  $\Phi = \begin{pmatrix} 0,3 & 0 \\ 0 & 0,5 \end{pmatrix}$  e  $\Sigma_e = \begin{pmatrix} 1 & 0,5 \\ 0,5 & 1 \end{pmatrix}$ . De acordo com as expressões (8), (10) e (11):

$$\bar{M}_i = \frac{2}{5} \times \frac{1}{2} \underbrace{\sum_{t=1}^2 \mathbf{X}_{i-1,2t}}_{\bar{Y}_{i-1}} + \frac{3}{5} \times \frac{1}{3} \underbrace{\sum_{t=1}^3 \mathbf{X}_{i,2t-1}}_{\bar{Z}_i}$$

$$\Gamma_{\bar{Y}} = \frac{1}{4} [(\Phi + \Phi^3)\Gamma(\Phi + \Phi^3)' + (I + \Phi^2)\Sigma_e(I + \Phi^2)' + \Phi\Sigma_e\Phi' + \Sigma_e]$$

$$\Gamma_{\bar{Y}} = \begin{pmatrix} 0,5989 & 0,3441 \\ 0,3441 & 0,8333 \end{pmatrix} e$$

$$\Gamma_{\bar{Z}} = \frac{1}{9} \left[ (I + \Phi^2 + \Phi^4)\Gamma(I + \Phi^2 + \Phi^4)' + (\Phi + \Phi^3)\Sigma_e(\Phi + \Phi^3)' + (I + \Phi^2)\Sigma_e(I + \Phi^2)' + \Phi\Sigma_e\Phi' + \Sigma_e \right]$$

$$\Gamma_{\bar{Z}} = \begin{pmatrix} 0,4122 & 0,2451 \\ 0,2451 & 0,6111 \end{pmatrix}$$

Finalmente, com a equação (9):

$$\Gamma_{\bar{M}} = \left(\frac{2}{5}\right)^2 \Gamma_{\bar{Y}} + \left(\frac{3}{5}\right)^2 \Gamma_{\bar{Z}} = \begin{pmatrix} 0,2442 & 0,1433 \\ 0,1433 & 0,3533 \end{pmatrix}$$

A inversa da matriz de variância-covariância  $\Gamma_{\bar{M}}$  é utilizada para calcular a estatística de monitoramento do gráfico  $T^2$  de Hotelling.

#### 4. PROPRIEDADES ESTATÍSTICAS DO GRÁFICO $T^2$ DE HOTELLING COM AMOSTRAS COMPOSTAS

Quando a estratégia de amostras compostas é usada, a estatística de monitoramento do gráfico de  $T^2$  é dada por:

$$T_t^2 = (\bar{\mathbf{X}} - \boldsymbol{\mu}_0)^T \Gamma_{\bar{M}}^{-1} (\bar{\mathbf{X}} - \boldsymbol{\mu}_0) \quad (12)$$



sendo  $\boldsymbol{\mu}_0 = (\mu_{0X}, \mu_{0Y})^T$ . Se as matrizes  $\boldsymbol{\Phi}$  e  $\Sigma_e$  são conhecidas ou estimadas com precisão, a estatística de monitoramento  $T_t^2$  segue uma distribuição *qui-quadrado* com  $p=2$  graus de liberdade ( $\chi_p^2$ ). Ocorrendo uma causa especial que modifique o vetor de médias para  $\boldsymbol{\mu}_1 = (\mu_{1X}, \mu_{1Y})^T$ , a distribuição de probabilidade da estatística de monitoramento  $T_t^2$  se passa a ser uma distribuição *qui-quadrado não central* ( $\chi_{(p,\lambda)}^2$ ) com parâmetro de não centralidade  $\lambda^2 = \boldsymbol{\delta}^T \Gamma_M^{-1} \boldsymbol{\delta}$ , em que  $\boldsymbol{\delta}$  representa a mudança padronizada no vetor de médias  $\boldsymbol{\delta} = (\delta_X, \delta_Y)^T = \left( \frac{\mu_{1X} - \mu_{0X}}{\sigma_{eX}}, \frac{\mu_{1Y} - \mu_{0Y}}{\sigma_{eY}} \right)^T$  (FRANCO; COSTA; MACHADO, 2012; WU; MAKIS, 2008).

A estatística de eficiência mais usual de um gráfico de controle é o *NMA* - número médio de amostras até o sinal (APLEY; TSUNG, 2002; COSTA; EPPRECHT; CARPINETTI, 2005; HUANG; BISGAARD; XU, 2013; HWARNG; WANG, 2010; JIANG, 2004; PAN; JARRETT, 2011; VANHATALO; KULAHCI, 2014). O *NMA* é dado por:

$$NMA = \frac{1}{P} \quad (13)$$

sendo  $P = \alpha$ , se o processo estiver em controle e  $P = 1 - \beta$ , se o processo estiver fora controle.

O *NMA* também é denominado *NMAo* quando  $P = \alpha$ . Se, por exemplo,  $\alpha = 0,0027$ , tem-se em média, um alarme falso a cada  $1/0,0027=370,4$  amostras.

Quando o processo está sob a ação de causas especiais, o poder do gráfico de controle está relacionado com o erro tipo II, sendo  $P = 1 - \beta$ . Nesse caso, o *NMA* representa o número médio de amostras até o sinal de um alarme verdadeiro anunciado pelo gráfico de controle.

O erro tipo I do gráfico de  $T^2$  é dado por:

$$\alpha = 1 - \Pr(\chi_p^2 < LSC) \quad (14)$$

sendo *LSC* o limite superior de controle do gráfico. O *LSC* é determinado de acordo com o *NMAo*= $1/\alpha$  desejado, sendo este valor uma função do  $(1-\alpha)$ -ésimo quantil da distribuição *qui-quadrado* (CHAMP; JONES-FARMER; RIGDON, 2005).

Se uma causa especial ocorre entre os instantes em que se formam os subgrupos racionais  $i-1$  e  $i$ , segue-se que  $\bar{\mathbf{Y}}_{i-1} \sim N_2[\boldsymbol{\mu}_0; \Gamma_{\bar{\mathbf{Y}}}]$  e  $\bar{\mathbf{Z}}_i \sim N_2[\boldsymbol{\mu}_1; \Gamma_{\bar{\mathbf{Z}}}]$ , conseqüentemente, o erro tipo II para a primeira amostra composta  $i$  formada depois da ocorrência da causa especial é dado por:

$$\beta_1 = \Pr(\chi_{(p,\lambda_1)}^2 < LSC) \quad (15)$$

sendo,  $\lambda_1^2 = \boldsymbol{\delta}^T \Gamma_M^{-1} \boldsymbol{\delta}$  com  $\boldsymbol{\delta} = \frac{n_0}{n} (\delta_X, \delta_Y)^T$ .

Para as sucessivas amostras compostas  $i+1, i+2, \dots$ ,  $\bar{\mathbf{Y}}_{i-1} \sim N_2[\boldsymbol{\mu}_1; \Gamma_{\bar{\mathbf{Y}}}]$  e  $\bar{\mathbf{Z}}_i \sim N_2[\boldsymbol{\mu}_1; \Gamma_{\bar{\mathbf{Z}}}]$ , conseqüentemente, o erro tipo II é dado por:

$$\beta_2 = \Pr(\chi_{(p,\lambda_2)}^2 < LSC) \quad (16)$$

sendo,  $\lambda_2^2 = \boldsymbol{\delta}^T \Gamma_M^{-1} \boldsymbol{\delta}$  com  $\boldsymbol{\delta} = (\delta_X, \delta_Y)^T$ .

Se *NA* é o número de amostras que antecedem um alarme,  $P(NA = 1) = 1 - \beta_1$ ,  $P(NA = 2) = \beta_1(1 - \beta_2)$ ,  $P(NA = 3) = \beta_1\beta_2(1 - \beta_2)$ ,  $P(NA = 4) = \beta_1\beta_2^2(1 - \beta_2)$  e, em geral,

$$P(NA = l) = \begin{cases} 1 - \beta_1 & \text{se } l = 1 \\ \beta_1\beta_2^{l-2}(1 - \beta_2) & \text{se } l > 1 \end{cases} \quad (17)$$



O *NMA* do gráfico de  $T^2$  será:

$$\begin{aligned} NMA &= 1 \times (1 - \beta_1) + 2 \times \beta_1(1 - \beta_2) + 3 \times \beta_1\beta_2(1 - \beta_2) + 4 \times \beta_1\beta_2^2(1 - \beta_2) + \dots \\ &= 1 - \beta_1 + \beta_1(1 - \beta_2) \sum_{l=2}^{\infty} l\beta_2^{l-2}, \end{aligned} \quad (18)$$

Dado que a série  $\sum_{l=2}^{\infty} l\beta_2^{l-2}$  é convergente, pode-se reescrevê-la para obter o *NMA*.

$$NMA = 1 - \beta_1 + \beta_1(1 - \beta_2) \frac{2 - \beta_2^2}{(1 - \beta_2)^2} = \frac{\beta_1}{(1 - \beta_2)} + 1 \quad (19)$$

Se a causa especial ocorrer antes da primeira amostra, então  $NMA = 1/(1 - \beta_2)$ , pois  $\beta_1 = \beta_2$ .

## 5. O EFEITO DA AUTOCORRELAÇÃO NO DESEMPENHO DE GRÁFICO DE $T^2$

Investigou-se nesta seção a influência dos parâmetros de autocorrelação ( $a$ ,  $b$ ,  $c$ ,  $d$ ), da correlação ( $\rho$ ) e do deslocamento no vetor de médias ( $\delta_x$ ,  $\delta_y$ ) no desempenho estatístico do gráfico  $T^2$  de Hotelling.

A estratégia de amostragem composta (MS) é comparada com a estratégia de amostragem padrão (STD). Na estratégia de amostragem STD as unidades da amostra são selecionadas de acordo com o conceito de subgrupos racionais. Assume-se que  $\Phi$  permanece inalterado quando o vetor de médias sofre deslocamento e passa para a condição fora de controle estatístico. Com o processo em controle, adotou-se *NMA*o igual a 370,4 e tamanhos de amostras iguais a 3 e 5.

As Tabelas A1 e A2 (ver ANEXO I) apresentam os valores do *NMA* do gráfico de  $T^2$  para ambas as estratégias adotadas (STD e MS). Os menores valores do *NMA* são destacados em negrito. Os níveis de correlação ( $\rho$ ) adotados são: baixo (0,3), médio (0,6) e alto (0,9). A Tabela A1 considera os casos em que  $n=3$  e a Tabela A2 os casos em que  $n=5$ .

Em geral, o emprego da estratégia de amostragem composta reduz o efeito negativo da autocorrelação no desempenho do gráfico de  $T^2$ . Por exemplo, na Tabela A1 verifica-se que na presença de observações moderadamente autocorrelacionadas ( $a=b=0,5$ ;  $\rho = 0,3$ ) e  $\delta = (0,5; 1,0)^T$ , o gráfico de  $T^2$  aplicado com a estratégia STD requer, em média, 50,3 amostras para o sinal; o *NMA* reduz para 28,1 (aproximadamente 44% a menos) com a estratégia MS.

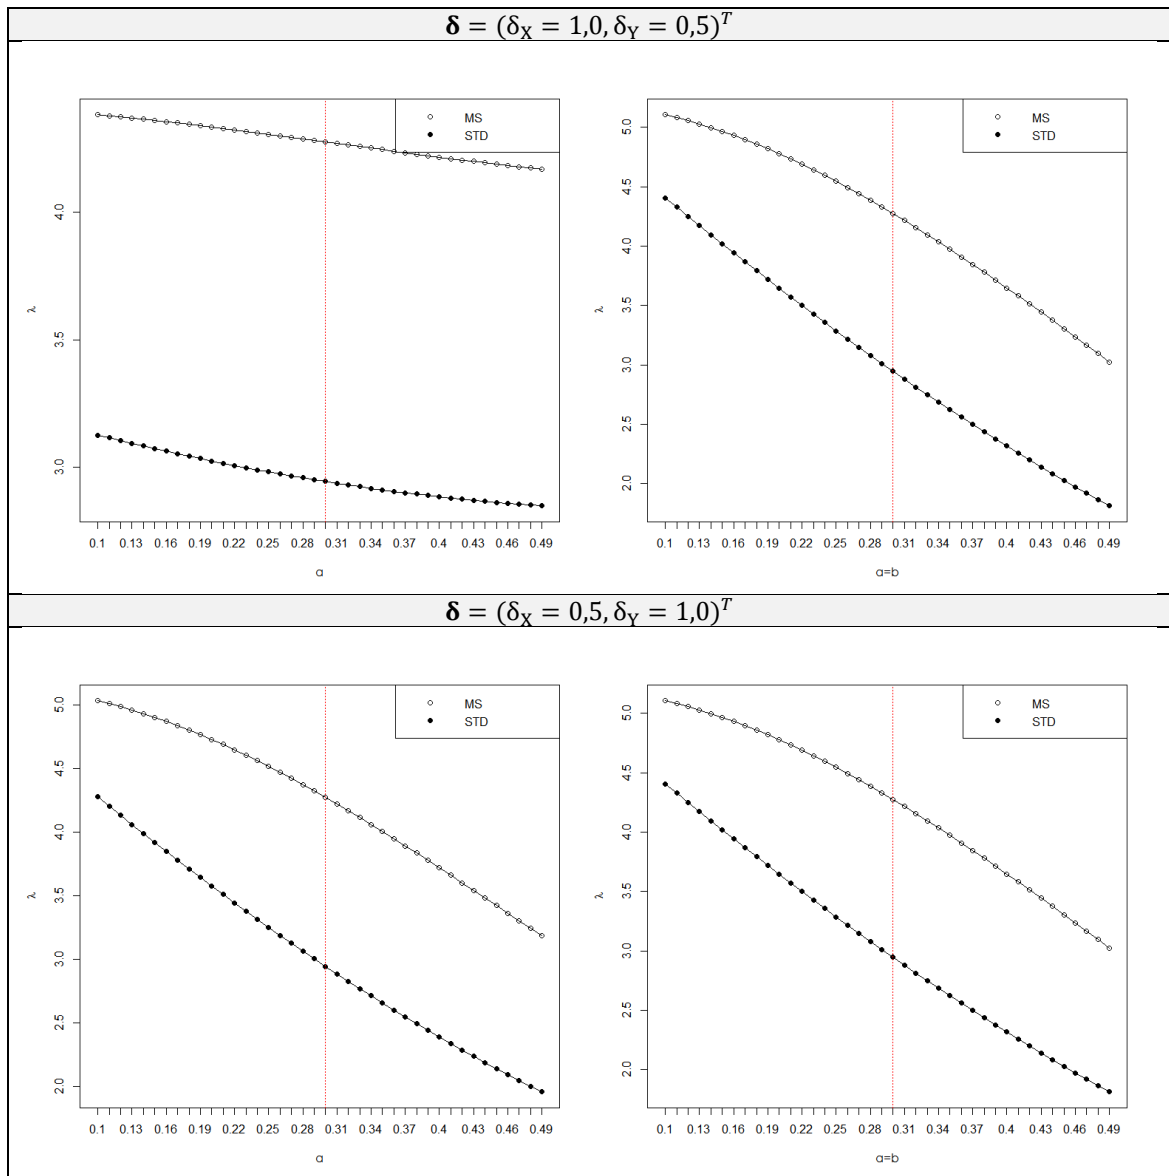
Nos cenários em que a variável autocorrelacionada raramente é afetada por uma causa especial e a variável independente é que sofre alguma ação que modifique o valor médio em controle, ou seja, ( $a=0$ ,  $b>0$ ,  $\delta_x>0$ ,  $\delta_y=0$ ) ou ( $a>0$ ,  $b=0$ ,  $\delta_x=0$ ,  $\delta_y>0$ ), a estratégia de amostragem composta reduz o poder do gráfico de  $T^2$ . Por exemplo, se ( $a=0$ ;  $b=0,5$ ;  $\rho = 0,3$ ) e  $\delta = (1,0; 0)^T$ , o gráfico de  $T^2$  com a estratégia STD requer, em média, 5,7 amostras para dar o sinal, veja a Tabela A2. Com a estratégia MS, o *NMA* aumenta para 6,6.

Em muitas aplicações a magnitude do deslocamento da média é difícil de ser predita. Baseando-se nesse fato, a estratégia MS é recomendada somente para processos com ambas as variáveis autocorrelacionadas.

Em relação aos parâmetros de autocorrelação, é possível inferir que o gráfico de  $T^2$  com a estratégia MS é mais robusto que o gráfico de  $T^2$  com a estratégia STD. Por exemplo, fixando  $\delta_x = 1,0$ ,  $\delta_y = 0,5$ ,  $\rho = 0,6$ ,  $n = 5$  e variando  $a$  e  $b$  como apresentado na Tabela A2, a amplitude para os valores do *NMA* é igual a 30,9 (=40,5-9,6) para a estratégia MS, e igual a 64,9 (=81,0-16,1) para a estratégia STD. Esses resultados evidenciam que o uso da técnica MS deve ser adotada quando há algum tipo de incerteza acerca no nível de autocorrelação.



As Figuras 2-3 ilustram o desempenho de ambas as técnicas em função do parâmetro de não centralidade ( $\lambda$ ). Quanto maior é o valor de  $\lambda$ , melhor é o desempenho do gráfico de controle. A Figura 2 apresenta os cenários em que  $a \in \{0,1; 0,49\}$ ;  $b = 0$  e  $a = b \in \{0,1; 0,49\}$ . A Figura 3 apresenta os casos em que  $a \in \{0,5; 0,89\}$ ;  $b = 0$  e  $a = b \in \{0,5; 0,89\}$ . Observa-se que em todos os cenários a estratégia MS é melhor que a estratégia STD, pois  $\lambda_{MS}$  é sempre superior a  $\lambda_{STD}$ .



**Figura 2:** Parâmetro de não centralidade  $\lambda$ ;  $n=5$ ;  $\rho=0,3$ ;  $a \in \{0,1; 0,49\}$ ;  $b = 0$  and  $a = b \in \{0,1; 0,49\}$ .



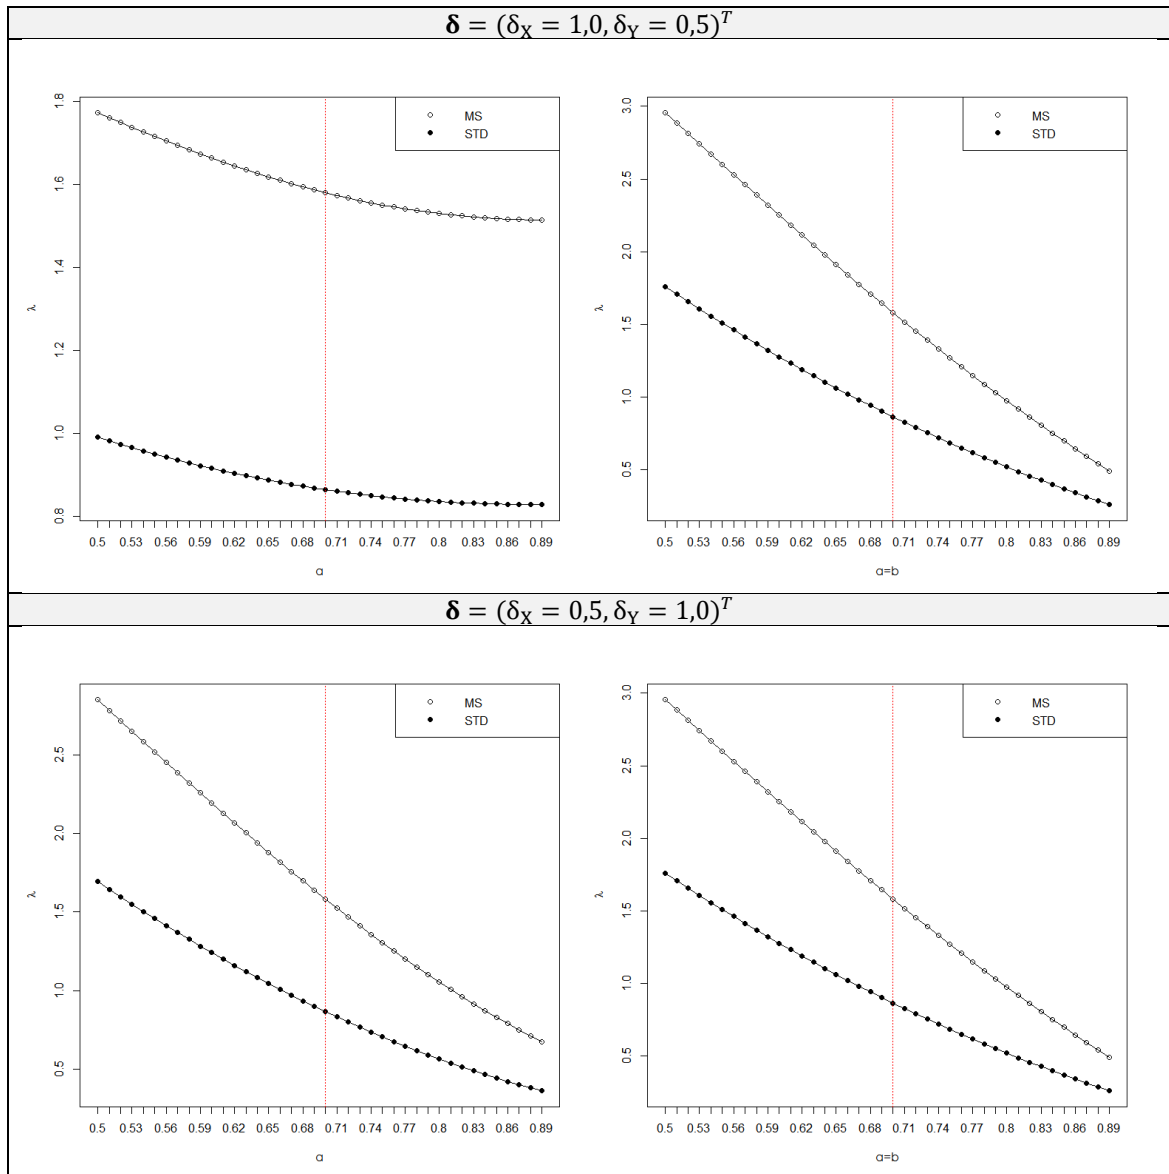


Figura 3: Parâmetro de não centralidade  $\lambda$ ;  $n=5$ ;  $\rho=0,3$ ;  $a \in \{0,5; 0,89\}$ ;  $b = 0$  and  $a = b \in \{0,5; 0,89\}$ .

## 6. EXEMPLO ILUSTRATIVO

Montgomery (2009) introduz um processo em que duas características de qualidade são monitoradas: resistência a tração e diâmetro de uma fibra têxtil. O grau de correlação ( $\rho$ ) entre as variáveis é igual a 0,78;  $\mu_0 = (115,9; 0,0106)'$  e  $\Sigma_e = \begin{pmatrix} \sigma_{e_X}^2 & \sigma_{e_{XY}} \\ \sigma_{e_{XY}} & \sigma_{e_Y}^2 \end{pmatrix} = \begin{pmatrix} 1,23 & 0,79 \\ 0,79 & 0,83 \end{pmatrix}$ .

O engenheiro de qualidade decide empregar o gráfico de  $T^2$  com amostras de tamanho  $n=5$ . Na Tabela 1 a estratégia de amostragem padrão (STD) é comparada com a estratégia de amostragem composta (MS) assumindo que as variáveis resistência a tração e diâmetro são ambas autocorrelacionadas ( $a = 0,45$ ;  $b = 0,6$ ).

Observa-se que mesmo para essas variáveis moderadamente autocorrelacionadas, a estratégia MS é vantajosa diante da estratégia STD; por exemplo, com a estratégia STD o NMA correspondente a ( $\delta_1=0,5$ ;  $\delta_2=1,0$ ) é igual a 34,66; com a estratégia MS o NMA reduz



em mais de 55% ( $NMA=15,29$ ). A Tabela 1 revela um percentual médio de redução igual a 47,6 %.

Tabela 1: Valores do  $NMA$  para o gráfico de  $T^2$ .

$\delta_1$	$\delta_2$	STD	MS	Redução percentual do $NMA$ (%)
		$NMA$		
0	0,5	74,82	39,05	47,81
1	0	9,84	5,29	46,24
<b>0,5</b>	<b>1</b>	<b>34,66</b>	<b>15,29</b>	<b>55,89</b>
0,5	0	69,38	39,53	43,02
0	1	11,03	5,23	52,58
0,5	0,5	144,93	93,65	35,38
1	1	34,07	16,35	52,01

## 7. CONCLUSÃO

O presente artigo considerou o uso do gráfico de controle de  $T^2$  com a estratégia de amostragem composta para monitorar processos bivariados e autocorrelacionados. Com a estratégia composta, a estatística de  $T^2$  depende da matriz de variância-covariância do vetor de médias amostrais formado a partir da combinação dos dois últimos subgrupos racionais.

Os resultados apresentados evidenciaram que a estratégia de amostragem composta é altamente recomendada para controlar o vetor de médias de processos bivariados e autocorrelacionados. Contudo, se no processo em estudo apenas uma variável for autocorrelacionada e robusta ação de causas especiais, a estratégia de amostragem composta deve ser usada com cautela; dependendo do deslocamento ocorrido no vetor de médias, a estratégia composta pode reduzir o poder do gráfico.

Com a intenção de melhorar o desempenho do gráfico de  $T^2$ , ou seja, melhorar o poder de detecção de causas especiais atuantes no vetor de médias de processos multivariados com observações autocorrelacionadas, sugere-se, em futuros trabalhos, o emprego dos gráficos de controle EWMA, CUSUM ou esquemas *synthetic* em conjunto com a estratégia de amostragem composta.

## 8. REFERÊNCIAS

- ARKAT, J.; NIAKI, S. T. A.; ABBASI, B. Artificial neural networks in applying MCUSUM residuals charts for AR(1) processes. **Applied Mathematics and Computation**, v. 189, n. 2, p. 1889–1901, jun. 2007.
- BILLER, B.; NELSON, B. L. Modeling and generating multivariate time-series input processes using a vector autoregressive technique. **ACM Transactions on Modeling and Computer Simulation**, v. 13, n. 3, p. 211–237, 1 jul. 2003.
- CHAMP, C. W.; JONES-FARMER, L. A.; RIGDON, S. E. Properties of the  $T^2$  Control Chart When Parameters Are Estimated. **Technometrics**, v. 47, n. 4, p. 437–445, nov. 2005.
- COSTA, A. F. B.; CASTAGLIOLA, P. Effect of measurement error and autocorrelation on the  $\bar{X}$  chart. **Journal of Applied Statistics**, v. 38, n. 4, p. 661–673, abr. 2011.
- COSTA, A. F. B.; EPPRECHT, E. K.; CARPINETTI, L. C. R. **Controle estatístico de qualidade**. 2. ed. São Paulo: Atlas, 2005.



28 · 29 · 30  
de OUTUBRO

**XII SEGeT**  
SIMPOSIUM DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA  
TEMA 2015  
Otimização de Recursos e Desenvolvimento



FRANCO, B. C. et al. A new sampling strategy to reduce the effect of autocorrelation on a control chart. **Journal of Applied Statistics**, v. 41, n. 7, p. 1408–1421, 20 dez. 2013.

FRANCO, B. C. et al. Economic design of Shewhart control charts for monitoring autocorrelated data with skip sampling strategies. **International Journal of Production Economics**, v. 151, p. 121–130, maio 2014.

FRANCO, B. C.; COSTA, A. F. B.; MACHADO, M. A. G. Economic-statistical design of the  $\bar{X}$  chart used to control a wandering process mean using genetic algorithm. **Expert Systems with Applications**, v. 39, n. 17, p. 12961–12967, dez. 2012.

HUANG, X.; BISGAARD, S.; XU, N. Model-based multivariate monitoring charts for Autocorrelated processes. **Quality and Reliability Engineering International**, 12 jun. 2013.

HWARNG, H. B.; WANG, Y. Shift detection and source identification in multivariate autocorrelated processes. **International Journal of Production Research**, v. 48, n. 3, p. 835–859, fev. 2010.

ISSAM, B. K.; MOHAMED, L. Support vector regression based residual MCUSUM control chart for autocorrelated process. **Applied Mathematics and Computation**, v. 201, n. 1-2, p. 565–574, jul. 2008.

JARRETT, J. E.; PAN, X. The quality control chart for monitoring multivariate autocorrelated processes. **Computational Statistics and Data Analysis**, v. 51, n. 8, p. 3862–3870, maio 2007.

KALGONDA, A. A. A note on generalization of Z chart. **Journal of Academia and Industrial Research**, v. 1, n. 6, p. 286–289, 2012.

KALGONDA, A. A.; KULKARNI, S. R. Multivariate Quality Control Chart for Autocorrelated Processes. **Journal of Applied Statistics**, v. 31, n. 3, p. 317–327, abr. 2004.

KIM, S. B.; JITPITAKLERT, W.; SUKCHOTRAT, T. One-Class Classification-Based Control Charts for Monitoring Autocorrelated Multivariate Processes. **Communications in Statistics - Simulation and Computation**, v. 39, n. 3, p. 461–474, 24 fev. 2010.

LEONI, R. C.; MACHADO, M. A. G.; COSTA, A. F. B. Simultaneous Univariate  $\bar{X}$  Charts to Control Bivariate Processes with Autocorrelated Data. **Quality and Reliability Engineering International**, n. 1, p. n/a–n/a, 12 jul. 2014.

MASTRANGELO, C. M.; FORREST, D. R. Multivariate autocorrelated processes: Data and shift generation. **Journal of Quality Technology**, v. 34, n. 2, p. 216–221, 2002.

MONTGOMERY, D. C. **Introduction to Statistical Quality Control**. 6. ed. Hoboken, NJ: John Wiley and Sons, Inc., 2009.

NIAKI, S. T. A.; DAVOODI, M. Designing a multivariate–multistage quality control system using artificial neural networks. **International Journal of Production Research**, v. 47, n. 1, p. 251–271, jan. 2009.

SHEWHART, W. A. **Economic control of quality of manufactured product**. New York: D. Van Nostrand Company, 1931.

WU, J.; MAKIS, V. Economic and economic-statistical design of a chi-square chart for CBM. **European Journal of Operational Research**, v. 188, n. 2, p. 516–529, jul. 2008.



