

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

André Luis Korzenowski

CONTROLE ESTATÍSTICO DO PROCESSO
APLICADO A AMBIENTES CUSTOMIZADOS

Porto Alegre

2012

André Luis Korzenowski

Controle estatístico do processo
aplicado a ambientes customizados

Tese submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Doutor em Engenharia, na área de concentração em Sistemas de Qualidade.

Orientador: Professora Carla S. ten Caten, Dr.

Porto Alegre

2012

André Luis Korzenowski

Controle estatístico do processo
aplicado a ambientes customizados

Esta tese foi julgada adequada para a obtenção do título de Doutor em Engenharia e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

Profa. Dra. Carla S. ten Caten
Orientadora PPGEP/UFRGS

Prof. Dr. José Luis Duarte Ribeiro
Coordenador PPGEP/UFRGS

Banca Examinadora:

Professor Michel Anzanello, PhD. (PPGEP/UFRGS)

Professor Lorí Viali, Dr. (FAMAT/PUCRS)

Professor Guilherme Vaccaro, Dr. (PPGEPS/UNISINOS)

DEDICATÓRIA

Dedico este trabalho à minha amada esposa Angela e seu apoio incondicional nesta jornada de transformação pessoal.

"A ciência nunca resolve um problema sem criar pelo menos outros dez".
(George Bernard Shaw)

*"A tarefa é, não tanto ver aquilo que ninguém viu ainda, mas pensar o que ninguém
ainda pensou, sobre o que todo mundo vê".*
(Erwin Schrödinger)

Agradecimentos

À minha orientadora, Carla Schwengber ten Caten, pelo trabalho e oportunidade de aprendizado.

Ao professor Yu Ding, pela oportunidade de aprimoramento técnico junto à Texas A&M University.

À FAMAT/PUCRS, especialmente os professores Augusto Vieira Cardona e João Feliz Duarte de Moraes, pelo esforço na minha cedência para o Sanduíche junto à Texas A&M University.

À Coordenação de Aprimoramento de Pessoal de Nível Superior (CAPES), pela bolsa de estudos de Doutorado Sanduíche concedida.

À UFRGS, pela minha formação acadêmica.

Ao meu amigo Gabriel Vidor, pelos auxílios e contra-pontos nas discussões teóricas e também pela parceria ao longo do doutorado.

Aos amigos, colegas, funcionários e amigos da Texas A&M University Daniel Jornada, Fabiano Santos, José Luiz Preciado, José Ramirez e Cherryl Kocman, pelo suporte e apoio.

Especialmente, à minha esposa Angela, pelo carinho e compreensão durante o período de estudos e elaboração da tese e, principalmente, por ser minha companheira sempre, inclusive quando afastou-se de sua profissão para estar comigo em uma parte importante desta jornada.

Resumo

Durante os anos 70, os sistemas de produção evoluíram de planos de produção em massa para planos flexíveis, capazes de prover para cada consumidor produtos ou serviços diferenciados através de um processo ágil, flexível e integrado com baixo custo. O aumento de opções do menu de escolha por parte dos clientes resulta na produção de pequenos lotes de produtos e, conseqüentemente, dados em volume insuficiente para estimar os parâmetros do processo necessários para o monitoramento da característica de qualidade. A literatura reconhece que não existem métodos capazes de tratar o problema do monitoramento de ferramentas de qualidade em sistemas de produção flexíveis e customizados. O objetivo deste trabalho é propor ferramentas de controle estatístico do processo para este tipo de ambiente. Verifica-se que cenários de produção customizados sujeitos à produção em pequenos lotes são suscetíveis a violações de suposições e estimativas imprecisas dos parâmetros do processo. Além disso, as ações adotadas pelos engenheiros de qualidade na fase I da implantação de cartas de controle nas empresas visitadas é conflitante com o que é sugerido na literatura. Verificação dos pressupostos de normalidade e independência não são executados, mesmo quando cartas de controle são implantadas. Os principais procedimentos de controle de qualidade do atual estado da arte são apresentados para verificar alternativas para a implantação de ferramentas de controle estatístico do processo em ambientes onde as estratégias atuais de produção causaram o aumento da necessidade de flexibilidade. Nestes casos, a característica da qualidade costuma ser a mesma, mas para diferentes produtos, o que significa que se tem uma única observação para cada produto em cada momento, no mesmo processo. Discussões sobre a viabilidade em implantar as principais metodologias neste contexto são apresentadas. Entre os métodos levantados no estado da arte, uma única abordagem capaz é a carta que utiliza o desvio do alvo no instante t , apresentada por Del Castillo et. al. (1996), porém não é aplicável ao problema de pesquisa apresentado nesta tese, pois exige

uma fase retrospectiva de análise. Além disso, a inclusão de um novo produto ou uma mudança significativa no processo antigo em um ambiente flexível não pode ser tratada pelos métodos apresentados. Uma carta de controle multivariada de auto-inicialização baseada no filtro de Kalman para o sistema de múltiplos *setups* é proposta além de adaptações da carta de auto-inicialização de Shewhart e da carta de controle de Quesenberry (1991) com média e variância desconhecidos. O modelo baseado no filtro de Kalman foi escolhido depois de um estudo de simulação que comparou o desempenho preditivo dos modelos ARIMA, Regressão PLS e Estrutural Básico. O desempenho das abordagens de controle estatístico do processo propostas foi comparado através de medidas de ARL e a análise considerou a implantação das ferramentas em uma série de dados real e em séries simuladas de ambientes sujeitos à violação das suposições básicas das cartas tradicionais. Como *benchmark*, foi utilizada a análise retrospectiva da carta de resíduos apresentada por Del Castillo et. al. (1996). Os resultados mostram que a hipótese de violação da normalidade é a que mais deteriora o desempenho das cartas de controle. Efeitos de violação da independência e da suposição de homocedasticidade não são significativos ao nível de 5%, de acordo com a análise de variância realizada. Conclui-se que, dos cinco procedimentos propostos, os adaptados obtiveram resultados similares ao *benchmark*, podendo ser tratados como alternativas para lidar com o problema de monitoramento da qualidade em ambientes organizados com sistemas de produção customizados.

Palavras-chave: produção customizada, controle estatístico do processo, desempenho das cartas de controle, violação das suposições.

Abstract

During the 70s, production systems have evolved from mass production plans to flexible plans, able to provide for each customer differentiated products or services with low cost through an agile, flexible and integrated process. The number increase of choices results in production of small batches of products, and therefore insufficient volume data to estimate the required process parameters for the monitoring of quality characteristics. The literature shows that there are no methods to treat the problem of quality monitoring in flexible and customized production systems. The objective of this thesis is to propose tools for this type of environment. It is verified that customized scenarios are subject to small-batch production and are also susceptible to violation of assumptions and inaccurate estimate of process parameters. In addition, actions taken by quality engineers in Phase I implementation of control charts in visited companies is conflicting with what is suggested in the literature. Verification of assumptions such as normality or independence are not performed, even when control charts are implemented. The state of art quality control procedures are presented in order to verify how to implement quality control tools in environments where the current strategies of production has increasing flexibility. In these cases, the quality characteristic is usually the same, but for different products, which means that it has an observation for each product in each time frame for the same process. Discussion on the feasibility of implementing the main methodologies are presented in this context. Among the methods considered the state of the art, the chart which uses the deviation from the target at time t , presented by Del Castillo *et al.* (1996) is the only that could be able to work in this problem, but shall be not applied to the research problem presented in this thesis, since it requires a Phase I of retrospective analysis. Moreover, the inclusion of a new product or significant change in old process in a flexible environment can not be treated by the methods presented. A self-start multivariate control chart based on Kalman filter for multiple setups is proposed, as well as

the adaptations of the self-start Shewhart control chart and the self-start Quesenberry's control chart (1991). The model based on the Kalman filter was chosen after a simulation study that compared the predictive performance of ARIMA, PLS Regression and Structural Basic models. The performance of the proposed quality control approaches was compared with measures of ARL and the analysis considered the implementation of tools in series of real data and simulated data subject to violation of the traditional charts' basic assumptions. As a benchmark, we used a retrospective analysis of the chart presented by Del Castillo *et al.* (1996). The results show that the assumption of normality violation is the one that most deteriorates the performance of control charts. Effects of independence and homoscedasticity violation of assumptions are not significant at 5%, according to the analysis of variance performed. We conclude that, among the five proposed procedures, the adapted ones obtained similar results to the benchmark and can be treated as alternatives to deal with the problem of quality monitoring in environments with customized production systems.

Keywords: customized systems, statistical process control, control charts performance, violation of assumptions.

Lista de Abreviações

ABEPRO: Associação Brasileira de Engenharia de Produção.

ANOVA: Análise de Variância.

ARIMA(p,d,q): Modelo autoregressivo integrado de média móvel, de ordem autoregressiva p , média móvel de ordem q , após terem sido tomadas d diferenças.

ARMA(p,q): Modelo autoregressivo de média móvel, de ordem autoregressiva p e médiamóvel de ordem q .

AR(p): Modelo autoregressivo de ordem p .

ARL: Do inglês *Average Run Length*, ARL significa o número médio de observações entre ou antes da ocorrência de um sinal.

ARL_0 : Medida associada ao erro do tipo I, informa o intervalo médio entre a ocorrência de alarmes falsos.

ARL_1 : Medida associada ao erro do tipo II, informa o número médio de observações apontadas como sob controle estatístico do processo antes de um sinal de fora de controle, uma vez que o processo já não esteja mais em condição de estabilidade estatística.

CEP: Controle Estatístico do Processo.

Dados i.n.d.: Dados independentes, normal e identicamente distribuídos.

MCuSum: Carta de controle multivariada de soma cumulativa.

MEWMA: Carta de controle multivariada de média móvel exponencialmente ponderada.

Regressão PLS: Regressão de mínimos quadrados parciais.

RMSE: Raíz quadrada do erro quadrático médio.

SOA: Carta de Shewhart para múltiplos itens.

SSS: Carta de autoinicialização de Shewhart para múltiplos itens com estimativa de variância simples.

SSP: Carta de autoinicialização de Shewhart para múltiplos itens com estimativa de variância combinada.

QCS: Carta de Quesenberry para múltiplos itens com estimativa de variância simples.

QCP: Carta de Quesenberry para múltiplos itens com estimativa de variância combinada.

SKM: Carta multivariada de autoinicialização para múltiplos itens baseada no filtro de Kalman.

Lista de Figuras

2.1	Fluxograma para a verificação das suposições e escolha da carta indicada	32
4.1	Fluxograma do processo de implantação do CEP nas empresas participantes	54
4.2	Aspectos de maior relevância apontados por cada entrevistado das empresas participantes	57
4.3	Passos na implantação do CEP apresentados na literatura e observados nas empresas participantes	58
4.4	Gramatura dos 5 produtos da série de dados da empresa ABC	64
4.5	Valores observados e preditos da característica da qualidade gramatura nos modelos ARIMA, Estrutural Básico e de regressão PLS	65
4.6	Gramatura observada na série histórica de dados da empresa ABC (mg/mm^2)	76
4.7	Histograma do tamanho das sequências produtivas	77
4.8	Valores observados e esperados pelo modelo estrutural, da série de dados histórica e resíduos do modelo	78
4.9	Cartas de controle propostas aplicadas aos dados históricos da empresa ABC	79
4.10	Gráfico dos resultados do ARL_0 para a interação Homocedasticidade*Método	84
4.11	Gráfico dos resultados do ARL_0 para a interação Independência*Método	84
4.12	Gráfico dos resultados do ARL_0 para a interação Normalidade*Método	85
4.13	Gráfico dos resultados do ARL_1 para a interação Homocedasticidade*Método	88
4.14	Gráfico dos resultados do ARL_1 para a interação Independência*Método	89
4.15	Gráfico dos resultados do ARL_1 para a interação Normalidade*Método	90
4.16	Gráfico dos resultados do ARL_1 para a interação Desvio*Método	91
4.17	Gráfico dos resultados do ARL_1 para a interação Normalidade*Independência	92
4.18	Gráfico dos resultados do ARL_1 para a interação Normalidade*Desvio	93
4.19	Gráficos dos resultados do ARL_1 para a interação Normalidade*Desvio*Método	95
B.1	ARL_1 da interação Desvio*Método para o cenário I	115
B.2	ARL_1 da interação Desvio*Método para o cenário II	115
B.3	ARL_1 da interação Desvio*Método para o cenário III	116
B.4	ARL_1 da interação Desvio*Método para o cenário IV	116

B.5	ARL_1 da interação Desvio*Método para o cenário V	117
B.6	ARL_1 da interação Desvio*Método para o cenário VI	117
B.7	ARL_1 da interação Desvio*Método para o cenário VII	118
B.8	ARL_1 da interação Desvio*Método para o cenário VIII	118

Lista de Tabelas

3.1	Descrição dos cenários simulados para comparação das técnicas de controle estatístico do processo aplicados a ambientes customizados	51
4.1	Resumo das principais informações obtidas junto aos entrevistados das empresas participantes	56
4.2	Resumo das metodologias de controle de qualidade e suas limitações para implantação em ambientes customizados	60
4.4	Comparativo entre as medidas de ajustamento dos modelos ARIMA, estrutural básico e regressão PLS	64
4.5	Resultados da ANOVA para a acurácia do ajustamento mensurado através do RMSE	67
4.6	Resultados do teste de Tukey (HSD) para a interação tripla $\tau * \gamma * \delta$	68
4.7	Medidas descritivas da série de produtos na série histórica fornecida pela empresa ABC para a característica Gramatura	75
4.8	Sinais de pontos fora de controle observados na série histórica nos seis procedimentos avaliados	78
4.9	ARL_0 estimado na simulação para cada carta nos diferentes cenários simulados	80
4.10	ARL_0 e desvio-padrão estimados a partir de limites de controle ajustados para cada carta no cenário ideal	82
4.11	Resultados da análise de variância para o ARL_0	83
4.12	Estimativa dos parâmetros do modelo linear de análise de variância da variável de resposta ARL_0	85
4.13	Resultados da análise de variância para o ARL_1	87
4.14	Estimativa dos parâmetros do modelo linear de análise de variância da variável de resposta ARL_1	90
4.15	Comparações múltiplas dos métodos através do teste de Tukey (HSD) quanto ao ARL_1	93

A.1	ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário I	110
A.2	ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário II	110
A.3	ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário III	111
A.4	ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário IV	111
A.5	ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário V	112
A.6	ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário VI	112
A.7	ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário VII	113
A.8	ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário VIII	113

Sumário

1	Introdução	18
1.1	Problematização	19
1.2	Objetivos	21
1.3	Justificativa	22
1.4	Delimitações	24
1.5	Delineamento	25
1.6	Estrutura da tese	27
2	Revisão Bibliográfica	28
2.1	Pressupostos para a adequada implantação de cartas de controle	29
2.2	Metodologias de controle estatístico do processo	33
2.3	Modelos preditivos com variáveis exógenas	41
3	Procedimentos metodológicos	46
3.1	O problema de pesquisa e o levantamento das soluções	46
3.2	Da escolha de um modelo preditivo	48
3.3	Do estudo comparativo para avaliar o desempenho das cartas propostas	50
4	Apresentação e discussão dos resultados	53
4.1	Teoria e prática na implantação de cartas de controle	54
4.2	Metodologias tradicionais em ambientes de múltiplos <i>setups</i>	59
4.3	Modelos preditivos em cenários afetados por múltiplos <i>setups</i>	63
4.4	Construção da carta T^2 para ambientes customizados	68
4.5	Adaptação das cartas existentes para aplicação no problema de pesquisa	71
4.6	Estudo comparativo	74
5	Considerações Finais	96
5.1	Principais contribuições da pesquisa	98
5.2	Sugestões para pesquisas futuras	99
	Referências Bibliográficas	102

A	ARLs estimados por cenários	109
B	Gráficos com resultados da interação Desvio*Método*Cenário	114
C	Códigos do Matlab para simulação e análise	119
C.1	Análise dos dados da série histórica	120
C.2	Exibição das cartas	123
C.3	Dados independentes simulados	124
C.4	Dados autocorrelacionados simulados	125
C.5	Algoritmo <i>lkfilter.m</i>	126
C.6	Análise dos dados simulados - ARL_0	127
C.7	Análise dos dados simulados - ARL_1	131
D	Artigos Elaborados	136
D.1	Statistical process control in highly customized environment	137
D.2	Theory and practice in phase I of control charts implementation	138
D.3	Mudança de Regime Markoviano Aplicado à Fase I do CEP em ambientes de múltiplos <i>setups</i>	139
D.4	Predictive models with endogenous variables for quality control in custo- mized scenarios affected by multiple setups	140
D.5	Quality control tools in customized systems: a comparative study	141

1 Introdução

A entrada de produtos japoneses no mercado ocidental, durante a década de 70, gerou diversas discussões na imprensa americana segundo Schonberger (?). Apenas no início dos anos 80 que a ascensão do mercado japonês como potência industrial foi associada à gestão dos sistemas de produção. Womack *et al.* (?) sugeriram que a forma generalizada do sistema de produção da Toyota, nomeado de produção enxuta, seria a sucessora natural da produção em massa. Isto porque a mesma conseguia uma maior diversificação de produtos com baixo custo. Segundo Hoss (?), as diferentes abordagens dadas desde os anos 80 formaram um corpo de conhecimento que moldou um entendimento sobre a organização do trabalho, da produção, do gerenciamento e da engenharia existentes nas empresas japonesas de alto desempenho. Os sistemas evoluíram de planos de produção em massa para planos flexíveis, capazes de gerar produtos mais customizados.

Segundo Da Silveira *et al.* (2001), o termo customização em massa refere-se à habilidade de um processo produtivo prover produtos ou serviços customizados em altos volumes e com custos razoáveis. O conceito de um plano de produção customizado surge no final dos anos 80 como solução para diferenciar companhias em segmentos de mercado altamente competitivos. Este conceito surge com a ideia de prover, para cada consumidor, produtos ou serviços customizados através de um processo ágil, flexível e integrado.

As referências que abordam o tema ressaltam a capacidade desse tipo de sistema em produzir com qualidade e baixo custo (?PINE II & S., 1999). Entretanto, não são muito comuns as discussões sobre como implantar sistemas de controle de qualidade nestes ambientes. Ferramentas têm sido desenvolvidas ao longo do tempo para atender às demandas próprias do controle de qualidade em sistemas de produção em massa. Observou-se o desenvolvimento de procedimentos e técnicas estatísticas mais refinados e complexos com o objetivo de identificar se os produtos de consumo seguem as especificações, com durabilidade garantida e com a qualidade desejada.

Apesar da evolução dos processos e de suas técnicas de controle, as tradicionais cartas de Shewhart, propostas em 1924, ainda são frequentemente utilizados em países como Estados Unidos e Japão, especialmente durante e após os anos 80 (ELDIN & HAMZA, 2009; SEREL, 2009). Zhao (2011) destaca que as cartas de controle, independentemente do tipo, são o alicerce do controle estatístico do processo, sendo frequentemente utilizadas

na prática do controle da qualidade. Entretanto, as novas estratégias de produção customizada evoluíram a passos rápidos se comparados com a evolução das soluções de controle estatístico do processo para estes ambientes. Assim, ferramentas de controle estatístico do processo concebidas e especificadas para uso em sistemas de produção em massa são implantadas em ambientes flexíveis.

Cartas desenvolvidas para sistemas de produção em massa, apresentam problemas conceituais quando aplicadas a estes ambientes. Principalmente porque as cartas tradicionais foram desenvolvidas para atender a apenas um produto e não um rol de produtos, frutos de uma mesma estação de trabalho que agora é flexível o suficiente para produzir desta maneira. Um sistema de controle e monitorização contínua em ambientes flexíveis, mais eficiente que a inspeção das características de qualidade, exige uma ferramenta diferente, segundo Fogliatto *et al.* (2012). A busca por uma ferramenta que atenda estas necessidades consiste no foco principal desse trabalho.

1.1 Problematização

As cartas de controle de Shewhart foram originariamente desenhadas para monitorar processos com uma reduzida variedade e produzidos em larga escala, tal como os produtos produzidos em linhas de produção (HO & TRINDADE, 2009; SNOUSSI *et al.*, 2005). Entretanto, a demanda por flexibilidade tem forçado as empresas de manufatura a aumentar o leque de opções aos clientes e, conseqüentemente, reduzir o tamanho dos lotes de produtos. Atualmente, diferentes estratégias de produção, tais como, produção em massa, produção *Lean*¹ e customização em massa devem prover flexibilidade. Uma vez que a flexibilidade dos processos produtivos é alcançada, o desafio é estabelecer como garantir a qualidade em produtos provenientes deste tipo de ambiente de produção.

Problemas na implantação das cartas de controle em cenários sujeitos à alta flexibilidade e produção em pequenos lotes, segundo Fan & You (2009), são:

1. a suposição de independência dos dados é usualmente não satisfeita;
2. a produção de uma dada quantidade de itens finaliza antes de se obter uma amostra suficientemente grande para garantir estimativas com a acurácia necessária para a estimação adequada dos parâmetros do processo e em consequência dos limites de controle;

¹É possível encontrar diversos termos e definições que são utilizados pelos pesquisadores para designar o fenômeno *Lean*. Podem ser citados: *Toyota production system*, *lean production*, *Toyota management system*, *flexible production system*, *Japanese production system*, etc. Apesar de cada termo apresentar uma significação específica para o sentido em que está sendo empregado, de uma forma geral todos compartilham implicitamente de princípios semelhantes.

3. os processos modernos tendem a operar em fluxo contínuo enquanto que o processo de controle da qualidade não o é, fazendo com que ele esteja atrasado em relação à produção (por obtenção de subgrupos de amostragem) o que termina por aumentar o volume de produção fora de controle.

Ohno & Bodek (1988) dizem que é necessário minimizar as perdas geradas por processos de inspeção em 100% das unidades fabricadas, principalmente as associadas ao tempo. Por outro lado, um sistema de controle e monitoração contínua da característica da qualidade e especificações demandam uma ferramenta diferente para cada produto em um ambiente flexível (FOGLIATTO *et al.*, 2012).

Suponha que se tenha uma única sequência de observações provenientes de k diferentes variáveis aleatórias (uma mesma característica de qualidade a partir de k diferentes produtos). Note que isto não representa uma distribuição multivariada, mas uma sequência de mais de uma distribuição univariada, onde o comprimento de cada uma destas sequências não é constante. A ordem e o tamanho da sequência são definidos pelo plano de produção. Assim,

$$x_{1,k_j}, x_{2,k_j}, \dots, x_{t,k_j}, \dots, x_{t+1,k_l \neq j}, \dots, x_{t+i,k_l \neq j}, x_{t+i+1,k_m \neq l}, \dots \quad (1.1)$$

onde \mathbf{x}_{tk_j} é um vetor com as observações da variável de resposta, i depende do plano de produção, k indica qual o produto em produção no tempo t e j representa o número de vezes que o produto k foi observado no histórico de produção. Note que x_{tk_j} pode ser uma sequência de observações independentes ou não, normalmente distribuída ou não, e para cada produto k , a variabilidade pode ser a mesma ou não. O desafio é encontrar uma metodologia que resolva os problemas associados a este tipo de ambiente de rápida inovação, sem perder a robustez da análise efetuada através do controle estatístico do processo.

Para solucionar estas dificuldades, é necessário ajustar uma abordagem que seja robusta a todas estas características. Técnicas estatísticas foram propostas e adaptadas para capturar mudanças no nível de uma série durante o controle estatístico do processo. Estas técnicas incluem a utilização de cartas de controle baseadas no filtro de Kalman (DEL CASTILLO & MONTGOMERY, 1995; SEMINO *et al.*, 1996), modelagem baseada na construção do modelo em espaço dos estados (SHI *et al.*, 2000), modelagem de processos markovianos em tempo contínuo (ZEIFMAN & INGMAN, 2003), modelo baseado em redes neuronais (GHIASSI & NANGOY, 2009; GUH, 2010), etc. Estas abordagens são robustas a problemas de violação da normalidade, da independência ou até mesmo para implantação em ambientes de produção de pequenos lotes, mas não são robustas simultaneamente a todos eles.

A chave então é identificar uma abordagem que solucione todas as dificuldades

relatadas anteriormente e que, ainda seja adequada para um ambiente de produção customizada, o que significa, um ambiente de alta flexibilidade e de lotes pequenos. Uma solução geral para este problema consiste na utilização de uma carta de controle para cada produto (ZANTEK, 2006). Esta abordagem submete a uma questão maior: a construção de uma carta para cada tipo de produto não é um modelo representativo do processo como um todo e nem aproveita as estimativas de variabilidade inerentes à tecnologia e equipamentos, previamente estimadas pelas outras cartas. Além disso, para a implantação destes tipos de ferramentas, é necessária a execução da chamada fase retrospectiva (fase I), o que é crítico uma vez que, como apresentado anteriormente, não se tem garantia de que a produção seja contínua em tempo suficiente para uma boa estimativa dos parâmetros. Esta limitação pode gerar erros de análise e baixo nível de desempenho das cartas tradicionais. Destaca-se então a necessidade do desenvolvimento e da validação de ferramentas de controle estatístico do processo que atendam às demandas desse tipo de sistema produtivo.

1.2 Objetivos

O objetivo geral é propor ferramentas de controle estatístico do processo para ambientes de produção customizados onde, em cada linha, sejam produzidos mais de um item, apresentando diferentes níveis da característica da qualidade mensurada na série observada.

Os objetivos específicos são:

1. contrapor os pressupostos relevantes identificados na literatura com a realidade de implantação de cartas de controle em empresas que utilizam sistemas de produção customizada;
2. verificar a capacidade das principais metodologias de controle da qualidade levantadas no estado da arte em atender às demandas exigidas no contexto de produção em ambientes customizados;
3. adaptar as ferramentas para atender à capacidade de incluir ou excluir produtos sem a necessidade de reinicialização da carta de controle;
4. comparar os resultados de desempenho entre as ferramentas em diferentes cenários de violação das suposições básicas.

1.3 Justificativa

A demanda por flexibilidade tem forçado as indústrias de manufatura a incrementar as opções dos clientes e reduzir o tamanho dos lotes. Atualmente, diferentes estratégias de produção, tais como produção em massa, produção *Lean* e customização em massa, devem almejar flexibilidade. O problema desta flexibilização é que as mudanças nos processos produtivos resultam em conjuntos de dados históricos insuficientes para estimar os parâmetros do processo em controle estatístico.

Uma vez que o objetivo da flexibilização tem sido alcançado, o desafio passa a ser como garantir a qualidade dos produtos provenientes desses ambientes. Uma maneira de fazê-lo é implantar cartas de controle. Porém, este tipo de sistema de produção, de alterações no tipo de produto e curtas séries de observações, deteriora a eficiência dos tradicionais ferramentas de controle do processo, de acordo com Da Silveira et al. (2001), principalmente as cartas de controle de Shewhart, que originariamente foram designadas para monitorar processos com reduzida variabilidade e produção em larga escala (HO & TRINDADE, 2009; SNOUSSI *et al.*, 2005).

Embora seja possível observar aspectos positivos nestes cenários, tais como aumento da habilidade dos trabalhadores e velocidade da produção, é difícil de definir como implantar cartas de controle em cenários flexíveis, onde as séries de variáveis observáveis são pequenas e o tipo de produto está mudando a todo momento (HO & TRINDADE, 2009; FOGLIATTO *et al.*, 2012). Ohno & Bodek (1988) dizem que é essencial a implantação de ferramentas de controle da qualidade nestes cenários para minimizar as perdas geradas por inspeções. Entretanto, sistemas de monitorização contínua de características de qualidade e especificações em ambientes flexíveis exigem ferramentas diferentes para o controle da qualidade de cada item. A literatura reconhece que não existem métodos capazes de tratar o problema da implantação de ferramentas de controle estatístico do processo em sistemas de produção flexíveis e customizados (FOGLIATTO *et al.*, 2012).

Note-se que, neste contexto, tem-se uma única sequência de observações (um único vetor) proveniente de k diferentes variáveis aleatórias, tal qual apresentado na equação 1.1 na página 20. Destaca-se que não se trata de uma observação multivariada mas a sequência de mais de uma distribuição univariada e que o número de observações sequenciais de cada uma destas variáveis é previamente desconhecida. A ordem e o tamanho da sequência são também desconhecidos *a priori* uma vez que são definidos pelo plano de produção. Assim, supondo, apenas para efeito didático, que a sequência observada siga um modelo de distribuição de probabilidade Normal tal que

$$x_{t,k_j} \sim \mathcal{N}(\mu_k; \sigma_k) \quad (1.2)$$

onde x_{t,k_j} é o vetor das observações da característica da qualidade, t é o número da unidade observada na série, k indica o produto em produção no tempo t e j é o número de vezes que o produto k foi observado nesta sequência. Destaca-se que μ_k e σ_k são, respectivamente, a média e o desvio-padrão do produto k e nada garante que as medidas sejam as mesmas para cada produto k . Além disso, x_{t,k_j} pode ser independente ou autocorrelacionado, normalmente distribuído ou não e, para cada produto k , a variabilidade pode ser a mesma ou não. O desafio é encontrar uma metodologia que possa ser implantada em um ambiente de múltiplos itens, isto é, um ambiente de alta flexibilidade, inovação e produção em pequenos lotes, além de permitir a inclusão de novos itens sem que haja a necessidade da reconstrução de todo o modelo e consequente re-início de todo processo de controle estatístico do processo.

A solução típica disponível consiste em implantar uma carta de controle para cada produto, ignorando as pausas de produção de determinado item causadas pela troca de *setup* decorrente do plano de produção (ZANTEK, 2006). Esta abordagem apresenta uma grande limitação: a construção de um modelo para cada tipo de produto não utiliza uma estimativa da variabilidade inerente à tecnologia de equipamentos já estimado para os modelos ajustados anteriormente, em outras cartas para outros produtos. Esse esquema também ignora tempos de aquecimento, que provavelmente mudam a variabilidade do processo entre todos os produtos. A única abordagem para modelar o problema da produção de múltiplos itens em uma única carta de controle é a definição do desvio do alvo ou média em cada momento t , como apresentado por Del Castillo *et al.* (1996). As limitações dessa abordagem são o pequeno tamanho da amostra e a alta velocidade de alteração do produto além do que, nesta abordagem, os dados devem ser independentes e normalmente distribuídos. Além destes aspectos, o número de observações disponíveis para cada produto pode não ser suficiente para obter uma estimativa precisa dos parâmetros do processo na fase I (retrospectiva) de implantação da carta de controle.

Em processos de produção flexível com lotes pequenos, a série de dados observada sofre mudanças determinadas pelo sequenciamento da produção, como mostrado na equação 1.1. A consequência disto é que a série não é estacionária, uma vez que, no mínimo, mudanças no nível da série ocorrerão em função dos valores nominais dos produtos em produção. Os problemas da implantação de ferramentas de controle neste ambiente não são somente aqueles relacionados às alterações intencionais no processo. Isto constitui apenas mais um elemento para aumentar a complexidade do problema. Produção de pequenas tiragens raramente oferece dados suficientes para fins de estimativa de acordo com Snoussi *et al.* (2005). Sabe-se que boas estimativas são essenciais para um bom controle estatístico e que a falta de acurácia dessas estimativas gera aumento de falsos alarmes (SNOUSSI *et al.*, 2005). Quesenberry (1991) demonstra que no mínimo $400/(n - 1)$ amostras são necessárias para uma acurada estimação dos limites de controle, onde n é o

tamanho de cada subgrupo. Além disso, são restritos os estudos quando o controle estatístico do processo volta-se para o problema da produção em pequenos lotes. A literatura mostra casos onde em uma mesma linha ou célula trabalhadores utilizam-se de diversas cartas para o controle de características da qualidade (FAN & YOU, 2009; ZANTEK, 2006)

Por outro lado, minimizar as perdas geradas por inspeções de produtos personalizados também é uma necessidade na indústria moderna. Dadas as dificuldades de implantação de um sistema de controle e monitorização contínua das características de qualidade, uma estratégia de monitoramento tão flexível quanto o próprio esquema de produção é necessária para implementar um programa de controle neste ambiente.

1.4 Delimitações

Esta tese foi conduzida sob a área de conhecimento de Engenharia de Produção e, segundo a classificação da ABEPRO (?), no escopo da sub-área Engenharia da Qualidade². Autores da Engenharia da Qualidade têm apresentado estudos relacionados a questões de gestão da qualidade ou questões relacionadas a métodos quantitativos aplicados ao controle da qualidade e dos processos. Esta tese versa sobre o lado quantitativo da Engenharia da Qualidade.

Sobre as influências teóricas mais significativas que moldaram a tese, dois grupos distintos são identificados. O primeiro grupo está relacionado à modelagem de séries temporais e sua implantação no controle da qualidade. Podem ser citados Box *et al.* (1970) que idealizaram os modelos autoregressivos, além de Enders (2003) e Harvey (1989) que contribuíram no desenvolvimento de técnicas de modelagem de séries de dados econômicos. Montgomery (2004) apresenta a utilização de resíduos de modelos para avaliar a estabilidade de um processo produtivo. Uma série de outros autores apresentaram soluções alternativas, utilizando diferentes princípios de modelagem para obtenção de resíduos ou construindo ferramentas baseadas nos próprios modelos. Estas contribuições também são apresentadas ao longo do texto. O segundo grupo está relacionado diretamente com a aplicação de ferramentas de controle estatístico do processo em pequenos lotes e/ou procedimentos de auto-inicialização, onde é desnecessária uma fase de análise retrospectiva (fase I) durante a implantação das cartas de controle. Neste grupo pode-se citar vários autores, como Del Castilho & Montgomery (1995; 1996), Del Castillo *et al.* (1996), Woodall (1983; 2000) e Quesenberry (1991; 1997). Estes apresentam as contribuições mais significativas para controle da qualidade em pequenos lotes e esquemas de auto-inicialização e, conseqüentemente, para o desenvolvimento desta tese.

Três pontos principais ainda precisam ser destacados quanto às delimitações deste

²Na literatura de língua inglesa é equivalente ao termo *Quality Engineering*.

estudo. O primeiro foi o grau de detalhamento explicativo sobre a implantação e execução de modelos de produção em ambientes customizados. Apesar da tentativa de apresentar os aspectos principais desta realidade, um detalhamento maior não foi incluído. O segundo foi a indisponibilidade de um volume maior de séries reais para a verificação do desempenho das diversas ferramentas apresentadas. Esta limitação é contornada, em parte, pelo estudo de simulação efetuado. Neste estudo, foram gerados diferentes cenários, buscando atingir diversas possibilidades que podem ser encontradas na realidade das empresas. O terceiro ponto é que os resultados são restritos aos obtidos no estudo de simulação, sendo sugerida a implantação em ambientes customizados reais em estudos futuros.

Por fim, é necessário destacar que os métodos buscam avaliar somente o nível da série de dados com diferentes produtos. Ferramentas capazes de avaliar a variabilidade da característica da qualidade não foram incluídas neste estudo.

1.5 Delineamento

Antes de apresentar o delineamento da pesquisa, se faz necessário definir as seguintes características em relação à tese (???):

1. Quanto a natureza é uma pesquisa aplicada já que almeja gerar conhecimento tanto para os atores sociais quanto para comunidade científica ao investigar um caso real e gerar resultados simulados para cenários similares aos cenários reais;
2. Quanto a abordagem é uma pesquisa quantitativa pois tem como característica permitir uma abordagem focalizada, pontual e estruturada, utilizando-se de dados quantitativos e obtendo resultados generalizáveis;
3. Quanto aos objetivos a pesquisa é metodológica pois se refere à elaboração de caminhos, formas, maneiras, procedimentos para atingir determinado fim. Também é uma pesquisa descritiva pois tem como finalidade comparar o uso de diferentes métodos em diferentes cenários; e
4. Quanto aos meios de investigação a pesquisa é experimental pois é realizada através de simulação de dados em laboratório.

Puderam ser identificadas cinco fases durante o tempo de execução desta tese. Estas fases permitiram não só determinar rumos para o trabalho, mas também atingir os objetivos específicos. Aspectos relacionados à identificação do problema, a sua importância na área, além da necessidade de elaborar uma solução para aplicação no contexto da produção flexível delinearam a trajetória desta pesquisa.

A primeira fase relaciona-se com a situação problemática vivenciada pela empresa ABC³. A empresa ABC está na cadeia de suprimentos de uma grande multinacional e necessitava da implantação de ferramentas de controle estatístico do processo a pedido deste cliente. O sistema de produção da companhia está configurado de forma a produzir múltiplos itens em uma mesma linha de produção. Após consulta à literatura, verificou-se que a indicação para atender à demanda da empresa ABC era a utilização de cartas tradicionais de controle estatístico do processo, ignorando-se os *lags* de produção. Esta é a fase que motivou a execução deste trabalho.

Na segunda fase foi realizado um estudo exploratório com empresas de um setor produtivo diverso ao da companhia ABC. O objetivo era observar o quão geral era o problema enfrentado pela empresa ABC. Além disso, havia a expectativa pelo indicativo de algum procedimento que poderia ser adaptado e/ou aproveitado para utilização no contexto do problema vivenciado pela empresa ABC. O estudo exploratório culminou na terceira fase: a revisão da literatura.

A partir da revisão bibliográfica foi possível identificar as dificuldades de implantação de ferramentas de controle estatístico do processo. Também pode-se efetuar uma comparação entre os aspectos teóricos relevantes e os passos utilizados na implantação dos procedimentos de controle e monitoramento estatístico do processo. Por fim, verificou-se a existência de uma lacuna na literatura relativa a procedimentos de controle estatístico do processo para ambientes customizados. Esta lacuna demonstrou a necessidade do desenvolvimento ou da adaptação de ferramentas para utilização neste meio.

A quarta fase foi a de criação e adaptação. Um plano de desenvolvimento de uma ferramenta original foi traçado e executado. A idéia geral era a utilização de conceitos de cartas baseadas em modelos, monitoramento de perfis e análise multivariada. Outro aspecto a considerar era a capacidade de lidar com a ausência de uma fase retrospectiva de análise dos dados além de ser capaz de lidar com ciclos de vida de produtos curtos e da inclusão de novos itens sem a necessidade de reinicialização do processo de monitoramento. Foram também desenvolvidas adaptações em modelos de cartas de controle pré-existentes para utilização neste contexto. Mesmo entre as ferramentas adaptadas, a capacidade de autoinicializar-se e de ter incluídos novos itens sem reinicialização do processo foram considerados como requerimentos necessários no desenvolvimento.

A quinta e última fase relaciona-se à pesquisa aplicada: uma pesquisa experimental para avaliar e comparar o desempenho de cinco ferramentas de controle estatístico do processo entre elas e também em comparação a um *benchmark* em oito cenários simulados. Cada cenário representava uma combinação de possíveis violações às suposições básicas de cartas tradicionais. Por não se tratar de cartas tradicionais, além de identificar qual

³Nome fictício da empresa que apresentou o problema de pesquisa e forneceu a série de dados reais para avaliação.

procedimento apresentava melhor desempenho frente aos critérios de avaliação, buscou-se identificar nesta fase quais os efeitos associados a violações das suposições básicas.

1.6 Estrutura da tese

Este documento está estruturado em cinco capítulos. O capítulo 1 apresentou uma contextualização sobre implantação de ferramentas de controle em ambientes customizados, a problematização, os objetivos, a justificativa que motivou a realização do trabalho, a delimitação da investigação e o delineamento da abordagem utilizada para realizar a pesquisa aplicada. O capítulo dois discorre sobre a revisão bibliográfica e está dividida em três partes consideradas relevantes para o desenvolvimento deste trabalho de pesquisa: as linhas gerais de implantação de ferramentas de controle, os aspectos principais de várias metodologias não tradicionais de controle estatístico do processo⁴ e a formulação básica de três modelos preditivos potenciais para serem utilizados em uma das ferramentas propostas. O capítulo três detalha o método de pesquisa utilizado, bem como os procedimentos de simulação adotados. No capítulo quatro são apresentados os resultados e as discussões pertinentes em 6 subseções: os resultados do estudo qualitativo exploratório sobre implantação de cartas de controle em ambientes customizados, uma análise crítica sobre os impedimentos da implantação das ferramentas de controle apresentadas no capítulo dois, os resultados do processo de escolha de um modelo preditivo para ajuste de dados provenientes de ambientes de produção customizados, a proposição de um método original baseado em um modelo preditivo, a adaptação ao problema de métodos de controle estatístico do processo pré-existentes e os resultados do estudo comparativo entre os métodos propostos. No Capítulo cinco são apresentadas as conclusões bem como sugestões para trabalhos futuros.

⁴Entende-se por metodologia tradicional as cartas de controle de Shewhart.

2 Revisão Bibliográfica

Sistemas de produção customizada têm sido identificados por um crescente número de empresas como uma estratégia competitiva de gestão da produção. Customização em massa pode ser definida como um sistema que utiliza tecnologia da informação, processos flexíveis e estruturas organizacionais para entregar uma grande variedade de produtos que atendam às necessidades individuais dos clientes com um custo similar ao verificado em ambientes de produção em massa (DA SILVEIRA *et al.*, 2001).

Pine II (1999) destaca que os desejos do consumidor são incertos e, portanto, é difícil prover o mercado com apenas um produto. É mais provável que um certo número de diferentes produtos seja criado na tentativa de identificar as necessidades dos consumidores. É o que se observa, por exemplo, no mercado de produtos eletrônicos. De acordo com o autor, uma variedade de produtos são lançados e substituídos rapidamente, pois não há certeza sobre o que o mercado deseja. Um processo de rápida inovação ocorre, até que surja um design dominante. Então, inovações pontuais são incrementadas, buscando atender novas tendências identificadas. Isto faz com que o ciclo de vida de um dado produto seja efetivamente curto.

Um ambiente de produção contínuo que se adapte a mudanças de demanda de quantidade e variedade é criado quando dois conceitos chaves são alcançados: *Just-in-time* e checagem autônoma de anomalias no processo (?). De acordo com o autor, estes são os conceitos chave do sistema de produção *Lean*, por exemplo. A fim de realizar a produção *Just-in-time* perfeitamente, 100% de produtos sem defeitos devem seguir para o processo subsequente, na quantidade e tempo esperados e sem interrupções. Assim, de acordo com o autor, o controle de qualidade é tão importante que deveria coexistir com a operação *Just-in-time*. Monden (?) ainda aponta que o controle da qualidade deve adaptar-se a um sistema com flutuações diárias ou mensais na demanda, tanto em termos de quantidade quanto de variedade. Além disso, a segurança da qualidade deve garantir que cada processo irá suprir apenas com boas unidades os processos subsequentes.

O uso de ferramentas de controle estatístico do processo em ambientes de produção em massa tem obtido certo destaque na literatura, principalmente pelos efeitos gerados pela inadequada implantação. A violação das suposições acarretam na deterioração do desempenho destas ferramentas. Suspeita-se que a inadequada implantação em ambientes

customizados sofra do mesmo mal. Assim, neste capítulo de revisão, uma seção é dedicada a apresentar os aspectos relevantes quanto à verificação das suposições para a adequada implantação de cartas de controle.

Além da adequada implantação das cartas de controle, outros dois aspectos importantes merecem destaque no desenvolvimento de uma ferramenta de controle estatístico do processo para a utilização em ambientes customizados. O tipo de metodologia de controle e monitoramento e a capacidade desta em lidar com as constantes e rápidas mudanças verificadas neste ambiente. Autores da Engenharia da Qualidade desenvolveram diversas metodologias de monitoramento e controle. Diferentes metodologias foram detectadas, entre elas cartas de controle de resíduos, baseadas em modelos, controle de componentes de variância, cartas de controle multivariadas, monitoramento de perfis e esquemas de controle com auto-inicialização. Uma seção acerca das principais metodologias de controle da qualidade é apresentada nesta revisão.

Monden (?) destaca a importância do controle de qualidade em sistemas customizados mas ressalta a necessidade de sua adaptação para esses ambientes. Uma metodologia de destaque na literatura utiliza modelos preditivos para a construção de cartas de controle. Deste modo, com o uso da modelagem estatística do processo, um sistema de controle capaz de lidar com as rápidas mudanças de um sistema produtivo customizado pode vir a ser desenvolvido. A última seção desta revisão apresenta a formulação básica de três modelos preditivos, que já foram anteriormente utilizados no controle da qualidade, introduzindo a eles variáveis indicadoras para uso no contexto de produção de múltiplos itens.

2.1 Pressupostos para a adequada implantação de cartas de controle

Duas etapas complementares devem ser executadas para a implantação do controle estatístico do processo antes do início da fase II de monitoramento (MONTGOMERY, 2004). A primeira envolve o estudo da estabilidade do processo, conhecida como fase I, onde cartas de controle são implantadas. A segunda contempla o estudo de capacidade do processo, onde é verificado se o processo é centrado e se ele é capaz de produzir itens de acordo com as especificações. Esta seção foca-se nos aspectos relevantes à adequada implantação de cartas de controle no que diz respeito à primeira etapa da implantação do controle estatístico do processo, mais especificamente da verificação das suposições.

Para a maior parte das cartas de controle, o processo de implantação do estudo de estabilidade apresenta duas fases distintas: a fase I, de exploração e entendimento do processo; e a fase II, de controle e monitoramento (CAULCUTT, 1995; JONES-FARMER

et al., 2009). Na fase I, diagnóstico acerca da independência das observações, distribuição dos dados, estimativas da média e da variabilidade da série observada são obtidos. Isto é necessário pois as cartas de controle são construídas sobre suposições acerca dos modelos matemáticos e estatísticos utilizados. As suposições das cartas de Shewhart, por exemplo, são de que as observações sejam provenientes de uma população normalmente distribuída, que as observações sejam independentes uma das outras e que não exista alteração na variabilidade da série ao longo do tempo (MONTGOMERY, 2004; WOODALL, 2000). Em outras palavras, espera-se que os dados sejam independentes, normal e identicamente distribuídos (i.n.d.). De acordo com Mood *et al.* (1974), quando as suposições não são atendidas, os resultados não podem ser garantidos em termos probabilísticos. Além destas suposições, também é necessário verificar uma premissa básica para a implantação: que o processo esteja sob controle estatístico (KORZENOWSKI, 2009).

Estudos demonstram que o desempenho das cartas de controle é comprometido quando as suposições são violadas, aumentando a probabilidade de resultados falhos. Considerando a violação da independência entre as observações (presença de auto-correlação) na série de dados observados da característica da qualidade, Alwan (1992) e Loredó *et al.* (2002) mostram resultados que indicam que os procedimentos gráficos detectam um número excessivamente superior ao esperado de pontos fora de controle (falsos alarmes). Além disso, esta violação aumenta o número médio de observações necessárias para indicar que o processo se alterou de um estado sob controle para um estado fora de controle (ARL_1).

Dados não normais são frequentemente encontrados em processos industriais segundo Lin e Chou (2004). De acordo com estes autores, é esperado que, com amostras suficientemente grandes, a distribuição da média (estatística usada em uma das principais cartas de Shewhart), convirja para o modelo de distribuição Normal. Este resultado é devido ao Teorema Central do Limite (MOOD *et al.*, 1974). Entretanto, nem sempre é possível obter uma boa aproximação ao modelo Normal. Dependendo do nível de assimetria dos dados observados nas amostras, a convergência ao modelo Normal pode ser vagarosa, conduzindo a um elevado número de alarmes falsos, mesmo em subgrupos relativamente grandes, tais como $n = 25$, por exemplo (?). Moore (1957), Yourstone & Zimmer (1992) e Lin & Chou (2005) mostram que a violação da suposição de normalidade também elevam o ARL_1 .

Supor que os dados sejam i.n.d. refere-se também ao fato da distribuição apresentar média e variância constantes ao longo da série de dados observada. Isto constitui uma importante suposição para a implantação das cartas de controle uma vez que a maior parte das cartas assume limites de controle fixos ao longo do tempo. A violação desta suposição, de acordo com Chan *et al.* (1998) resulta em imprecisão na estimativa dos limites de controle que podem ter como consequência a elevação na taxa de alarmes falsos

e/ou do ARL_1 .

De acordo com Jensen *et al.* (2006), é necessário verificar uma premissa antes da implantação das cartas de controle: verificar se os dados coletados indicam que o processo está sob controle estatístico, isto é, se o processo está estabilizado. A ocorrência de causas especiais de variação neste processo faz com que as estimativas de variabilidade utilizadas na construção de limites de controle não reflitam adequadamente a variabilidade do processo, uma vez que estes podem ser superestimados. Com isso, maiores intervalos de controle serão gerados. Certificando-se de que os dados são originados a partir de um processo estacionário (sob controle), as verificações das suposições podem ser realizadas. Observa-se que, mesmo quando as cartas de controle propostas por Shewhart não têm as suas suposições atendidas, existem alternativas para executar o controle estatístico do processo.

Korzenowski (2009) propôs uma abordagem de verificação das suposições para a implantação da fase I das cartas de controle. Esta estrutura apresenta os principais procedimentos estatísticos que devem ser utilizados para a verificação de cada suposição. A Figura 2.1 apresenta uma adaptação da proposição do autor e, na sequência, quais os principais testes estatísticos podem ser utilizados para efetuar tais verificações.

A implantação de uma carta de controle deve iniciar com a coleta de dados durante um certo período de tempo. Esta coleta deve durar até que se tenha um tamanho suficiente para verificar se o processo encontra-se sobre controle (a premissa básica para a implantação das cartas de controle). Para a verificação de mudanças no nível da série, o estudo de Korzenowski (2009) indica a utilização dos testes de Bai & Perron (2003), um teste capaz de identificar se as séries observadas no processo contêm intervalos onde ocorreram mudanças no nível da série¹. O teste é baseado no ajustamento de modelos lineares e a verificação de diferenças entre os parâmetros dos modelos ajustados em cada sub-parte da série. A sugestão de execução deste teste difere da implantação tradicional, que sugere a execução de uma análise retrospectiva nos dados após a estimativa dos parâmetros do processo.

Após a verificação da premissa, é sugerido verificar a suposição de independência entre as observações. A identificação da presença de autocorrelação é efetuada, geralmente, através da construção das funções de autocorrelação $-ACF$ e autocorrelação parcial $-PACF$ (BOX *et al.*, 1970). Depois da construção destas funções, é possível testar a significância destas funções para cada defasagem (lag) e então, identificar se a série apresenta autocorrelação. Estes testes utilizam as estatísticas Q de Box-Pierce e Ljung-Box

¹O teste de Bai & Perron foi desenvolvido para utilização em aplicações econométricas objetivando a verificação da presença de quebras estruturais em séries econômicas. Quebras estruturais são definidas como alterações no nível ou na tendência de uma série temporal e transpondo esta definição para o controle da qualidade este teste pode verificar se há alterações que indiquem um processo fora de controle durante a fase I.

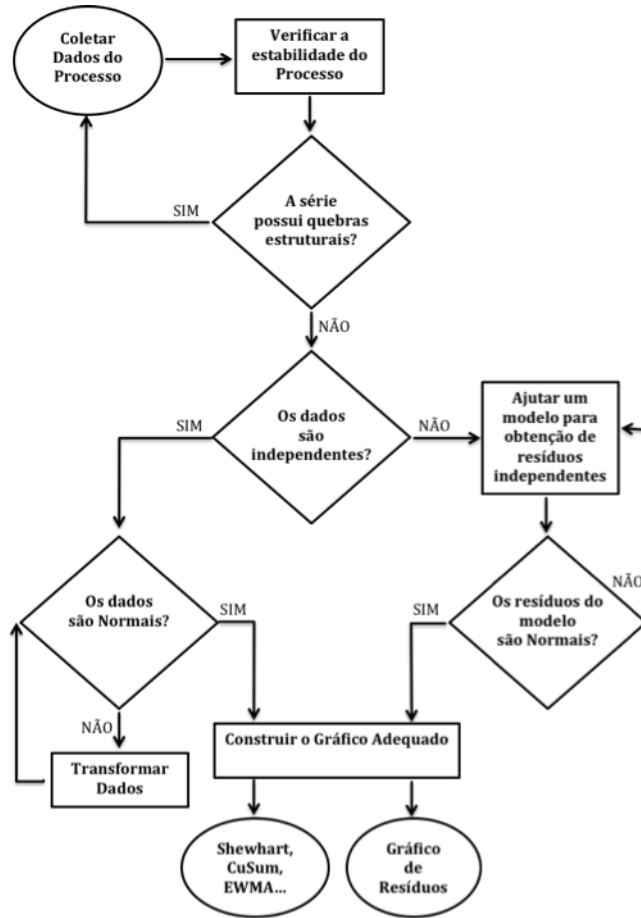


Figura 2.1: Fluxograma para a verificação das suposições e escolha da carta indicada
 Fonte: Adaptado de Korzenowski (2009)

(ENDERS, 2003). Além destes procedimentos, o teste das corridas C de Geary e o teste de hipóteses d de Durbin-Watson podem ser utilizados para a verificação da não independência entre as observações amostradas. Violando-se as suposições de independência, será necessário a implantação de cartas baseadas em resíduos, geralmente obtidos pelo ajuste de modelos ARMA, também propostos por Box *et al.* (1970), como sugerido por Montgomery (2004). Outras sugestões que contemplem a presença de autocorrelação serial podem ser utilizadas, tais como as propostas por Alwan & Roberts (1988) ou Loredó *et al.* (2002). Ramjee *et al.* (2002) também desenvolveram uma abordagem que lida com o problema de autocorrelação, mas em séries que apresentam correlação de longo termo.

Uma vez verificadas a premissa e a suposição de independência, é necessário verificar se as amostras selecionadas são provenientes de uma população com distribuição normal (ou se os resíduos o são). Para verificação de aderência ao modelo normal, é recomendado o teste de Shapiro-Wilk (SHAPIRO & WILK, 1965), para pequenas amostras, e a correção de Lilliefors para o teste de Kolmogorov-Smirnov, quando tratar-se de grandes amostras (LILLIEFORS, 1967). Na presença de autocorrelação, é necessário um teste de normalidade mais robusto. Nestas condições o teste de Jarque-Bera pode ser utilizado

(JARQUE & BERA, 1980; 1981). No caso dos dados serem independentes, porém não normalmente distribuídos, uma transformação pode ser aplicada. Bisgaard & Kulahci (2008) sugerem o uso do procedimento de Box-Cox para transformar os dados. Dependendo do nível de assimetria dos dados é possível decidir pela obtenção de subgrupos de amostras maiores, a fim de, através do teorema do limite central, buscar uma aproximação da distribuição média da distribuição normal, ou, ainda, assumir a ascensão do erro do tipo I gerado pela decisão de colocar em prática os procedimentos gráficos sob a violação desta suposição (LIN & CHOU, 2004; KORZENOWSKI, 2009; STOWMBOS & REYNOLDS, 2000). No caso de dados i.n.d., cartas tradicionais de Shewhart são indicadas. Para dados autocorrelacionados são indicadas cartas de resíduos ou baseadas em modelos, ressaltando que, neste caso, os resíduos necessitam ser verificados e também supõe-se serem i.n.d.

2.2 Metodologias de controle estatístico do processo

Em função dos problemas existentes quanto à implantação de controle estatístico do processo em cenários sujeitos à alta flexibilidade e produção em lotes pequenos é necessário encontrar uma abordagem de monitoramento que seja robusta a estes problemas. Muitas técnicas estatísticas foram propostas e adaptadas para capturar mudanças não intencionais em processos produtivos, seja por violações às suposições das cartas tradicionais, seja pelo número de variáveis monitoradas simultaneamente. Algumas destas técnicas foram citadas na contextualização do problema de pesquisa desta tese. Nesta seção serão apresentadas algumas metodologias de controle e monitoramento da qualidade relatadas na literatura.

2.2.1 Cartas de controle baseadas em modelos e de resíduos

Cartas de controle baseadas em modelos são um conjunto de procedimentos onde um modelo é ajustado ao longo do tempo e os valores preditos ou esperados devido ao ajuste do modelo são comparados com os valores observados (PEDRINI & TEN CATEN, 2011). Nesta construção, os limites de controle são determinados usando os valores esperados e a estimativa de variabilidade dos resíduos. Os limites de controle, tais como intervalos de confiança, são valores em torno dos valores esperados.

Cartas de controle baseadas em resíduos são um conjunto de procedimentos onde é tomada a diferença entre os valores observados e os valores estimados pelo modelo ajustado (MONTGOMERY, 2004). Neste caso, o gráfico é construído com os resíduos e a média dos resíduos é, por definição, zero. Os limites de controle também serão determinados pela estimativa de variabilidade dos resíduos.

Em ambos os casos, um modelo estatístico de previsão é ajustado nos dados reais ao longo do tempo (no sentido longitudinal) e os parâmetros do processo representado pelo modelo são estimados. Estes procedimentos são usualmente utilizados para solucionar problemas associados à violação de suposições. Por exemplo, para dados autocorrelacionados, um modelo ARMA é ajustado e são obtidos resíduos que, supostamente, são não correlacionados ao longo do tempo. Diversos autores discutem o efeito da autocorrelação e propõem alternativas para solucioná-los, como Schmid & Schone (1997), Runger & Willemain (1995), Superville & Adams (1994) e Alwan (1992). Assim como as cartas de Shewhart, cartas baseadas em modelos ou de resíduos supõem que os dados observados sejam classificados no rol de variáveis contínuas. Para dados discretos, outros métodos como a carta de controle baseada no modelo Beta (SANT'ANNA & TEN CATEN, 2010) ou a carta de resíduos obtidos de um modelo linear generalizado (SKINNER *et al.*, 2003) foram propostos na literatura e são classificados neste particular conjunto de metodologias.

A forma geral de uma carta de resíduos é plotar a seguinte estrutura quando, por exemplo, $n = 1$

$$z_t \pm k\hat{\sigma}_z \quad (2.1)$$

onde $z_t = y_t - \mu_0$, k é uma constante que define o erro do tipo I e $\hat{\sigma}_z^2$ é a variância estimada de z_t .

Para a abordagem de cartas de controle baseada em modelos ou de resíduos é necessário no mínimo um razoável número de observações coletada para o ajustamento do modelo. Estes dados observados farão parte da fase I de implantação e serão utilizados para obter o ajuste do modelo e consequente estimação dos parâmetros do processo para então, na fase II, iniciar-se o monitoramento da característica da qualidade.

Del Castillo *et al.* (1996) apresentam uma abordagem de carta baseada em resíduos para ambientes de múltiplos *setups*. No estado da arte, esta é a abordagem mais próxima para o problema de pesquisa apresentado nesta tese. Os autores sugerem a seguinte técnica: determinar o desvio entre o valor observado da característica da qualidade e o valor de especificação (distância ao alvo) em cada tempo t . Após, plotar este desvio (resíduo) em uma carta tradicional de Shewhart. Se a variância em cada um dos diferentes *setups* não puder ser assumida como idêntica, então este desvio é padronizado, dividindo-o pela estimativa do desvio-padrão. A formulação desta carta é definida como segue:

$$z_t = \frac{x_{t,k} - \mu_{0,k}}{\sigma_{0,k}}$$

$$z_t \sim \mathbf{N}(0, 1) \quad (2.2)$$

onde z_t é a observação da característica da qualidade no tempo t e $\mu_{0,k}$ é a média estimada do produto k em produção no tempo t . Assumindo normalidade, os limites de controle são determinados pela equação 2.3 a fim de garantir que o erro do tipo I (α) será menor

do que 0,27%.

$$CL = \hat{Z}_{it} \pm 3\sigma_{z_{it}} \quad (2.3)$$

onde

$$\bar{Z}_{it} = \frac{1}{n} \sum_{t=1}^n z_{it}$$

Como trata-se de um gráfico de resíduos, uma fase I necessita ser considerada para obtenção de estimativas para a média e para o desvio-padrão de cada item em produção. Desvios da média podem ser utilizados ao invés de desvios do alvo neste tipo de carta. Assim, esse procedimento é implantado considerando que os parâmetros do processo são conhecidos, ou são adequadamente estimados a partir de observações obtidas em uma série de dados histórica que passou pela fase I de implantação. A abordagem padronizada (onde divide-se o resíduo pelo desvio-padrão) ainda possui a vantagem da construção de limites de controle, uma vez que, assumindo a normalidade dos resíduos, os limites são definidos diretamente a partir da tabela de distribuição Normal. Assim, para um erro do tipo I $\alpha = 0.0027$, os limites de controle são definidos como ± 3 .

2.2.2 Componentes de variância

Análise de componentes de variância é utilizado em controle estatístico do processo para construir limites de controle através da variabilidade observada intra-subgrupo. Este é o caso de quase todos as cartas de média de Shewhart. Generalizações de modelo sob-controle incluem múltiplos componentes de causas comuns de variabilidade, como por exemplo a variabilidade entre lotes apresentada por Woodall & Thomas (1995). No exemplo, onde considera-se a variabilidade entre lotes, supõe-se que cada subgrupo é uma amostra homogênea que pode apresentar uma característica de variabilidade do processo impossível de ser removida. Esta variabilidade inerente ao processo não é considerada nas abordagens tradicionais de cartas de controle e, frequentemente, em decorrência disto, os limites de controle serão mais estreitos, gerando um grande número de alarmes falsos (e conseqüentemente aumentando a probabilidade de erro do tipo I) (YASHCHIN, 1994). Destaca-se que estes falsos sinais de causas especiais não refletem pontos fora de controle mas confirmam a presença de variabilidade entre lotes, por exemplo.

A construção de uma carta de Shewhart com estimativa de componentes de variância baseada em um modelo de análise de variância (ANOVA) foi apresentado por Woodall & Thomas (1995). De acordo com os autores, este é o mais simples método e pode ser facilmente adotado na prática. A carta de controle proposta pode ser construída de acordo com a seguinte estrutura:

$$\bar{X} \pm k[\hat{\sigma}_L^2 + \hat{\sigma}_I^2/m + \hat{\sigma}_W^2/mn]^{\frac{1}{2}} \quad (2.4)$$

onde

$$\begin{aligned} \hat{\sigma}_W^2 &= \sum_{i=1}^r \sum_{j=1}^m \sum_{k=1}^n (X_{ijk} - \bar{X}_{ij.})^2 / (rm(n-1)) \\ \hat{\sigma}_I^2 &= \sum_{i=1}^r \sum_{j=1}^m (\bar{X}_{ij.} - \bar{X}_{i..})^2 / r(m-1) - \hat{\sigma}_W^2/n \\ \hat{\sigma}_L^2 &= \sum_{i=1}^r (\bar{X}_{i..} - \bar{X}_{...})^2 / (r-1) - \hat{\sigma}_{WI}^2/m - \hat{\sigma}_W^2/mn \\ \bar{X}_{ij.} &= \sum_{k=1}^n X_{ijk} / n \\ \bar{X}_{i..} &= \sum_{j=1}^m \bar{X}_{ij.} / m \\ \bar{X}_{...} &= \sum_{i=1}^r \bar{X}_{i..} / r \end{aligned}$$

e $\hat{\sigma}_W^2$ representa a variabilidade do erro experimental, $\hat{\sigma}_I^2$ representa a variabilidade observada entre as médias do tratamento I e $\hat{\sigma}_L^2$ representa a variabilidade observada entre as médias do tratamento L hierárquico a I^2 .

Outra estratégia de monitoração baseada em componentes de variância é apresentada por Yashchin (1994). Neste caso, é assumido que as mensurações seguem um modelo de efeitos mistos hierárquico³, a estratégia de monitoramento discutida é baseada na decomposição dinâmica da sequência de observações da característica da qualidade em diferentes sequências de controle. Para cada sequência de controle, uma carta de controle de soma cumulativa univariada (CuSum) é aplicada. Para início do monitoramento, deve-se obter estimativas iniciais em uma sequência de observações de subgrupos de tamanho $n > 1$.

2.2.3 Cartas de controle multivariadas

Neste grupo de procedimentos, é esperado que, a cada tempo t , seja observado um vetor de diferentes características da qualidade de um mesmo produto, isto é, um vetor

²Em projeto de experimentos a expressão tratamento é frequentemente utilizada para designar as fontes de variação. Deste modo, os tratamentos hierárquicos podem ser, por exemplo, lote e fornecedor.

³Um modelo de análise de variância de efeitos mistos hierárquico consiste em um modelo onde as diferentes fontes de variação apresentam efeitos fixos e aleatórios no mesmo modelo.

multivariado. Assim, quando múltiplas variáveis não independentes e um processo são monitoradas simultaneamente, as cartas de controle multivariadas apresentam melhores resultados em comparação com cartas de controle univariadas individuais (SULLIVAN & WOODALL, 1996). Isto justifica-se, segundo os autores, pelo fato deste tipo de carta considerar a estrutura de correlação entre as variáveis analisadas. Além disso, os autores também destacam que cartas multivariadas podem mostrar uma perspectiva mais clara do desempenho geral do processo, inclusive relativo a aspectos não observáveis, como a covariância entre as diferentes variáveis.

A literatura apresenta diferentes técnicas para uso em controle de qualidade multivariado. Entre eles destacam-se versões multivariadas da carta de soma cumulativa (MCuSum), carta multivariada de média móvel exponencialmente ponderada (MEWMA)⁴ multivariada e carta T^2 de Hotteling (BODNAR & SCHMID, 2011; MAHMOUD & MARAVELAKIS, 2011; LOWRY *et al.*, 1992; ALWAN, 1986; WOODALL & NCUBE, 1985). Todos estes exemplos assumem um conhecimento prévio sobre os parâmetros do processo quando este encontra-se sob controle estatístico, ou seja, é necessário a implantação de uma fase I para obtenção destas informações para novos processos ou mesmo para mudanças em um processo corrente.

Uma abordagem diferente para análise de um processo multivariado é apresentada por MacGregor & Kourti (1995). Nesta abordagem, é sugerido um procedimento de redimensionamento da base de dados através de Análise de Componentes Principais⁵. Após esta redução, cartas de controle multivariadas tradicionais podem ser aplicadas diretamente nas componentes retidas. Os resultados encontrados através deste procedimento são, segundo os autores, melhores quando comparados com as tradicionais cartas de controle multivariadas.

Uma abordagem que utiliza o modelo de regressão por mínimos quadrados parciais (Regressão PLS⁶) é apresentada por MacGregor & Kourti (1995). A abordagem multi-blocos PLS proposta pelos autores consiste em, dados \mathbf{Y} e \mathbf{X} , matrizes de variáveis de resposta (dependentes) e de variáveis explicativas (independentes), aplicar a análise de componentes principais em ambas as matrizes. Este procedimento é efetivamente importante quando deseja-se incluir variáveis explicativas (*inputs*) no modelo para monitoramento dos *outputs* do processo. Cartas de controle multivariadas para subpartes importantes da planta, como também para todo o processo, podem ser construídas utilizando-se as variáveis latentes produzidas pelo método.

Outra estratégia multivariada de controle de qualidade é apresentada por Chen *et*

⁴Em inglês, EWMA significa Exponentially Weighted Moving Average.

⁵Análise de Componentes Principais (Principal Component Analysis, em Inglês) é uma técnica tradicional em análise estatística multivariada, geralmente utilizada para construção de índices. Detalhes de sua formulação pode ser obtida em ?.

⁶Maiores detalhes sobre este tipo de regressão serão apresentados na subseção 2.4.3.

al. (1998). Trata-se de uma estratégia em múltiplos estágios e consiste em um modelo de análise de componentes principais que incorpora diversas variáveis obtidas em intervalos de tempo distintos (*time lagged*, segundo o autor). O objetivo de controle é expresso através de um escore no espaço do modelo de componentes principais.

Tanto para a utilização do redimensionamento da base de dados através de análise de componentes principais quanto para a utilização da regressão PLS, ou ainda da estratégia de múltiplos estágios de Chen *et al.* (1998), é requerida a existência de uma base de dados históricos considerável. Esta base de dados deve ser proveniente de operações efetuadas no passado do processo e sua análise para estimativa dos parâmetros do processo é tratada como fase I de implantação.

2.2.4 Esquemas para monitoramento de perfis

Em aplicações de controle estatístico do processo, a qualidade de um processo ou produto pode ser melhor caracterizada e resumida pela relação entre uma variável de resposta (dependente ou *outputs*) e uma ou mais variáveis explicativas (independentes ou *inputs*). Assim, a cada estágio de amostragem (obtenção de um novo subgrupo), observa-se uma coleção de pontos que podem ser caracterizados por um perfil (por um modelo estatístico). Note que este modelo é ajustado no sentido transversal e não no sentido longitudinal das observações (ao longo do tempo) como nos gráficos baseados em modelos e cartas de resíduos.

Monitoramento de perfis é um caso particular da aplicação de cartas de controle multivariadas, onde a cada instante do tempo t , não se tem $k > 1$ variáveis, mas $k > 1$ parâmetros do modelo para serem controlados. Uma revisão vasta deste tipo de abordagem é encontrada em Woodall (2004). O referido artigo destaca o verdadeiro sentido de *profile monitoring*.

Segundo Mahmoud & Woodall (2004) e Williams *et al.* (2007) o monitoramento estatístico de perfis pode ser similar a aplicações de calibração. A cada instante do tempo t , um conjunto de variáveis X_i é observado em uma amostra (subgrupo) de tamanho n e um modelo que explica a resposta y é ajustado. Assim, um esquema de monitoramento é aplicado para verificar se o novo modelo ajustado representa um estágio de produção em controle ou fora de controle.

Perfis podem ter as mais variadas formas, desde um modelo de regressão linear simples até mais complexos, dependendo da aplicação específica a que se destinam. Abordagens não paramétricas também foram desenvolvidas e puderam ser localizadas na literatura, como por exemplo os estudos de Ding *et al.* (2006), Mahmoud & Woodall (2004) e Walker & Wriqh (2002). Geralmente, as cartas de controle multivariadas utilizadas

utilizam a distância estatística de Mahalanobis ⁷ observada entre o vetor de parâmetros no tempo t e o vetor de parâmetros do modelo estimado na fase I de implantação do controle estatístico do processo.

Diferentes abordagens das apresentadas anteriormente utilizam análise de componentes principais e regressão PLS (BERSIMIS *et al.*, 2007), análise de componentes independentes (ICA) (DING *et al.*, 2006) ou um teste de hipóteses com um conjunto de cartas de controle para o intercepto, inclinação e variabilidade dos resíduos (MAHMOUD & WOODALL, 2004). Em todos os casos, os autores assumem que os resíduos são independentes. Esta suposição é tanto necessária para perfis lineares quanto para os não lineares.

Uma revisão sobre perfis univariados é apresentado por Bersimis *et al.* (2007) e por Sullivan & Woodall (1996). Entretanto, as soluções propostas quando $n = 1$ não podem ser consideradas como monitoramento de perfis de acordo com Woodall *et al.* (2004). Isto porque em monitoramento de perfis a cada tempo t , é observada uma amostra com um conjunto de variáveis explanatórias e é ajustado um modelo cujos parâmetros serão observados ao longo do tempo. Séries observadas quando o tamanho do subgrupo é $n = 1$ permite apenas o ajuste de modelos no sentido longitudinal, tal como a análise de uma série temporal.

2.2.5 Esquemas de auto-inicialização

Todas as abordagens apresentadas previamente necessitam de dados históricos para ser analisados durante a fase I do processo de implantação das cartas de controle. Uma carta de controle de auto-inicialização é baseada em resíduos recursivos, uma vez que a primeira vez em que foram propostas ferramentas de monitoramento deste tipo, os valores nominais do processo eram desconhecidos (ZOU *et al.*, 2007).

Neste conjunto de métodos, as estimativas dos parâmetros são atualizadas a cada nova observação e, simultaneamente, os dados são conferidos quanto à sua condição em controle ou fora de controle. Há disponível na literatura diversos procedimentos para controle univariado, multivariado ou de monitoramento de perfis que se autoinicializam sem a necessidade da execução de uma fase I de análise (SULLIVAN & JONES, 2002; HAWKINS & OLWELL, 1997; QUESENBERRY, 1997). A ideia mais simples consiste em, uma vez que se obtenha a segunda observação, compara-se esta com a primeira para mensurar quão grande é a diferença entre elas. Assim, a média das duas primeiras observações pode ser comparada com a terceira observação e assim por diante. Para procedimentos deste tipo, os diversos autores recomendam que após um razoável número de observações uma análise retrospectiva seja efetuada (como em uma fase I) e então

⁷Distância estatística de Mahalanobis difere-se da distância euclidiana no plano do \mathbb{R}^n por considerar a matriz de covariância das variáveis observadas.

cartas tradicionais sejam implantadas (como em uma fase II).

A formulação básica para procedimentos de auto-inicialização é apresentada na equação 2.5.

$$z_t = \frac{x_t - \bar{X}_t}{\hat{\sigma}_t}, \text{ for } t=2, \dots, T. \quad (2.5)$$

onde

$$\bar{X}_t = \frac{1}{n} \sum_{i=2}^n x_i$$

$$\hat{\sigma}_t = \frac{1}{n-1} \sum_{i=2}^n (x_i - \bar{X}_t)^2$$

onde n é o tamanho da sequência observada até o tempo t . Neste caso, a média e a variância do processo são atualizadas a cada novo tempo t , a partir da segunda observação. De acordo com Del Castillo & Montgomery (1994), uma prática comum em controle de qualidade em ambientes de produção de pequenos lotes é monitorar o desvio em relação à própria especificação do produto, ao invés do parâmetro estimado dos dados. Assim, para a primeira observação, o monitoramento poderia ser efetuado a partir de

$$z_1 = \frac{x_1 - \mu_0}{\hat{\sigma}_1} \quad (2.6)$$

onde μ_0 é o valor nominal

$$\hat{\sigma}_1^2 = (x_1 - \mu_0)^2.$$

As cartas Q para problemas de produção de pequenos lotes foram introduzidos por Quesenberry (1991). Os procedimentos assumem que a característica da qualidade segue um modelo de distribuição Normal. Quatro casos são apresentados e classificados de acordo com o conhecimento *a priori* acerca do processo. O caso IV de Quesenberry é definido quando μ_0 e σ_0^2 são desconhecidos. Neste caso, a estatística Q será dada pela equação 2.7.

$$Q_t(x_t) = \Phi^{-1} \left[T_{t-1} \left(\frac{x_t - \bar{X}_t}{s_{0,t-1}} \right) \right] \quad (2.7)$$

onde

$$S_{0,t}^2 = \frac{1}{t-1} \sum_{j=1}^t (x_j - \bar{X}_t)^2$$

onde Φ^{-1} denota a inversa de uma distribuição Normal padronizada e T_v denota a distribuição acumulada da distribuição t de Student com v graus de liberdade. Como a estatística Q comporta-se de acordo com um modelo de distribuição Normal, os limites

de controle são definidos como ± 3 para um nível de significância $\alpha = 0.0027$.

2.3 Modelos preditivos com variáveis exógenas

Dentre as metodologias de controle de qualidade que utilizam gráficos baseados em modelos ou em resíduos, a literatura recomenda, geralmente, modelos ARIMA ou modelos regressivos. Modelos deste tipo também são ajustados quando se pretende monitorar o perfil de um conjunto de dados. Uma estratégia para ajustar mudanças de nível conhecidas em uma série de dados é a inclusão de variáveis indicadoras. Assim, esta seção apresenta a formulação básica da utilização destas variáveis indicadoras em três tipos de modelos preditivos: o modelo ARIMA, proposto por Box *et al.* (1970); o modelo estrutural básico, proposto por Harvey (1989) e o modelo de regressão linear PLS, tal como descrito em Anzanello *et al.* (2012). Estes modelos foram selecionados devido à flexibilidade, suas capacidades em atender os pressupostos básicos da implantação de ferramentas de controle estatístico do processo e por já terem sido utilizados previamente em controle estatístico do processo.

2.3.1 Modelo ARIMA com variáveis indicadoras

O modelo autoregressivo de média móvel (ARIMA) é um modelo frequentemente utilizado em controle estatístico do processo (ALWAN, 1992; BISGAARD & KULAHCI, 2005). Sua estrutura considera uma porção autoregressiva e uma porção média móvel. Uma vez que os dados originais são correlacionados ao longo do tempo, isto é, o modelo que explica o comportamento dos dados depende de observações da própria série no passado, este modelo é utilizado para se obter resíduos independentes (não correlacionados) e que, espera-se, não violem nenhuma outra suposição requerida para a implantação de cartas de controle.

Mudanças na média do processo podem ocorrer devido às diferenças nas características da qualidade nos diversos tipos de produtos controlados. A estacionariedade da série de dados é uma suposição dos modelos ARIMA (BOX *et al.*, 1970). Segundo os mesmos autores, é suposto que a ausência de estacionariedade pode ser solucionada pela tomada de diferenças da observação atual em relação a observações anteriores. Entretanto, em controle de qualidade, cada trecho da série correspondente a um diferente produto, deve apresentar estacionariedade. A mudança de nível está relacionada à alteração no tipo de produto sendo produzido. Desta forma, uma estratégia para modelar neste contexto é a utilização de variáveis exógenas (indicadoras) ao invés de integrar a série para ajustar o modelo ARIMA (ENDERS, 2003).

Box *et al.* (1970) desenvolveram uma abordagem para identificar corretamente

o modelo ARIMA. Esta abordagem consiste em escolher o modelo mais adequado para uma série estacionária com o objetivo de efetuar previsão de séries temporais univariadas. Os autores propuseram as funções de autocorrelação (ACF) e de autocorrelação parcial (PACF) para a identificação do modelo.

Os parâmetros de um modelo ARIMA com variáveis regressoras e resíduos normalmente distribuídos podem ser estimados pela função de máxima-verossimilhança, o que é similar a estimar os parâmetros de um modelo ARIMA com variáveis exógenas. Assim, considere o modelo ARIMA (p, d, q) com variáveis indicadoras apresentado na equação 2.8.

$$\phi(B)\Delta y_t = \theta(B)a_t + \sum_{i=1}^{k-1} D_{it} \quad (2.8)$$

onde $\phi(B)$ é a porção autoregressiva, Δy_t é a série de observações coletadas, $\theta(B)a_t$ é a porção média móvel, $\sum_{i=1}^{k-1} D_{it}$ é a soma de variáveis regressoras indicadoras e a_t é o elemento normal e identicamente distribuído (i.n.d.) conhecido como ruído branco. As estimativas de máxima verossimilhança para o vetor de parâmetros $\epsilon = (\phi, \theta, D, \sigma_a^2)$ para as observações y_1, \dots, y_T é obtido pela maximização da função conjunta de a_1, \dots, a_T supondo normalidade.

2.3.2 Modelo estrutural básico e filtro de Kalman

O modelo estrutural básico proposto por Harvey (1989) é um caminho alternativo para modelar séries temporais que incluam variáveis exógenas. Entretanto, neste caso, os parâmetros podem ser variantes no tempo. Isto habilita o uso de modelos não lineares em formato de espaço dos estados onde os parâmetros podem então ser estimados através de um processo de filtragem. A presença de autocorrelação na série de dados também não reduz o desempenho deste tipo de abordagem uma vez que os principais modelos ARIMA apresentam representações equivalentes no espaço dos estados (HARVEY & SHEPHARD, 1993).

O filtro de Kalman é capaz de ajustar os parâmetros do modelo utilizando um processo recursivo baseado em um número de unidades amostrais que é, geralmente, menor quando comparado com os métodos convencionais (HARVEY, 1989). Além disso, segundo o autor, o modelo apresenta melhor ajustamento aos dados que um modelo linear tradicional.

De acordo com Harvey & Shephard (1993), os estados não observáveis de uma série temporal podem ser estimados através de um processo de filtragem e, então, ser atualizados tão logo uma nova observação seja coletada. A formulação estatística do modelo de nível + tendência + componente irregular é dado pela equação 2.9.

$$y_t = \mu_t + \varepsilon_t, \quad t = 1, \dots, T \quad (2.9)$$

onde y_t é a série de observações da característica da qualidade do processo ao longo do tempo, μ_t é o fator não observável de nível + tendência da série e ε_t é um componente irregular i.n.d.⁸

A função estocástica de nível + tendência é dada pela equação 2.10.

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t \quad (2.10)$$

$$\beta_t = \beta_{t-1} + \xi_t \quad (2.11)$$

onde η_t e ξ_t são ruídos brancos mutuamente não correlacionados com média zero e variâncias σ_η^2 e σ_ξ^2 , respectivamente. Se $\sigma_\eta^2 = \sigma_\xi^2 = 0$, as equações 2.10 e 2.11 são reduzidas a uma função determinística de nível + tendência e parâmetros invariantes ao longo do tempo serão obtidos, como foi proposto por Fan & You (2009).

Mudanças nos *setups* ou devidas à troca de produtos podem ser modelados por variáveis exógenas, que podem ser ou não estocásticas ao longo do tempo. De acordo com Harvey (1989), variáveis indicadoras podem ser incluídas na equação 2.10 resultando na equação 2.12.

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \sum_{i=1}^k D_{it} + \eta_t \quad (2.12)$$

onde k é o número de mudanças de nível na série e D_{it} refere-se às variáveis indicadoras que descrevem as mudanças de nível na série de observações da característica da qualidade do processo. Em formato de espaço dos estados, a equação 2.12 é reescrita como 2.13.

$$y_t = \mathbf{X}_t \alpha_t + \varepsilon_t = \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} \mu_t \\ \beta_t \end{bmatrix} + \varepsilon_t, \quad t = 1, \dots, T \quad (2.13)$$

onde y_t é uma série temporal de N elementos relacionada a um vetor ($M \times 1$) α_t conhecido como vetor dos estados, \mathbf{X}_t é uma matriz não estocástica ($N \times M$), e ε_t é um vetor de ruído branco ($N \times 1$) com média zero e variância H_t . A equação resultante é similar à equação de regressão linear clássica, onde o vetor de estados representa seus coeficientes e está associado com uma equação de transição 2.14.

⁸Veja HARVEY (1989) para maiores detalhes.

$$\alpha_t = \begin{bmatrix} \mu_t \\ \beta_t \end{bmatrix} = \mathbf{M}_t \alpha_{t-1} + \nu_t = \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 0 \end{bmatrix} \begin{bmatrix} \alpha_{t-1} \\ \beta_{t-1} \\ D_1 \\ \vdots \\ D_k \end{bmatrix} + \begin{bmatrix} \eta_t \\ \xi_t \\ \delta_{1t} \\ \vdots \\ \delta_{kt} \end{bmatrix} \quad (2.14)$$

onde \mathbf{M}_t é uma matriz conhecida ($M \times M$) e ν_t é um vetor de ruído branco ($G \times 1$) com média zero e variância \mathbf{Q}_t .

No modelo proposto por Harvey (1989), ν_t e ε_t são supostamente não correlacionados para cada $s \neq t$, entretanto Commaundeur & Koopman (2007) relaxaram esta suposição, mostrando que o procedimento é robusto à existência de dependência entre ν_t e ε_t .

Se todas as perturbações dos parâmetros são assumidas como sendo i.n.d., os hiperparâmetros σ_ε^2 , σ_η^2 , σ_ξ^2 , $\sigma_{\delta_i}^2$ podem ser estimados por máxima-verossimilhança, levando em consideração às mudanças de nível representadas pelas variáveis indicadoras, através do filtro de Kalman.

Uma vez que se trata de um processo recursivo, uma estimativa inicial para os estados do processo (α_0) é necessária. Estes valores iniciais podem ser definidos aleatoriamente, porém, em procedimentos de controle de qualidade, Del Castillo & Montgomery (1995) recomendam a utilização dos alvos do processo como valores iniciais em procedimentos de auto-inicialização.

Combinando as equações de medida 2.13 e de transição 2.14, pode-se derivar dois conjuntos de equações denominadas equações de previsão 2.15 e equações de atualização 2.16.

$$\begin{aligned} \alpha_{t|t-1} &= \mathbf{M}_t \alpha_{t-1} \\ \Sigma_{t|t-1} &= \mathbf{M}_t \Sigma_{t-1} \mathbf{M}_t' + \mathbf{R}_t \mathbf{Q}_t \mathbf{R}_t' \end{aligned} \quad (2.15)$$

$$\begin{aligned} \alpha_{t|t} &= \alpha_{t|t-1} + \mathbf{K}_t [y_t - \mathbf{X}_t \alpha_{t|t-1}] \\ \Sigma_{t|t} &= \Sigma_{t|t-1} + \Sigma_{t|t-1} \mathbf{X}_t' \mathbf{F}_t^{-1} \mathbf{X}_t \Sigma_{t|t-1}' \end{aligned} \quad (2.16)$$

onde $\mathbf{K}_t = \Sigma_{t|t-1} \mathbf{X}_t' \mathbf{F}_t^{-1}$ e $\mathbf{F}_t = \mathbf{X}_t' \Sigma_{t|t-1} \mathbf{X}_t + \mathbf{H}_t$. As equações de atualização produzem, deste modo, um vetor de estados (vetor de parâmetros) filtrado a cada tempo t para ser utilizado na equação de medida (Equação 2.13) para gerar a predição para y no tempo $t + 1$.

2.3.3 Modelo de regressão linear PLS com variáveis indicadoras

A regressão PLS constrói combinações lineares independentes \mathbf{t}_a ($a = 1, \dots, A$) a partir de variáveis não estocásticas x_{im} , $t_{ia} = w_{1a}x_{i1} + w_{2a}x_{i2} + \dots + w_{Ja}x_{iM}$, com $A \leq M$. O vetor $w_a = (w_{1a}, w_{2a}, \dots, w_{Ma})'$ representa os pesos e o elemento w_{ma} é o peso da variável não estocástica m na componente a . As componentes, isto é, as combinações lineares das variáveis, são também construídas para as variáveis da série temporal Y , $u_{ia} = c_{1a}y_{i1}, c_{2a}y_{i2}, \dots, c_{Ma}y_{iM}$, onde $\mathbf{c}_a = (c_{1a}, c_{2a}, \dots, c_{Ma})'$ representa os pesos de uma variável de série temporal, caso o vetor de resposta seja multivariado (ANZANELLO *et al.*, 2012).

Os vetores de peso \mathbf{w}_a e \mathbf{c}_a são selecionados de modo a maximizar a covariância entre as componentes PLS \mathbf{t}_a e \mathbf{u}_a . Além disso, os pesos são definidos de acordo com componentes ortogonais, ou seja, as componentes \mathbf{t}_a são independentes umas das outras do mesmo modo que as componentes \mathbf{u}_a são independentes uma das outras, como descrito em Wold *et al.* (2001).

O número de componentes retidos é usualmente pequeno quando comparado com o número original de variáveis, o que pode ser consideravelmente grande. Muitos métodos para identificar o adequado número de componentes do processo foram propostos, incluindo a abordagem de validação cruzada, em Hoskuldsson *et al.* (1988), e o algoritmo inferencial, em Lazraq *et al.* (2003). O número limitado de componentes retidos capturam a maior parte da variância da série temporal e das variáveis não estocásticas além da covariância entre estas variáveis. É esperado que este procedimento gere melhores previsões dos valores de uma série temporal Y . A fração da variância em Y explicada por cada componente a retida no processo é representada por $R_{Y_a}^2$.

O modelo de regressão PLS resultante remete a um modelo cuja equação é similar ao de uma regressão linear múltipla tal qual na equação 2.17, apesar de os coeficientes b_m terem sido computados de forma diferente. Eles são decorrentes dos pesos estimados previamente pelas componentes \mathbf{w}_a e \mathbf{c}_a (conforme a equação 2.18).

$$y_i = \sum_{m=1}^M b_m x_{im} \quad (2.17)$$

$$b_{mj} = \sum_{a=1}^A c_{ma} w_{ja} \quad m = 1, \dots, M \text{ e } j = 1, \dots, J. \quad (2.18)$$

3 Procedimentos metodológicos

O delineamento metodológico que suporta esta tese é feito nesta seção, entretanto, parte desta pesquisa envolve o desenvolvimento de um método de controle de qualidade. Neste caso, o processo de desenvolvimento da ferramenta será apresentado no Capítulo 4, juntamente com os resultados, diferentemente do que é feito com os trabalhos positivistas onde a integralidade dos passos metodológicos são apresentados no capítulo de apresentação do método de pesquisa. Assim, este capítulo apresenta, inicialmente, como foi descoberto e verificado na prática o problema de pesquisa. Após são descritos os fundamentos do estudo de simulação e de comparação efetuados.

3.1 O problema de pesquisa e o levantamento das soluções

O primeiro questionamento da tese surgiu durante uma investigação em uma indústria produtora de filmes plásticos na região sul do Brasil. Neste contexto, uma mesma linha de produção era responsável pela confecção de 5 diferentes produtos, sendo 3 diferentes estruturas das quais duas apresentavam alterações de *setup* modificando o nível da série da característica da qualidade mensurada. Entre as mensurações disponíveis, optou-se pela análise da gramatura do filme plástico em detrimento da resistência ao descolamento e resistência à tração. Esta decisão foi tomada tendo em vista que, no contexto do problema, as três variáveis de resposta apresentavam situação similar frente ao problema de pesquisa, isto é, as três apresentavam as mesmas dificuldades em relação à implantação de ferramentas de controle de qualidade pela característica de customização do ambiente produtivo.

Os resultados e reflexões resultantes da intervenção na empresa ABC forneceram um conhecimento dependente do contexto, podendo em certa medida ser transferível para situações similares. Deste modo, um estudo foi conduzido em empresas do setor metal-mecânico, mais especificamente do setor de auto-peças, a fim de avaliar o processo de implantação do controle de qualidade em novos produtos, provenientes de diferentes setores de produção. Buscava-se neste estudo a identificação do processo de implantação

especificamente em ambientes produtivos customizados. Este estudo foi conduzido seguindo uma abordagem qualitativa de natureza exploratória usando o método de estudo de múltiplos casos através de entrevistas semi-estruturadas e observações.

Um levantamento bibliográfico foi efetuado buscando a indicação do tipo de carta de controle adequada a ser implantada em cada contexto, sob o ponto de vista teórico. O segundo estágio deste levantamento qualitativo consistiu na execução de três entrevistas em profundidade com engenheiros da qualidade, com experiência prévia na implantação de ferramentas de controle nas empresas de auto-peças do sul do Brasil. As principais companhias no setor foram contatadas. Os critérios de seleção envolveram a execução de controle estatístico do processo através de cartas de controle (eliminatório), participação no mercado e localização (classificatório). As empresas selecionadas foram aquelas que atenderam aos critérios e responderam positivamente quanto à participação neste estudo. Os engenheiros entrevistados foram selecionados através de um processo de seleção amostral não-probabilístico por conveniência. As entrevistas foram conduzidas seguindo um roteiro de perguntas enquanto que as observações foram apontadas em formulários próprios. O registro das entrevistas foi efetuado através de gravação digital. Os dados foram classificados de acordo com conteúdo, estágio da ação e nível de importância, sendo este definido a partir do levantamento bibliográfico. Durante a visita às companhias, observações foram efetuadas acerca do tipo de ferramentas utilizadas no controle estatístico do processo.

A análise de conteúdo das entrevistas pretendia verificar:

1. Os principais passos adotados durante a implantação de cartas de controle;
2. As principais verificações quanto às suposições das ferramentas utilizadas;
3. As impressões subjetivas acerca dos resultados observados na fase II, principalmente quanto à taxa de alarmes falsos e ARL_1 ; e
4. As fontes de evidência da implantação de cartas de controle.

As notas realizadas durante as observações foram utilizadas como suporte na descrição, análise e interpretação dos dados coletados nas entrevistas. O último estágio desta etapa da pesquisa consistiu na comparação teórica entre a abordagem teórica de implantação de cartas de controle adaptada de Korzenowski (2009) e as fontes de evidências coletadas. Na apresentação dos resultados foram utilizados diagramas, tabelas e mapas conceituais.

Os resultados do estudo qualitativo exploratório evidenciaram as dificuldades de implantação de ferramentas de controle estatístico do processo em ambientes customizados. Estes resultados levaram à conclusão de que os achados durante a intervenção na empresa ABC eram de fato transferíveis a outras realidades. Deste modo, a segunda parte da pesquisa consistiu no levantamento de soluções que lidassem com o problema de

ambientes customizados, produção em pequenos lotes e ferramentas de auto-inicialização. Identificou-se no estado da arte um único método em condições de lidar com o problema de produção de múltiplos itens. Ainda sim, este método apresentava limitações que o tornavam incapaz de atender às dificuldades de implantação da ferramenta no contexto de sistemas de produção customizados visitados.

Diversas metodologias foram verificadas e listadas as características que tornavam-as impeditivas para uso neste contexto. Assim, surgiu a necessidade de propor um novo método de controle de qualidade para ambientes customizados, bem como de desenvolver a adaptação de algumas ferramentas a fim de contornar seus impedimentos de implantação neste contexto. Os detalhes relacionados ao desenvolvimento das soluções propostas nesta tese serão apresentados no Capítulo 4. Um estudo comparativo para definição de um modelo preditivo e para a análise do desempenho das ferramentas propostas foi efetuado e será detalhado a seguir. Nestes estudos, foram ajustados modelos de análise de variância (ANOVA) e adotou-se em todas as análises como nível de significância $\alpha = 5\%$. A análise dos pressupostos dos modelos de análise de variância foram efetuados a partir da análise gráfica dos resíduos.

3.2 Da escolha de um modelo preditivo

O processo de desenvolvimento de uma ferramenta de controle adequada para implantação em ambientes customizados envolveu a decisão quanto à escolha de um modelo preditivo para ajustamento dos dados. Os problemas de produção em pequenos lotes ou relacionados a ambientes customizados jamais foram estudados sob o ponto de vista da relação entre uma variável de resposta e um conjunto de variáveis explicativas. Assim, foram escolhidos 3 diferentes procedimentos de modelagem preditiva. O critério de seleção destes modelos foi sua utilização prévia no contexto amplo de controle da qualidade. Como variáveis explicativas, foram inseridas variáveis indicadoras que representariam os produtos em produção no tempo t , tal qual apresentado no Capítulo 2.

Uma série cuja demanda é irregular e não há tamanho de lote mínimo foi obtida para a característica da qualidade gramatura junto a empresa ABC. A série de tamanho $n = 200$ apresentava 40 observações de cada um de 5 produtos distintos. Os três modelos apresentados no Capítulo 2 foram ajustados nas primeiras 150 observações da série. O erro quadrático médio (RMSE) ¹ e a estatística U de Theil² foram utilizados para avaliar a aderência dos modelos aos dados. As medidas de acurácia dos modelos foi calculada utilizando as 50 observações restantes da série a fim de avaliar a capacidade preditiva dos modelos. As 50 observações representam, neste caso, novas observações não incluídas na

¹veja Chong & Jun (2005)

²A estatística U de Theil consiste na razão entre o RMSE de dois modelos.

fase de ajuste.

Para a confirmação dos resultados, um estudo de simulação também foi efetuado. Bases de dados foram geradas assumindo que a verdadeira resposta comportava-se como um dos dois seguintes modelos: um modelo estrutural do tipo nível + tendência, tal qual o apresentado na equação 2.12 ou um modelo ARIMA, tal qual apresentado na equação 2.8. Os parâmetros dos modelos simulados foram baseados nos resultados obtidos nos dados reais analisados. Não foram geradas bases de dados baseadas no modelo de Regressão PLS para evitar o excesso de fatores no experimento simulado.

Foram definidos 2, 3 e 5 como número de itens em produção, o que determina o número de níveis simulados na série. A sequência de produção de cada um dos itens depende do tamanho do lote, o que é desconhecido *a priori* se o processo de produção é sob demanda. Entretanto, a demanda pode ser simulada através de um processo de Poisson. Assim, os tamanhos das sequências foram geradas considerando como tamanho médio o comprimento médio das sequências observadas nos dados reais. As séries foram geradas com média 100 e após foram inseridas mudanças no nível de, no mínimo, 10%. Esta escolha deu-se a fim de garantir uma diferença no nível da série entre os produtos que pudesse ser detectada pelos modelos testados. Além disso, foram testados dois níveis de variabilidade (2, 98 e 3, 31), gerados de acordo com Chong & Jun (2005).

Um delineamento fatorial completo com blocos foi efetuado. Três fatores foram analisados: número de produtos, variabilidade da componente de erro aleatório e modelo ajustado. O processo gerador dos dados foi considerado como bloco nas análises. Para cada combinação foram efetuadas 100 replicações e avaliado o desempenho de predição dos modelos testados pela média aritmética simples do RMSE. Para cada replicação, uma série de 500 observações foi gerada usando as equações 2.12 e 2.8.

Os resultados da simulação foram analisados através do teste F da Análise de Variância a fim de identificar a existência de diferenças significativas na média do RMSE entre os níveis dos fatores testados. O teste de comparações múltiplas de Tukey (Tukey HSD) foi utilizado nas comparações dos resultados significativos. A Hipótese nula (H_0) assume que todas as médias do RMSE são iguais, enquanto que a hipótese alternativa (H_1) assume que há ao menos uma média que difere significativamente das demais. Testes foram efetuados considerando o nível de significância $\alpha = 5\%$. O modelo que apresentasse a melhor capacidade de predição seria recomendado para utilização no futuro processo de monitoramento, endereçado ao problema do controle de qualidade em ambientes de pequenos lotes e múltiplos *setups*.

3.3 Do estudo comparativo para avaliar o desempenho das cartas propostas

Um estudo foi realizado comparando seis diferentes técnicas de controle estatístico do processo para ambientes de pequenos lotes e múltiplos *setups*. A técnica apresentada por Del Castillo et. al. (1996) foi comparada com outras quatro técnicas propostas a partir da adaptação de cartas de autoinicialização além de uma sexta carta que consistia na utilização de um modelo preditivo. Todas as cartas foram aplicadas em uma série de dados reais com 1070 observações da característica da qualidade gramatura, fornecida pela empresa ABC. A aplicação das técnicas nos dados reais objetivou a execução de uma análise exploratória, onde poder-se-iam obter parâmetros para a geração de novas séries, estas simuladas. Foram geradas, por simulação 5.000 séries de tamanho 400 em 8 diferentes cenários para verificar a robustez dos métodos a violações de suposições tradicionais de cartas de controle.

As alterações de produtos na produção foram definidas através de sorteio completamente randomizado. Do mesmo modo, o tamanho do lote foi determinado de acordo com um modelo de distribuição de Poisson, com média igual à média da série de dados reais.

Foram considerados dois diferentes níveis de variabilidade: igualdade de variâncias e igualdade no coeficiente de variação entre todos os produtos simulados. Este procedimento garantiu cenários homocedásticos e heterocedásticos. Variância e Coeficiente de variação foram definidos de acordo com os valores obtidos na análise da série histórica da empresa ABC.

Também foram considerados cenários onde as observações fossem independentes ou autocorrelacionadas ao longo do tempo. A correlação serial foi definida através de um processo gerador que consistia em um modelo AR(1) - autoregressivo de ordem 1 - estacionário com variáveis indicadoras.

Ainda foram considerados cenários onde os resíduos comportavam-se de acordo com duas diferentes distribuições de probabilidade: o modelo Normal padronizado e a distribuição χ^2 transformada, com graus de liberdade determinada de acordo com a variância do cenário simulado. A transformação de posição apresentada na equação 3.1 foi efetuada a fim de garantir que os resíduos possuíssem média igual a zero (suposição comum no ajustamento de modelos preditivos).

$$\chi_v^2 - \mu_{\chi_v^2} \tag{3.1}$$

Um resumo de todos os cenários simulados é apresentado na Tabela 3.1. A distribuição dos fatores foi efetuada de acordo com um modelo fatorial completo 2^3 .

As medidas de desempenho utilizadas foram o ARL_0 e o ARL_1 . Entende-se por ARL_0 o número de observações médio entre a indicação de dois alarmes falsos, determinado de acordo com a equação 3.2. Entende-se por ARL_1 o tamanho médio da sequência até a ocorrência do primeiro alarme após o processo ter verdadeiramente passado de um estado sob controle estatístico para um estado fora de controle estatístico, determinado de acordo com a equação 3.3.

$$ARL_0 = \frac{1}{\frac{1}{N} \sum_{i=1}^N \left(\frac{1}{n} \sum_{j=1}^n I_{j\{x:x>LCL \cup x<UCL \mid \mu=\mu_0\}} \right)} \quad (3.2)$$

$$ARL_1 = \frac{\sum_{i=1}^N \left(1 + \sum_k^l I_{k\{x:LCL<x<UCL \mid \mu \neq \mu_0\}} \right)}{N} \quad (3.3)$$

onde n é o tamanho da série, N é o número de séries simuladas, x é a estatística correspondente à carta de controle utilizada, LCL e UCL são limites de controle determinados pelo procedimento de implantação da carta, $I_{j\{x:x>LCL \cup x<UCL \mid \mu=\mu_0\}}$ é uma função que indica que x está além dos limites de controle quando o processo encontra-se estável ($\mu = \mu_0$), $I_{k\{x:LCL<x<UCL \mid \mu \neq \mu_0\}}$ é uma função que indica que x está entre os limites de controle quando de fato o processo está fora de controle estatístico ($\mu \neq \mu_0$), k é a posição do primeiro ponto onde a série encontra-se fora de controle na simulação e $k + l$ é a posição do primeiro sinal de que o processo encontra-se fora de controle após a mudança ocorrida em k . Destaca-se que todas as cartas de controle foram ajustadas com os parâmetros padrão para um erro do tipo I ($\alpha = 0,0027$). Neste caso, é esperado um sinal fora de controle a cada 370 observações.

Tabela 3.1: Descrição dos cenários simulados para comparação das técnicas de controle estatístico do processo aplicados a ambientes customizados

Cenário	Variabilidade	Presença de autocorrelação	Distribuição dos resíduos
I	$\sigma = 5.1465$	Não	Normal
II	$\sigma = 5.1465$	Não	χ^2
III	$\sigma = 5.1465$	Sim	Normal
IV	$\sigma = 5.1465$	Sim	χ^2
V	$CV = 15.34\%$	Não	Normal
VI	$CV = 15.34\%$	Não	χ^2
VII	$CV = 15.34\%$	Sim	Normal
VIII	$CV = 15.34\%$	Sim	χ^2

No final, duas novas análises de variância foram executadas tendo como variável de resposta os valores do ARL_0 e ARL_1 simulados por cenário. A interação entre as fontes de variação tipo de variabilidade, presença de auto correlação e distribuição dos resíduos também foi considerada. No caso da análise do ARL_1 , o tamanho do desvio também foi utilizado como fonte de variação. Por utilizar o ARL como variável de resposta (replicação

única do projeto fatorial³), a interação de maior ordem foi definida como variação do erro experimental. Além de observar a existência de diferenças significativas entre os diferentes cenários, o objetivo desta análise foi verificar o tamanho do efeito do ARL associado a cada violação. Para tanto, ao invés da execução de testes de comparações múltiplas de Tukey (HSD), como habitual neste tipo de análise, optou-se pela análise dos parâmetros significativos do modelo linear associado da análise de variância. A exceção foi a utilização de comparações múltiplas para a fonte de variação método associada ao estudo comparativo das ferramentas de controle.

³Para maiores detalhes sobre experimentos fatoriais de replicação única, veja Ledolter & Hogg (?) p. 391.

4 Apresentação e discussão dos resultados

O capítulo 4 apresenta os resultados e discussões acerca das várias etapas do desenvolvimento da tese. Inicialmente, os resultados do estudo qualitativo nas empresas do setor metal-mecânico são apresentados. Nesta primeira seção são destacados os principais equívocos observados durante a implantação de ferramentas de controle em três empresas da região sul do Brasil. Aspectos observados em relação ao controle da qualidade em ambientes customizados são também apontados.

A segunda seção apresenta um quadro resumo das características de cada metodologia de controle de qualidade apresentadas no capítulo 2. Esta seção discute ainda acerca dos principais motivos pelos quais estas técnicas não se enquadram para utilização neste problema de pesquisa.

A seção 3 mostra os resultados do estudo de simulação realizado para definição de qual dos modelos preditivos apresentados no Capítulo 2 apresentam melhor ajustamento em séries da característica da qualidade de um processo real e de processos simulados de múltiplos itens. O modelo com melhor desempenho foi identificado através de uma análise de variância e será adotado na proposição de uma ferramenta de controle para ambientes customizados.

A seção 4 traz a formulação da metodologia de controle estatístico do processo baseada no modelo estrutural básico, por apresentar características de auto-inicialização. O procedimento de monitoração da característica da qualidade é efetuado a partir de uma carta de controle multivariada aplicada sobre o vetor dos estados.

A seção 5 apresenta o desenvolvimento da adaptação efetuada aos modelos de auto-inicialização a fim de torná-los compatíveis com a aplicação no problema de pesquisa. Duas cartas são utilizadas como base e as adaptações são efetuadas não só formulação mas também no modo como é estimada a variabilidade do processo.

Por fim, a seção 6 objetiva mostrar os resultados do estudo de comparação entre a metodologia apresentada por Del Castillo *et al.* (1996) e as metodologias de auto-inicialização propostas. Os resultados são avaliados e as diferenças são apontadas com base em uma análise de variância.

4.1 Teoria e prática na implantação de cartas de controle

A fim de confirmar as dificuldades encontradas na empresa ABC quanto a implantação de ferramentas de controle em seu ambiente de produção customizado, três companhias da indústria automotiva do Rio Grande do Sul aceitaram participar do estudo. O engenheiro da qualidade responsável pela implantação das cartas de controle foi alvo de uma entrevista em profundidade com o objetivo de identificar quais as ferramentas de qualidade utilizadas no processo e como elas são implantadas. Restringiu-se a busca de informações ao processo relacionado ao segmento mais importante. Ao final, foi reportado pelos entrevistados que os procedimentos para os demais segmentos são similares. Além das entrevistas, visitas às instalações permitiram complementar as informações com observações acerca da utilização de ferramentas de qualidade.

Apesar de as três empresas apresentarem participação no mercado distintas, assim como número de empregados, os procedimentos empregados na implantação e monitoramento do controle da qualidade eram similares. A Figura 4.1 mostra um esboço do processo de implantação do controle da qualidade entre as companhias participantes.




Figura 4.1: Fluxograma do processo de implantação do CEP nas empresas participantes

Foi verificado que a primeira preocupação das companhias é realizar o estudo de capacidade do processo em produzir de acordo com as especificações determinadas pelo cliente ou pelo projeto. Uma amostra piloto (de tamanho 50 a 300, dependendo da companhia) é obtida e os índices Cp e Cpk são determinados. Sendo o processo capaz, a produção é programada e o estudo da estabilidade do processo é iniciada com a construção das cartas de controle.

Três tipos de cartas são utilizadas para monitorar o nível da série (todas apresentadas por Shewhart): Carta de média, Carta de mediana e Carta de medidas individuais. Para monitoramento da variabilidade, são utilizadas as cartas de amplitude e de amplitude móvel. Em uma das companhias, a variabilidade do processo não é monitorada, entretanto, a característica da qualidade é inspecionada em 100% das peças produzidas durante os primeiros 5000 componentes produzidos, três meses ou três *setups*, o que ocorrer primeiro. O objetivo demandado pelo cliente é não haver componentes fora das especificações durante este período.

Sobre a frequência e tamanho das amostras (subgrupos), amostras são obtidas em intervalos de 2 a 4 horas de produção com número de observações fixo. O entrevistado da companhia C reportou que, caso haja mudança de setup, 100% dos primeiros itens são inspecionados. Estas condições de monitoramento foram similares para todas as companhias observadas. Por outro lado, diferenças no processo de controle da qualidade também foram encontradas entre companhias. Nas companhias A e C, o controle estatístico do processo começou a ser implantado no início dos anos 90 devido à exigência dos clientes e segue linhas tradicionais. Na companhia A, mais nova e trabalhando em uma estrutura projetizada, as estratégias de ação quando do aparecimento de causas especiais de variação são definidas pela equipe de projeto, junto com o desenvolvimento do produto. Tanto na companhia A quanto na C, uma análise de efeitos e modos de falha (FMEA) é utilizada, o que, segundo os entrevistados, auxilia no controle das ações de correção no processo. A pré-determinação de ações corretivas não é observada na companhia B, sendo estas adotadas pelo próprio trabalhador de acordo com sua experiência prévia.

Uma diferença marcante observada diz respeito à localização das cartas de controle. Nas companhias A e C, as cartas encontram-se junto aos equipamentos produtivos permitindo que os trabalhadores, após a mensuração, anotem os valores observados, determinem as estatísticas e marquem-nas nas respectivas cartas de controle. Em cada posto de trabalho que opera cartas de controle há equipamentos de mensuração disponíveis. Destaca-se que na companhia A, parte dos processos de controle é feito computacionalmente, inclusive o que diz respeito à geração das cartas. Na companhia B, por sua vez, existe uma célula de controle. Findada a produção de uma peça, o trabalhador desloca-se pela planta até a central de controle, onde as devidas medições eram efetuadas e marcadas nos respectivos gráficos. Destaca-se que, o mesmo produto, produzido em diferentes postos de trabalho e por diferentes trabalhadores, tinham suas características da qualidade lançadas na mesma carta, sem nenhum controle adicional de variabilidade devido ao conjunto de produção.

Em todas as companhias, uma carta foi construída para cada característica da qualidade. Mesmo características provenientes de um mesmo produto, onde há a indicação da utilização de cartas multivariadas, são monitoradas em cartas distintas. No caso da companhia A, em certos equipamentos puderam ser observados mais de 10 cartas distintas em um mesmo posto de trabalho, decorrentes da produção de múltiplos itens. Nas companhias B e C, por sua vez, foi reportado que, em alguns casos, diferentes características da qualidade em diferentes produtos utilizam a mesma carta de controle, principalmente quando as características mensuradas apresentam o mesmo nível. Apesar de, na companhia A, parte dos procedimentos utilizarem recursos computacionais e a característica de qualidade do produto ser informada junto com o respectivo código do produto, foi ressaltado que nenhum tratamento especial é dado aos dados para efetuar a construção das

cartas de controle para múltiplos itens. Assim, basicamente dois tipos de procedimentos de controle para múltiplos itens foram observados:

1. marcar em uma mesma carta as observações de mais de um item quando estes apresentam o mesmo nível, independente de sua variabilidade, local de produção ou característica da qualidade;
2. informar conjuntamente com a observação da característica da qualidade o código do produto. Neste caso, supõe-se que seja obtida a diferença entre o valor observado e a média do produto, tal qual descrito na carta de desvio em relação a média apresentada por Del Castillo *et al.* (1996).

Considerando o primeiro tipo de procedimento acima, verifica-se sua inadequabilidade uma vez que não é considerada qualquer informação acerca das variabilidades dos diferentes itens em monitoramento no processo. No caso do segundo procedimento observado, as implicações apresentadas referentes à execução da Fase I colocam em questionamento a eficácia desta ferramenta, principalmente por não ter sido reportado pelos entrevistados a execução de análises acerca das suposições para sua adequada implantação.

A Tabela 4.1 apresenta os aspectos mais relevantes encontrados nas companhias participantes acerca do controle estatístico do processo. Destaca-se que nenhum dos entrevistados reportou a existência de uma fase de estudo diagnóstico durante a implantação das cartas de controle. Foi observado que, de fato, a fase I de implantação de cartas de controle é completamente negligenciada, apesar dos relatos na literatura acerca dos problemas decorrentes da violação das suposições, tal qual descrito na Subseção 2.2.

Tabela 4.1: Resumo das principais informações obtidas junto aos entrevistados das empresas participantes

Empresas	A	B	C
Produto	Componente Mecânico	Sensor de Velocidade	Componente Eletrônico
Passo 1	Estudo de Capacidade	Estudo de Capacidade	Estudo de Capacidade
Passo 2	Estudo de Estabilidade	Estudo de Estabilidade	Estudo de Estabilidade
Carta de Controle utilizada	Mediana e Amplitude	Média	Média e Amplitude
Requerimento do Cliente	Zero defeitos no primeiro lote (300 peças)	Zero defeitos	Não reportado
Número de características críticas	3	5	3
Número de cartas FMEA	Por grupos Sim	Uma por característica Não	Uma por característica Sim

A implantação das cartas de controle pode ser considerada falha sob o ponto de vista teórico, principalmente por não considerar a execução de uma análise retrospectiva. O entrevistado da companhia A inclusive reportou que "nós sabemos que deveríamos

verificar a normalidade e outras coisas necessárias, mas nós estamos fazendo o melhor que podemos". Na companhia B a carta da média também apresenta falhas em sua implantação uma vez que não há controle de variabilidade e nem mesmo efetuada alguma estimativa da variabilidade. Os limites de controle não são determinados e em seu lugar estão plotados os limites das especificações.

Durante a análise de conteúdo dos discursos dos entrevistados foi identificada maior ênfase nos aspectos relacionados na Figura 4.2.

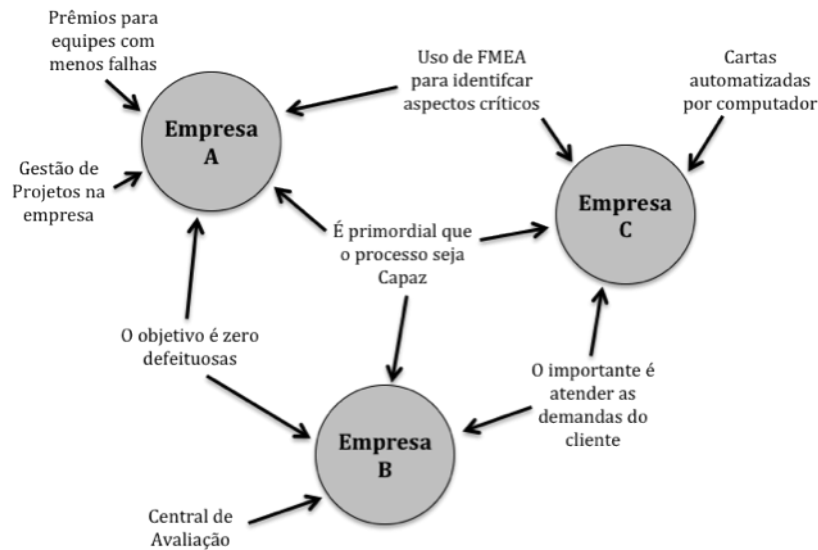
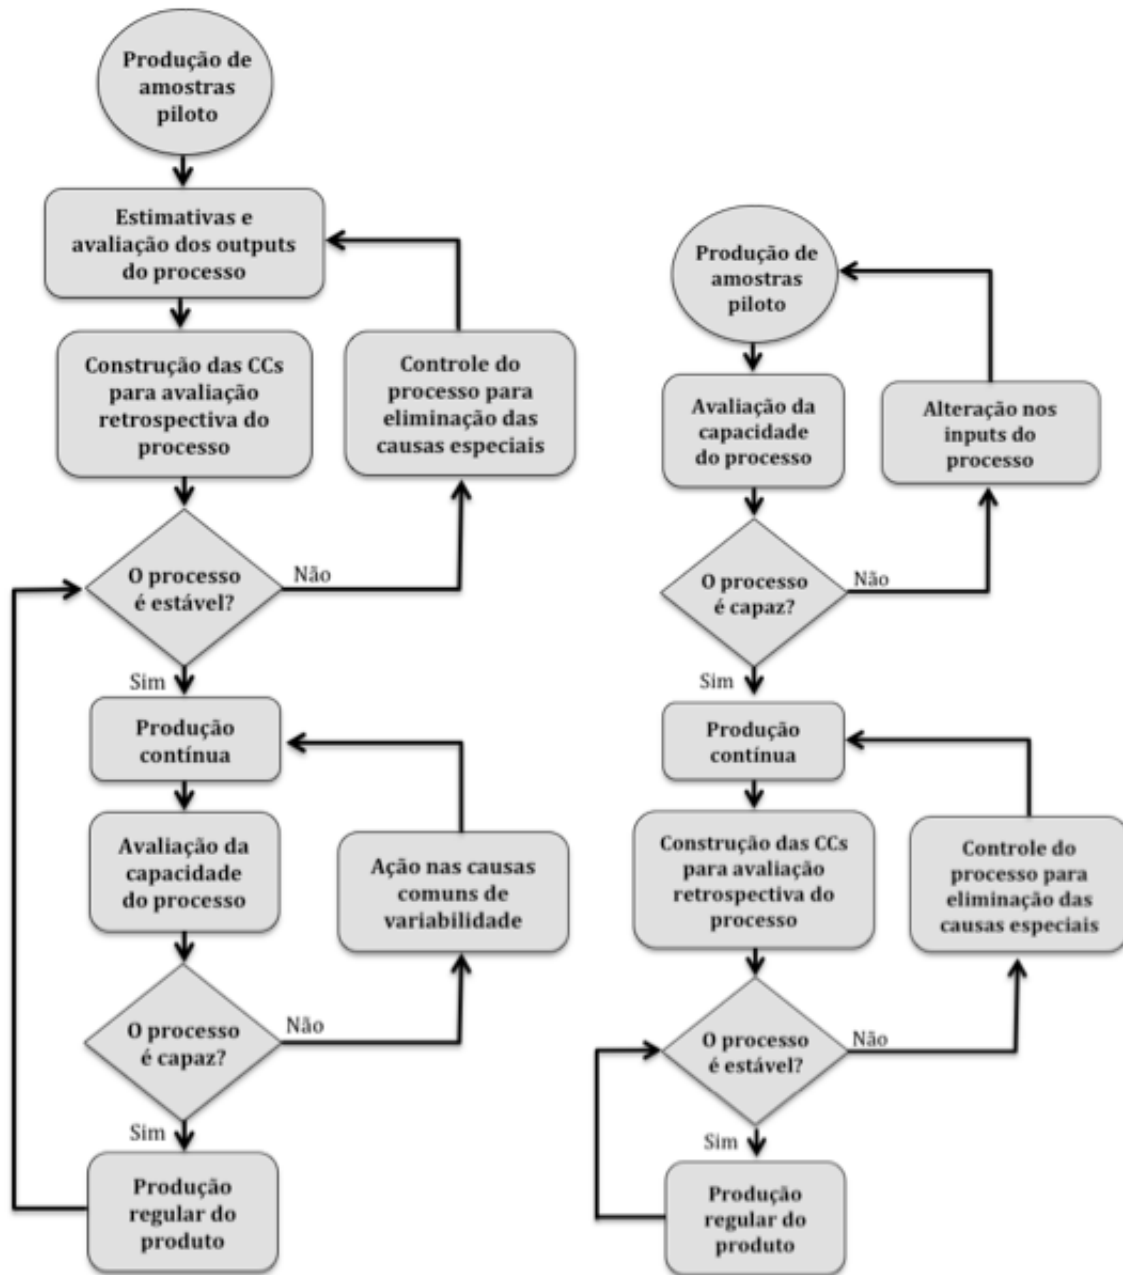


Figura 4.2: Aspectos de maior relevância apontados por cada entrevistado das empresas participantes

Nas companhias A e C foi destacada como fundamental a utilização da FMEA como um método estruturado para identificação dos aspectos críticos do processo. Na companhia A um sistema de premiação para as equipes com menor número de itens defeituosos produzidos está em execução. Quando questionado sobre o objetivo de produção com zero por cento de itens defeituosos, o entrevistado da companhia B destacou que a existência do centro de medições para o controle estatístico do processo objetiva inibir a marcação de medições falsas, de modo a parecer que o processo está controlado aos olhos da administração. O objetivo de zero defeituosos é a justificativa para a utilização dos limites de especificação ao invés dos limites de controle na carta implantada.

A Figura 4.3 mostra um resumo comparativo entre os passos da implantação de ferramentas da qualidade e os passos observados nas empresas participantes acerca da implantação do controle estatístico do processo. O primeiro aspecto a considerar é a inversão entre os passos indicados na literatura e os passos identificados nas companhias participantes.



Passos indicados na Literatura

Passos observados nas empresas

Figura 4.3: Passos na implantação do CEP apresentados na literatura e observados nas empresas participantes

Segundo Antony *et al.* (?), o objetivo do controle estatístico do processo é eliminar causas de variação especial a fim de tornar o processo estável. Uma vez que o processo esteja estável, causas comuns de variação podem ser trabalhadas e reduzidas gerando melhorias na capacidade. De acordo com Montgomery (2004), não sendo estável, inicialmente deve-se verificar se existem causas especiais de variação e se as causas comuns possuem variabilidade muito alta. Isto só é possível verificar se, *a priori*, o estudo de

estabilidade foi bem implantado, isto é, se a fase I, de análise retrospectiva, foi executada.

A inversão observada traz um questionamento sobre a possibilidade de se identificar as causas da não capacidade de um processo sem a adequada implantação das cartas de controle. É evidente que, uma vez implantada adequadamente as cartas de controle e verificado que o processo é capaz, o monitoramento quanto à estabilidade deve continuar sendo executado, assim como tomadas de avaliação da capacidade do processo devem ser executadas. Entretanto, observa-se que a prática adotada nas empresas visitadas apresenta problemas metodológicos.

Pode-se dizer que a implantação das cartas de controle, na perspectiva adotada pelas companhias visitadas, apontam apenas para o cumprimento de pré-requisitos para obtenção de certificações de qualidade e não para o real aprimoramento dos processos. A maior preocupação mostrada pelos entrevistados é com o menor volume possível de componentes defeituosos produzidos. Esta preocupação excessiva é fruto da exigência dos clientes de que o processo seja capaz e, tão somente capaz. Nenhuma referência ao aperfeiçoamento dos processos foi relatada pelos entrevistados. Possivelmente, o comportamento das empresas quanto ao controle estatístico do processo é baseada em fatores econômicos. Se a produção está dentro dos limites de especificação não há retornos, custos com perdas e retrabalho, independentemente de como está o processo.

Estudos de estabilidade ajudam a identificar pontos de melhoria que, geralmente, exigem investimentos adicionais, o que muitas vezes não é bem visto pelo corpo de diretores. Muitas vezes a decisão de investimento recai sobre a própria produção em detrimento da qualidade. Apesar de autores como Deming (?) e Taguchi (?) explicarem claramente que este pensamento é equivocado, ele continua sendo praticado por muitas empresas, como as visitadas neste estudo.

4.2 Metodologias tradicionais em ambientes de múltiplos *setups*

A Tabela 4.2 apresenta um resumo das metodologias de controle estatístico do processo apresentadas no Capítulo 2. Este resumo traz os aspectos principais de cada metodologia bem como suas limitações no que diz respeito à implantação de controle estatístico do processo em ambientes customizados.

Tabela 4.2: Resumo das metodologias de controle de qualidade e suas limitações para implantação em ambientes customizados

Metodologia	Aspectos Principais	Limitações
Cartas de Controle de Resíduos	Grupo I: Resíduos são obtidos pela diferença entre valores observados e o alvo do processo a cada tempo t ; Grupo II: Resíduos são obtidos pela diferença entre valores observados e os valores esperados devido a um modelo ajustado a cada tempo t ; Suposição de independência e normalidade dos resíduos; Pode ser utilizado com subgrupos de qualquer tamanho.	É necessário um conjunto de observações para estimativa dos parâmetros (Fase I); A estimativa precisa ser feita para todos os produtos; É necessário uma abordagem que identifique qual produto encontra-se em produção a cada tempo t .
Cartas de Controle baseadas em Modelos	O modelo é ajustado no sentido longitudinal; A linha central é o valor esperado pelo modelo; Os limites de controle estão no mesmo nível dos valores observados na série; Suposição de independência e normalidade; Pode ser utilizado com subgrupos de qualquer tamanho.	É necessário um conjunto de observações para estimativa dos parâmetros do modelo (Fase I); A estimativa precisa ser feita para todos os produtos; É necessário uma abordagem que identifique qual produto encontra-se em produção a cada tempo t .
Controle dos Componentes de Variância	Um modelo linear é ajustado considerando diversas fontes de variação; A média da característica observada corresponde a linha central; Os limites de controle são construídos considerando todos os componente da variância; As suposições do delineamento linear devem ser verificadas.	É necessário um conjunto de observações para estimativa dos parâmetros do modelo linear (Fase I); Dificil aplicação para subgrupos de tamanho $n = 1$ ou em cenários desbalanceados.
Cartas de Controle Multivariada	Uma estatística multivariada é determinada; Alguns esquemas necessitam de parametrização adicional para a construção dos limites de controle; É usual promover uma redimensionalidade na base de dados antes da aplicação da técnica multivariada.	Inadequado para aplicação no problema de pesquisa por tratar-se este de um problema univariado, como apresentado na Eq. (1.1).
Monitoramento de Perfis	Um modelo é ajustado no sentido transversal, a cada tempo t ; Os parâmetros do modelo são tratados como um conjunto multivariado.	Um modelo não pode ser ajustado a cada tempo t porque um conjunto de variáveis explanatórias não está disponível; É necessário um conjunto de observações para estimativa dos hiperparâmetros de controle (Fase I); Não pode ser aplicado quando subgrupos tem tamanho $n = 1$.
Esquemas de auto-inicialização	Iniciando na primeira ou segunda observações, a diferença é tomada entre a observação no tempo t e a média do processo observada até o tempo t ou $t - 1$; Os limites de controle são obtidos a partir da estimativa do desvio padrão determinada dos próprios dados até o tempo t ou $t - 1$.	Não foi encontrado pelo autor nenhuma abordagem que seja capaz de lidar com a esperada mudança de nível da série.

A dificuldade em implantar cartas de controle tradicionais em ambientes customizados é que este tipo de cenário pode não prover a quantidade de dados necessária para uma estimativa acurada dos parâmetros do processo. Como as mudanças são muito rápidas, o estudo de estabilidade fica comprometido, uma vez que as alterações decorrentes das trocas de *setups* ou mesmo troca de produtos faz com que as sequências de produção de dado item sejam curtas. Se observada a sequência de apenas um produto ao longo de todo o tempo há uma série de informações faltantes, uma vez que nestes intervalos (*lags*) outros itens estão sendo produzidos.

O que ocorre na prática da implantação das cartas de controle é a não consideração dos *lags*, tratando a série como uma série de dados contínua e então obtendo-se dados suficientes para as estimativas dos parâmetros do processo. Esta solução pode até funcionar em certos casos particulares, mas não pode ser garantida uma vez que se desconhece o que, de fato, está ocorrendo quando há troca de setup.

Além disso, os novos períodos de *warm-up* são completamente negligenciados pela análise. Este tipo de prática foi observada nas empresas A, B e C visitadas no estudo qualitativo, bem como na empresa ABC, onde foi identificado o problema e onde foram disponibilizados os dados para análise nesta pesquisa. Este tipo de prática também é relatada na literatura, como por exemplo em Fan & You (2009) e Zantek (2006).

Neste contexto, cartas de resíduos e cartas baseadas em modelos seguem as mesmas implicações que as observadas na implantação das cartas de controle tradicionais. As trocas rápidas, ou até mesmo um ciclo de vida curto do produto, não disponibilizam dados em quantidade suficiente para uma acurada estimativa dos parâmetros dos modelos ajustados. Em outras palavras, o estudo retrospectivo é comprometido pela escassez de dados, ainda mais que parâmetros associados a todos os produtos em produção na linha precisam ser estimados, o que aumenta ainda mais a necessidade de dados de análise para a fase I. A estratégia de ajuste de uma única carta de controle para todos os produtos apresentada por Del Castillo *et al.* (1996) solucionaria o problema da implantação de cartas de controle em ambientes de múltiplos *setups*, não fosse o fato da necessidade da execução de uma fase I, o que pode gerar estimativas não acuradas neste contexto. Isto sem falar que um produto com ciclo de vida extremamente curto pode não conseguir entrar em fase de monitoramento por ter sua produção encerrada antes mesmo de obter-se um número razoável de observações para a estimativa dos seus parâmetros.

Dentro do contexto da análise de componentes de variância, a troca de *setups*, ou melhor, o produto em produção pode ser considerado como uma fonte de variação do modelo linear generalizado ajustado. A implantação considerando produto como fonte de variação atende à necessidade do contexto de múltiplos *setups*. Entretanto, ainda que os autores relatem que as sequências de controle nesta abordagem são atualizadas tão logo um novo lote torne-se disponível, é necessária a análise retrospectiva para o início do

processo de monitoramento. Para atender as necessidades deste procedimento, tal qual um delineamento de experimentos, aspectos como balanceamento das observações também deve ser considerado. Isto, em um ambiente de troca rápida e em sequência, certamente dificulta o processo de ajustamento. Além disso, como as sequências são desiguais e, no limite, apenas uma unidade de um produto pode ser produzida, o balanceamento adequado facilmente pode ser inviabilizado. Enfim, não há como lidar com a inclusão ou exclusão de produtos sem a reinicialização de todo o processo, a partir da análise de uma nova fase I.

Considerando a abordagem multivariada, a descrição do problema apresentado aponta para a existência de k variáveis observadas decorrentes de k produtos em produção. Entretanto, aqui não se trata de um vetor multivariado pois estas diferentes variáveis são observadas em sequência temporal, isto é, após, por exemplo, 5 observações correspondentes ao produto 1, 12 observações do produto 2 e mais 7 observações do produto 3 são coletadas, e assim por diante. Cada observação é disposta no sentido longitudinal e não no transversal, como quando se observa um vetor multivariado.

Os maiores problemas na implantação de cartas de controle multivariadas neste contexto são: 1. As variáveis não são observadas ao mesmo tempo, não configurando assim um vetor multivariado. A obtenção das informações ocorre de acordo com a sequência mostrada na equação 1.1; 2. Procedimentos multivariados, tal qual análise de componentes principais, exigem grandes bases de dados para a estimativa acurada da matriz de covariâncias. Uma grande base de dados para análise retrospectiva é justamente uma das principais dificuldades verificadas em ambientes customizados. Pelas razões listadas, é inviável a implantação de cartas multivariadas neste contexto.

Como explicitado na equação 1.1, a estrutura de dados observada não permite a utilização de ferramentas de controle de monitoramento de perfis. Inicialmente porque um conjunto de variáveis explanatórias pode não estar disponível. De acordo com Woodall *et al.* (2004), monitoramento de perfis é uma técnica que prevê o ajustamento de um modelo entre a variável de resposta (característica da qualidade observada) e um conjunto de variáveis explanatórias em cada subgrupo, ou seja, em cada tempo t . Caso sejam formados subgrupos de observações de tamanho $n = 1$, não há como ajustar um modelo em cada subgrupo unitário. Além disso, a implantação da carta prevê a execução da análise retrospectiva, pois a carta multivariada será implantada de acordo com as estimativas do comportamento dos parâmetros na fase I, o que pode não estar disponível dependendo da velocidade da troca de produtos na linha de produção.

Todas as metodologias discutidas anteriormente carecem da necessidade da execução de uma análise retrospectiva, para obtenção de parâmetros do processo a serem monitorados. As cartas de auto-inicialização são as únicas, entre as metodologias apresentadas, que não carecem de uma fase I. Os parâmetros do processo são estimados e atu-

alizados a partir das próprias observações efetuadas no processo. Assim, o monitoramento pode iniciar-se desde a primeira observação. De fato, este conjunto de procedimentos foi desenvolvido para lidar com ambientes de produção em pequenos lotes, mas podem ser utilizados no início do monitoramento em linhas de produção contínuas tradicionais de acordo com Sullivan & Jones (2002). Destaca-se a necessidade da construção de múltiplas cartas para o monitoramento de um processo com vários itens, uma vez que não há um procedimento deste tipo capaz de lidar com as mudanças conhecidas de nível da série da característica da qualidade observada para os diferentes produtos.

Em ambientes de alta flexibilidade, a carência de dados históricos também está associada à inclusão de novos produtos e à exclusão eventual de produtos antigos cujo ciclo de vida encerrou-se. Assim, a cada nova inclusão, todo o processo de implantação deve ser repetido. Um procedimento que permita a inclusão e a exclusão de itens sem a necessidade de reiniciar a ferramenta de controle, a partir do conhecimento do autor, também carece até o momento de desenvolvimento, uma vez que não foram encontradas referências a este tipo de habilidade nas ferramentas propostas na literatura e discutidas nesta seção.

4.3 Modelos preditivos em cenários afetados por múltiplos *setups*

Esta seção apresenta os resultados do ajuste dos métodos preditivos previamente apresentados no Capítulo 2 em uma série de dados reais provenientes da empresa ABC. O processo em questão é responsável pela produção de bobinas de filme plástico. A linha produz produtos de 3 diferentes estruturas, sendo duas com variações no setup dos equipamentos, perfazendo um total de 5 itens produzidos: PE/PE1, PE/PE2, PE/PET1, PE/PET2 e PE/BOPP. Baseado nas estimativas obtidas na análise dos dados reais, um estudo simulado foi conduzido para confirmar os resultados encontrados.

4.3.1 Análise dos dados reais

A Figura 4.4 mostra as primeiras 150 observações da série de dados coletada. A característica observada nos cinco produtos descritos no prólogo desta seção apresentam não só diferentes níveis mas também diferentes variabilidades entre si. Trinta observações de cada produto foram selecionadas, de acordo com a ordem de produção e serviram de base para o ajustamento dos modelos, num total de 150 observações. Cinquenta observações finais foram obtidas e foram utilizadas para a validação do ajuste. Foram então obtidos os erros de previsão e computada a estatística de comparação entre os modelos.




Figura 4.4: Gramatura dos 5 produtos da série de dados da empresa ABC

Tabela 4.4: Comparativo entre as medidas de ajustamento dos modelos ARIMA, estrutural básico e regressão PLS


Testes e Estatísticas	ARIMA	Estrutural Básico	Regressão PLS
Estatística Q de Box-Pierce	$\chi^2 = 0,878$ $p - \text{valor} = 0,3487$	$\chi^2 = 3,334$ $p - \text{valor} = 0,0679$	$\chi^2 = 0,005$ $p - \text{valor} = 0,9452$
RMSE	4,5124	4,0383	3,7392
U-Theil	—	0,8949	0,8286

O melhor ajuste aos dados entre os modelos ARIMA foi o de média móvel de ordem 1, após ser tomada uma diferença na série. A Figura 4.5 apresenta a série original com as 150 observações originais seguidas das 50 observações adicionais onde foi efetuada a previsão através dos modelos ARIMA (a), estrutural básico (b) e de regressão PLS (c). Os três gráficos apresentam ainda intervalos de ± 3 erros padrão.

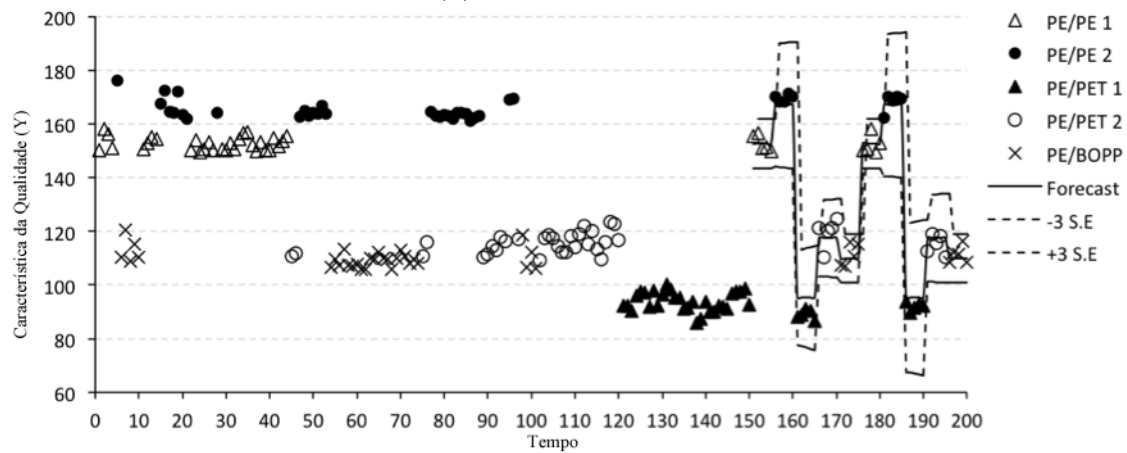
A Tabela 4.4 traz os resultados do estudo comparativo entre as técnicas de modelagem ajustadas à série real de dados observados da característica da qualidade gramatura. A estatística Q de Box-Pierce obtida indica a não existência de autocorrelação serial nos resíduos dos modelos ajustados ao nível de significância $\alpha = 5\%$. A tabela ainda mostra resultados referentes à raiz quadrada da soma quadrática média dos resíduos (RMSE) que nada mais é do que uma medida de acurácia preditiva dos modelos testados¹. A medida U de Theil consiste na razão entre os valores de RMSE de dois modelos distintos. Assim, valores de RMSE de dois ajustamentos distintos podem ser comparados e como resultado é possível apontar qual apresenta, comparativamente, o melhor ajuste. Nesta análise, optou-se pela utilização do RMSE do modelo ARIMA como base de comparação (denominador da estatística U).

Pode-se verificar que o modelo de regressão PLS obteve o menor RMSE, sendo este o que apresentou melhor qualidade de ajustamento (RMSE=3,7392). O segundo melhor


¹No caso do RMSE, quanto menor o valor observado, melhor a qualidade preditiva do modelo ajustado.



(a) Modelo ARIMA



(b) Modelo Estrutural Básico



(c) Modelo de Regressão PLS

Figura 4.5: Valores observados e preditos da característica da qualidade gramatura nos modelos ARIMA, Estrutural Básico e de regressão PLS

resultado foi observado para o modelo estrutural básico (RMSE=4,0383) seguido do modelo ARIMA (RMSE=4,5124). Na comparação via estatística U de Theil, a regressão PLS apresentou predições 20,69% mais acuradas em comparação com o modelo ARIMA ajustado. Já a acurácia preditiva do modelo estrutural básico foi 11,74% maior do que a acurácia preditiva do modelo ARIMA.

4.3.2 Análise dos dados simulados

Com o objetivo de confirmar os resultados observados na série real, foram geradas 100 replicações de uma série temporal de tamanho $n = 500$ com múltiplos produtos, conforme descrito no Capítulo 3. O modelo foi ajustado utilizando-se as primeiras 400 observações e foi construído um intervalo de predição para as 100 observações finais. No intervalo de predição, a estatística RMSE foi obtida e comparada através de um modelo de análise de variância (ANOVA), a fim de identificar a existência de diferenças significativas entre as combinações no delineamento proposto. Os fatores de variação considerados foram o processo gerador dos dados simulados, o número de produtos, a variância do componente de erro aleatório e o tipo de modelo ajustado (ARIMA, estrutural básico ou de regressão PLS).

O modelo linear da ANOVA analisado é apresentado na equação 4.1.

$$y_{ijkl} = \mu + \beta_i + \tau_j + \gamma_k + \delta_l + (\tau\gamma)_{jk} + (\tau\delta)_{jl} + (\gamma\delta)_{kl} + (\tau\gamma\delta)_{jkl} + \varepsilon_{ijkl} \quad (4.1)$$

onde μ é a média geral da série, β_i é o processo gerador dos dados, τ_j é o efeito do número de produtos, γ_k é o efeito da variância do componente de erro aleatório, δ_l é o efeito do modelo ajustado e $(\tau\gamma)_{jk}$, $(\tau\delta)_{jl}$, $(\gamma\delta)_{kl}$ e $(\tau\gamma\delta)_{jkl}$ representam as interações entre os fatores. A acurácia preditiva y_{ijkl} dos modelos testados é a estatística RMSE observada em cada série replicada. A Tabela 4.5 mostra os resultados da ANOVA a partir dos dados simulados.

Os resultados mostram que todos os fatores (fontes de variação) são significativos ao nível $\alpha = 5\%$. Uma vez que a interação tripla é significativa, serão estudados os efeitos apenas nesta fonte de variação, uma vez que ela contempla todas as demais. A Tabela 4.6 apresenta os resultados do teste de comparações múltiplas de Tukey(HSD), assim como as médias observadas em cada combinação de fatores. Valores médios menores implicam em melhor acurácia preditiva. Médias em um mesmo grupo não diferem significativamente ao nível de 5%.

Os resultados apontam que o modelo estrutural básico apresentou a melhor acurácia em comparação com os outros modelos independente do tamanho da variância do componente de erro e do número de produtos na série. Estes resultados são contraditórios

Tabela 4.5: Resultados da ANOVA para a acurácia do ajustamento mensurado através do RMSE

Fonte de Variação	gl	SQ	QM	F	valor p
Gerador do processo (β)	1	665,29	665,29	7942,802	<0,0001
Número de produtos (τ)	2	134,36	67,18	802,086	<0,0001
Variância do Erro (γ)	1	110,53	110,53	1319,600	<0,0001
Modelo ajustado (δ)	2	4521,12	2260,56	26988,487	<0,0001
($\tau * \gamma$)	2	20,60	10,30	123,009	<0,0001
($\tau * \delta$)	4	278,76	69,69	832,012	<0,0001
($\gamma * \delta$)	2	10,34	5,17	61,677	<0,0001
($\tau * \gamma * \delta$)	4	53,60	13,40	159,968	<0,0001
Erro	3581	299,90	0,08	—	—

com os resultados observados na análise dos dados Reais, onde o modelo de regressão PLS apresentou a melhor acurácia preditiva. Nos resultados simulados, por vezes, o modelo de regressão PLS apresentou inclusive resultados piores que os modelos do tipo ARIMA, o pior na análise de dados reais.

Os resultados observados confirmam algumas hipóteses esperadas, como por exemplo, o aumento da variância da componente de erro aleatório reduz o desempenho preditivo dos modelos. Quanto ao número de produtos, no modelo estrutural básico as melhores médias foram obtidas para os cenários simulados com 3 e 5 produtos. Resultados melhores do que quando a série apresentava apenas dois produtos distintos. Entretanto, observa-se que as diferenças entre as médias de RMSE para os diferentes números de produtos não é significativa quando trata-se do modelo estrutural básico. Neste modelo, são observadas diferenças significativas apenas quando é alterada a variabilidade do componente de erro aleatório.

Considerando o modelo de regressão PLS, o melhor resultado observado foi o comportamento pelo cenário com 2 produtos e variância da componente erro igual a 2,98. Nas demais combinações, os resultados da PLS foram sempre piores que os resultados observados no ajuste dos modelos ARIMA, exceto para o cenário com 2 produtos e com o nível elevado de variabilidade da componente de erro ($\sigma^2 = 3,31$), onde a média observada foi melhor do que as combinações com 2 e 5 produtos e variabilidade $\sigma^2 = 3,31$ ajustadas com modelos do tipo ARIMA, apesar da diferença entre eles não ser considerada significativa ao nível $\alpha = 5\%$.

Enfim, nos resultados simulados, o modelo estrutural básico superou os demais modelos, mesmo quando ajustado em uma série com processo gerador distinto. Apesar da regressão PLS ter obtido melhores resultados no ajuste dos dados reais, este modelo teve o pior desempenho quando analisado sob a luz dos dados simulados. Pode ser notado que o aumento do número de produtos piora o desempenho preditivo do modelo de regressão PLS. Esse resultado é intrigante, pois a regressão PLS ajustada em uma série real com

Tabela 4.6: Resultados do teste de Tukey (HSD) para a interação tripla $\tau * \gamma * \delta$

Combinação ($\tau * \gamma * \delta$)	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo5	Grupo 6	Grupo 7	Grupo8
3*2,98*Modelo Estrutural	1,61							
5*2,98*Modelo Estrutural	1,62							
2*2,98*Modelo Estrutural	1,64							
3*3,31*Modelo Estrutural		1,80						
5*3,31*Modelo Estrutural		1,83						
2*3,31*Modelo Estrutural		1,87						
2*2,98*PLS			3,39					
2*2,98*ARMA			3,41					
5*2,98*ARMA			3,44					
3*2,98*ARMA			3,46					
3*3,31*ARMA				3,79				
2*3,31*PLS				3,80				
2*3,31*ARMA				3,83				
5*3,31*ARMA				3,85				
3*2,98*PLS					4,06			
5*3,31*PLS						4,92		
5*2,98*PLS							5,04	
3*3,31*PLS								5,15

5 modelos de produtos obteve os melhores resultados. A inserção de níveis mais altos de ruído nos dados simulados comparados aos dados reais podem ter comprometido os coeficientes do modelo de regressão PLS e, por consequência, a precisão do modelo como um todo. O modelo de regressão PLS e os modelos do tipo ARIMA alternaram seus desempenhos, dependendo do número de itens em análise e variabilidade da componente de erro aleatório. Este resultado é dissonante com os resultados a partir da observação de dados reais, onde a regressão PLS superou todos os modelos.

4.4 Construção da carta T^2 para ambientes customizados

A abordagem original proposta para utilização em ambientes customizados é o resultado da pesquisa em diversas metodologias de controle estatístico do processo. Ideias gerais das metodologias de cartas baseadas em modelos e de resíduos, monitoramento de componentes de variância, cartas multivariadas e esquemas de auto-inicialização foram utilizadas na composição desta proposta. Em cartas baseadas em resíduos, os desvios são tomados da série de dados e cartas de controle são construídas com eles. Monitoramento dos componentes de variância mostra que a decomposição da variância em diferentes elementos é possível e viável. Cartas multivariadas são utilizadas quando mais de uma característica é observada em cada tempo t . Monitoramento de Perfis é um caso parti-

cular de cartas multivariadas, onde as cartas são aplicadas nos parâmetros ajustados a cada tempo t entre a característica da qualidade (variável de resposta) e um conjunto de variáveis explicativas (variáveis de entrada do processo). Esquemas de auto-inicialização são aqueles que inicializam-se a si mesmos, estimando e atualizando os parâmetros do processo a cada nova observação tomada no tempo t .

A abordagem proposta aqui consiste em ajustar um modelo estrutural de nível local através do filtro de Kalman, tal qual proposto por Harvey (1989). Os estudos comparativos que tratavam da escolha de modelos de predição para utilização em ambientes customizados chegaram a resultados inconclusivos quanto ao melhor modelo. Entretanto este modelo tem a capacidade de auto-atualização de parâmetros, tal qual os esquemas de auto-inicialização. Esta característica é a principal justificativa para sua escolha nesta proposição. O modelo estrutural de nível local é ajustado no sentido longitudinal dos dados, tal qual em cartas de controle baseadas em modelos ou de resíduos. Para atender às mudanças determinísticas geradas pelo plano de produção, variáveis indicadoras foram inseridas neste modelo.

Como visto na subseção 2.4.2, o modelo estrutural ajustado pelo processo de filtragem atualiza seus parâmetros tão logo uma nova observação seja coletada. Esta ação de atualização dos parâmetros faz com que o modelo persiga as variações observadas nos dados, gerando, como consequência, resíduos relativamente menores do que em modelos de regressão, onde o nível da série não é estocástica. A utilização de estratégias de análise de resíduos é proibitiva pois, uma vez que seja observado um potencial ponto fora de controle, os parâmetros serão atualizados pelo erro de previsão fazendo com que o ponto volte para dentro dos limites de controle.

Por outro lado, o conjunto de parâmetros definido pelas variáveis indicadoras inseridas no modelo e atualizadas pelo filtro a cada tempo t configuram um esquema similar ao de monitoramento de perfis (onde a cada tempo t um novo vetor de estados atualizado está disponível). Um esquema de controle multivariado pode então ser inserido neste vetor de parâmetros - ou no vetor dos estados, de acordo com a linguagem definida por Harvey (1989) na apresentação de seu modelo. Note que o modelo representa o processo e mudanças neste processo implicam em mudanças nos parâmetros do modelo. Esta é a razão pela qual neste caso, e em monitoramento de perfis, os parâmetros são controlados ao invés dos pontos observados ou dos resíduos obtidos.

O modelo de nível local com variáveis indicadoras no espaço dos estados é apresentado na equação 4.2.

$$y_t = \mathbf{X}_t \beta_t + \varepsilon_t$$

$$\beta_t = \begin{bmatrix} D_{1,t} & D_{2,t} & \dots & D_{k,t} \end{bmatrix}' = \mathbf{M}_t \beta_{t-1} + \epsilon_t \quad (4.2)$$

onde y_t é a série da característica da qualidade observada, β_t é um vetor de parâmetros do processo, \mathbf{X}_t e \mathbf{M}_t são matrizes conhecidas, $\varepsilon_t \sim \mathbf{N}(0, \mathbf{W}_t)$ e $\epsilon_t \sim \mathbf{N}(0, \mathbf{U}_t)$.

As equações de previsão e atualização do filtro de Kalman são apresentadas nas equações 4.3 e 4.4, respectivamente.

$$\beta_{t|t-1} = \mathbf{M}_t \beta_{t-1}$$

$$\Sigma_{t|t-1} = \mathbf{M}_t \Sigma_{t-1} \mathbf{M}'_{t-1} + \mathbf{R}_t \mathbf{Q}_t \mathbf{R}'_t \quad (4.3)$$

$$\beta_{t|t} = \beta_{t|t-1} + \mathbf{K}_t [y_t - \mathbf{X}_t \beta_{t|t-1}]$$

$$\Sigma_{t|t} = \Sigma_{t|t-1} - \Sigma_{t|t-1} \mathbf{X}'_t \mathbf{F}_t^{-1} \mathbf{X}_t \Sigma'_{t|t-1} = \Sigma_{t|t-1} - \mathbf{K}_t \mathbf{X}_t \Sigma'_{t|t-1} \quad (4.4)$$

onde $\mathbf{K}_t = \Sigma_{t|t-1} \mathbf{X}'_t \mathbf{F}_t^{-1}$ é definido como o ganho do Filtro de Kalman, $\mathbf{F}_t = \mathbf{X}'_t \Sigma_{t|t-1} \mathbf{X}_t + \mathbf{H}_t$, \mathbf{R}_t , \mathbf{Q}_t e \mathbf{H}_t são matrizes arbitrárias.

As equações de atualização produzem um vetor de estados (parâmetros do processo) filtrados a cada tempo t , que supostamente estão sob controle estatístico do processo. Alterações neste vetor podem ser observadas através de um esquema de controle multivariado. Destacam-se dois aspectos importantes aqui:

1. Fan & You (2009) apontam que um dos problemas da implantação de cartas de controle em cenários sujeitos à alta flexibilidade é que os processos modernos operam em fluxo contínuo. A espera pela observação de um subgrupo de tamanho $n > 1$ acaba por gerar um aumento no volume de peças fora de controle produzidas. O procedimento proposto utiliza medidas individuais para o monitoramento de modo que, mesmo com algum atraso entre a produção e o controle, o volume de peças fora de controle produzidas é reduzido pela não necessidade da produção de um subgrupo completo de tamanho $n > 1$ para monitoração; e
2. considerando o término do ciclo de vida de um dado produto em análise, sua remoção do processo de monitoramento implica em, tão somente, a matriz \mathbf{M}_t não receber mais a entrada correspondente a este item. Por outro lado, a inclusão de um novo item repercute tão somente no redimensionamento das matrizes \mathbf{M}_t e \mathbf{X}_t e do vetor dos estados β_t . Destaca-se que a exclusão pode também ser efetuada pelo redimensionamento das mesmas matrizes e vetor. Esta simplicidade é devida ao fato de o processo de filtragem, devido à recursividade, carregar nas estimativas atuais toda a informação do passado.

Uma abordagem simples para o problema a partir deste ponto é obter a matriz de co-

variâncias a partir da matriz de estados filtrados ao longo da série. A estatística T_t^2 de Hotelling pode então ser determinada a partir da equação 4.5 com matriz de covariâncias estimada por máxima verossimilhança como na equação 4.6. O limite de controle, por sua vez, é definido pela equação 4.7.

$$T_t^2 = (\hat{\beta}_t - \bar{\beta})' S_L^{-1} (\hat{\beta}_t - \bar{\beta}), \quad t=1, \dots, T \quad (4.5)$$

onde

$$S_L = \frac{1}{T} \sum_{t=1}^T (\hat{\beta}_t - \bar{\beta})(\hat{\beta}_t - \bar{\beta})' \quad (4.6)$$

e

$$UCL_{\chi^2} = \chi_{1-\alpha, p}^2 \quad (4.7)$$

4.5 Adaptação das cartas existentes para aplicação no problema de pesquisa

Esta seção apresenta a formulação de uma carta de controle de auto-inicialização padronizada baseada em uma carta de controle recursiva de Shewhart apresentada por Del Castillo *et al.* (1996) e a adaptação ao problema de múltiplos *setups* das cartas de controle de auto-inicialização propostas por Quesenberry (1991). Nestas adaptações são consideradas duas formas distintas para obtenção de estimativas da variabilidade das séries. Assim, chega-se à proposição final de quatro ferramentas adaptadas, sendo baseadas em dois procedimentos distintos, cada um tendo duas formas de tratamento da variabilidade dos dados da série. É definido como regra geral que pontos fora de controle são assinalados quando o primeiro ponto for observado além dos limites de controle. A probabilidade de ocorrência de um alarme falso, isto é, um sinal fora de controle em um processo estável, é definido pela expressão 4.8.

$$P(\text{Fora de controle} | \text{Processo é estável}) = 1 - P[LCL \leq X \leq UCL | \text{Processo é estável}] \quad (4.8)$$

4.5.1 Carta de auto-inicialização de Shewhart para múltiplos itens

Uma carta de controle recursiva baseada em resíduos foi inicialmente proposta para monitorar a característica da qualidade quando os parâmetros do processo eram desconhecidos (ZOU *et al.*, 2007). Nestes modelos, as estimativas dos parâmetros são

atualizadas após cada nova observação e simultaneamente o processo é verificado quanto à presença de situações fora de controle. A literatura apresenta diversos procedimentos univariados, multivariados ou de monitoramento de perfis que inicializam-se sozinhos, sem a necessidade de estimativas prévias dos parâmetros do processo em uma fase retrospectiva de análise (fase I). Sullivan & Jones (2002), Hawkins & Olwell (1997) e Quesenberry(1997) apresentam exemplos destas ferramentas.

A ideia é relativamente simples e consiste em, uma vez que se disponha a segunda observação, obtém-se a média e variância do processo no tempo $t = 2$ e posteriormente determina-se quão grande é o desvio da observação no tempo $t = 2$ em relação a média neste mesmo tempo. Ao obter-se a observação no tempo $t = 3$, faz-se o mesmo e assim por diante. Este procedimento, assim como o proposto da seção anterior, monitora observações individuais da característica da qualidade, minimizando desta forma os efeitos destacados por Fan & You (2009).

A formulação para este procedimento é apresentada na equação 4.9, onde a adaptação proposta consiste em estimar a média e a variância para cada produto, individualmente. Assim que um novo produto $k + 1$ é inserido na carta, inicia-se a estimativa dos parâmetros associados a este produto de acordo com o procedimento descrito, permitindo assim a inclusão de novos itens na carta de controle sem a necessidade de reinicialização de todo o processo. A exclusão de um item do *setup* de produção não afeta a evolução da carta de controle, uma vez que as informações ficarão congeladas.

$$z_t = \frac{x_{t,k} - \bar{X}_{t,k}}{\hat{\sigma}_{t,k}}, \text{ para } t=2, \dots, T. \quad (4.9)$$

onde

$$\bar{X}_{t,k} = \frac{1}{n_k} \sum_{i=2}^{n_k} x_{i,k} \quad (4.10)$$

$$\hat{\sigma}_{t,k}^2 = \frac{1}{n_k - 1} \sum_{i=2}^{n_k} (x_{i,k} - \bar{X}_{t,k})^2 \quad (4.11)$$

onde n_k é o número de observações efetuadas relativas ao produto k até o tempo t . Para a primeira observação tem-se a formulação:

$$z_1 = \frac{x_{1,k} - \mu_0}{\hat{\sigma}_{1,k}} \quad (4.12)$$

onde μ_0 é o valor nominal associado à especificação do produto k e

$$\hat{\sigma}_{1,k}^2 = (x_{1,k} - \mu_0)^2.$$

Nesta proposição, a média e a variância do processo, relacionados ao produto k , são atualizados a cada tempo t . O procedimento escolhido para promover a adaptação à

situação de troca de produtos é similar ao proposto na carta apresentada por Del Castillo *et al.* (1996). A diferença é que os valores dos parâmetros não são conhecidos e nem sequer foram estimados em uma fase I de análise retrospectiva mas estão sendo estimados e atualizados a cada nova observação, num sistema de auto-inicialização.

Ao invés de estimar a variância individualmente para cada produto k , a variabilidade pode ser estimada a partir do princípio da variância combinada². Variância combinada é um método de estimar a variância a partir de diversas amostras diferentes, tomadas em diferentes circunstâncias onde a média pode diferir entre as amostras, porém a verdadeira variabilidade é assumida como constante. Apropriando estes conceitos ao problema da estimação da variabilidade em ambientes customizados, onde mais de um produto está em produção na mesma estação de trabalho, a variabilidade do processo poderia ser estimada pela equação 4.13.

$$\hat{\sigma}_t^2 = \frac{1}{t-1} \sum_{i=2}^t (x_{i,k} - \bar{X}_{t,k})^2 \quad (4.13)$$

Neste caso, a formulação para a estatística z_t da carta de controle será dada pela equação 4.14.

$$z_t = \frac{x_{t,k} - \bar{X}_{t,k}}{\hat{\sigma}_t}, \text{ for } t=2, \dots, T. \quad (4.14)$$

Assumindo normalidade, os limites de controle associados à estatística z_t devem ser definidos como ± 3 . Limites de controle mais conservadores podem ser adotados utilizando a distribuição t de Student ao invés da distribuição Normal. Assim, os limites de controle são definidos por $\pm t_{\alpha,v} \hat{\sigma}$, onde α é o nível de significância adotado e v é o número de graus de liberdade associados à distribuição t. v , graus de liberdade, é determinado por $v = n - 1$ ou $v_k = n_k - 1$, dependendo de como a variância está sendo estimada. Destaca-se que, na estimativa da variância combinada (equação 4.13), o tamanho da amostra cresce mais rapidamente por agregar as observações de todos os produtos e desta forma, o valor de $t_{\alpha,v}$, converge rapidamente para o valor de uma distribuição Normal padronizada.

4.5.2 Carta Q para múltiplos itens

As cartas Q para utilização em ambientes de produção de pequenos lotes foram introduzidas por Quesenberry em 1991. Nestes modelos, é suposto que as características da qualidade seguem um modelo de distribuição Normal. Quatro casos foram apresentados e são classificados de acordo com o conhecimento *a priori* sobre os parâmetros do processo. Quesenberry definiu como caso IV quando ambos parâmetros do processo, μ_0 e σ_0^2 , são desconhecidos. Neste caso, a formulação para construção da carta e obtenção da estatística

²A expressão *pooled variance* é utilizada em idioma Inglês para designar a variância combinada.

Q é dada pela equação 2.7.

Em um ambiente de produção de múltiplos itens, uma adaptação similar a utilizada no caso da carta de auto-inicialização de Shewhart para múltiplos itens apresentada na subseção 4.5.1. foi utilizada. Assim, a carta Q adaptada passa a ter a formulação apresentada na equação 4.15.

$$Q_t(x_{t,k}) = \Phi^{-1} \left[T_{t-1} \left(\frac{x_t - \bar{X}_{t,k_n}}{s_{0,t-1,k}} \right) \right] \quad (4.15)$$

$$S_{0,t,k}^2 = \frac{1}{t} \sum_{j=1}^t (x_j - \bar{X}_{t,k_n})^2$$

Nesta adaptação da carta Q , a cada tempo t a diferença da observação da característica da qualidade x_t é tomada em relação a \bar{X}_{t,k_n} , a média do produto k , em produção no tempo t . A média do produto k é atualizada de acordo com o número de observações n do produto k até o tempo t . A estimativa da variância também se altera em relação ao exibido na equação 2.7 na página 40, pois na formulação exibida na equação 4.15 a variância é estimada para cada diferente produto k . Se a escolha de estimativa de variabilidade considerar o conceito de variância combinada, tal qual demonstrado na equação 4.13 na página anterior, então a formulação da carta Q adaptada segue a equação 4.16.

$$Q_t(x_{t,k}) = \Phi^{-1} \left[T_{t-1} \left(\frac{x_t - \bar{X}_{t,k_n}}{s_{0,t-1}} \right) \right] \quad (4.16)$$

onde

$$S_{0,t}^2 = \frac{1}{t} \sum_{j=1}^t (x_j - \bar{X}_{t,k_n})^2$$

Os limites de controle seguem o mesmo esquema da carta Q tradicional. Note que neste caso, assim como nas proposições anteriores, o controle é efetuado através de observações individuais da característica da qualidade, reduzindo assim a produção de itens defeituosos. Além disso, a inclusão e exclusão de itens é possível por procedimento similar ao explicitado para a carta de auto-inicialização de Shewhart para múltiplos itens apresentada na subseção 4.5.1.

4.6 Estudo comparativo

Esta seção apresenta a análise comparativa entre o método apresentado por Del Castillo et. al. (1996) e todos os demais métodos propostos. Inicialmente uma análise exploratória é efetuada com a aplicação das seis ferramentas em uma série de dados reais.

O método apresentado por Del Castillo *et al.* (1996) foi denominado como (SOA). Os métodos apresentados nas seções 4.4 e 4.5 foram denominados como: 1. Carta de

auto-inicialização padronizada de Shewhart com variância simples (SSS); 2. Carta de auto-inicialização padronizada de Shewhart com variância combinada (SSP); 3. Carta Q adaptada com variância simples (QCS); 4. Carta Q adaptada com variância combinada (QCP); e 5. Carta de auto-inicialização multivariada baseada no filtro de Kalman (SKM).

Limites de controle foram configurados para apresentarem, sob o ponto de vista teórico, o mesmo erro α , isto é, $\alpha = 1 - Pr(LCL \leq X \leq UCL | \mu = \mu_o)$. Como pontos fora de controle não são conhecidos na série real, este estudo de caso foi utilizado para obter estimativas dos parâmetros do processo que auxiliem no processo de simulação, bem como, para executar uma análise qualitativa quanto à sensibilidade de cada método. No estudo simulado, oito diferentes cenários foram construídos de acordo com a seção 3.3 a fim de comparar o desempenho das ferramentas.

4.6.1 Análise da base de dados histórica

Uma base de dados histórica da característica da qualidade Gramatura foi cedida pela empresa ABC (setor de plásticos) localizada no sul do Brasil. A série contava com 1.070 observações de um processo em uma linha de produção customizada, com produção de 5 diferentes produtos. A base de dados foi descrita e após analisada de acordo com os seis procedimentos listados no prólogo desta seção. As estimativas dos parâmetros do processo, bem como a média e desvio-padrão geral do processo, são apresentados na Tabela 4.7. Note que o desvio-padrão geral inclui a variabilidade inerente às mudanças de nível da série, devido à mudança dos produtos na linha, enquanto que o desvio-padrão dos produtos contabiliza apenas a variabilidade entre as observações de um mesmo produto em relação à sua própria média.

Tabela 4.7: Medidas descritivas da série de produtos na série histórica fornecida pela empresa ABC para a característica Gramatura

Produto	Média	Desvio-padrão	Núm. de observações
A	155,16	5,41	587
B	167,76	5,74	195
C	92,99	3,56	40
D	115,78	4,16	137
E	112,33	4,67	111
Geral	145,65	5,14	1070

O desvio-padrão entre todos os produtos é similar na série de dados histórica. Alguns produtos, como o caso do produto A, por exemplo, possuem maior frequência de ordens de produção. Isto deve-se à demanda dos clientes, que é irregular entre os produtos. Neste caso, o produto A representa 54,86% do total de itens produzidos. Os parâmetros do processo estimados e apresentados na Tabela 4.7 foram utilizados no método SOA como verdadeiros parâmetros do processo, isto é, onde não há auto-inicialização, foi efetuada

uma análise retrospectiva que servirá como *benchmark* de comparação aos demais métodos. A Figura 4.6 apresenta as 1070 observações da série de dados histórica. Observa-se que o produto C entrou em produção apenas na segunda metade da coleta. Esta situação tem duas implicações diretas: o pequeno número de unidades amostradas e a necessidade do procedimento de análise ser capaz de introduzir novos produtos sem interromper o andamento da fase de monitoramento.





Figura 4.6: Gramatura observada na série histórica de dados da empresa ABC (mg/mm^2)

O tamanho das sequências de produção até a próxima troca são apresentadas na Figura 4.7. O tempo médio de produção de cada item foi determinado e confirmam que mudanças de *setup* neste processo ocorrem rapidamente, aproximadamente a cada 5,74 itens produzidos.

A implantação do procedimento SKM exige o ajuste de um modelo estrutural tal qual apresentado na equação 4.2 a fim de obter a matriz dos estados que será monitorada pela carta multivariada. Vale lembrar que, nesta abordagem, alterações observadas nos parâmetros estimados implicam no indicativo de um sinal de processo fora de controle. A Figura 4.8 mostra a série de dados histórica (círculos) além dos valores esperados (linha) obtidos pela substituição dos estados atualizados pelas equações de previsão (equação 4.3) nas equações de medida (equação 4.2) a cada tempo t .

A variância dos resíduos deste modelo apresentou valor $\sigma^2 = 7.4290mg/mm^2$ enquanto que a variância combinada, como apresentado na equação 4.13, foi $\sigma^2 = 5.1465mg/mm^2$. A estimação da variabilidade a partir dos resíduos do modelo retornou um valor maior quando comparado com a variância combinada determinada diretamente a partir dos da-

Figura 4.7: Histograma do tamanho das sequências produtivas



dos reais. Note que, a média utilizada para o cálculo da variância combinada neste caso, foi determinada a partir de todas as observações do produto em questão. Como o modelo estrutural é ajustado por um processo de filtragem, onde se espera que as estimativas dos parâmetros converjam para seus verdadeiros valores após uma série de observações, é esperado que a estimativa da variabilidade intra-produto seja maior neste caso do que a obtida pela variância combinada. Assim, esta discrepância era esperada.

A Figura 4.9 mostra o resultado dos seis procedimentos apresentados neste estudo aplicados na série histórica fornecida pela empresa ABC. Como não se tem conhecimento sobre a real existência de pontos fora de controle e eventuais sinais podem ser alarmes falsos, esta figura pretende mostrar tão somente a sensibilidade dos procedimentos, isto é, a capacidade de produzir sinais de fora de controle. Na Figura 4.9, a linha contínua representa o valor da estatística e as linhas tracejadas representam os limites de controle das cartas. Para as cartas SSS e SSP, uma postura mais conservadora foi adotada, definindo os limites de controle a partir da distribuição *t* de Student, tal qual descrito na seção 4.4.

Todos os procedimentos foram capazes de gerar alarmes indicando a existência de pontos fora de controle na série. A Tabela 4.8 mostra quantos pontos fora de controle foram identificados na série por procedimento. A tabela também apresenta quais pontos foram identificados. Apesar do procedimento SKM ter apresentado um alto número de alarmes em termos absolutos, de fato, 4 *clusters* foram identificados onde, em apenas um ocorre a troca de produtos. A conjectura é de que a mudança apontada neste caso onde o *cluster* apresenta mais de um produto é devido ao processo em si como um todo, e não

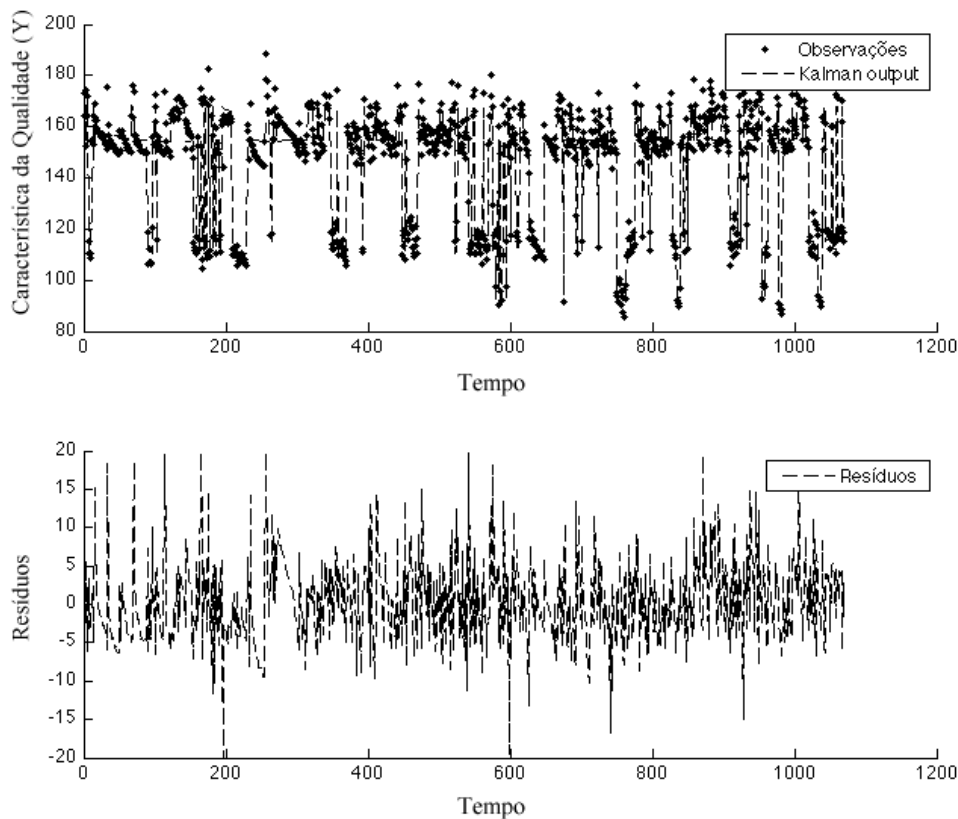


Figura 4.8: Valores observados e esperados pelo modelo estrutural, da série de dados histórica e resíduos do modelo

devido a alterações decorrentes da produção de um único produto como se verifica nas demais ferramentas.

Tabela 4.8: Sinais de pontos fora de controle observados na série histórica nos seis procedimentos avaliados

Procedimento	Sinais de pontos foram de controle ¹	Total de sinais
SOA	34, 71, 114, 164, 196, 256, 542, 576, 598, 741, 872	11
SSS	71, 114, 164, 175, 196, 256, 524, 542, 576, 598, 872	11
SSP	34, 71, 114, 164, 165, 196, 256, 542, 576, 598, 741, 872	12
QCS	34, 71, 114, 164, 175, 196, 256, 524, 542, 576, 598, 872	12
QCP	34, 71, 114, 164, 165, 196, 256, 542, 576, 598, 741, 872	12
SKM	156-166, 581-584, 588, 595-605	27

¹. Número da observação onde o sinal foi observado

Os procedimentos SOA e SSS mostraram 11 sinais enquanto SSP, QCS e QCP apresentaram 12 sinais de pontos fora de controle. Entretanto, apesar de terem o mesmo número do sinais, o que implica na mesma sensibilidade, SOA e SSS não concordam sobre quais pontos apresentam sinais fora de controle. Enquanto SOA aponta um sinal na observação número 34, SSS não visualiza este ponto como fora de controle. Destaca-se que os procedimentos SSP, QCS e QCP também identificaram a observação 34 como fora




Figura 4.9: Cartas de controle propostas aplicadas aos dados históricos da empresa ABC de controle.

Observando a Figura 4.9, uma vez que os limites de controle da carta SSS são ajustados com a distribuição t de Student, eles ainda estão muito amplos nesta observação para indicar este ponto como fora de controle. Isto deve-se ao fato de ter-se observado poucas unidades deste produto até esta observação. Apesar da carta SSP utilizar limites de controle similares (baseados na distribuição t de Student) a forma de estimação da variabilidade (variância combinada) faz com que o tamanho da amostra cresça mais rapidamente, uma vez que todos os diferentes produtos são considerados na mesma amostra.

Os únicos dois procedimentos que concordaram quanto ao número de sinais e em quais observações os sinais foram disparados foram SSP e QCP, podendo ser considerados equivalentes neste contexto. Observa-se que todos os procedimentos identificaram a observação do tempo 164 com um sinal fora de controle. Entretanto, no caso do procedimento SKM, esta observação encontra-se dentro de um agrupamento de pontos fora de controle que inicia-se na observação 156. O mesmo ocorre com a observação 598, apontada como fora de controle por todos os procedimentos, mas também incluída em um agrupamento no procedimento SKM, que inicia-se na observação 595. Por outro lado, todos os procedimentos apontaram a observação 576 como fora de controle com exceção do SKM, onde

nesta faixa do tempo, pontos fora de controle são apontados apenas após a observação 581.

Como não há controle na geração dos dados históricos, não se pode justificar a razão para a ocorrência das discrepâncias observadas. Entretanto, os resultados apontam que há diferenças entre os procedimentos devido a características não conhecidas deste processo. A simulação executada e analisada na próxima subseção apresenta diferentes cenários de implantação de cartas de controle. Estes cenários apresentam violações frequentemente relatadas na literatura. Assim, com base na simulação deseja-se mensurar o desempenho desta cartas em ambientes que violem as suposições de normalidade, homogeneidade de variâncias e presença de autocorrelação serial nos dados, possíveis fatores geradores de deterioração no desempenho de cartas de controle.

4.6.2 Análise dos dados simulados

Baseado nos dados históricos analisados na subseção 4.6.1, foram simulados oito diferentes cenários com 5 diferentes produtos. No total, 5.000 séries de tamanho 400 foram geradas de acordo com os procedimentos descritos na Seção 3.3. Um resumo dos cenários simulados foi apresentado na Tabela 3.1. A Tabela 4.9 mostra os resultados do ARL_0 , isto é, o tamanho médio da sequência entre a ocorrência de falsos alarmes, para cada procedimento de monitoramento da característica da qualidade por cenário.

Tabela 4.9: ARL_0 estimado na simulação para cada carta nos diferentes cenários simulados

Cartas de	Cenários							
	I	II	III	IV	V	VI	VII	VIII
Controle	$\sigma I N$	$\sigma I \chi^2$	$\sigma \tilde{I} N$	$\sigma \tilde{I} \chi^2$	$CV I N$	$CV I \chi^2$	$CV \tilde{I} N$	$CV \tilde{I} \chi^2$
SOA	476,08	142,22	463,50	141,94	490,44	120,20	484,73	120,72
SSS	409,08	151,31	418,85	154,79	418,76	132,16	422,92	132,56
SSP	136,03	76,42	139,06	78,15	84,60	62,83	128,17	66,89
QCS	621,12	185,75	634,52	189,48	638,37	158,71	650,62	160,14
QCP	267,95	110,51	276,17	113,14	141,59	89,19	252,33	93,78
SKM	129,97	128,49	129,37	129,27	127,71	129,10	129,58	129,26

σ : desvio-padrão constante; I : dados independentes; N : resíduos normalmente distribuídos; CV : coeficiente de variação constante; \tilde{I} : dados autocorrelacionados; χ^2 : resíduos não normais; ARL_0 esperado igual à 370.

Os resultados mostram que, geralmente, em cenários onde a violação da normalidade ocorre (II, IV, VI e VIII) há um aumento na taxa de alarmes falsos, fazendo com que este tipo de sinal seja mais frequente do que em cenários onde a suposição de normalidade não é violada. Este aumento da taxa de alarmes falsos era esperado, como demonstrado em estudos que apresentam resultados quanto à violação desta suposição, como por exemplo, Lin & Chou (2004; 2005). Destaca-se que a violação à normalidade é o aspecto dominante no comprometimento do desempenho das cartas apresentadas, quando

se trata da taxa de alarmes falsos. O procedimento SKM é o único onde a violação à suposição de normalidade não surtiu efeitos na taxa de alarmes falsos quando comparado aos outros cenários.

Os cenários III, IV, VII e VIII são aqueles cuja suposição de independência entre as observações é violada. O efeito de correlação em série, tal como apresentado por Jiang et al. (2000) e Alwan (1992), não foi observado neste estudo. A diferença observada entre os cenários onde os dados são independentes e auto-correlacionados são pequenas e devem ser consideradas como parte da variação inerente ao processo aleatório de geração de dados. Novamente, a carta SKM foi a que apresentou resultados com menor variação entre os cenários simulados.

Em cenários de mesmas características quanto à normalidade e à independência, porém com a variância entre produtos constante ou não ao longo da série, os resultados seguiram o mesmo comportamento que o observado no caso da violação da suposição de independência. As variações na taxa de alarmes falsos, neste contexto, também devem ser consideradas como parte da variação inerente ao processo aleatório de geração de dados.

Entre os procedimentos, comparando-os por tipo de cenário, observa-se que aqueles procedimentos que apresentam a estimativa de variabilidade conjunta possuem pior desempenho quanto à taxa de alarmes falsos nos cenários em que a variância não é constante. Observa-se isto claramente quando se verifica o ARL_0 das cartas que utilizam a variância combinada (SSP e QCP) em relação aquelas que utilizam variância simples para cada produto (SSS e QCS) nos cenários V, VI, VII e VIII. As diferenças observadas em relação à taxa de alarmes falsos nos cenários onde a variância não é constante era esperado. Entretanto, estes mesmos resultados foram verificados quando as variâncias eram constantes entre os diferentes produtos. Este resultado contraria o que era esperado, uma vez que variâncias constantes em diferentes produtos convergiriam mais rapidamente ao verdadeiro valor do parâmetro quando estimadas por um estimador conjunto, tal qual mostrado na equação 4.13.

O procedimento de auto-inicialização com variância simples QCS foi o único que apresentou resultado melhor para todos os cenários que os resultados observados para o procedimento SOA, quanto ao ARL_0 . Apesar do procedimento SKM ter apresentado um desempenho fraco em relação ao desempenho quanto ao ARL_0 , a taxa de alarmes falsos foi a que permaneceu com maior constância entre os diversos cenários simulados. Este resultado confirma o que se esperava sobre a robustez do método quanto ao desvio dos dados às suposições de independência e normalidade. Como as variabilidades dos parâmetros do modelo estrutural ajustado (hiperparâmetros do modelo estrutural básico) são também atualizadas através do filtro a cada nova observação, a variabilidade entre os produtos não alterou o desempenho desta carta.

Um ajuste por iteração foi efetuado em cada carta para a obtenção de limites de

controle que fixassem o ARL_0 em torno de 370 observações como um cenário ideal (dados são normalmente distribuídos, independentes e de variância constante - Cenário I). A Tabela 4.10 apresenta os resultados do ARL_0 (desvio-padrão) após o ajuste dos limites no cenário ótimo (sem violação de nenhuma suposição). A tabela também apresenta os limites de controle obtidos. Destacam-se os limites para as cartas SSS e SSP que são determinados de acordo com a distribuição t de Student e, logo, são variáveis em função do número de observações. Assim, nas cartas SSS e SSP, os limites de controle são $\pm t$ tal que a probabilidade de um ponto estar entre $\pm t$ seja igual a $1 - \alpha$. Uma vez que as séries geradas tem tamanho 400, em muitas não foram observados alarmes falsos. Isto não interfere no cálculo do valor do ARL_0 , tal como mostrado na equação 3.2, pois este consiste na soma do total de alarmes falsos nas 400×5000 observações.

Tabela 4.10: ARL_0 e desvio-padrão estimados a partir de limites de controle ajustados para cada carta no cenário ideal

Cartas	ARL_0	Limites de Controle
SOA	376,93	$\pm 2,936$
SSS	372,16	$\pm t \Pr(-t < T < t) = 0,9971$
SSP	375,02	$\pm t \Pr(-t < T < t) = 0,99903$
QCS	375,94	$\pm 2,870$
QCP	370,30	$\pm 3,095$
SKM	372,86	41,000

A Tabela 4.11 apresenta os resultados da análise de variância para a variável de resposta ARL_0 . As fontes de variação consideradas foram os limites de controle teóricos e ajustados (como efeito de bloco), homocedasticidade (variância constante ou coeficiente de variação constante), independência (presença ou não de autocorrelação serial), normalidade e método (carta de controle analisada). Além destas, as interações duplas e triplas foram consideradas. Interações de maior ordem foram descartadas e compõem a variabilidade do erro experimental.

Os resultados mostram que apenas as fontes de variação Normalidade, Método e a interação Normalidade*Método apresentaram resultados significativos ao nível de 5% quando analisado o ARL_0 como medida de desempenho. Estes resultados confirmam as observações efetuadas anteriormente, onde foi expresso que o efeito da violação de normalidade é o que mais se destaca entre os cenários. Tanto a violação de homogeneidade de variâncias quanto de independência das observações apresentam efeitos não significativos ao desempenho das cartas de controle medidos através do ARL_0 (valor $p > 0,05$), contrariando a literatura. Destaca-se a violação da suposição de independência, uma vez que grande parte dos trabalhos associados ao desempenho de cartas de controle tradicionais buscam verificar os efeitos desta violação. Os resultados mostram que a violação à normalidade, no caso de múltiplos *setups*, deteriora com muito mais ênfase o desempenho

Tabela 4.11: Resultados da análise de variância para o ARL_0

Fonte de variação	Soma de Quadrados	g.l.	Quadrado Médio	Teste F	valor p
Intercepto	5.801.929,32	1	5.801.929,32	641,97	<0,001
Limites de Controle (Bloco)	22.309,04	1	22.309,04	2,47	0,122
Homocedasticidade	9.194,35	1	9.194,35	1,02	0,318
Independência	3.554,12	1	3.554,12	0,39	0,533
Normalidade	978.569,42	1	978.569,42	108,28	<0,001
Método	303.946,65	5	60.789,33	6,73	<0,001
Homocedasticidade*Independência	2.493,21	1	2.493,21	0,28	0,602
Homocedasticidade*Normalidade	210,31	1	210,31	0,02	0,879
Homocedasticidade*Método	12.934,59	5	2.586,92	0,29	0,919
Independência*Normalidade	2.561,00	1	2.561,00	0,28	0,597
Independência*Método	5.868,56	5	1.173,71	0,13	0,985
Normalidade*Método	341.478,72	5	68.295,74	7,56	<0,001
Homocedasticidade*Independência*Normalidade	2.437,56	1	2.437,56	0,27	0,606
Homocedasticidade*Independência*Método	4.721,25	5	944,25	0,10	0,991
Homocedasticidade*Normalidade*Método	10.527,62	5	2.105,52	0,23	0,946
Independência*Normalidade*Método	4.964,21	5	992,84	0,11	0,990
Erro experimental	469.960,21	52	9.037,70		
Total	7.977.660,13	96			

das cartas de controle, sendo esta uma preocupação que deveria ser a tônica dos estudos sobre desempenho.

As Figuras 4.10, 4.11 e 4.12 apresentam os ARL_0 das interações entre Homocedasticidade, Independência e Normalidade e os diferentes Métodos deste estudo. Na Figura 4.10 pode-se verificar que os ARL_0 médios tendem a ser similares em todos os métodos, com exceção dos SSP e QCP (métodos com variância combinada), que apresentam um aumento quando a variância definida na simulação é constante em todos os produtos. Entretanto, esta diferença não pode ser considerada significativa ao nível de 5% de acordo com a análise de variância efetuada, o que significa que, sob o ponto de vista estatístico, a heterocedasticidade não deteriora o desempenho dos diferentes métodos apresentados neste estudo.

Do mesmo modo, a interação Independência*Método não apresenta resultados significativos de acordo com a análise de variância. A violação a suposição de independência não apresentar uma deterioração significativa no desempenho dos métodos contraria o que é apresentado na literatura, porém, uma redução no ARL_0 pelos dados serem independentes, caso o resultado fosse significativo, é completamente inesperado. Isto é o que se observa nos métodos que estimam a variância de modo conjunto para todos os produtos (SSP e QCP). O impacto da estimativa da variabilidade conjunta no desempenho de cartas de controle para múltiplos itens deve ser melhor explorada em trabalhos futuros.

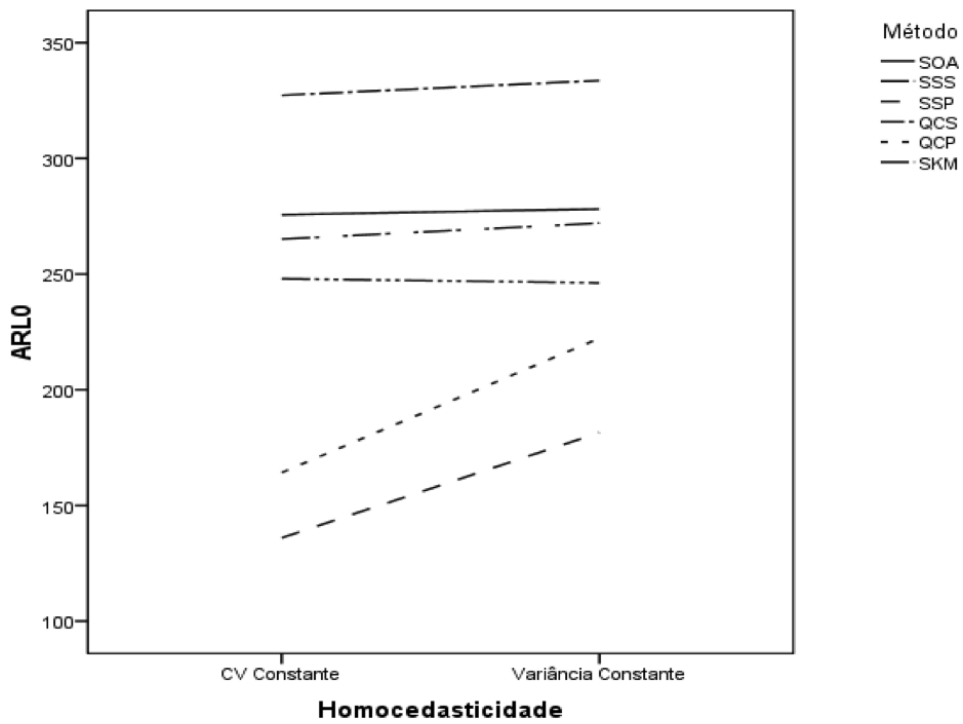


Figura 4.10: Gráfico dos resultados do ARL_0 para a interação Homocedasticidade*Método




Figura 4.11: Gráfico dos resultados do ARL_0 para a interação Independência*Método

A única interação significativa na análise de variância que contou com o ARL_0 como

variável de resposta foi Normalidade*Método. Observa-se que em todos os métodos, a violação à suposição de normalidade reduziu significativamente o valor do ARL_0 , com exceção do método SKM, que se mostrou robusto à esta violação, conforme pode ser verificado na Figura 4.12.

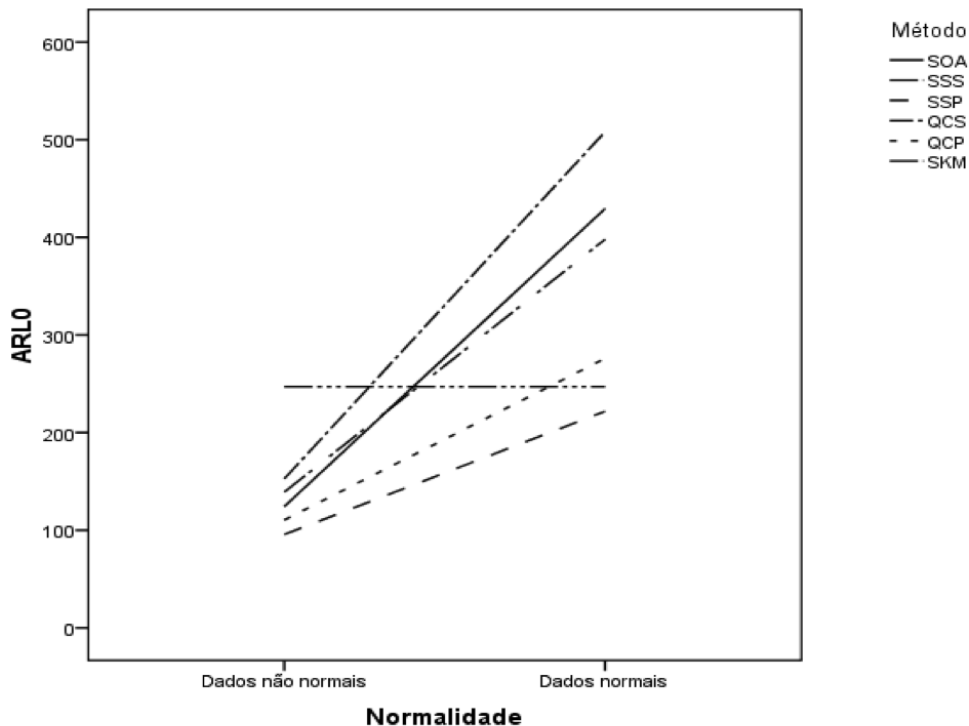


Figura 4.12: Gráfico dos resultados do ARL_0 para a interação Normalidade*Método

O efeito observado nas fontes de variação significativas pode ser determinado pelo coeficiente do modelo linear associado à análise de variância. Os coeficientes significativos são apresentados na Tabela 4.12. O coeficiente de determinação R^2 do modelo ajustado foi igual a 0,94.

Tabela 4.12: Estimativa dos parâmetros do modelo linear de análise de variância da variável de resposta ARL_0

Parâmetro	Coefficiente	E.P.	Estatística t	p-valor
Intercepto	380,56	64,36	5,913	<0,001
Violação à Normalidade	-253,65	84,59	-2,999	0,004
Violação à Normalidade*SKM	239,12	116,43	2,054	0,045

Os dados mostram que, em média, o ARL_0 obtido na simulação foi de 380,56. Entretanto, considerando as séries onde a violação da normalidade foi inserida, o ARL_0 apresentou resultados menores. A redução observada foi, em média, na ordem de 253,65 observações. Destaca-se que a redução do ARL_0 pode ser observada em todos os métodos, exceto no método SKM, robusto às violações, conforme descrito nos resultados descritivos.

De fato, em cenários de violação da normalidade combinados com o método SKM, a redução observada no ARL_0 é, em média, de apenas 14,53 observações (239,12-253,65).

A partir do ajuste dos limites de controle, alterações no nível da série puderam ser intencionalmente inseridos de modo a gerar alarmes de observações fora de controle. Estas alterações inseridas no nível da série foram de 0,5, 1,0, 2,0, 3,0 e 5,0 vezes o tamanho do desvio padrão no produto da série simulada original. Estatísticas quanto ao número médio de observações necessárias para que o alarme seja disparado pela carta (ARL_1) foram contabilizadas. Uma nova análise de variância foi efetuada a fim de identificar os efeitos dos componentes de cada cenário, isto é, as violações às suposições de homogeneidade de variâncias, independência entre as observações e normalidade dos resíduos. Também foi considerado o tamanho do desvio em relação aos níveis sob controle como fonte de variação. Os resultados são apresentados na Tabela 4.13. Novamente foram considerados apenas os efeitos principais de cada fonte de variação além das interações de segunda e terceira ordem. As interações de maior ordem foram utilizadas para estimativa do erro experimental.

Os resultados da análise de variância para a medida de desempenho ARL_1 apontaram três fontes principais como significativas: Normalidade, Desvio e Método. Entre as interações, são significativas Independência*Normalidade, Normalidade*Desvio e Desvio*Método. Inicialmente, mesmo quando os resultados não apresentaram significância estatística, gráficos de interações cuja fonte de variação Método esteja envolvido serão mostrados. Assim, as Figuras 4.13, 4.14, 4.15 e 4.16 apresentam os ARL_1 das interações entre Homocedasticidade, Independência, Normalidade e Desvios e os diferentes Métodos deste estudo.

Observa-se que, assim como no caso do ARL_0 , não há interação entre Homocedasticidade e Método. Destaca-se apenas o desempenho pobre do método SKM que apresentou um ARL_1 médio significativamente superior (resultados de comparações múltiplas entre os diferentes métodos são apresentados na Tabela 4.15 na página 93). De modo geral, todos os procedimentos foram robustos à violação da suposição de homogeneidade de variâncias, ao menos nos níveis levantados neste estudo. Observa-se apenas um leve aumento no ARL_1 para ambientes onde os produtos apresentam variância constante para os métodos SSP e QCP, porém não significativo. Nestes métodos, o tamanho da amostra para estimativa da variabilidade cresce mais rapidamente do que em seus pares, onde a variância é estimada de forma individual. Este aspecto leva a crer que, em cenários de variabilidade constante, a estimativa da variabilidade seria mais apurada nos métodos que utilizam a variância combinada, porém não foi o que os resultados demonstraram: quando da violação da suposição, estes procedimentos apresentaram menores ARL_1 em comparação com eles próprios em cenários com variância constante.

A análise de dados provenientes de ambientes onde as observações violam a suposi-

Tabela 4.13: Resultados da análise de variância para o ARL_1

Fonte de variação	Soma de Quadrados	g.l.	Quadrado Médio	Teste F	p-valor
Intercepto	1.281.130,00	1	1.281.130,00	1.340,21	<0,001
Limites de Controle (Bloco)	72.525,65	1	72.525,65	75,87	<0,001
Homocedasticidade	741,82	1	741,82	0,78	0,379
Independência	549,99	1	549,99	0,58	0,449
Normalidade	62.070,72	1	62.070,72	64,93	<0,001
Desvio	933.466,42	5	158.918,42	166,25	<0,001
Método	794.592,11	5	158.918,42	166,25	<0,001
Homocedasticidade*Independência	119,63	1	119,63	0,13	0,724
Homocedasticidade*Normalidade	124,78	1	124,78	0,13	0,718
Homocedasticidade*Desvio	1.031,30	5	206,26	0,22	0,956
Homocedasticidade*Método	682,51	5	136,50	0,14	0,982
Independência*Normalidade	317,67	1	317,67	0,33	<0,001
Independência*Desvio	606,94	5	121,39	0,13	0,986
Independência*Método	370,81	5	74,16	0,08	0,996
Normalidade*Desvio	110.787,57	5	22.157,51	23,18	<0,001
Normalidade*Método	9.340,55	5	1.868,11	1,95	0,085
Desvio*Método	118.331,02	25	4.733,24	4,95	<0,001
Homocedasticidade*Independência*Normalidade	100,96	1	100,96	0,11	0,745
Homocedasticidade*Independência*Desvio	231,99	5	46,40	0,05	0,999
Homocedasticidade*Independência*Método	285,16	5	57,03	0,06	0,998
Homocedasticidade*Normalidade*Desvio	112,27	5	22,45	0,02	1,000
Homocedasticidade*Normalidade*Método	422,52	5	84,50	0,09	0,994
Homocedasticidade*Desvio*Método	1.084,26	25	43,37	0,05	1,000
Independência*Normalidade*Desvio	404,21	5	80,84	0,08	0,995
Independência*Normalidade*Método	308,57	5	61,71	0,06	0,997
Independência*Desvio*Método	725,86	25	29,03	0,03	1,000
Normalidade*Desvio*Método	25.044,08	25	1.001,76	1,05	0,402
Erro Experimental	379.498,54	397	955,92		
Total	3.795.007,93	576			

ção de independência também não afetaram de sobremaneira o desempenho dos métodos. Além disso, novamente os métodos SSP e QCP apresentaram uma leve, porém não significativa, mudança em seu comportamento em relação ao ARL_1 . Observa-se neste caso, diferentemente do caso da homocedasticidade, um aumento do ARL_1 quando da violação da suposição de independência.

Considerando a interação Normalidade*Método, que também não apresentou resultados significativos de acordo com a análise de variância, observa-se que, para todos os diferentes métodos estudados, a violação à suposição de normalidade reduz o ARL_1 . Lembre-se que o efeito principal da violação da Normalidade foi significativo pela análise de variância, entretanto, seu comportamento é similar entre todos os diferentes métodos, razão pela qual a interação não é significativa ao nível de significância de 5%. Destaca-se que o mesmo não ocorreu quando do estudo do ARL_0 , onde a interação foi significativa e




Figura 4.13: Gráfico dos resultados do ARL_1 para a interação Homocedasticidade*Método

o método SKM apresentou resultados robustos a esta violação. No caso do ARL_1 , apesar da alteração nesta ferramenta ser menor quando comparada com os demais métodos, o comportamento médio segue o mesmo sentido dos demais métodos.

A última interação a envolver os métodos estudados engloba a fonte de variação tamanho do desvio em relação ao processo controlado. Verificam-se dois aspectos importantes na Figura 4.16. O primeiro refere-se aos resultados de modo geral. Enquanto o comportamento de todos os métodos que não o SKM segue uma curva com rápido decréscimo do ARL_1 nos menores incrementos dos desvios, praticamente estabilizando-se em uma linha horizontal a partir de 2 desvios, o método SKM segue uma descida suave e aproximadamente linear com o incremento dos desvios. O segundo aspecto relevante é o tamanho do ARL_1 para o método SKM. Para todos os desvios ele é notadamente superior, sendo, em termos de ARL_1 , o método com pior desempenho.

A Figura 4.17 apresenta os ARL_1 médios da interação Independência*Normalidade, significativa de acordo com a análise de variância. Destaca-se que, em linhas gerais, para dados não normais, os valores do ARL_1 são significativamente menores. Além disso, praticamente não há diferença entre a ocorrência da violação da suposição de independência se os dados não são normalmente distribuídos. Por outro lado, observa-se um distanciamento das médias quando os dados são normais. Neste caso, dados normais e independentes apresentam ARL_1 em média menor do que em cenários onde os dados são normais, porém autocorrelacionados.




Figura 4.14: Gráfico dos resultados do ARL_1 para a interação Independência*Método

A Figura 4.18 apresenta os resultados da interação significativa Normalidade*Desvio. Verifica-se neste caso que, em relação a normalidade, as diferenças no ARL_1 são significativas apenas em desvios pequenos em relação ao processo estável. A capacidade dos métodos em identificar que o processo tornou-se fora de controle estatístico é maior em dados não normais, quando os desvios são pequenos. Entretanto, a violação da suposição de normalidade perde efeito quando os desvios incrementados na série são maiores do que 1,5 desvios-padrão.

Os resultados da análise do ARL_1 mostraram que a violação da normalidade afeta de sobremaneira o desempenho das cartas de controle. Entretanto, quando os dados não seguem o modelo de distribuição normal, os resultados do ARL_1 são significativamente melhores do que quando esta suposição não é violada. Neste caso, deve-se lembrar que esta melhora é penalizada, uma vez que esta violação é responsável por um aumento também significativo da taxa de alarmes falsos, representada pelo ARL_0 . É importante destacar que os efeitos da violação da normalidade são contraditórios nestas duas medidas de desempenho, e portanto, resultados práticos de aplicação destas ferramentas nestes ambientes podem estar carregados de alarmes falsos, tornando o método ineficiente, uma vez que o processo poderá vir a ser interrompido com uma frequência relativamente elevada por erro da ferramenta de controle, gerando assim custos associados a paradas desnecessárias. Neste aspecto, há uma vantagem no método SKM, que apesar do seu fraco desempenho quanto a análise do ARL_1 , mostrou-se robusto a esta violação, o maior




Figura 4.15: Gráfico dos resultados do ARL_1 para a interação Normalidade*Método

problema dos demais métodos quando analisados sob o prisma do ARL_0 .

A análise do ARL_1 através de um modelo de análise de variância é também responsável pela informação de coeficientes que podem ser interpretados como efeitos associados a cada fonte de variação principal ou combinações destas, no caso das interações. Deste modo, a Tabela 4.14 apresenta os coeficientes significativos do modelo linear associado à análise de variância executada. O coeficiente de determinação R^2 do modelo ajustado foi igual a 0,90.

Tabela 4.14: Estimativa dos parâmetros do modelo linear de análise de variância da variável de resposta ARL_1

Parâmetro	Coefficiente	E.P.	Estatística t	p-valor
Limite Ajustado	22,44	2,58	8,710	<0,001
Desvio=0,5	173,08	23,19	7,464	<0,001
Desvio=1,0	84,96	23,19	3,664	<0,001
SKM*Desvio=1,0	71,52	30,92	2,313	0,021
SKM*Desvio=1,5	87,42	30,92	2,827	0,005
SKM*Desvio=2,0	78,69	30,92	2,545	0,011
Violação à Normalidade*Desvio=0,5	-101,90	25,24	-4,036	<0,001
Violação à Normalidade*SKM*Desvio=0,5	98,57	30,92	3,188	0,002

O limite de controle definido na ferramenta foi ajustado de modo a que todos os métodos apresentassem a mesma taxa de alarmes falsos. Entretanto, para análise de vari-




Figura 4.16: Gráfico dos resultados do ARL_1 para a interação Desvio*Método

ância todos os dados foram utilizados (tanto os com limites teóricos como os com limites ajustados). Deste modo, os limites de controle foram considerados na análise como efeito de blocagem. Seus resultados foram significativos de modo que o limite de controle corrigido foi responsável por um incremento no ARL_1 na ordem de 22,44 observações em média. Este resultado é de certo modo esperado, uma vez que, como mostrado na Tabela 4.9, com os limites de controle teóricos, frequentemente havia uma taxa de alarmes falsos maior do que o esperado. Observa-se ainda que, em linhas gerais, em desvios menores tal como 0,5 e 1,0 o ARL_1 é maior em 173,08 e 84,96 observações em média, respectivamente. Esta correção no ARL_1 pode ser particularmente percebida na Figura 4.16, onde o decaimento do ARL_1 para todos os métodos que não o SKM é notadamente íngreme nestes desvios. Os demais efeitos significativos observados dizem respeito ao método SKM. A Figura 4.18 apresenta os gráficos da interação tripla normalidade*Desvio*Método. Apesar de não significativa, esta interação auxilia no entendimento dos coeficientes associados ao método SKM e consequente comportamento do ARL_1 .

Para desvios igual a 1,0, 1,5 e 2,0, o ARL_1 associado ao método SKM é significativamente superior aos demais métodos. O efeito destes desvios neste método é de 71,52, 87,42 e 78,69 observações, respectivamente. Note que para desvio igual a 1,0, já há uma adição média de 84,96 observações no ARL_1 , e portanto, neste caso, o ARL_1 para o método SKM é, em média 156,48 observações maior (71,52+84,96). Quando considera-se o desvio de apenas 0,5 desvio-padrão no nível da série, o método SKM sofre também o

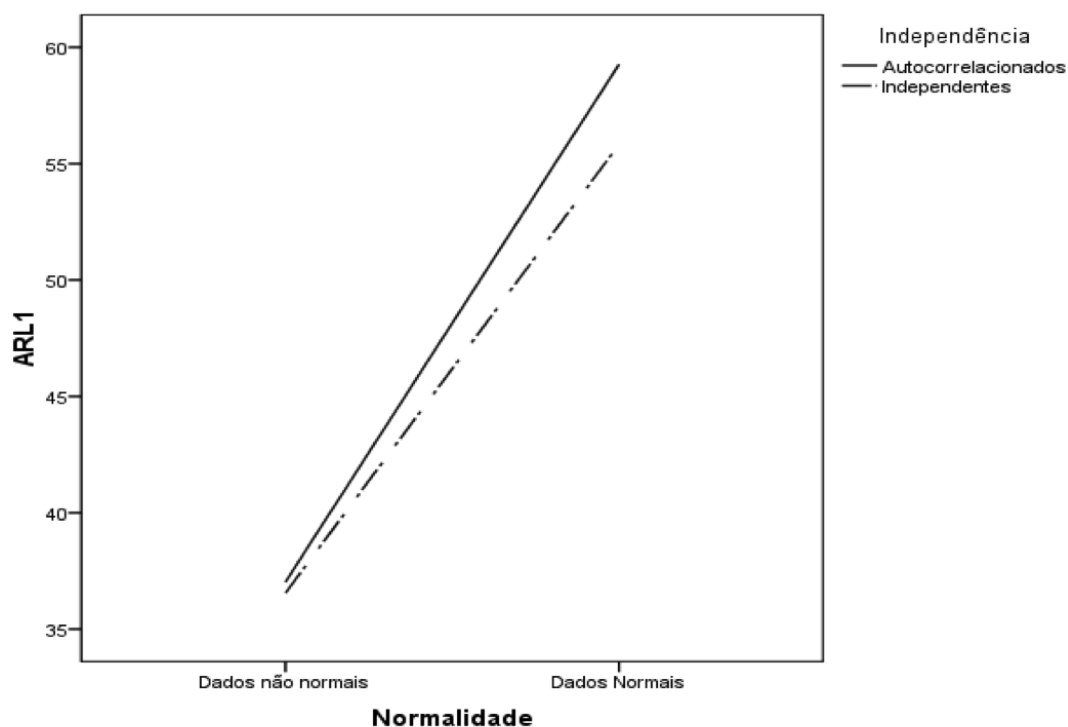


Figura 4.17: Gráfico dos resultados do ARL_1 para a interação Normalidade*Independência

efeito da violação da suposição da normalidade. A Figura 4.19 mostra que, quando os dados são normalmente distribuídos, neste nível de desvio, o ARL_1 dos demais métodos é mais próximo do observado para o método SKM do que quando os dados são provenientes de um cenário onde a suposição de normalidade foi violada.

Os resultados de ARL_1 também são apresentados por cenários nas Tabelas A.1 a A.8 nos Apêndices, de acordo com o tamanho do desvio em relação à média imputada e ARL_0 . De modo geral, os resultados observados confirmam o esperado em relação à consistência: com valores maiores de ARL_0 , observam-se valores de ARL_1 também maiores. Os resultados também são consistentes quanto ao tamanho da alteração de nível inserida em termos do desvio-padrão: Quanto maior o incremento adicionado ao nível da série, mais rapidamente um alarme é disparado, em média, apresentando assim, um menor ARL_1 .

Os resultados apontaram ainda que a violação das suposições surtem efeitos no desempenho de todas as cartas comparadas neste estudo. Apesar de nenhum dos procedimentos ter, em linhas gerais, batido o *benchmark* estabelecido pela carta SOA apresentada por Del Castillo *et al.* (1996), esta também sofre variações severas em suas medidas de desempenho, de acordo com o tipo de violação observada nos diferentes cenários. Todos os procedimentos, com exceção do método SKM, aproximaram-se do desempenho da carta SOA. Os métodos comportaram-se de modo similar à carta SOA, inclusive nas variações




Figura 4.18: Gráfico dos resultados do ARL_1 para a interação Normalidade*Desvio

decorrentes da violação das suposições, decorrentes da construção dos cenários de análise. A Tabela 4.15 mostra o resultado das comparações múltiplas para os diferentes métodos analisados quanto ao ARL_1 . O método utilizado para comparações múltiplas foi o teste de Tukey (HSD) e as médias de ARL_1 mostradas na tabela para os métodos são baseadas nas médias observadas, sendo que médias em um mesmo grupo não diferem estatisticamente ao nível de 5% (o erro quadrático médio para cálculo da diferença significativa do teste foi de 955,916).

Tabela 4.15: Comparações múltiplas dos métodos através do teste de Tukey (HSD) quanto ao ARL_1

Método	Grupo 1	Grupo 2
SOA	23,2253	
SSP	27,5298	
QCP	33,3997	
QCS	33,6496	
SSS	35,4778	
SKM		129,6853
p-valor	0,069	1,000

O procedimento SKM, apesar de ter o desempenho mais consistente no ARL_0 , apresentou os piores resultados quando analisado seu desempenho em termos de ARL_1 . Isto deu-se basicamente pois o modelo estrutural básico está sendo atualizado através

do filtro de Kalman com um vetor esparso de observações. Como apenas um produto é produzido a cada tempo t , qualquer mudança de nível na série afeta tão somente um parâmetro do vetor de estados. Como as mudanças observadas no vetor de estados ao longo do tempo dizem respeito a apenas um parâmetro sob monitoramento através da carta T^2 de Hotteling, o procedimento fica muito pouco sensível a mudanças, elevando drasticamente o tempo para detecção.

Destaca-se que no estudo comparativo dos métodos foram realizados tão somente simulações em ambientes com produção de 5 itens. Uma vez que apenas a quinta parte da informação está sendo atualizada a cada tempo t , espera-se que com um número maior de itens a ferramenta apresente resultados quanto ao desempenho ainda piores. Por outro lado, para um menor número de produtos ou um maior número de parâmetros por produtos na modelagem, espera-se resultados melhores. Uma alternativa pode ser também a utilização de ferramentas multivariadas capazes de detectar alterações menores, tais como a carta multivariada de média móvel exponencialmente ponderada-MEWMA ou a carta multivariada de soma cumulativa-MCuSum (ALWAN, 1986; LOWRY *et al.*, 1992; CHEN *et al.*, 1998; BERSIMIS *et al.*, 2007; SAGHAEI *et al.*, 2009; NOROSSANA *et al.*, 2010; BODNAR & SCHMID, 2011; CHENOURI & VARIYATH, 2011; MAHMOUD & MARAVELAKIS, 2011).

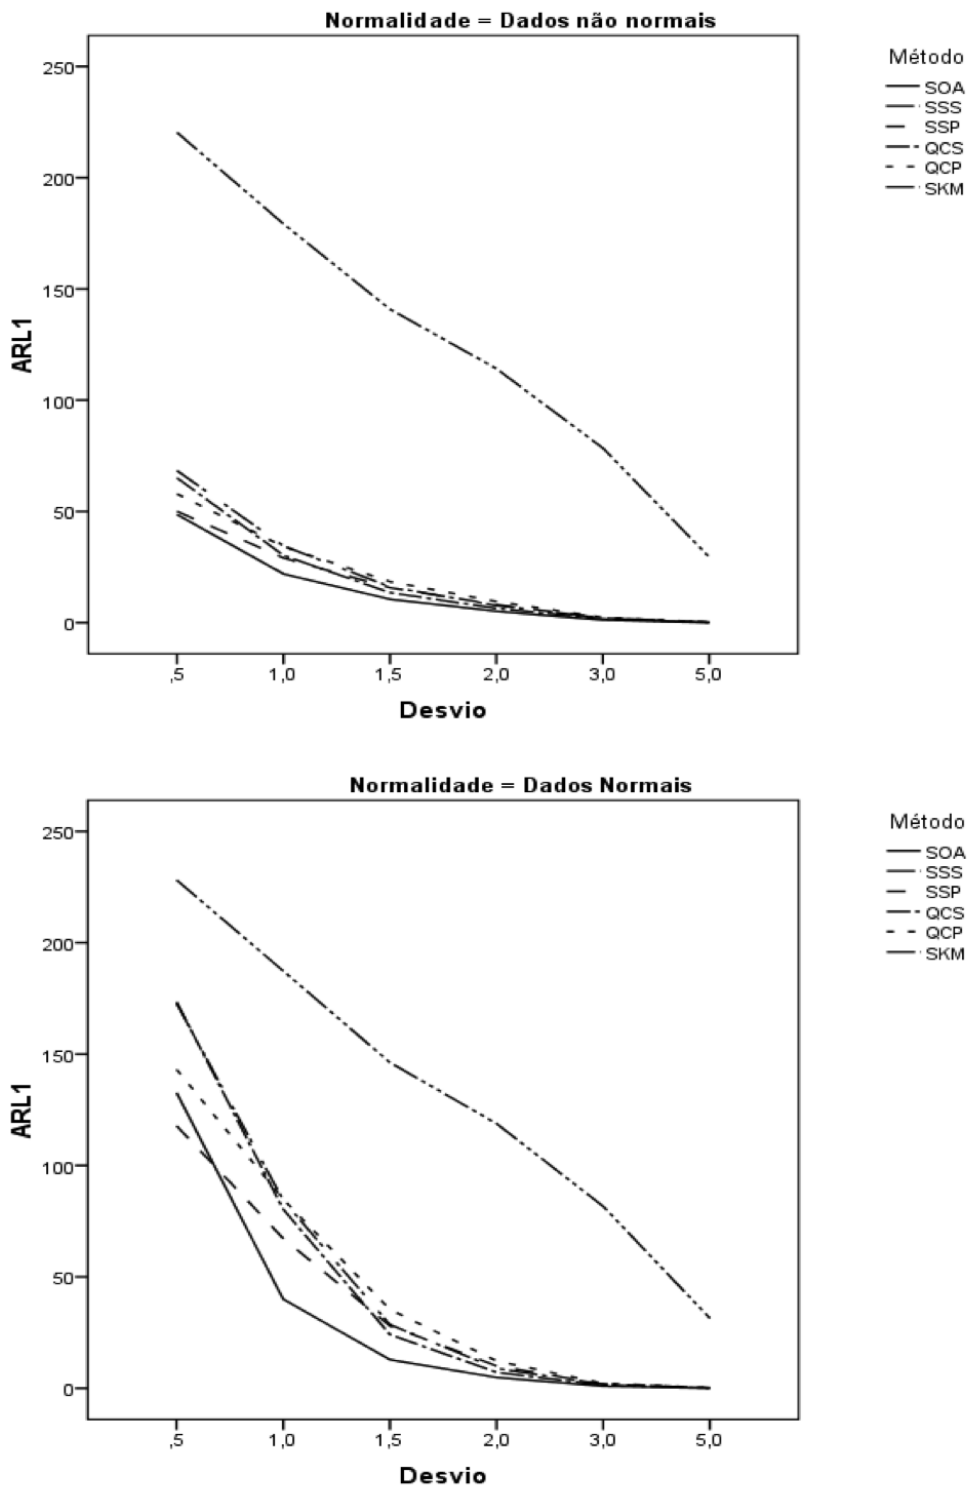


Figura 4.19: Gráficos dos resultados do ARL_1 para a interação Normalidade*Desvio*Método

5 Considerações Finais

O aumento do número de possibilidades de escolha para atender completamente às demandas dos clientes resulta em menores lotes de produção e insuficientes dados históricos para estimar com a acurácia desejada os limites das cartas de controle. O desafio então é encontrar uma metodologia que se ajuste a este ambiente produtivo de alta flexibilidade e que, ao mesmo tempo, preserve o rigor da análise da qualidade. Esta tese não só mostrou os problemas na implantação de cartas de controle observados em ambientes de produção customizados, mas também as limitações da implantação de diversos procedimentos existentes na literatura neste tipo de ambiente. Os resultados destacam uma resposta à questão principal deste estudo: é possível implantar ferramentas de controle estatístico do processo em ambientes de produção flexível.

O objetivo geral desta tese é propor ferramentas de controle estatístico do processo para ambientes de produção customizados. No estudo qualitativo realizado em empresas com características de produção flexível, observou-se que nem todas as avaliações necessárias são executadas para a implantação das ferramentas de controle de modo adequado. Nas companhias participantes, foi observado que o controle estatístico do processo iniciava-se com os estudos de capacidade do processo enquanto que a literatura sugere que este estudo seja efetuado apenas após a confirmação de que o processo esteja estável por meio da implantação de cartas de controle (no mínimo a fase I). Além disso, a revisão da literatura não mostrou procedimentos capazes de preencher todos os requerimentos do problema de pesquisa.

A abordagem mais próxima encontrada na literatura consiste no monitoramento da diferença padronizada entre cada observação e o respectivo parâmetro do processo. Esta abordagem necessita da estimativa dos parâmetros do processo em uma série histórica. Em uma situação sem prévio conhecimento do tamanho dos lotes, do sequenciamento de produção ou inclusive do ciclo de vida do produto, não é possível estimar quão longa deverá ser a série de dados coletada para execução da fase I retrospectiva de implantação das cartas de controle. Um exemplo disso é o próprio estudo de caso apresentado na subseção 4.6.1. São analisados 1070 pontos e a carta de resíduos obtidos a partir da diferença da média do processo poderia utilizar, talvez, os primeiros 146 pontos para estimativa dos parâmetros de cada produto no processo. Note que, de acordo com a

Figura 4.6, o produto "C" não aparece na análise antes da observação de número 146. Um novo produto, ou até mesmo uma alteração de *design* que represente uma alteração significativa na característica da qualidade, não pode ser tratado neste modelo de controle. De fato, nenhuma das abordagens tradicionais pode lidar com esta situação.

A fim de implantar uma ferramenta que pudesse lidar com todas as características já abordadas em relação ao ambiente de produção customizado, buscou-se adaptar e desenvolver soluções de controle estatístico do processo com objetivo de atender a estas demandas, mas que também fossem capazes de lidar com limitações impostas pelo ciclo de vida do produto, ou seja, procedimentos capazes de terem incluídos ou excluídos produtos a qualquer tempo, sem a necessidade de reinicialização do processo de implantação da carta de controle.

Um ferramenta original foi concebida para o monitoramento da característica da qualidade em diferentes itens: uma carta de auto-inicialização multivariada para monitorar o vetor dos estados de um modelo nível-local ajustado via filtro de Kalman (SKM). Além desta, dois outros procedimentos de auto-inicialização foram adaptados à realidade de monitoramento de múltiplos itens: a carta de auto-inicialização de Shewhart e a carta de Quesenbery (1991). Como estas duas últimas ferramentas foram originariamente desenvolvidas para um único item, a estimativa da variância dos dados também necessitou de ajustes. Assim, dois procedimentos foram utilizados para lidar com a questão da estimativa da variância: um estimador da variância individual para cada item em produção e um estimador da variância combinada para todos os itens, concluindo assim 4 diferentes ferramentas de monitoramento estatístico do processo.

Os resultados apontaram que a violação das suposições deteriora o desempenho de todas as cartas comparadas neste estudo. Nenhum dos procedimentos apresentou desempenho significativamente melhor que o *benchmark* estabelecido. Destaca-se que o procedimento SOA, apresentado por Del Castillo *et al.* (1996), sofreu variações severas em suas medidas de desempenho de acordo com o tipo de violação observada nos diferentes cenários.

Os procedimentos que mais se aproximaram do desempenho da carta SOA foram as cartas com variância combinada, principalmente a de auto-inicialização de Shewhart que, assumindo normalidade, detectou mudanças no estado de controle inclusive mais rapidamente para desvio na ordem de meio desvio-padrão. De modo geral, todos os métodos adaptados comportaram-se de modo similar ao *benchmark*, inclusive nas variações decorrentes da violação das suposições, não apresentando assim diferenças significativas frente aos testes realizados. Este resultado aponta a possibilidade real de utilização destas ferramentas nestes cenários, sem perda de desempenho quando comparadas com a ferramenta apresentada por Del Castillo *et al.* (1996) que exige a utilização de uma fase I de análise retrospectiva nos dados da característica da qualidade.

O procedimento SKM, apesar de ter o desempenho mais consistente no ARL_0 , apresentou os piores resultados quando analisado seu desempenho em termos de ARL_1 . Um motivo foi identificado como gerador deste fraco desempenho: a atualização de apenas um dos parâmetros no espaço dos estados do modelo estrutural básico faz com que as alterações observadas sejam relativamente pequenas para serem percebidas pelo esquema multivariado T^2 de Hotelling. Por outro lado, há duas alternativas que podem ser utilizadas para contornar este problema. A primeira refere-se ao modelo ajustado: a inclusão de mais variáveis no modelo estrutural poderá fazer com que o sistema perceba mais rapidamente as alterações do processo. Esta solução deve apresentar melhores resultados para um número de produtos relativamente pequeno em análise, mas deve voltar a ter um desempenho fraco conforme se aumenta o número de produtos na série. De qualquer modo, a inclusão de componentes de tendência para cada produto transformaria o modelo de nível local em um modelo de nível+tendência associado a cada variável indicadora, melhorando o ajuste do modelo e por consequência, a sua sensibilidade às mudanças. Em contrapartida, a utilização de outra ferramenta multivariada, tal qual um esquema de soma cumulativa multivariada (MCuSum) ou até mesmo um esquema multivariado de média móvel exponencialmente ponderada (MEWMA), levaria a um melhor desempenho quanto ao ARL_1 . A melhora de desempenho de cartas destes tipos é referenciada na literatura que destaca, principalmente, a capacidade de detectar mais rapidamente que o processo passou de um estado sob controle para outro fora de controle.

5.1 Principais contribuições da pesquisa

A proposição de monitorar múltiplos itens com apenas uma ferramenta destaca-se como a principal contribuição deste trabalho, uma vez que é referenciado na literatura a não existência de procedimentos capazes de atender a esta demanda do controle estatístico do processo em ambientes customizados. Apesar de não resolver completamente o problema, a mudança de paradigma apresentada, do uso de uma carta para cada produto para o uso de uma carta para o processo destaca-se, principalmente, pela abertura de novas possibilidades de estudo na área.

Além da proposição e descrição de procedimentos para a realização de controle estatístico do processo em ambientes sujeitos a produção de múltiplos itens, ambientes customizados e de produção flexível, outras importantes contribuições devem ser destacadas:

1. a capacidade dos procedimentos propostos em atender o pressuposto de inclusão de novos produtos no monitoramento, bem como de exclusão de produtos que tiveram findado seu ciclo de vida;

2. a obtenção de resultados satisfatórios nos procedimentos adaptados que validam a sua utilização neste tipo de ambiente;
3. a observação de que a estimativa da variabilidade simples não apresenta ganhos efetivos de desempenho nas cartas propostas quando comparada com o modo de estimação simples tradicional em ambientes heterocedásticos; e
4. o indicativo de que a violação à normalidade configura-se no principal efeito de deterioração do desempenho das cartas de controle, apontando para uma direção divergente à da literatura que tem apresentado frequentes estudos associados à violação da suposição de independência.

5.2 Sugestões para pesquisas futuras

O estudo desenvolvido nesta tese deu início em uma empresa do setor de plásticos. Foi observado o problema de implantação de cartas de controle, uma vez que na mesma linha produtiva era produzido mais de um produto. Uma série de dados histórica de uma característica da qualidade foi cedida para este estudo. Uma pesquisa qualitativa foi realizada nos setores metal-mecânico e de componentes eletrônicos associados a fabricação de auto-peças da indústria de transformação.

Além de aspectos identificados na condução deste trabalho e que serão apresentados a seguir, a principal sugestão para pesquisa futura é o acompanhamento crítico da implantação destas ferramentas em ambientes reais de produção, buscando verificar tanto as dificuldades de implantação e monitoramento devido à complexidade dos métodos propostos quanto o próprio desempenho destas ferramentas. A verificação do comportamento destas ferramentas em séries reais de outros processos certamente irá contribuir para o aprimoramento de suas sensibilidades.

A segunda sugestão diz respeito à apresentação dos resultados de estudos simulados, tal qual os apresentados neste trabalho. Geralmente os resultados da avaliação de desempenho de cartas de controle levam em consideração apenas os valores médios. Um estudo sobre a variabilidade do ARL_0 e ARL_1 contribuiria para a comparação de procedimentos diversos. Isto porque intervalos de confiança poder-se-iam ser estimados e utilizados na comparação do desempenho das ferramentas.

Uma vez que a avaliação do desempenho de cartas é efetuado através das medidas de ARL , é importante avaliá-las de modo a compreender melhor seu comportamento na distribuição. Supõe-se que o ARL seja distribuído tal qual um modelo Geométrico, entretanto um estudo mais detalhado de suas características de distribuição podem gerar ao reconhecimento ou construção de um modelo próprio de distribuição de probabilidade para esta medida, de modo que avaliações futuras de desempenho poder-se-ão ser mais

eficientes. Um ARL_1 , por exemplo, baixo porém com alta variabilidade pode vir a ser inclusive pior do que um ARL_1 maior, porém com maior precisão. Deste modo, sugerem-se as seguintes expressões para estimativa da variabilidade dos ARL .

$$s_{ARL_0}^2 = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{1}{\frac{1}{n} \sum_{j=1}^n I_{j\{x:x>LCL \cup x<UCL | \mu=\mu_0\}}} - ARL_0 \right)^2 \quad (5.1)$$

$$s_{ARL_1}^2 = \frac{1}{N-1} \sum_{i=1}^N \left(1 + \sum_k^l I_{k\{x:LCL < x < UCL | \mu \neq \mu_0\}} - ARL_1 \right)^2 \quad (5.2)$$

onde N é o número de séries simuladas, n é o tamanho da série simulada, ou tamanho do intervalo, $I_{j\{x:x>LCL \cup x<UCL | \mu=\mu_0\}}$ é uma função indicadora que aponta se o valor observado encontra-se fora dos limites de controle quando o processo está estável e $I_{k\{x:LCL < x < UCL | \mu \neq \mu_0\}}$ é uma função indicadora que aponta se o processo está sob controle quando a hipótese de processo controlado deveria ser rejeitada.

Os resultados demonstraram que, em grande parte, as alterações no desempenho dos métodos de controle estatístico do processo são oriundos da violação da suposição da normalidade. Entretanto, a maior parte das referências sobre violações de suposições de cartas de controle disponíveis na literatura atentam para a questão da autocorrelação. Acredita-se que isto deve-se principalmente ao fato de que nas ferramentas tradicionais, onde há fase I do controle estatístico do processo, os estimadores dos parâmetros do processo exigem como suposição a independência das observações. Em ambientes de produção customizados, onde se opte por ferramentas desenvolvidas baseadas em princípios de auto-inicialização, a violação da normalidade foi destrutiva para o desempenho. Estudos futuros devem-se atentar a esta característica como principal, inclusive por referências na literatura de que, geralmente, esta é a suposição violada em ambientes de produção customizados e em pequenos lotes (YOURSTONE & ZIMMER, 1992; STOWMBOS & REYNOLDS, 2000; LIN & CHOU, 2004; 2005; NOOROSSANA *et al.*, 2011; ?).

O volume de produtos monitorados no processo foi considerado como fonte de variação no estudo associado à escolha do modelo preditivo, entretanto não foi considerado no estudo comparativo efetuado para avaliar o desempenho das cartas de controle propostas. Isto porque o número de produtos não foi um fator significativo para o modelo preditivo, utilizado na construção da carta SKM, naquela análise. Uma replicação deste estudo, considerando também o número de itens monitorados como fonte de variação, é sugerido para pesquisas futuras.

Também é necessário propor a utilização de outra carta de controle multivariado no método SKM. Um procedimento como o MCuSum ou o MEWMA por exemplo, uma vez que são procedimentos capazes de detectar mudanças menores e, por consequência, mais rapidamente que o procedimento T^2 de Hotelling. Uma alternativa poderia ser

a determinação da diferença observada no vetor de estados entre os tempos $t + 1$ e t , construindo assim uma carta de resíduos com $lag = 1$.

Por fim, desenvolver um método de controle estatístico para a variabilidade da característica da qualidade em ambientes customizados permanece como uma lacuna a ser preenchida uma vez que esta tese restringiu-se à avaliação do nível da série. Uma possibilidade poderia ser a inclusão da variabilidade na carta multivariada numa versão aperfeiçoada do método SKM. Entretanto, como administrar a dependência entre o nível da série e a sua variabilidade também é uma questão em aberto.

Referências Bibliográficas

- ALWAN, L. C. 1986. Cusum quality control multivariate approach. *Communications in Statistics: Theory and Methods*, **15**(12), 3531–3543.
- ALWAN, L. C. 1992. Effects of autocorrelation on control chart performance. *Communications in Statistics: Theory and Methods*, **21**(4), 1025–1049.
- ALWAN, L. C., & ROBERTS, H. V. 1988. Time-Series Modeling for Statistical Process Control. *Journal of Business & Economic Statistics*, **6**, 87–95.
- ANZANELLO, M., ALBIN, S., & CHAOVALITWONGSE, W. 2012. Multicriteria variable selection for classification of production batches. *European Journal of Operational Research*, **218**, 97–105.
- BAI, J., & PERRON, P. 2003. Computation and Analysis of Multiple Structural Change Modes. *Journal of Applied Econometrics*, **18**, 1–22.
- BERSIMIS, S., PSARAKIS, S., & PANARETOS, J. 2007. Multivariate statistical process control charts: an overview. *Quality and Reliability Engineering International*, **23**(5), 517–543.
- BISGAARD, S., & KULAHCI, M. 2005. Quality Quandaries: The Effect of Autocorrelation on Statistical Process Control Procedures. *Quality Engineering*, **17**, 481–489.
- BISGAARD, S., & KULAHCI, M. 2008. Box-Cox Transformations and Time Series Modeling Ð Part I. *Quality Engineering*, **20**, 376–388.
- BODNAR, O., & SCHMID, W. 2011. CUSUM charts for monitoring the mean of a multivariate Gaussian process. *Journal of Statistical Planning and Inference*, **141**(6), 2055 – 2070.
- BOX, G., JENKINS, G. M., & reinsel, G. C. 1970. *Time series analysis: forecasting and control*. Holden-Day.
- CAULCUTT, R. 1995. The Rigths and Wrongs of Control Charts. *Applied Statistics*, **44**, 279–288.

- CHAN, L. K., HAPUARACHCHI, K. P., & MACPHERSON, B. D. 1998. Robustness of X-bar and R chart. *IEEE Transactions on Reliability*, **37**, 117–123.
- CHEN, G, McAVOY, T., & PIOVOSO, M. J. 1998. A multivariate statistical controller for on-line quality improvement. *Journal of Process Control*, **8**(2), 139 – 149.
- CHENOURI, S., & VARIYATH, A. M. 2011. A comparative study of phase II robust multivariate control charts for individual observations. *Quality and Reliability Engineering International*, **27**(7), 857–865.
- CHONG, I., & JUN, C. 2005. Performance of some variable selection methods when multicollinearity is present. *Chemometrics and Intelligent Laboratory Systems*, **11**(2), 101–105.
- COMMANDEUR, J. J. F., & KOOPMAN, S. J. 2007. *An introduction to State Space Time Series Analysis*. Oxford.
- DA SILVEIRA, G., BORENSTEIN, D., & FOGLIATTO, F. S. 2001. Mass customization: literature review and research directions. *International Journal of Production Economics*, **72**, 1–13.
- DEL CASTILLO, E., & MONTGOMERY, D. C. 1994. Short-Run Statistical Process Control: Q-Chart enhancements and alternative methods. *Quality and Reliability Engineering International*, **10**, 87–97.
- DEL CASTILLO, E., & MONTGOMERY, D. C. 1995. A Kalman filtering process control scheme with an application in semiconductor short run manufacturing. *Quality and Reliability Engineering International*, **11**(2), 101–105.
- DEL CASTILLO, E., & MONTGOMERY, D. C. 1996. A general model for the optimal economic design of X-bar charts used to control short or long run processes. *IIE Transactions*, **28**(3), 193–201.
- DEL CASTILLO, E., GRAYSON, J. M., MONTGOMERY, D. C., & RUNGER, G .C. 1996. A review of statistical process control techniques for short run manufacturing systems. *Communications in Statistics: Theory and Methods*, **25**(11), 2723–2737.
- DING, Y., ZENG, L, & ZHOU, S. 2006. Phase I analysis for monitoring nonlinear profiles in manufacturing processes. *Journal of Quality Technology*, **38**(3), 199–.
- ELDIN, S., & HAMZA, A. 2009. Monitoring and controlling design process using control charts and process sigma. *Bussiness Process Management Journal*, **15**, 358–370.
- ENDERS, W. 2003. *Applied Econometric Time Series*. John Wiley & Sons, Inc.

- FAN, Z., & YOU, L. 2009. Study on Quality Control Method of Using The Kalman Filtering. *In: Annals of International Conference on E-Business and Information System Security - EBISS*.
- FOGLIATTO, F. S., DA SILVEIRA, G., & BORENSTEIN, D. 2012. The mass customization decade: An updated review of the literature. *International Journal of Production Economics*, **138**(1), 14 – 25.
- GHIASSI, M., & NANGOY, S. 2009. A dynamic artificial neural network model for forecasting non linear processes. *Computers and Industrial Engineering*, **57**, 287–297.
- GUH, R-S. 2010. Simultaneous process mean and variance monitoring using artificial neural networks. *Computers and Industrial Engineering*, **58**, 739–753.
- HARVEY, A. C. 1989. *Forecasting Structural Time Series Models and the Kalman Filter*. Cambridge University Press.
- HARVEY, A. C., & SHEPHARD, N. 1993. *Handbook of Statistics*. Chap. Structural Time Series Models.
- HAWKINS, D. M., & OLWELL, D. H. 1997. *Cumulative Sum Charts and Charting for Quality Improvement*. Springer-Verlag.
- HO, L. L., & TRINDADE, A. L. G. 2009. Economic design of an X chart for short-run production. *International Journal of Production Economics*, **120**, 613–624.
- HOSKULDSSON, A., CLEROUX, R., & GAUCHI, J. 1988. PLS regression methods. *Journal of Chemometrics*, **2**, 211–228.
- JARQUE, C. M., & BERA, K. 1980. Efficient tests for normality, homocedasticity and serial independence of regression residuals. *Economics Letters*, **6**, 255–259.
- JARQUE, C. M., & BERA, K. 1981. Efficient tests for normality, homocedasticity and serial independence of regression residuals: Monte Carlo Evidence. *Economics Letters*, **7**, 313–318.
- JENSEN, W. A., JONES-FARMER, L. A., CHAMP, C. W., & WOODALL, W. H. 2006. Effects of Parameter Estimation on Control Chart Properties: A Literature Review. *Journal of Quality Technology*, **38**(4), 349–364.
- JIANG, W., TSUI, K-L., & WOODALL, W. H. 2000. A New SPC Monitoring Method: The ARMA Chart. *Technometrics*, **42**(4), 399–410.
- JONES-FARMER, L. A., JORDAN, V., & CHAMP, C. W. 2009. Distribution-Free Phase I Control Charts for Subgroup Location. *Journal of Quality Technology*, **41**, 304–316.

- KORZENOWSKI, A. L. 2009. *Premissas e suposicoes para construcao de graficos de controle: um framework para verificacao*. M.Phil. thesis, Engineering Scholl/UFRGS.
- LAZRAQ, A., CLEROUX, R., & GAUCHI, J. 2003. Selecting both latent and exploratory variables in the PLS regression model. *Chemometrics and Intelligent Laboratory Systems*, **66**, 117–126.
- LILLIEFORS, H. 1967. On the Kolmogorov–Smirnov test for normality with mean and variance unknown. *Journal of the American Statistical Association*, **62**, 399–402.
- LIN, Y-C., & CHOU, C-Y. 2004. On the design of variable sample size and sampling intervals \bar{X} -bar charts under non-normality. *Internacional Journal of Production Economics*, **96**, 249–261.
- LIN, Y-C., & CHOU, C-Y. 2005. Non-normality and the variable parameters \bar{X} -bar control charts. *European Journal of Operational Research*, **176**, 361–373.
- LOREDO, E. N., JEARKPAPORN, D., & BORROR, C. M. 2002. Model-based control chart for autoregressive and correlated data. *Quality and Reliability Engineering International*, **18**, 489–496.
- LOWRY, C. A., WOODALL, W. H., CHAMP, C. W., & RIGDON, S. E. 1992. A Multivariate Exponentially Weighted Moving Average Control Chart. *Technometrics*, **34**, 46–53.
- MACGREGOR, J.F., & KOURTI, T. 1995. Statistical process control of multivariate processes. *Control Engineering Practice*, **3**(3), 403 – 414.
- MAHMOUD, M. A., & MARAVELAKIS, P. E. 2011. The performance of multivariate CUSUM control charts with estimated parameters. *Journal of Statistical Computation and Simulation*, **0**(0), 1–18.
- MAHMOUD, M. A., & WOODALL, W. H. 2004. Phase I Analysis of Linear Profiles With Calibration Applications. *Technometrics*, **46**(4), 380–391.
- MONTGOMERY, D. C. 2004. *Introduction to statistical quality control*. John Wiley & Sons, Ltd.
- MOOD, A. M., GRAYBILL, F. A., & BOES, D. C. 1974. *Introduction to the Theory of Statistics*. New York: Mc-Graw-Hill, Inc.
- MOORE, P. 1957. Normality in Quality Control Charts. *Applied Statistics*, **6**, 171–179.

- NOOROSSANA, R., VAGHEFI, A., & DORRI, M. 2011. Effect of non-normality on the monitoring of simple linear profiles. *Quality and Reliability Engineering International*, **27**(4), 425–436.
- NOROSSANA, R., EYVAZIAN, M., AMIRI, A., & MAHMOUD, M. A. 2010. Statistical monitoring of multivariate multiple linear regression profiles in phase I with calibration application. *Quality and Reliability Engineering International*, **26**(3), 291–303.
- OHNO, T., & BODEK, N. 1988. *Toyota Production System: Beyond Large-Scale Production*. Productivity Press.
- PEDRINI, D. C., & TEN CATEN, C. S. 2011. Metodo para aplicacao de graficos de controle de regressao no monitoramento de processos. *Producao*, **211**, 106–117.
- PINE II, B. J., & S., DAVIS. 1999. *Mass Customization: The New Frontier in Business Competition*. Harvard Business School Press.
- QUESENBERRY, C. P. 1991. SPC Q Charts for start-up process and short or long runs. *Journal of Quality Technology*, **23**(3), 213–224.
- QUESENBERRY, C. P. 1997. *SPC Methods for Quality Improvement*. Wiley.
- RAMJEE, R., CRATO, N., & RAY, B. K. 2002. A note on moving average forecasts of long memory processes with an application to quality control. *International Journal of Forecasting*, **8**, 291–297.
- RUNGER, G. C., & WILLEMAIN, T. R. 1995. Model-Based and Model-Free Control of Autocorrelated Processes. *Journal of Quality Technology*, **27**, 283–292.
- SAGHAEI, A., MEHRJOO, M., & AMIRI, A. 2009. A CUSUM-based method for monitoring simple linear profiles. *The International Journal of Advanced Manufacturing Technology*, **45**, 1252–1260. 10.1007/s00170-009-2063-2.
- SANT'ANNA, A. M. O., & TEN CATEN, C. S. 2010. Modelagem da fracao de nao-conformes em processos industriais. *Pesquisa Operacional*, **30**, 53–72.
- SCHIMID, W., & SCHONE, A. 1997. Some Properties of the EWMA Control Chart in the Presence of Autocorrelation. *The Annals of Statistics*, **25**(3), 1277–1283.
- SEMINO, D., MORRETTA, C., & SCALI, C. 1996. Parameter Estimation in extended Kalman Filters for Quality Control in Polymerization Reactors. *Computers & Chemical Engineering*, **20**, S913–S918.
- SEREL, D. A. 2009. Economic Design of EWMA control charts based on loss function. *Mathematical and Computer Modelling*, **49**, 745–759.

- SHAPIRO, S. S., & WILK, M. B. 1965. An analysis of variance test for normality (complete samples). *Biometrika*, **52**, 591–611.
- SHI, J., CEGLAREK, D., & DING, Y. 2000. Modeling and Diagnosis of Multistage Manufacturing Processes: Part I: State Space Model. *In: Annals of JAPAN/USA Symposium on Flexible Automation*.
- SKINNER, K. R., MONTGOMERY, D. C., & RUNGER, G. C. 2003. Process monitoring for multiple count data using generalized linear model-based control charts. *International Journal of Production Research*, **41**(6), 1167–1180.
- SNOUSSI, A., GHOURABI, M. EL, & LIMAM, M. 2005. On SPC for Short Run Autocorrelated Data. *Communications in Statistics: Simulation and Computation*, **34**, 219–234.
- STOWMBOS, Z. G., & REYNOLDS, M. R. 2000. Robustness to non-normality and autocorrelation of individuals control charts. *The Journal of Statistical Computation and Simulation*, **66**, 145–187.
- SULLIVAN, J. H., & JONES, L. A. 2002. A Self-Starting Control Chart for Multivariate Individual Observations. *Technometrics*, **44**(1), 24–33.
- SULLIVAN, J. H., & WOODALL, W. H. 1996. A comparison of multivariate control charts for individual observations. *Journal of Quality Technology*, **28**, 398–408.
- SUPERVILLE, C. R., & ADAMS, B. M. 1994. An evaluation of forecast-based quality control schemes. *Communications in Statistics: Simulation and Computation*, **23**(3), 645–661.
- WALKER, E., & WRIGTH, S. 2002. Comparing Curves using additive models. *Journal of Quality Technology*, **34**, 118–129.
- WILLIAMS, J. D., WOODALL, W. H., & BIRCH, J. B. 2007. Statistical monitoring of nonlinear product and process quality profiles. *Quality and Reliability Engineering International*, **23**(8), 925–941.
- WOLD, S., SJOSTROM, M., & ERIKSSON, L. 2001. PLS-regression: a basic tool of chemometrics. *Chemometrics and intelligent Laboratory Systems*, **58**, 109–130.
- WOODALL, W. H. 1983. The Distribution of the Run Length of One-Sided CUSUM Procedures for Continuous Random Variables. *Technometrics*, **25**(3), 295–301.
- WOODALL, W. H. 2000. Controversies and Contradictions in Statistical Process Control. *Journal of Quality Technology*, **32**, 341–350.

- WOODALL, W. H., & NCUBE, M. M. 1985. Multivariate CUSUM Quality-Control Procedures. *Technometrics*, **27**, 285–292.
- WOODALL, W. H., & THOMAS, E. V. 1995. Statistical process control with several components of common cause variability. *IEE Transactions*, **27**, 757–764.
- WOODALL, W. H., SPITZNER, D. J., MONTGOMERY, D. C., & GUPTA, S. 2004. Using Control Charts to Monitor Process and Product Quality Profiles. *Journal of Quality Technology*, **36**(3), 309–320.
- YASHCHIN, E. 1994. Monitoring Variance Components. *Technometrics*, **36**(4), pp. 379–393.
- YOURSTONE, S. A., & ZIMMER, W. J. 1992. Non-normality and design of control chart averages. *Decisions Sciences*, **23**, 1099–1113.
- ZANTEK, P. F. 2006. Design of Cumulative Sum Schemes for Start-up Processes and Short Runs. *Journal of Quality Technology*, **38**(4).
- ZEIFMAN, M. I., & INGMAN, D. 2003. Continuous Markovian Model for Unexpected Shift in SPC. *Methodology and Computing in Applied Probability*, **5**, 455–466.
- ZHAO, X. 2011. A Process Oriented Quality Control Approach Based on Dynamic SPC and FMEA. *International Journal of Engineering: Theory, Applications and Practice*, **8**, 444–451.
- ZOU, C., C., ZHOU, Z., WANG, & TSUNG, F. 2007. A self-Starting Control Chart for Linear Profiles. *Journal of Quality Technology*, **39**(4), 364–375.

A ARLs estimados por cenários

Tabela A.1: ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário I

Carta	ARL_0	ARL_1					
		$0,5\sigma$	$1,0\sigma$	$1,5\sigma$	$2,0\sigma$	$3,0\sigma$	$5,0\sigma$
SOA	476,0771	139,6628	42,5254	13,5802	5,2532	1,0006	0,0182
	376,9318	121,6756	35,7632	11,9222	4,6266	0,9032	0,0158
SSS	409,0816	173,1692	89,8462	28,7832	9,2446	1,8290	0,2712
	372,1623	165,4060	82,9870	26,0166	8,7054	1,7532	0,2572
SSP	136,0267	85,1632	39,7060	15,1556	5,4734	1,0570	0,0748
	375,0234	168,7912	104,5854	44,2496	15,5108	2,1296	0,2212
QCS	621,1180	190,3710	93,3222	28,6710	8,4084	1,5374	0,1566
	375,9398	150,0714	63,2514	18,1668	6,1834	1,2490	0,1368
QCP	267,9528	142,5350	80,3894	31,6330	10,5872	1,6508	0,2100
	370,3018	167,9162	104,0130	43,9370	15,2414	2,0616	0,2210
SKM	129,9714	195,1750	123,9256	61,8474	28,6336	9,5978	3,9988
	372,8561	261,2326	249,7870	233,4626	209,2088	153,9808	57,2768

Tabela A.2: ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário II

Carta	ARL_0	ARL_1					
		$0,5\sigma$	$1,0\sigma$	$1,5\sigma$	$2,0\sigma$	$3,0\sigma$	$5,0\sigma$
SOA	142,2172	57,9792	23,2554	11,0074	5,2640	1,1990	0,0014
	126,2547	47,4152	21,3010	9,9982	4,8232	1,1058	0,0010
SSS	151,3088	73,8382	37,1104	16,5210	7,6764	2,0904	0,2714
	143,3486	70,1386	35,0752	15,6280	7,3656	2,0156	0,2664
SSP	76,4234	38,7194	21,1460	10,9448	5,3018	1,3852	0,1104
	131,8652	66,7474	39,9418	21,4326	10,9406	2,6444	0,2420
QCS	185,7528	78,1208	35,9860	15,1118	6,9942	1,8754	0,1466
	139,8652	59,3778	27,1322	11,7722	5,6038	1,5336	0,1196
QCP	110,5094	55,7572	32,6396	17,3590	8,7482	2,0666	0,2322
	130,9243	66,3624	39,6348	21,2518	10,8562	2,6364	0,2406
SKM	128,4934	181,5756	113,5206	54,5858	25,6466	9,4066	3,9808
	360,8805	257,0830	242,2208	223,3768	199,6132	145,4078	53,2904

Tabela A.3: ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário III

Carta	ARL_0	ARL_1					
		$0,5\sigma$	$1,0\sigma$	$1,5\sigma$	$2,0\sigma$	$3,0\sigma$	$5,0\sigma$
SOA	463,4994	143,0978	43,2246	13,7842	5,0950	0,9806	0,0240
	371,8163	124,1786	37,1996	11,9976	4,5616	0,8926	0,0208
SSS	418,8482	178,2358	93,0704	31,4432	9,5780	1,8028	0,2442
	380,0836	171,0138	85,9696	28,5658	8,7970	1,7130	0,2320
SSP	139,0627	88,9134	43,6072	14,8808	5,5212	1,0788	0,0576
	380,5899	174,4962	111,3986	47,6786	15,3248	2,2694	0,2178
QCS	634,5178	196,1698	97,2680	33,0882	8,4748	1,5062	0,1508
	380,0114	155,8236	66,4902	18,8712	6,1340	1,2488	0,1206
QCP	276,1668	147,9980	86,2018	33,4300	10,8298	1,6222	0,0830
	375,7280	173,3956	110,5328	46,9650	15,1766	2,2574	0,2168
SKM	129,3745	199,1116	129,0054	64,6468	30,3116	9,5912	4,0780
	360,4903	260,1726	248,4614	232,3136	210,3218	154,7340	61,1508

Tabela A.4: ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário IV

Carta	ARL_0	ARL_1					
		$0,5\sigma$	$1,0\sigma$	$1,5\sigma$	$2,0\sigma$	$3,0\sigma$	$5,0\sigma$
SOA	141,9446	52,9086	23,4808	11,2150	5,4480	1,2192	0,0030
	126,3025	47,4618	21,2628	10,1974	4,8924	1,0936	0,0014
SSS	154,7868	72,9222	36,5482	17,0262	8,0038	2,2302	0,3072
	146,6168	68,9746	34,4012	15,9776	7,6086	2,1346	0,2982
SSP	78,1494	39,5564	21,0936	11,2818	5,5452	1,2556	0,0838
	134,5895	67,2094	40,7948	21,9932	10,9104	2,3464	0,1838
QCS	189,4837	76,7072	35,2926	15,5076	7,2094	1,9514	0,1938
	142,3893	58,8892	26,7760	12,0060	5,8348	1,5876	0,1620
QCP	113,1414	57,8828	32,7230	17,5184	8,6092	1,8596	0,1110
	133,4401	66,7918	40,4120	21,7564	10,7896	2,3342	0,1816
SKM	129,2741	186,0686	117,5318	56,6636	25,9040	9,2790	3,9624
	358,4229	257,1580	245,7108	227,1546	203,0336	149,7356	57,4430

Tabela A.5: ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário V

Carta	ARL_0	ARL_1					
		$0,5\sigma$	$1,0\sigma$	$1,5\sigma$	$2,0\sigma$	$3,0\sigma$	$5,0\sigma$
SOA	490,4365	142,4640	43,4482	14,0558	5,1112	1,0074	0,0216
	387,3117	124,1610	36,9824	12,1398	4,5182	0,8936	0,0166
SSS	418,7605	176,9118	59,7172	30,0012	9,0334	1,8452	0,3006
	378,7879	169,2778	86,3226	26,6970	8,5196	1,7660	0,2894
SSP	84,5952	59,7172	30,8974	13,6006	6,5500	1,8178	0,2320
	181,5376	115,4336	66,5268	29,9410	12,1442	3,2062	0,5220
QCS	638,3658	193,7250	97,5696	28,6812	8,1598	1,5678	0,1966
	381,6066	153,4574	64,9534	18,2314	5,9514	1,2930	0,1748
QCP	141,5929	95,3904	52,3114	22,8950	9,7662	2,8466	0,3652
	179,2597	114,6848	65,8716	29,6624	11,9990	3,1858	0,5206
SKM	127,7058	194,1876	122,7514	60,2252	26,7886	9,7402	3,9956
	359,8417	258,2868	246,2776	227,9854	205,9622	150,2424	55,0336

Tabela A.6: ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário VI

Carta	ARL_0	ARL_1					
		$0,5\sigma$	$1,0\sigma$	$1,5\sigma$	$2,0\sigma$	$3,0\sigma$	$5,0\sigma$
SOA	120,1995	47,5836	22,3540	10,9502	5,4158	1,2468	0,0022
	108,0555	43,4486	20,5262	9,9772	4,9592	1,1404	0,0012
SSS	132,1615	66,0418	33,3312	16,5908	8,0842	2,1850	0,2648
	126,1034	62,7458	31,8412	15,6288	7,7554	2,0914	0,2576
SSP	62,8279	35,0808	19,6686	10,9222	6,2170	2,0458	0,1976
	104,7120	56,1618	33,0652	18,0794	10,3310	3,4596	0,3870
QCS	158,7176	68,6056	32,8886	15,1702	7,4152	1,8856	0,1656
	122,2868	53,1282	24,7318	11,7946	5,8974	1,5986	0,1398
QCP	89,1862	48,6996	27,9666	15,5284	8,7902	2,9062	0,3076
	104,0150	55,8084	32,9460	17,9802	10,2896	3,4474	0,3734
SKM	129,0998	182,8680	112,4070	55,5930	26,9244	9,2048	3,9302
	369,7541	257,2224	243,6946	225,5044	202,6408	147,4196	54,5248

Tabela A.7: ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário VII

Carta	ARL_0	ARL_1					
		$0,5\sigma$	$1,0\sigma$	$1,5\sigma$	$2,0\sigma$	$3,0\sigma$	$5,0\sigma$
SOA	484,7310	142,6278	43,4890	13,5742	5,1780	0,9528	0,0190
	385,3565	123,7374	37,1846	11,8006	4,5860	0,8634	0,0160
SSS	422,9224	178,0752	92,0996	29,7856	9,0500	1,8646	0,2640
	383,8035	169,8396	84,9370	27,3190	8,4130	1,7674	0,2506
SSP	128,1723	83,7712	39,5340	14,8428	5,1956	0,9746	0,1264
	349,8950	166,0754	101,8834	43,6144	14,8090	2,3950	0,2694
QCS	650,6181	193,7220	95,6576	28,7944	8,2926	1,5150	0,1550
	383,8772	154,0298	64,0672	18,4946	5,9376	1,2186	0,1380
QCP	252,3341	137,9778	78,2262	31,5018	9,9708	1,8774	0,2090
	344,7681	164,9360	101,0934	42,9694	14,6712	2,3350	0,2690
SKM	129,5840	197,1824	129,7722	56,5930	29,2578	9,5576	4,1004
	366,9725	259,8108	248,5346	232,6886	209,9634	155,9450	61,9406

Tabela A.8: ARL_1 obtido por análise de dados simulados após incremento no nível da série para limites de controle teóricos e ajustados no cenário VIII

Carta	ARL_0	ARL_1					
		$0,5\sigma$	$1,0\sigma$	$1,5\sigma$	$2,0\sigma$	$3,0\sigma$	$5,0\sigma$
SOA	120,7219	48,3476	22,6628	10,9246	5,3206	1,2696	0,0024
	108,3482	43,5860	20,5494	9,9504	4,8820	1,1372	0,0010
SSS	132,5645	67,5610	34,7964	16,2208	7,7940	2,1932	0,2640
	126,1750	64,5580	32,7756	15,4558	7,3772	2,0848	0,2564
SSP	66,8896	36,3260	19,7952	10,5632	5,1530	1,1742	0,0534
	109,4511	60,5986	37,1484	20,4864	10,2428	2,1570	0,0930
QCS	160,1409	71,3210	33,8806	14,8522	6,9956	1,8884	0,1492
	122,6843	54,7072	25,3172	11,7490	5,6558	1,5536	0,1286
QCP	93,7778	51,6448	30,4664	16,2246	8,1410	1,8026	0,0796
	108,8732	60,2030	36,8582	20,1506	10,1230	2,1438	0,0924
SKM	129,2574	183,3888	113,5502	57,1512	26,9170	9,3668	4,0562
	371,6781	257,2556	245,2722	227,1474	202,8808	148,1372	54,5354

B Gráficos com resultados da interação Desvio*Método*Cenário




Figura B.1: ARL₁ da interação Desvio*Método para o cenário I

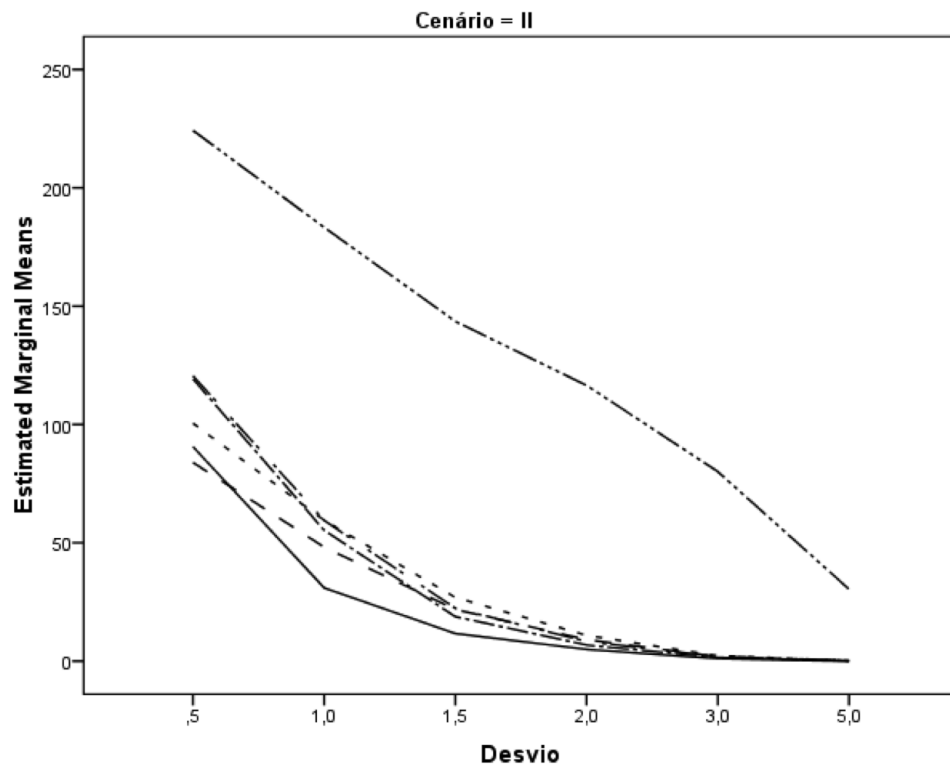


Figura B.2: ARL₁ da interação Desvio*Método para o cenário II




Figura B.3: ARL₁ da interação Desvio*Método para o cenário III




Figura B.4: ARL₁ da interação Desvio*Método para o cenário IV




Figura B.5: ARL₁ da interação Desvio*Método para o cenário V




Figura B.6: ARL₁ da interação Desvio*Método para o cenário VI




Figura B.7: ARL₁ da interação Desvio*Método para o cenário VII




Figura B.8: ARL₁ da interação Desvio*Método para o cenário VIII

C Códigos do Matlab para simulação e análise

C.1 Análise dos dados da série histórica

```

1  %% read data and estimate parameters in the entire serie
2  dados = csvread('data.csv');
3  % Remove the out-of-control data points found in Real_series.m
4  %foo = find(rs1 | rs2 | rs3 | rs4);
5  %dados1 = dados;
6  %dados(foo,:)=[];
7  %% parameters = zeros(5,2);
8  for i=1:5 % Obtained estimate of process parameters in entire serie
9      parameters(i,1) = mean(dados(find(dados(:,2)==i),1));
10     parameters(i,2) = std(dados(find(dados(:,2)==i),1));
11 end
12 n = size(dados);
13 n = n(1);
14 %% ARL product plan
15 ARL=[];
16 cont=1;
17 for i=2:n
18     if dados(i-1,2)==dados(i,2)
19         cont=cont+1;
20     else
21         ARL(end+1)=cont;
22         cont=1;
23     end
24 end
25 hist(ARL)
26 ylabel('Frequency')
27 xlabel('Run Length: Avg=5.74')
28 sum(ARL)/size(ARL,2)
29 return
30 %% Data Chart
31 data_plot=zeros(n,5);
32 for i=1:n
33     data_plot(i,dados(i,2))=dados(i,1);
34 end
35 x=1:n;
36 figure;
37 hold on;
38 A=plot(x,data_plot(:,1),'k +');
39 B=plot(x,data_plot(:,2),'k o');
40 C=plot(x,data_plot(:,3),'k ^');
41 D=plot(x,data_plot(:,4),'k d');
42 E=plot(x,data_plot(:,5),'k *');
43 legend([A B C D E], 'A', 'B', 'C', 'D', 'E', 0, 'Location', 'Northeast', 'Orientation', 'horizontal');
44 ylim([80 200]);
45 hold off;
46 %return
47 %% Del Catillo & Montgomery - SOA
48 fprintf('Analysing data according Del Castillo & Montgomery... \n')
49 for i=1:n
50     z(i) = (dados(i,1) - parameters(dados(i,2),1)) / parameters(dados(i,2),2);
51 end
52 RSOA.z = z';
53 RSOA.r = (z < -3 | z > 3)';
54 %% Self-Start standardized Shewhart CC with simple variance - SSS
55 fprintf('Analysing data according to SSS... \n')
56 z = zeros(n,1);
57 t = zeros(n,1);
58 avg = zeros(5,2); % Average at time i
59 sos = zeros(5,1); % Sum Of Squares
60 for i=1:n
61     avg(dados(i,2),1) = avg(dados(i,2),1) + dados(i,1);
62     avg(dados(i,2),2) = avg(dados(i,2),2) + 1;
63     sos(dados(i,2)) = sos(dados(i,2)) + (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))^2;

```

```

64 if avg(dados(i,2),2) > 1
65     z(i) = (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2))) / sqrt(sos(dados(i,2))/(
        avg(dados(i,2),2)-1));
66     ts(i) = tinv(0.9987,(avg(dados(i,2),2)-1));
67 end
68 end
69 RSSS.z = z';
70 RSSS.r = (z < -ts' | z > ts')';
71 %% Self-Start standardized Shewhart CC with pooled variance - SSP
72 fprintf('Analysing data according Quesenberry QCP... \n')
73 z = zeros(n,1);
74 t = zeros(n,1);
75 avg = zeros(5,2); % Average at time i
76 sos = 0; % Sum Of Squares
77 for i=1:n
78     avg(dados(i,2),1) = avg(dados(i,2),1) + dados(i,1);
79     avg(dados(i,2),2) = avg(dados(i,2),2) + 1;
80     sos = sos + (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))^2;
81     if avg(dados(i,2),2) > 1
82         z(i) = (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2))) / sqrt(sos/i-1);
83         tp(i) = tinv(0.9987,i-1);
84     end
85 end
86 RSSP.z = z';
87 RSSP.r = (z < -tp' | z > tp')';
88 %% Quesenberry - QCS
89 fprintf('Analysing data according Quesenberry QCS... \n')
90 z = zeros(n,1);
91 q = zeros(n,1);
92 avg = zeros(5,2); % Average at time i
93 sos = zeros(5,1); % Sum Of Squares
94 for i=1:n
95     avg(dados(i,2),1) = avg(dados(i,2),1) + dados(i,1);
96     avg(dados(i,2),2) = avg(dados(i,2),2) + 1;
97     sos(dados(i,2)) = sos(dados(i,2)) + (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)
        ))^2;
98     if avg(dados(i,2),2) > 1
99         z(i) = (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2))) / sqrt(sos(dados(i,2))/(
        avg(dados(i,2),2)-1));
100        q(i) = norminv(tcdf(z(i),i-1));
101    end
102 end
103 RQCS.q = q';
104 RQCS.r = (q < -3 | q > 3)';
105 %% Quesenberry - QCP
106 fprintf('Analysing data according Quesenberry QCP... \n')
107 z = zeros(n,1);
108 q = zeros(n,1);
109 avg = zeros(5,2); % Average at time i
110 sos = 0; % Sum Of Squares
111 for i=1:n
112     avg(dados(i,2),1) = avg(dados(i,2),1) + dados(i,1);
113     avg(dados(i,2),2) = avg(dados(i,2),2) + 1;
114     sos = sos + (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))^2;
115     if avg(dados(i,2),2) > 1
116         z(i) = (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2))) / sqrt(sos/i-1);
117         q(i) = norminv(tcdf(z(i),i-1));
118     end
119 end
120 RQCP.q = q';
121 RQCP.r = (q < -3 | q > 3)';
122 %% SKM
123 fprintf('Analysing data according SKM... \n')
124 np=5;
125 a=round(parameters(:,1));
126 H = 1; % Arbitrary
127 Q = eye(np) * 1000000; % Larger number
128 S = eye(np);
129 % Vectors to save output

```

```

130 ey = [0];
131 K = zeros(np, 1);
132 X = zeros(n,np); % Observation Matrix over time t(end)=num
133 for i=1:n
134     X(i,dados(i,2))=1;
135 end
136 for t=1:n-1
137     foo = lkfilter( dados(t,1), a(:,:,end), X(t,:), X(t+1,:), H, Q, S(:,:,end));
138     ey(end+1) = foo.ey;
139     a(:,:,end+1) = foo.a;
140     K(:,:,end+1) = foo.K;
141     S(:,:,end+1) = foo.S;
142 end
143 figure hold on
144 grid on
145 % plot measurement data:
146 hz=plot([dados(:,1)],'ro');
147 % plot a-posteriori state estimates:
148 hk=plot([ey(1:end-1)],'k-');
149 %ht=plot([true], 'k-');
150 legend([hz hk], 'Observations', 'Kalman output', 0, 'Location', 'NorthEast');
151 ylim([80 200]);
152 %title('Kalman Filter Fit');
153 hold off

```

C.2 Exibição das cartas

```
1 %% RESULTS CHARTS
2 x=1:n;
3 figure;
4 subplot(6,1,1);
5 plot(x,RSOA.z,'k');
6 ylabel('SOA');
7 line(x,-3*ones(1,n),'LineStyle','--','Color','k');
8 line(x,3*ones(1,n),'LineStyle','--','Color','k');
9 title('Control Charts');
10 subplot(6,1,2);
11 plot(x,RSSS.z,'k');
12 ylabel('SSS');
13 ylim([-5 5]);
14 line(x,-ts,'LineStyle','--','Color','k');
15 line(x,ts,'LineStyle','--','Color','k');
16 subplot(6,1,3); plot(x,RSSP.z,'k');
17 ylabel('SSP');
18 ylim([-5 5]);
19 line(x,-tp,'LineStyle','--','Color','k');
20 line(x,tp,'LineStyle','--','Color','k');
21 subplot(6,1,4);
22 plot(x,RQCS.q,'k');
23 ylabel('QCS');
24 line(x,-3*ones(1,n),'LineStyle','--','Color','k');
25 line(x,3*ones(1,n),'LineStyle','--','Color','k');
26 subplot(6,1,5);
27 plot(x,RQCP.q,'k');
28 ylabel('QCP');
29 line(x,-3*ones(1,n),'LineStyle','--','Color','k');
30 line(x,3*ones(1,n),'LineStyle','--','Color','k');
31 subplot(6,1,6);
32 plot(x,RSKM1.T,'k');
33 ylabel('SKM'); ylim([0 50]);
34 line(x,UCL1,'LineStyle','--','Color','k');
35 xlabel('Time');
```

C.3 Dados independentes simulados

```
1 %% Parameters
2 dados = csvread('data.csv');
3 parameters = zeros(5,1);
4 for i=1:5 % Obtained estimate of process parameters in entire serie
5     parameters(i,1) = round(mean(dados(find(dados(:,2)==i),1)));
6 end
7 parameters(4,1)=parameters(4,1)*1.10;
8 np=5;
9 ssize=400;
10 var=0; % 0=CV, 1=sd
11 sd=5.1465; CV=5.1465/145.65;
12 dist=0; % 0=chhisq; 1=Normal
13 %% %%%%%%%%%%%
14 sample=zeros(400,10000);
15 fprintf('Generating samples...')
16 for i=1:2:10000
17     % production sequency and simlution of independent data
18     serie=zeros(1,2);
19     n=size(serie);
20     n=n(1);
21     while n<=ssize
22         prod=randsample(np,1);
23         RL=poissrnd(5.74);
24         for z=1:RL
25             serie(end+1,2)=prod;
26             if dist
27                 if var
28                     serie(end,1)=parameters(prod,1) + normrnd(0,sd,1);
29                 else
30                     serie(end,1)=parameters(prod,1) + normrnd(0,CV*parameters(prod,1),1);
31                 end
32             else
33                 if var
34                     serie(end,1)=parameters(prod,1) + chi2rnd(round(sd^2/2),1)-round(sd^2/2);
35                 else
36                     serie(end,1)=parameters(prod,1) + chi2rnd(round((CV*parameters(prod,1))^2/2),1) -
37                         round((CV * parameters(prod,1))^2/2);
38                 end
39             end
40             n=size(serie); n=n(1);
41         end
42         serie=serie(2:401,:);
43         sample(:,i:i+1)=serie;
44         if mod(i,50)==0 fprintf(' '); end
45         if mod(i,250)==0 fprintf('\n'); end
46     end
47     csvwrite('scenario6.csv', sample);
48 return
```

C.4 Datos autocorrelacionados simulados

```
1 %% Parameters
2 % Parameters
3 dados = csvread('data.csv');
4 parameters = zeros(5,1);
5 for i=1:5 % Obtained estimate of process parameters in entire serie
6     parameters(i,1) = round(mean(dados(find(dados(:,2)==i),1)));
7 end
8 parameters(4,1)=parameters(4,1)*1.10;
9 np=5;
10 ssize=400;
11 var=0; % 0=CV, 1=sd
12 sd=5.1465; CV=5.1465/145.65;
13 dist=0; % 0=chhisq; 1=Normal
14 %% production sequency and simultion of correlated data
15 sample=zeros(400,10000);
16 fprintf('Generating samples...')
17 for j=1:2:10000
18     serie=zeros(1,2);
19     n=size(serie); n=n(1);
20     while n<=ssize
21         prod=randsample(np,1);
22         RL=poissrnd(5.74);
23         for z=1:RL
24             serie(end+1,2)=prod;
25         end
26         n=size(serie); n=n(1);
27     end
28     serie=serie(2:401,:);
29     sd=5.1465; CV=5.1465/145.65;
30     if dist
31         if var
32             AR = normrnd(0,sd,1);
33         else
34             AR = normrnd(0,CV*parameters(prod,1),1);
35         end
36     else %
37         if var
38             AR = chi2rnd(round(sd^2/2),1)-round(sd^2/2);
39         else
40             AR = chi2rnd(round((CV*parameters(prod,1))^2/2),1)-round((CV*parameters(prod,1))^2/2);
41         end
42     end
43     for i=1:ssize
44         if dist
45             if var
46                 serie(i,1) = parameters(serie(i,2),1) + AR + normrnd(0,sd,1);
47             else
48                 serie(i,1) = parameters(serie(i,2),1) + AR + normrnd(0,CV*parameters(prod,1),1);
49             end
50         else %
51             if var
52                 serie(i,1) = parameters(serie(i,2),1) + AR + chi2rnd(round(sd^2/2),1)-round(sd^2/2);
53             ;
54             else
55                 serie(i,1) = parameters(serie(i,2),1) + AR + chi2rnd(round((CV*parameters(prod,1))^2/2),1)-round((CV*parameters(prod,1))^2/2);
56             end
57         end
58         AR = AR*0.15;
59     end
60     sample(:,j:j+1)=serie;
61 end
62 csvwrite('scenario8.csv', sample);
```

C.5 Algoritmo *lkfilter.m*

```

1 function [ out ] = lkfilter(y, a, X, X1, H, Q, S)
2 % The function calculate the gain of the Kalman Filter and the updated
3 % parameters for a structural model in state-space form as
4 %  $y[t] = X[t] * a[t] + w[t]$  % as a measurement equation
5 %  $a[t] = M[t] * a[t-1] + e[t]$  % as a transition equation
6 % where Y[t] is a vector of observations
7 % X[t] is an (1xm) non-stochastic array variable over time
8 % a[t] is an (mx1) array of stochastic state vector
9 % w[t] is an irregular componente (error)
10 % M[t] is an (mxm) fixed matrix and
11 % e[t] is an (mx1) array of irregular components (error)
12 % The inputs of this function are described below:
13 % y: is the observation in time t
14 % a: is the current array of parameters (for inicial use especification
15 % values)
16 % X: is the current Design array (Kx1)
17 % X1: is the Design array one step ahead (X can be fixed over time, so
18 % X=X1) (Kx1)
19 % H: measurement noise variance (1x1)
20 % Q: parameters noise covariance (It is suggest as initial larges values)
21 % (kxk) % S: A identidy matrix of size (kxk)
22 % Outputs: An structure with the follow elements:
23 % K: the gain of Kalman Filter % a: updated values of states parameters
24 % S: updated values of covariance parameters
25 % ey: expect value of observation one step ahead
26 %
27 M = eye(max(size(X)));
28 if ~S
29 S = inv(M)*H*inv(M');
30 end
31 % Prediction for state vector and covariance:
32 a = M * a;
33 %S = M * S * M' + Q;
34 S = M * S * M';
35 % Compute Kalman gain factor:
36 K = S * X' * inv(X * S * X' + H);
37 % Updated equations:
38 a = a + K * (y - X * a);
39 S = S - K * X * S;
40 % expected y one step ahead
41 ey = X1 * a;
42 out.K = K;
43 out.a = a;
44 out.S = S;
45 out.ey = ey;
46 end

```

C.6 Análise dos dados simulados - ARL_0

```
1 clear all
2 %% read data
3 for c=1:8
4     if c==1
5         scenario = csvread('scenario1.csv');
6     end
7     if c==2
8         scenario = csvread('scenario2.csv');
9     end
10    if c==3
11        scenario = csvread('scenario3.csv');
12    end
13    if c==4
14        scenario = csvread('scenario4.csv');
15    end
16    if c==5
17        scenario = csvread('scenario5.csv');
18    end
19    if c==6
20        scenario = csvread('scenario6.csv');
21    end
22    if c==7
23        scenario = csvread('scenario7.csv');
24    end
25    if c==8
26        scenario = csvread('scenario8.csv');
27    end
28    RLO=zeros(1,6);
29    for s=1:2:10000
30        dados=scenario(:,s:s+1);
31        %% Del Catillo & Montgomery - SOA
32        fprintf('Analysing data according Del Castillo & Montgomery... \n')
33        parameters = zeros(5,2);
34        for i=1:5 % Obtained estimate of process parameters in entire serie
35            parameters(i,1) = mean(dados(find(dados(:,2)==i),1));
36            parameters(i,2) = std(dados(find(dados(:,2)==i),1));
37        end
38        n = size(dados); n = n(1);
39        for i=1:n
40            z(i) = (dados(i,1)-parameters(dados(i,2),1))/parameters( dados(i,2),2);
41        end
42        RSOA.z = z';
43        RSOA.r = (z < -3 | z > 3)';
44        cont=1; m=find(RSOA.r); u=size(m);
45        if isempty(m)
46            cont=0;
47        else
48            for i=2:u(2)
49                if m(i)-m(i-1)>1
50                    cont=cont+1;
51                end
52            end
53        end
54        RLO(end+1,1)=cont;
55        %% Self-Start standardized Shewhart CC with simple variance - SSS
56        fprintf('Analysing data according to SSS... \n')
57        z = zeros(n,1); t = zeros(n,1);
58        avg = zeros(5,2); % Average at time i
59        sos = zeros(5,1); % Sum Of Squares
60        for i=1:n
61            avg(dados(i,2),1) = avg(dados(i,2),1)+dados(i,1);
62            avg(dados(i,2),2) = avg(dados(i,2),2)+1;
63            sos(dados(i,2)) = sos(dados(i,2))+((dados(i,1)-(avg( dados(i,2),1)/avg(dados(i,2),2))
64                )^2);
65            if avg(dados(i,2),2) > 1
```



```

65     z(i) = (dados(i,1)-(avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos(dados(i,2))/(avg
        (dados(i,2),2)-1));
66     ts(i) = tinv(0.9973,(avg(dados(i,2),2)-1));
67     end
68 end
69 RSSS.z = z';
70 RSSS.r = (z < -ts' | z > ts')';
71 cont=1; m=find(RSSS.r); u=size(m);
72 if isempty(m)
73     cont=0;
74 else
75     for i=2:u(2)
76         if m(i)-m(i-1)>1
77             cont=cont+1;
78         end
79     end
80 end
81 RLO(end,2)=cont;
82
83 %% Self-Start standardized Shewhart CC with pooled variance - SSP
84 fprintf('Analysing data according Quesenberry QCP... \n')
85 z = zeros(n,1); t = zeros(n,1);
86 avg = zeros(5,2); % Average at time i
87 sos = 0; % Sum Of Squares
88 for i=1:n
89     avg(dados(i,2),1) = avg(dados(i,2),1)+dados(i,1);
90     avg(dados(i,2),2) = avg(dados(i,2),2)+1;
91     sos = sos+(dados(i,1)-(avg(dados(i,2),1)/avg(dados(i,2),2)))^2;
92     if avg(dados(i,2),2)>1
93         z(i) = (dados(i,1)-(avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos/i-1);
94         tp(i) = tinv(0.9973,i-1);
95     end
96 end
97 RSSP.z = z';
98 RSSP.r = (z < -tp' | z > tp')';
99 cont=1; m=find(RSSP.r); u=size(m);
100 if isempty(m)
101     cont=0;
102 else
103     for i=2:u(2)
104         if m(i)-m(i-1)>1
105             cont=cont+1;
106         end
107     end
108 end
109 RLO(end,3)=cont;
110 %% Quesenberry - QCS
111 fprintf('Analysing data according Quesenberry QCS... \n')
112 z = zeros(n,1); q = zeros(n,1);
113 avg = zeros(5,2); % Average at time i
114 sos = zeros(5,1); % Sum Of Squares
115 for i=1:n
116     avg(dados(i,2),1) = avg(dados(i,2),1)+dados(i,1);
117     avg(dados(i,2),2) = avg(dados(i,2),2)+1;
118     sos(dados(i,2)) = sos(dados(i,2))+((dados(i,1)-(avg(dados(i,2),1)/avg(dados(i,2),2)))
        ^2);
119     if avg(dados(i,2),2)>1
120         z(i) = (dados(i,1)-(avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos(dados(i,2))/(avg
            (dados(i,2),2)-1));
121         q(i) = norminv(tcdf(z(i),i-1));
122     end
123 end
124 RQCS.q = q';
125 RQCS.r = (q < -3 | q > 3)';
126 cont=1; m=find(RQCS.r); u=size(m);
127 if isempty(m)
128     cont=0;
129 else
130     for i=2:u(2)

```

```

131     if m(i)-m(i-1)>1
132         cont=cont+1;
133     end
134 end
135 end
136 RLO(end,4)=cont;
137 %% Quesenberry - QCP
138 fprintf('Analysing data according Quesenberry QCP... \n')
139 z = zeros(n,1); q = zeros(n,1);
140 avg = zeros(5,2); % Average at time i
141 sos = 0; % Sum Of Squares
142 for i=1:n
143     avg(dados(i,2),1) = avg(dados(i,2),1)+dados(i,1);
144     avg(dados(i,2),2) = avg(dados(i,2),2)+1;
145     sos = sos+(dados(i,1)-(avg(dados(i,2),1)/avg(dados(i,2),2)))^2;
146     if avg(dados(i,2),2) > 1
147         z(i) = (dados(i,1)-(avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos/i-1);
148         try
149             q(i) = norminv(tcdf(z(i),i-1));
150             continue
151         end
152     end
153 end
154 RQCP.q = q';
155 RQCP.r = (q < -3 | q > 3)';
156 cont=1; m=find(RQCP.r); u=size(m);
157 if isempty(m)
158     cont=0;
159 else
160     for i=2:u(2)
161         if m(i)-m(i-1)>1
162             cont=cont+1;
163         end
164     end
165 end
166 RLO(end,5)=cont;
167 %% SKM
168 fprintf('Analysing data according SKM... \n')
169 np=5;
170 a=round(parameters(:,1));
171 H = 1; % Arbitrary
172 Q = eye(np) * 1000000; % Larger number
173 S = eye(np);
174 % Vectors to save output
175 ey = [0];
176 K = zeros(np, 1);
177 X = zeros(n,np);
178 % Observation Matrix over time t(end)=num
179 for i=1:n
180     X(i,dados(i,2))=1;
181 end
182 for t=1:n-1
183     foo = lkfilter( dados(t,1), a(:, :,end), X(t,:), X(t+1,:), H, Q, S(:, :,end));
184     ey(end+1) = foo.ey;
185     a(:, :,end+1) = foo.a;
186     K(:, :,end+1) = foo.K;
187     S(:, :,end+1) = foo.S;
188 end
189 uh=[]; uh(1,:)=a(:,1,1)';
190 AVG = a(:,1,1);
191 T = zeros(n,1); UCL = zeros(n,1);
192 for i=2:n
193     AVG = AVG+a(:,1,i);
194     uh(i,:) = a(:,1,i)';
195     Shat = cov(uh);
196     for k=1:np
197         if Shat(k,k)==0
198             Shat(k,k) = 1;
199         end

```

```

200     end
201     invShat = Shat^-1;
202     for k=1:np
203         if Shat(k,k)==1
204             Shat(k,k) = 0;
205         end
206     end
207     T(i) = (a(:,1,i)-(AVG/i))*invShat*(a(:,1,i)-(AVG/i));
208     UCL1(i) = 18.20514; %.9973
209     end
210     RSKM1.T = T';
211     RSKM1.r = (T > UCL1')';
212     cont=1; m=find(RSKM1.r); u=size(m);
213     if isempty(m)
214         cont=0;
215     else
216         for i=2:u(2)
217             if m(i)-m(i-1)>1
218                 cont=cont+1;
219             end
220         end
221     end
222     RLO(end,6)=cont;
223     RLO(end,:);
224 end
225
226 %% ARLO Results
227 N=size(RLO); N = N(1);
228 RLO=RLO(2:N,:); N=N-1;
229 SRL0=zeros(1,6);
230 ARLO=(sum(RLO)/(400*N)).^-1
231 for i=1:N
232     if i==1
233         for j=1:6
234             if RLO(i,j)==0
235                 SRL0(j) = (400-ARLO(j)).^2;
236             else
237                 SRL0(j) = (((RLO(i,j)/400).^(-1)-ARLO(j)).^2);
238             end
239         end
240     else
241         for j=1:6
242             if RLO(i,j)==0
243                 SRL0(j) = (401-ARLO(j)).^2;
244             else
245                 SRL0(j) = SRL0(j)+(((RLO(i,j)/400).^(-1)-ARLO(j)).^2);
246             end
247         end
248     end
249 end
250 SARLO=(SRL0/N).^(1/2)
251 clear all
252 end

```

C.7 Análise dos dados simulados - ARL_1

```

1  %% read data
2  clear all
3  for c=1:8
4  scenario = csvread(strcat('scenario',num2str(c),'.csv'));
5  strcat('scenario:',num2str(c))
6  for sz=[0.5 1.0 1.5 2.0 3.0 5.0]
7  RL1=zeros(1,6);
8  for s=1:2:10000 %10000
9  dados=scenario(:,s:s+1);
10 parameters = zeros(5,2);
11 for i=1:5 % Obtained estimate of process parameters in complete serie
12 parameters(i,1) = mean(dados(find(dados(:,2)==i),1));
13 parameters(i,2) = std(dados(find(dados(:,2)==i),1));
14 end
15 n = length(dados(:,1)); m=100;
16 %% Del Castillo & Montgomery - SOA
17 %fprintf('Analysing data according Del Castillo & Montgomery... \n')
18 for i=1:n
19     if i>m
20         z(i) = ((sz*parameters(dados(i,2),2)+dados(i,1)) - parameters(dados(i,2),1))/
                parameters(dados(i,2),2);
21     else
22         z(i) = (dados(i,1) - parameters(dados(i,2),1))/parameters(dados(i,2),2);
23     end
24 end
25 RSOA.z = z';
26 RSOA.r = (z < -3 | z > 3)';
27 cont=0; i=1; ind=find(RSOA.r);
28 if isempty(ind)
29     cont=300;
30 else
31     for i=1:length(ind)
32         if ind(i)>100
33             cont=ind(i)-101;
34             break
35         else
36             if i==length(ind)
37                 cont=300;
38             end
39         end
40     end
41 end
42 RL1(end+1,1) = cont;
43 %% Self-Start standardized Shewhart CC with simple variance - SSS
44 %fprintf('Analysing data according to SSS... \n')
45 z = zeros(n,1); t = zeros(n,1);
46 avg = zeros(5,2); % Average at time i
47 sos = zeros(5,1); % Sum Of Squares
48 for i=1:n
49     if i>m
50         avg(dados(i,2),1) = avg(dados(i,2),1) + (sz*parameters(dados(i,2),2)+dados(i,1));
51     else
52         avg(dados(i,2),1) = avg(dados(i,2),1) + dados(i,1);
53     end
54     avg(dados(i,2),2) = avg(dados(i,2),2) + 1;
55     sos(dados(i,2)) = sos(dados(i,2)) + (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))^2;
56     if avg(dados(i,2),2) > 1
57         if i>m
58             z(i) = ((sz*parameters(dados(i,2),2)+dados(i,1))-(avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos(dados(i,2))/(avg(dados(i,2),2)-1));
59         else
60             z(i) = (dados(i,1)-(avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos(dados(i,2))/(avg(dados(i,2),2)-1));
61         end

```

```

62     ts(i) = tinv(0.9973,(avg(dados(i,2),2)-1));
63     end
64 end
65 RSSS.z = z';
66 RSSS.r = (z < -ts' | z > ts')';
67 cont=0; i=1; ind=find(RSSS.r);
68 if isempty(ind)
69     cont=300;
70 else
71     for i=1:length(ind)
72         if ind(i)>100
73             cont=ind(i)-101;
74             break
75         else
76             if i==length(ind)
77                 cont=300;
78             end
79         end
80     end
81 end
82 RL1(end,2) = cont;
83 %% Self-Start standardized Shewhart CC with pooled variance - SSP
84 %fprintf('Analysing data according Quesenberry QCP... \n')
85 z = zeros(n,1); t = zeros(n,1);
86 avg = zeros(5,2); % Average at time i
87 sos = 0; % Sum Of Squares
88 for i=1:n
89     if i>m
90         avg(dados(i,2),1) = avg(dados(i,2),1) + (sz*parameters(dados(i,2),2)+dados(i,1));
91     else
92         avg(dados(i,2),1) = avg(dados(i,2),1) + dados(i,1);
93     end
94     avg(dados(i,2),2) = avg(dados(i,2),2) + 1;
95     sos = sos + (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))^2;
96     if avg(dados(i,2),2) > 1
97         if i>m
98             z(i) = ((sz*parameters(dados(i,2),2)+dados(i,1)) - (avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos/i-1);
99         else
100            z(i) = (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos/i-1);
101        end
102        tp(i) = tinv(0.9973,i-1);
103    end
104 end
105 RSSP.z = z';
106 RSSP.r = (z < -tp' | z > tp')';
107 cont=0; i=1; ind=find(RSSP.r);
108 if isempty(ind)
109     cont=300;
110 else
111     for i=1:length(ind)
112         if ind(i)>100
113             cont=ind(i)-101;
114             break
115         else
116             if i==length(ind)
117                 cont=300;
118             end
119         end
120     end
121 end
122 RL1(end,3) = cont;
123 %% Quesenberry - QCS
124 %fprintf('Analysing data according Quesenberry QCS... \n')
125 z = zeros(n,1); q = zeros(n,1);
126 avg = zeros(5,2); % Average at time i
127 sos = zeros(5,1); % Sum Of Squares
128 for i=1:n
129     if i>m

```

```

130     avg(dados(i,2),1) = avg(dados(i,2),1) + (sz*parameters(dados(i,2),2)+dados(i,1));
131     else
132     avg(dados(i,2),1) = avg(dados(i,2),1) + dados(i,1);
133     end
134     avg(dados(i,2),2) = avg(dados(i,2),2) + 1;
135     sos(dados(i,2)) = sos(dados(i,2)) + (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))^2;
136     if avg(dados(i,2),2) > 1
137     if i>m
138     z(i) = ((sz*parameters(dados(i,2),2)+dados(i,1)) - (avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos(dados(i,2))/(avg(dados(i,2),2)-1));
139     else
140     z(i) = (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos(dados(i,2))/(avg(dados(i,2),2)-1));
141     end
142     q(i) = norminv(tcdf(z(i),i-1));
143     end
144     end
145     RQCS.q = q';
146     RQCS.r = (q < -3 | q > 3)';
147     cont=0; i=1; ind=find(RQCS.r);
148     if isempty(ind)
149     cont=300;
150     else
151     for i=1:length(ind)
152     if ind(i)>100
153     cont=ind(i)-101;
154     break
155     else
156     if i==length(ind)
157     cont=300;
158     end
159     end
160     end
161     end
162     RL1(end,4) = cont;
163     %% Quesenberry - QCP
164     %fprintf('Analysing data according Quesenberry QCP... \n')
165     z = zeros(n,1); q = zeros(n,1);
166     avg = zeros(5,2); % Average at time i
167     sos = 0; % Sum Of Squares
168     for i=1:n
169     if i>m
170     avg(dados(i,2),1) = avg(dados(i,2),1) + (sz*parameters(dados(i,2),2)+dados(i,1));
171     else
172     avg(dados(i,2),1) = avg(dados(i,2),1) + dados(i,1);
173     end
174     avg(dados(i,2),2) = avg(dados(i,2),2) + 1;
175     sos = sos + (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))^2;
176     if avg(dados(i,2),2) > 1
177     if i>m
178     z(i) = ((sz*parameters(dados(i,2),2)+dados(i,1)) - (avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos/i-1);
179     else
180     z(i) = (dados(i,1) - (avg(dados(i,2),1)/avg(dados(i,2),2)))/sqrt(sos/i-1);
181     end
182     try
183     q(i) = norminv(tcdf(z(i),i-1)); continue
184     end
185     end
186     end
187     RQCP.q = q';
188     RQCP.r = (q < -3 | q > 3)';
189     cont=0; i=1; ind=find(RQCP.r);
190     if isempty(ind)
191     cont=300;
192     else
193     for i=1:length(ind)
194     if ind(i)>100

```

```

195     cont=ind(i)-101;
196     break
197 else
198     if i==length(ind)
199         cont=300;
200     end
201 end
202 end
203 end
204 RL1(end,5) = cont;
205 %% SKM
206 %fprintf('Analysing data according SKM... \n')
207 np=5;
208 a=round(parameters(:,1));
209 H = 1; % Arbitrary
210 Q = eye(np) * 1000000; % Larger number
211 S = eye(np);
212 % Vectors to save output
213 ey = [0];
214 K = zeros(np, 1);
215 X = zeros(n,np);
216 % Observation Matrix over time t(end)=num
217 for i=1:n
218     X(i,dados(i,2))=1;
219 end
220 for t=1:n-1
221     if t>m
222         foo = lkfilter( (sz*parameters(dados(t,2),2)+dados(t,1)), a(:,:,end), X(t,:), X(t
+1,:), H, Q, S(:,:,end));
223     else
224         foo = lkfilter( dados(t,1), a(:,:,end), X(t,:), X(t+1,:), H, Q, S(:,:,end));
225     end
226     ey(end+1) = foo.ey;
227     a(:,:,end+1) = foo.a;
228     K(:,:,end+1) = foo.K;
229     S(:,:,end+1) = foo.S;
230 end
231 uh=[]; uh(1,:)=a(:,1,1)';
232 AVG = a(:,1,1);
233 T = zeros(n,1); UCL = zeros(n,1);
234 for i=2:n
235     AVG = AVG + a(:,1,i);
236     uh(i,:)=a(:,1,i)';
237     Shat = cov(uh);
238     for k=1:np
239         if Shat(k,k)==0
240             Shat(k,k)=1;
241         end
242     end
243     invShat=Shat^-1;
244     for k=1:np
245         if Shat(k,k)==1
246             Shat(k,k)=0;
247         end
248     end
249     T(i) = (a(:,1,i)-(AVG/i))'*invShat*(a(:,1,i)-(AVG/i));
250     UCL1(i) = 18.20514; %41
251 end
252 RSKM1.T = T';
253 RSKM1.r = (T > UCL1)';
254 cont=0; i=1; ind=find(RSKM1.r);
255 if isempty(ind)
256     cont=300;
257 else
258     for i=1:length(ind)
259         if ind(i)>100
260             cont=ind(i)-101;
261             break
262         else

```

```

263     if i==length(ind)
264         cont=300;
265     end
266     end
267     end
268     end
269     RL1(end,6) = cont;
270     RL1(end,:);
271 end
272 %% ARL1 Results
273 N=length(RL1(:,1))-1;
274 RL1=RL1(2:N+1,:);
275 ARL1=mean(RL1) %
276 SRL1=zeros(1,6); %
277 for i=1:N %
278     SRL1(i,:)=(RL1(i,:)-ARL1).^2; %
279 end %
280 SARL1=(sum(SRL1)/(N-1)).^(1/2)
281 clearvars -except sz c scenario;
282 end
283 end

```


D Artigos Elaborados

Ao longo do trabalho, foram elaborados 5 artigos. Os títulos, resumos e palavras-chaves são apresentados no idioma original do trabalho. Detalhes da submissão também são apresentados bem como o *status* atual de cada um deles.

D.1 Statistical process control in highly customized environment

Abstract: The objective of this paper is to present the main quality control procedures to figure out how to solve the problem related to implementation of quality control tools in environments where current production strategies increased the necessity of flexibility. In this cases, quality characteristic used to be the same, but for different products, which means, it is one observation either for each product at each time in same process. Scenarios of highly customized productions are liable to small production lots, assumptions violations and inaccurate estimation of process parameters. This paper presents a discussion about negatives and positives aspects in: (i) model-based or residuals control charts, (ii) variance components monitoring, (iii) multivariate quality control, (iv) *profile* monitoring and (v) start-up or self-start procedures, and the feasibility of using them in a case study. Results show that the only approach that might be used is to model the multiple set up problem in one control chart defining the deviation from target at time t . On the other hand, new product or significant change in an old process in flexible environment could not be treated by methods proposed. It is important to consider multiple set up area open to new studies. SPC will require more sophisticated modeling and the incorporation of more engineering knowledge in order to find a better solution.

Keywords: Statistical process control, quality control implementation, highly customized scenarios, quality control for flexible production

Autores: Korzenowski, André Luis; Vidor, Gabriel; ten Caten, Carla S.

Dados da Submissão:

Journal: Quality and Reliability Engineering International (ISSN 0748-8017)

Classificação CAPES Engenharias III: B1

Status: O artigo foi concebido como texto de revisão mas apresentou resultados de um estudo de caso. O resultado da primeira avaliação encaminhada pelo editor informa que os avaliadores sugerem a inclusão de um estudo de simulação. O estudo de simulação foi efetuado para os resultados finais da tese, atendendo a demanda dos revisores. Estes resultados foram integrados ao artigo para nova submissão ao mesmo periódico. O artigo encontra-se em revisão final da versão em Inglês para re-submissão.

Previsão de re-submissão: Janeiro de 2013.

D.2 Theory and practice in phase I of control charts implementation

Abstract: Through a qualitative study, this article identifies the actions adopted by quality engineers in phase I of the implementation of control charts and it confronts these steps with what is suggested in literature. The main similarities and differences in the implementation in different companies are also identified. The study is based on interviews with quality engineers with previous experience in control chart implementation in the automotive sector in southern Brazil. It was evidenced that capability studies are performed in the first phase of the SPC implementation, conflicting with the one suggested by the literature. Verification of the suppositions of normality and independence, in turn, is not executed, even when control charts are implemented. Despite the possible violation of the suppositions, the interviewed technicians do not realize a raise in the number of false alarms and in the ARL.

Keywords: Statistical Process Control, Control Charts, Capability studies, Automotive sector

Autores: Korzenowski, André Luis; Werner, Liane; Ribeiro, José Luis; ten Caten, Carla S.

Dados da Submissão:

Journal: International Journal of Industrial Engineering: Theory, Applications and Practice (ISSN 1943-670X)

Classificação CAPES Engenharias III: B1

Data da primeira submissão: 28 de outubro de 2011

Status: O artigo ainda encontra-se esperando por designação. Contatos foram efetuados com os editores por e-mail sem retorno até o momento.

D.3 Mudança de Regime Markoviano Aplicado à Fase I do CEP em ambientes de múltiplos *setups*

Resumo: O controle estatístico do processo (CEP), através de suas ferramentas, tem como objetivo apontar quando o processo passa de um estado sob controle para um estado fora de controle. O CEP é dividido em duas fases: a fase de diagnóstico sobre a estrutura dos dados e a fase de controle do processo. Um dos objetivos principais da Fase I é estimar os valores dos parâmetros do processo. A estimação destes parâmetros fica prejudicada em um ambiente de múltiplos *setups*, pois as séries são mais curtas impedindo uma adequada inferência dos parâmetros. O objetivo deste artigo é propor a utilização do modelo de mudança de regime markoviano para diagnóstico na Fase I do CEP em ambientes de múltiplos *setups*. O procedimento de mudança de regime markoviano é capaz de estimar os parâmetros das séries em cada regime, levando em consideração a estrutura de variabilidade comum a todos os regimes a partir apenas da análise da variável de saída do processo.

Keywords: Controle Estatístico do Processo, Fase I, Mudança de Regime Markoviano

Autores: Korzenowski, André Luis; ten Caten, Carla S.

Dados da Submissão:

Journal: Produto & Produção (ISSN 1516-3660)

Classificação CAPES Engenharias III: B4

Data da primeira submissão: 05 de Junho de 2012

Status: Artigo em avaliação.

D.4 Predictive models with endogenous variables for quality control in customized scenarios affected by multiple setups

Abstract: The crescent demand for customized products has challenged industries with reduced lot sizes. As a result, frequent product model changing and short series of observable variables decreased the performance of many traditional tools used in process control. This paper proposes the use of endogenous variables in predictive models aimed at overcoming the multiple setup and short production runs problems found in customized manufacturing systems. The endogenous variables describe the type/model of manufactured products, while the response variable predicts a product quality characteristic. Three robust predictive models, ARIMA, structural model with stochastic parameters fitted by Kalman filter, and Partial Least Squares (PLS) regression, are tested in univariate time series relying on endogenous variables. The PLS modeling yielded better predictions in real manufacturing data, while the structural model led to more robust results in simulated data.

Keywords: ARIMA, Structural model, Kalman filter, PLS regression, Endogenous variables.

Autores: Korzenowski, André Luis; Anzanello, Michel J.; Portugal, Marcelo; ten Caten, Carla S.

Dados da Submissão:

Journal: Computers & Industrial Engineering (ISSN 0360-8352)

Classificação CAPES Engenharias III: A2

Data da primeira submissão: 27 de Julho de 2012

Status: Artigo passou pela primeira avaliação, sendo solicitadas alterações pelos revisores. Artigo encaminhado para segunda rodada de avaliação.

D.5 Quality control tools in customized systems: a comparative study

Abstract: The increase of menu choice options results in small lot sizes and consequently not enough data to estimate process parameters to monitoring quality characteristic in customized systems. The question is if it is possible to implement quality tools in customized and flexible customized production systems? Literature presents a non applicable in this problem nominated state-of-art procedure. Adaptations of the self-start Shewhart control chart and Quesenberry case IV control chart are proposed besides a Self-Start Kalman based multivariate control chart for multiple setup system. The objective of this study is measuring the performance of these five different approaches to monitoring the quality in customized systems scenarios subject to assumptions violation. Also, compare these proposed procedures with a nominated state-of-art control chart with known parameters. Analysis was performed in a real case and in a simulation study. Results show that the normality violation assumption is the one that more deteriorate the control charts performance. Independence and homocedastic assumptions violation effects are not significant at the 5% level, according to the analysis of variance performed. The proposed procedures get similar results to the non applicable state-of-art nominated procedure.

Keywords: Customized Systems, Quality Control, Control Charts Performance

Autores: Korzenowski, André Luis; ten Caten, Carla S.

Status: O artigo encontra-se em revisão final da versão em Inglês.

Previsão de submissão: Janeiro de 2013.

Journal: International Journal of Production Economics (ISSN 0925-5273)

Classificação CAPES Engenharias III: A1