

MINISTÉRIO DA DEFESA
EXÉRCITO BRASILEIRO
DEPARTAMENTO DE CIÊNCIA E TECNOLOGIA
INSTITUTO MILITAR DE ENGENHARIA
CURSO DE MESTRADO EM ENGENHARIA MECÂNICA

JOSIANE DA SILVA JESUS

**ESTUDO DA PROPAGAÇÃO DE ERROS EM PROCESSOS MECÂNICOS
MULTIVARIADOS CORRELACIONADOS**

Rio de Janeiro

2017

INSTITUTO MILITAR DE ENGENHARIA

JOSIANE DA SILVA JESUS

**ESTUDO DA PROPAGAÇÃO DE ERROS EM PROCESSOS
MECÂNICOS MULTIVARIADOS CORRELACIONADOS**

Dissertação de Mestrado apresentada ao Curso de Mestrado em Engenharia Mecânica do Instituto Militar de Engenharia, como requisito parcial para a obtenção do título de Mestre em Ciências em Engenharia Mecânica.

Orientador: Maj Paulo Henrique Coelho Maranhão - D.Sc.

Rio de Janeiro

2017

c2017

INSTITUTO MILITAR DE ENGENHARIA

Praça General Tibúrcio, 80 – Praia Vermelha

Rio de Janeiro – RJ CEP: 22290-270

Este exemplar é de propriedade do Instituto Militar de Engenharia, que poderá incluí-lo em base de dados, armazenar em computador, microfilmar ou adotar qualquer forma de arquivamento.

É permitida a menção, reprodução parcial ou integral e a transmissão entre bibliotecas deste trabalho, sem modificação de seu texto, em qualquer meio que esteja ou venha a ser fixado, para pesquisa acadêmica, comentários e citações, desde que sem finalidade comercial e que seja feita a referência bibliográfica completa.

Os conceitos expressos neste trabalho são de responsabilidade do(s) autores e do(s) orientadores.

620.1	Jesus, Josiane da Silva
J58e	Estudo da propagação de erros em processos mecânicos multivariados correlacionados / Josiane da Silva Jesus; orientada por Paulo Henrique Coelho Maranhão – Rio de Janeiro: Instituto Militar de Engenharia, 2017.
	106p.: il.
	Dissertação (Mestrado) – Instituto Militar de Engenharia, Rio de Janeiro, 2017.
	1. Curso de Engenharia Mecânica – teses e dissertações. 2. Propagação de erros. 2. Processos mecânicos. I. Maranhão, Paulo Henrique Coelho. II. Instituto Militar de Engenharia.

INSTITUTO MILITAR DE ENGENHARIA

JOSIANE DA SILVA JESUS

**ESTUDO DA PROPAGAÇÃO DE ERROS EM PROCESSOS
MECÂNICOS MULTIVARIADOS CORRELACIONADOS**

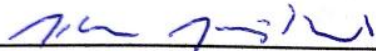
Dissertação de Mestrado apresentada ao Curso de Mestrado em Engenharia Mecânica do Instituto Militar de Engenharia, como requisito parcial para a obtenção do título de Mestre em Ciências em Engenharia Mecânica.

Orientador: Maj Paulo Henrique Coelho Maranhão – D.Sc.

Aprovada em 01 de Dezembro de 2017 pela seguinte Banca Examinadora:



Maj Paulo Henrique Coelho Maranhão - D.Sc. do IME – Presidente.



Maj Achille Arantes Bassi - D.Sc. do IME.



Prof. Bruno Francisco Teixeira Simões - D.Sc. da UNIRIO.

Rio de Janeiro

2017

AGRADECIMENTOS

Primeiramente, agradeço a Deus pelo dom da vida, por estar sempre presente em minha caminhada, me dando forças para superar obstáculos e para continuar acreditando que todos os meus sonhos são possíveis. À Virgem Santíssima por interceder por mim junto ao vosso filho Jesus Cristo e por todas as graças alcançadas.

Aos meus pais, Berenice e José Dimas, pelo amor, carinho, apoio, pela educação, pelos ensinamentos de valores éticos e morais, por serem a minha base e grandes incentivadores. Aos meus familiares que torceram pelo meu sucesso, em especial minha vó Zilda e minha prima Geniane.

Ao meu amor e melhor amigo Roni pelo carinho, pela compreensão, paciência, pelas palavras de incentivo e de ânimo, por sempre acreditar na minha capacidade. Aos amigos antigos e às amigas que foram feitas durante este período, parcerias de muito estudo e dedicação, em especial, Patrícia e Anna Rafaela.

Em especial ao meu orientador Maj Maranhão pela sua disponibilidade, paciência, atenção, conselhos, dicas e conhecimentos transmitidos. Á todos os professores pelos conhecimentos transmitidos e funcionários da Seção de Pós-graduação em Engenharia Mecânica pela atenção. Também, agradeço à banca examinadora pela sua disponibilidade.

“As falhas são o combustível para o sucesso”.

ISHIKAWA

SUMÁRIO

LISTA DE ILUSTRAÇÕES	8
LISTA DE TABELAS	11
LISTA DE ABREVIATURAS E SÍMBOLOS.....	16
LISTA DE SIGLAS	18
1 INTRODUÇÃO	19
1.1 Estado da Arte	20
1.2 Tema e Motivação.....	25
1.3 Objetivos	25
1.4 Organização do Trabalho	26
2 FUNDAMENTAÇÃO TEÓRICA	27
2.1 Modelo Autoregressivo de Propagação.....	27
2.2 Análise de Componentes Principais.....	34
2.3 Modelo Autoregressivo nas Componentes Principais.....	38
2.4 Análise de Agrupamentos	39
3 METODOLOGIA.....	46
3.1 Cenários.....	46
3.2 Processo Produtivo de Veículos.....	46
4 RESULTADOS	48
4.1 Modelos Autoregressivos para os Cenários	48
4.1.1 Modelos Autoregressivos nas Componentes Principais - Cenário 1	49
4.1.2 Modelos Autoregressivos nas Componentes Principais - Cenário 2	58

4.1.3	Modelos Autoregressivos nas Componentes Principais - Cenário 3	67
4.2	Estudo De Caso: Modelos Autoregressivos no Processo Produtivo de Veículos	75
5	CONCLUSÃO	87
6	REFERÊNCIAS BIBLIOGRÁFICAS.....	89
7	ANEXOS	92
7.1	Anexo 1	93
7.2	Anexo 2.	105

LISTA DE ILUSTRAÇÕES

FIG.2. 1 Exemplo de um Histograma dos Resíduos.	31
FIG.2. 2 Exemplo de um Gráfico Q-Q plot dos resíduos.....	31
FIG.2. 3 Exemplo de um Gráfico de Resíduos x Valores ajustados.	32
FIG.2. 4 Exemplo de um Gráfico de Resíduos x Ordem de coleta.	32
FIG.2. 5 Esquema do método ACP.	35
FIG.2. 6 Etapas para Análise de Agrupamentos.	41
FIG.2. 7 Exemplo Dendrograma Ligação Completa.....	42
FIG.2. 8 Exemplo Dendrograma Ligação por Média.....	42
FIG.2. 9 Exemplo Dendrograma Ligação por Centroide.	43
FIG.3. 1 Representação das variáveis em cada estágio	45
FIG.3. 2 Cenário 1.....	45
FIG.3. 3 Cenário 2	45
FIG.3. 4 Cenário 3.....	46
FIG.3. 5 Representação das componentes principais em cada estágio	46
FIG.3. 6 Carro analisado (Gaio e Sá, 2004).	47
FIG.4. 1 Propagação de Erros – Caso 1 - Cenário 1.	51
FIG.4. 2 Análise de Resíduos CP1 – Caso 1 - Variância 1 – Cenário 1.	52
FIG.4. 3 Análise de Resíduos CP1 – Caso 1 - Variância 3 – Cenário 1.	52

FIG.4. 4 Propagação de Erros – Caso 2 – Cenário 1.....	54
FIG.4. 5 Análise de Resíduos CP1 – Caso 2 - Variância 1 – Cenário 1.	54
FIG.4. 6 Análise de Resíduos CP1 – Caso 2 - Variância 3 – Cenário 1.	55
FIG.4. 7 Propagação de Erros – Caso 3 – Cenário 1.....	56
FIG.4. 8 Análise de Resíduos CP1 – Caso 3 - Variância 1 - Cenário 1.....	57
FIG.4. 9 Análise de Resíduos CP1 – Caso 3 - Variância 3 - Cenário 1.....	57
FIG.4. 10 Propagação de Erros – Caso 1- Cenário 2.	60
FIG.4. 11 Análise de Resíduos CP1 – Caso 1 - Variância 1– Cenário 2.	61
FIG.4. 12 Análise de Resíduos CP1 – Caso 1- Variância 3 – Cenário 2.	61
FIG.4. 13 Propagação de Erros – Caso 2 – Cenário 2.....	63
FIG.4. 14 Análise de Resíduos CP1 – Caso 2 - Variância 1 – Cenário 2.	63
FIG.4. 15 Análise de Resíduos CP1 – Caso 2 - Variância 3 – Cenário 2.	64
FIG.4. 16 Propagação de Erros – Caso 3 – Cenário 2.....	65
FIG.4. 17 Análise de Resíduos CP1 - Caso 3 - Cenário 2.....	66
FIG.4. 18 Propagação de Erros – Caso 1 - Cenário 3.	69
FIG.4. 19 Análise de Resíduos CP1 – Caso 1- Variância 1 – Cenário 3.	69
FIG.4. 20 Análise de Resíduos CP1 – Caso 1 - Variância 3 – Cenário 3.	70
FIG.4. 21 Propagação de Erros – Caso 2 – Cenário 3.....	71
FIG.4. 22 Análise de Resíduos CP1 – Caso 2 - Variância 1 – Cenário 3.	72

FIG.4. 23 Análise de Resíduos CP1 – Caso 2 - Variância 3 – Cenário 3.	72
FIG.4. 24 Propagação de Erros – Caso 3 – Cenário 3.....	74
FIG.4. 25 Análise de Resíduos – Caso 3 - Variância 3 – Cenário 3.	74
FIG.4. 26 Dendrograma Ligação Média - Carro.....	75
FIG.4. 27 Propagação de Erros – Grupo 1 – Carro.....	78
FIG.4. 28 Análise de Resíduos - Grupo 1 – Carro.	78
FIG.4. 29 Propagação de Erros – Grupo 2 – Carro.....	80
FIG.4. 30 Análise de Resíduos - Grupo 2 – Carro.	80
FIG.4. 31 Propagação da Variância – Grupo 3 – Carro.	81
FIG.4. 32 Análise de Resíduos - Grupo 3 – Carro.	82
FIG.4. 33 Propagação de Erros – Grupo 4 – Carro.....	83
FIG.4. 34 Propagação de Erros – Pontos 5 e 7 – Carro.....	85
FIG.4. 35 Análise de Resíduos Pontos 5 e 7 – Carro.....	86

LISTA DE TABELAS

TAB.2. 1	Resumo dos principais Métodos de Agrupamentos.	41
TAB.4. 1	Resumo dos Cenários.	48
TAB.4. 2	Percentual total da variância explicada pelas CPs Cenário 1 Estágios 1.	49
TAB.4. 3	Percentual total da variância explicada pelas CPs Cenário 1 Estágios 2.	49
TAB.4. 4	Parâmetros Modelo de Propagação – Caso 1 - Cenário 1.	50
TAB.4. 5	Variâncias em Estágios – Caso 1 – Cenário 1.	51
TAB.4. 6	Parâmetros Modelo de Propagação – Caso 2 – Cenário 1.	53
TAB.4. 7	Variâncias em Estágios – Caso 2 – Cenário 1.	53
TAB.4. 8	Parâmetros Modelo de Propagação – Caso 3 – Cenário 1.	55
TAB.4. 9	Variâncias em Estágios – Caso 3 – Cenário 1.	56
TAB.4. 10	Percentual total da variância explicada pelas CPs Cenário 2 Estágios 1.	58
TAB.4. 11	Percentual total da variância explicada pelas CPs Cenário 2 Estágios 2.	58
TAB.4. 12	Parâmetros Modelo de Propagação – Caso 1 – Cenário 2.	59
TAB.4. 13	Variâncias em Estágios – Caso 1 – Cenário 2.	60
TAB.4. 14	Parâmetros Modelo de Propagação – Caso 2 – Cenário 2.	62
TAB.4. 15	Variâncias em Estágios – Caso 2 – Cenário 2.	62
TAB.4. 16	Parâmetros Modelo de Propagação – Caso 3 – Cenário 2.	64

TAB.4. 17 Variâncias em Estágios – Caso 3 – Cenário 2.....	65
TAB.4. 18 Percentual total da variância explicada pelas CPs Cenário 3 Estágios 1.	67
TAB.4. 19 Percentual total da variância explicada pelas CPs Cenário 3 Estágios 2.	67
TAB.4. 20 Parâmetros Modelo de Propagação – Caso 1 – Cenário 3.	68
TAB.4. 21 Variâncias em Estágios – Caso 1 – Cenário 3.....	68
TAB.4. 22 Parâmetros Modelo de Propagação – Caso 2 – Cenário 3.	70
TAB.4. 23 Variâncias em Estágios – Caso 2 – Cenário 3.....	71
TAB.4. 24 Parâmetros Modelo de Propagação – Caso 3 – Cenário 3.	73
TAB.4. 25 Variâncias em Estágios – Caso 3 – Cenário 3.....	73
TAB.4. 26 Agrupamentos dos dados - Carro.	76
TAB.4. 27 Percentual da Variância explicada pelas CP's - Carro.	76
TAB.4. 28 Parâmetros Modelo de Propagação – Grupo 1 – Carro.....	77
TAB.4. 29 Variâncias em Estágios – Grupo 1 – Carro.	77
TAB.4. 30 Parâmetros Modelo de Propagação – Grupo 2 – Carro.....	79
TAB.4. 31 Variâncias em Estágios – Grupo 2 – Carro.	79
TAB.4. 32 Parâmetros Modelo de Propagação – Grupo 3 – Carro.....	81
TAB.4. 33 Variâncias em Estágios – Grupo 3 – Carro.	81
TAB.4. 34 Parâmetros Modelo de Propagação – Grupo 4 – Carro.....	82

TAB.4. 35 Variâncias em Estágios – Grupo 4 – Carro.....	83
TAB.4. 36 Parâmetros Modelo de Propagação – Grupo 5 – Carro.....	84
TAB.4. 37 Percentual da Variância explicada – Pontos 5 e 7 – Carro.....	84
TAB.4. 38 Parâmetros do Modelo de Propagação – Pontos 5 e 7 – Carro.....	85
TAB.4. 39 Variâncias em Estágios – Pontos 5 e 7 – Carro.....	85

LISTA DE ABREVIATURAS E SÍMBOLOS

ABREVIATURAS

Y_i	- distribuição avaliada
\hat{Y}_i	- valor y estimado
\bar{Y}_i	- média
k	- número de equações
R^2	- coeficiente de determinação
A^2, S	- estatísticas de teste de Anderson-Darling
X, Y	- variáveis
H_0	- hipótese nula
H_1	- hipótese alternativa
n, N	- quantidade de elementos da amostra
Z_i	- variável padronizada
$S_{ij}, S_{i-1,i}$	- covariâncias estimadas
S_{ii}, S_{jj}	- variâncias estimadas
$Var(Y_i)$	- variância total da distribuição avaliada no i-ésimo estágio
r_i	- resíduo
RP	- resíduo padronizado
$S(X, Y), R_{ij}$	- coeficiente de correlação ou de Pearson
$P_{p \times p}$	- matriz de correlação
CP_j	- j-ésima componente principal
CP_{ji}	- j-ésima componente principal no i-ésimo estágio
CP_i	- Componente principal no i-ésimo estágio

SÍMBOLOS

β_0	- parâmetro de adição da variância ou coeficiente linear
β_i	- parâmetro de propagação da variância ou coeficiente angular
μ_i	- média

σ_i^2	- variância
$\sigma_{i,A}^2$	- variância adicionada na etapa atual
$\sigma_{i,e}^2$	- variância dos erros aleatórios
σ_{i-1}^2	- variância no estágio anterior
$N(0, \sigma_{iA}^2)$	- distribuição normal com média zero e variância σ_{iA}^2
β_i^2	- coeficiente responsável pela transmissão da variabilidade
ε_i	- ruídos
ρ_{Y_i, X_k}	- coeficiente de Pearson ou de correlação
$\Sigma_{p \times p}$	- matriz de covariância
λ_i	- autovalores
e_i	- autovetores normalizados
$F_{\alpha, p, mn-m-p+1}$	- distribuição F de Snedecor

LISTA DE SIGLAS

IME	Instituto Militar de Engenharia
AR	Modelo Autoregressivo
AD	Anderson-Darling
ACP	Análise de Componentes Principais
CP	Componente Principal
SQE	Soma dos Quadrados Explicada
SQT	Soma dos Quadrados Total
SQR	Soma dos Quadrados dos Resíduos

RESUMO

A maioria dos processos produtivos consiste de um número significativo de estágios. Assim, modelar a variação das características de qualidade de produtos é uma estratégia fundamental para reduzir variação na produção e, por conseguinte, reduzir os custos das empresas responsáveis pelo processo. A ideia do estudo da transmissão da variação em processos com múltiplos estágios é identificar as fontes de variação em cada estágio no intuito de agir preventivamente em casos de erros no processo, ou seja, dado que o processo apresentou problemas, como identificar exatamente em qual estágio ocorreu. Nesse sentido, este trabalho propõe um modelo para avaliar a propagação da variância em processos multivariados correlacionados em estágios. O estudo foi realizado por meio de cenários e de um caso real.

ABSTRACT

Most industrial processes consist of a significant number of stages. Thus, modeling and monitoring the variation of the quality characteristics of products is a key to reducing variation in production and therefore reduce the costs of company responsible for the strategy process. The idea of studying the propagation of variation in multi-stage process is to identify the sources of variation in each stage in order to take preventive action in cases of errors in the process, in other words, since the case presented problems, how to identify exactly which stage occurred. In this sense, this work proposes a model to evaluate the propagation of variance in multivariate correlated processes in stages. The study was carried out through scenarios and real case.

1 INTRODUÇÃO

O mundo atual, competitivo e globalizado, provoca uma busca constante por qualidade, eficiência, diminuição de custos e maior retorno financeiro em toda e qualquer organização. Esse conjunto de objetivos se transformou em necessidade básica para sobrevivência de empresas e indústrias.

Um produto ou serviço pode ser afetado negativamente pela variabilidade durante o seu processo de fabricação ou execução. Qualquer diferença entre o produto obtido e o produto desejado é denominada de erro. Além disso, grande parte dos processos produtivos é composta por dois ou mais estágios. Em geral, observa-se que a variabilidade de um processo em uma etapa posterior ao primeiro estágio divide-se em duas partes: a primeira, adicionada pela própria etapa e, a segunda, transmitida pela a etapa anterior. Sendo assim, o estudo da contribuição de cada etapa para a variância final é de suma importância para a melhoria do processo. Assim, o desenvolvimento de estudos sobre a propagação de erros surge como uma ferramenta imprescindível para qualquer organização, já que uma vantagem imediata do monitoramento da variabilidade é a redução do custo.

Para melhor avaliar um processo, deve-se levar em consideração mais de uma variável de interesse. Porém, não é raro ocorrer casos em que as variáveis de interesse mensuradas em cada estágio também tenham um grau elevado de correlação e nesse caso, técnicas estatísticas multivariadas são necessárias para o desenvolvimento de métodos e modelos que consigam avaliar a propagação da variabilidade.

Portanto, a modelagem da propagação de erros permite identificar qual etapa do processo é a responsável pela maior variabilidade do mesmo, sendo utilizado como suporte para a tomada de ações corretivas e preventivas no processo.

1.1 ESTADO DA ARTE

O estudo sobre a propagação de erros em processos multivariados em múltiplos estágios está presente em um número cada vez maior de trabalhos, evidenciando assim a sua relevância ao longo do tempo.

Os primeiros estudos sobre o tema foram realizados em meados dos anos noventa. Dessa forma, Ceglarek (1998) estudou a variabilidade em um sistema flexível de montagem de portas de veículos ainda na fase de projeto através de layout fornecido pelo programa CAD. A metodologia utilizada foi composta por três passos: modelar a variação de peças pré-montadas, modelar o sistema de montagem de forma a corrigir os erros e a evolução da capacidade do sistema em compensar a variabilidade das peças. Para minimizar a folga entre a porta e o chassi, foi usado o sistema NF & P (Net Form e Pierce) capaz de corrigir os erros na montagem através de sensores de posição e orientação na porta, garantindo assim qualidade ao produto. A expansão da metodologia incluiria dados produtivos e assim seria necessária a técnica de análise de componentes principais, que modela a estrutura de variabilidade do processo por meio de uma transformação linear das n variáveis observadas.

Já, Lawless, Mackay e Robinson (1999) propuseram o modelo autoregressivo de ordem 1 (AR1) para estimar a variação em estágios de um processo produtivo em relação a uma única variável de interesse, identificando assim qual etapa produtiva contribuía significativamente para a maior variabilidade do processo. O estudo foi realizado com dados da produção de pistões, componentes de motores, onde foi concluído que o primeiro estágio tem maior participação na variabilidade do produto final. Agrawal, Lawless e Mackay (1999), avaliaram como os erros nas medições podem comprometer processos multi-estágios. Já que o controle e a redução da variabilidade são cruciais para que os produtos cumpram certas especificações nas características de qualidade de interesse. Para isso, desenvolveram uma simples técnica de estimativas baseada na máxima verossimilhança que funciona bem em casos com 3 etapas produtivas.

Posteriormente, Huang, Zhou e Shi (2002) se basearam em um modelo espaço de estados, baseado nas informações do projeto do produto e processo, com intuito de avaliar a propagação da variação em processo de usinagem, também utilizaram o conceito virtual de operação para isolar as falhas e determinar as causas das mesmas. O modelo espaço de

estados englobou quatro elementos responsáveis pela variabilidade: variação na superfície usinada, covariância entre operações, ruídos e variação das máquinas. Nesse trabalho foi observado que os desvios podem ser atenuados evitando a correlação entre as operações. A operação virtual serviu para diferenciar a variabilidade gerada pela etapa anterior e a dada pelos desvios operacionais gerados pela etapa atual, esse isolamento de falhas foi possível a partir da ocorrência ou não de falhas na operação atual. A modelagem por espaço de estados e a operação virtual serviram para analisar casos em que não existam dados históricos de medição.

Camelio, Hu e Zhong (2004) modelaram o processo de usinagem através de uma matriz homogênea de transformação, cujos elementos representam a diferença espacial entre dois sistemas de coordenadas, e método de análise de componentes designados (DCA), o qual é capaz de identificar falhas de fixação simultâneas em chapas metálicas e não considera qualquer tipo de interação entre elas e o processo de fabricação. O principal objetivo desse artigo foi desenvolver um método sistemático para isolar as falhas de fixação, garantindo maior qualidade ao processo. O método DCA é similar ao método das Componentes Principais, a diferença encontra-se no fato de que os componentes designados não são necessariamente independentes, conhecendo a contribuição da variância de cada um dos componentes designados e a correlação entre eles, foi possível identificar a causa das falhas. Concluíram que falhas dependentes são mais fáceis de diagnosticar do que as independentes. Gaio e Sá (2004) implementaram a metodologia Seis Sigma em um processo produtivo de automóveis, com o objetivo de reduzir os desvios gerados, por meio da análise da folga presente nas portas traseiras de 17 veículos em dois estágios de fabricação, Chaparia e Montagem.

Camelio, Hu e Ceglarek (2004) utilizaram um algoritmo de otimização que combina elementos finitos e programação não linear para determinar a melhor posição na fixação de componentes em um processo de montagem, de forma a minimizar a variabilidade do mesmo. Com os elementos finitos foi possível construir a matriz de sensibilidade que estabelece uma relação linear entre os desvios de entrada com os de saída. Concluíram que essas técnicas são válidas para detectar pequenas deformações e que as variações podem ser reduzidas a partir de posições ótimas das peças, devido ao uso do algoritmo.

No ano seguinte, Liao e Wang (2005) desenvolveram um método relacionado à dimensão da superfície de corpos não rígidos em um processo de montagem. A metodologia

proposta foi feita a partir da geometria fractal, a qual caracteriza fenômenos espaciais ou temporais contínuos de corpos não rígidos, e do método de elementos finitos, com o intuito de analisar a variação na superfície micro geométrica dos componentes desses corpos. A geometria fractal foi expressa por uma função chamada de Weierstrass-Mandelbrot, capaz de representar as características da superfície micro geométrica das peças utilizadas no processo de montagem. O método de elementos finitos foi usado para analisar a deformação dos componentes do sistema produtivo. Essa variação merece atenção em processos de montagem de alta precisão.

Zhang, Djurdjanovic e Ni (2007) apresentaram a metodologia do fluxo de variação baseada na descrição do projeto (CAD) e do processo. Essa metodologia utiliza a modelagem espaço de estados com o objetivo de estabelecer relação linear entre os erros e suas causas, facilitando a análise de sensibilidade para verificar o grau de impacto dos desvios na qualidade de cilindros automotivos e estabelecer a otimização do processo por meio de seleção ótima da localização de medidores e sensores na fixação de cilindros automotivos a fim de minimizá-los. O estudo da decomposição do erro auxilia engenheiros a identificar qual estágio contribui mais para a variabilidade do processo.

Yang, Popov e Mcwilliam (2012) identificaram que a variação pode ser controlada pelo tipo de processo de montagem. A minimização da propagação de erros pode ser feita avaliando estágio por estágio do processo ou minimizando o somatório ao quadrado das variações em todas as fases. Por exemplo, na montagem de componentes cilíndricos podem-se considerar dois métodos de construção: reta e paralela. Nota-se que a variação radial e erros angulares são minimizados de acordo com o tipo de montagem utilizada, conforme constatado nos resultados das simulações Monte Carlo. Em caso de montagem reta, a variabilidade radial é diminuída enquanto que na montagem em paralelo, os erros angulares são reduzidos.

Wang *et al.* (2012) realizaram o controle de erros do processo de usinagem através de um modelo matemático linear que contém a propagação do erro de operações anteriores, dados da operação atual e desvios das máquinas e ferramentas. O gráfico de controle T^2 de Hotelling também foi utilizado para identificar se a operação está ou não sob controle. Esse conjunto de técnicas mostrou-se eficaz ao detectar pontos que estavam fora dos limites de controle do gráfico, sinalizando que o processo estava fora de controle, porém essas ferramentas não foram capazes de identificar as possíveis causas dos erros, pois não foi feita a decomposição de T^2 de Hotelling.

Yang *et al.* (2013) consideraram uma abordagem probabilística para analisar a propagação da variação em processos mecânicos de montagem. Para isso, foram criados diferentes cenários para controlar a variabilidade: direto (sem otimização), melhor (minimização a cada rotação de uma peça) e pior (desvio maximizado). Os resultados dessa abordagem propõem que os itens sejam montados seguindo orientações que reduzem a excentricidade ou desvio do eixo central da peça.

Arif, Suryanna e Hussin (2013) desenvolveram um modelo de previsão de qualidade (CQPM), capaz de lidar com variáveis complexas presentes em sistemas multi-estágios de fabricação, através de técnicas de análise de dados como a Análise de Componentes Principais (ACP), que extrai informações de diversas variáveis inter-relacionadas e as expressa em um novo conjunto de variáveis ortogonais, o algoritmo de Dichotomiser 3 (ID3), o qual transforma as variáveis quantitativas em qualitativas. O uso da ACP foi importante para reduzir as 40 variáveis analisadas em 22. Para validação do modelo, foi feito um estudo de caso com dados da produção de semicondutores, comparando-o com os seguintes métodos: abordagem de um único ponto com o algoritmo ID3 e com ACP+ID3. A abordagem de um único ponto considera que cada estágio produtivo tem um efeito independente para o nível de qualidade do processo e é usada em linhas inteiras de fabricação. Concluíram que o modelo de previsão de qualidade proposto apresentou melhor desempenho em relação aos outros.

Han e Wang (2013) mostraram que o controle de um processo é feito otimizando cada fase do mesmo, ou seja, minimizando a transferência de desvios entre os diferentes estágios de fabricação. Para isso, foi necessária uma coordenação eficaz, capaz de dividir a produção em lotes com características semelhantes. Esse agrupamento foi feito para cada estágio de uma manufatura e o controlador R2R (Run-to-Run) eliminou os desvios presentes, fornecendo qualidade ao produto final. O R2R foi desenvolvido para detectar e corrigir os desvios de um processo, o principal objetivo desse controlador é minimizar os somatórios de variação dentro do lote e entre lotes.

Mais recentemente, Liu *et al.* (2015) aplicaram o controle em produtos complexos, como robôs, por meio da teoria clássica de controle e de conceitos da cinemática (matrizes de transformação) para a localização espacial das peças e acessórios do produto. Com essa teoria, foi possível determinar a propagação da variância em cada estágio do processo, utilizando as relações entre dados das peças, máquinas e ferramentas. Os resultados revelaram bom desempenho do modelo.

Pirhooshyaran e Niaki (2015) utilizaram o gráfico de controle multivariado de médias móveis ponderadas para monitorar um processo de variáveis autocorrelacionadas. Antes da construção do gráfico, foi necessário modelar o processo através de equações lineares de espaço de estados, dividir dados em subgrupos, calcular média e matriz de covariância. O gráfico mostrou-se eficiente na identificação de falhas, porém ele perdeu eficiência quando houve aumento no número de etapas produtivas.

Du *et al.* (2015) elaboraram um modelo 3D de propagação da variação aplicado em fabricação de peças rotativas, já que os modelos existentes unidimensionais baseados em equações de espaço de estados não são eficazes para retratar a variação em sistemas de referências diferentes. O modelo proposto utiliza quatro sistemas de coordenadas e identifica quatro tipos de erros (de alocação de peças, de medições, de máquinas e entre estágios), conduzindo uma análise sobre desvios nas medições e no processo. Essa metodologia foi satisfatória e pode ser aplicada em outras situações.

Souza e Ventura (2015) utilizaram o modelo proposto por Lawless, Mackay e Robinson (1999) para avaliar a transmissão da variabilidade em três processos mecânicos, estampagem profunda, montagem do painel interno de porta lateral de veículos e chaparia e montagem de portas traseiras de veículos. Os dados da estampagem profunda foram gerados aleatoriamente para cada uma das quatro etapas do processo. Neste caso, o modelo foi validado pela ordenação dos dados a partir de cada etapa. A porta lateral foi analisada em 11 etapas, nas quais a indução foi a etapa responsável pela maior variabilidade do processo. Já para a porta traseira avaliada na Chaparia e Montagem, o modelo foi aplicado somente em um dos 12 pontos de análise de folga, tendo como resultado que a Montagem é a etapa mais relevante.

Ao longo dos últimos anos, percebe-se um interesse constante sobre a variabilidade em processos produtivos. O acúmulo de erros ao longo dos diferentes estágios de fabricação pode ser extremamente prejudicial ao produto final. Assim, constatou-se um fato comum a todos os trabalhos apresentados aqui: a existência de propagação de erros ao longo de diferentes processos. Logo, o estudo sobre esse assunto ainda é bastante relevante, tanto para a academia como para empresas preocupadas com a qualidade de seus produtos e processos.

1.2 TEMA E MOTIVAÇÃO

Atualmente, uma parte considerável dos processos produtivos contém dois ou mais estágios. Assim a qualidade final de um produto está relacionada à propagação de erros nos diversos estágios. Além disso, não é raro que as variáveis de interesse desses processos sejam correlacionadas, de forma que um erro em uma das variáveis afeta todas as outras e em consequência, todo o processo é afetado.

Uma estratégia fundamental para reduzir a variância de processos com múltiplos estágios é verificar qual a etapa do processo é responsável pela maior propagação de erros, de forma que se possa agir preventivamente nessa etapa. Assim, o estudo da contribuição de cada etapa para a variância total é de suma importância para a melhoria do processo. Essa dissertação tem como tema principal o estudo da propagação de erros em processos mecânicos multivariados em estágios correlacionados. O estudo proposto propõe uma técnica relativamente fácil de implementar que foi aplicada em dois estudos de caso, o primeiro trata de cenários de processos com dois estágios, cujas variáveis estão correlacionadas entre si, o segundo é sobre duas etapas de um processo de fabricação de automóveis.

1.3 OBJETIVOS

O principal objetivo desse trabalho é desenvolver um estudo sobre a propagação de erros em processos mecânicos multivariados em estágios, cujas variáveis de interesse estejam correlacionadas.

O objetivo específico dessa dissertação é:

- propor um modelo para quantificar e avaliar a transmissão da variabilidade em processos multivariados em estágios;

1.4 ORGANIZAÇÃO DO TRABALHO

O trabalho proposto encontra-se organizado em cinco capítulos, que são descritos a seguir:

- O primeiro capítulo apresenta a introdução do tema, destacando a sua importância e ressaltando como diversos trabalhos abordaram o assunto. Além disso, são apresentados, a motivação e seus objetivos;
- No segundo capítulo são tratados os principais fundamentos teóricos utilizados neste trabalho, tais como, o Modelo Autoregressivo, os métodos de Análise de Componentes Principais e Análise de Agrupamentos, bem como, o desenvolvimento do Modelo Autoregressivo nas componentes principais, método proposto para avaliação da propagação em processos multivariados correlacionados em estágio;
- Já o terceiro capítulo descreve a metodologia que foi aplicada nos cenários e no processo real;
- No quarto capítulo é realizada a análise de resultados;
- Por fim, o quinto capítulo contém a conclusão e sugestões de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentadas as principais técnicas utilizadas nesse trabalho, a saber: Modelo Autoregressivo de Propagação, Análise de Componentes Principais, Modelo Autoregressivo nas Componentes Principais e Análise de Agrupamentos.

2.1 MODELO AUTOREGRESSIVO DE PROPAGAÇÃO

Uma das estratégias para reduzir a variância em processos produtivos é identificar as causas de tais variações. Através dessa identificação, é possível obter melhorias tanto em processos atuais quanto futuros. Em processos multi-estágios, pode haver etapas nas quais surgem desvios significativos, e outras etapas que absorvem esses desvios. Por isso, é importante entender como ocorre a transmissão de erros entre os vários estágios de um processo.

O modelo Autoregressivo (AR) de propagação é uma equação de ordem um, na qual o valor atual está fortemente relacionado com o imediatamente anterior, ou seja, há uma correlação na primeira defasagem, entre Y_i e Y_{i-1} . Isso também contribui para que as previsões sejam obtidas apenas um período a frente. O AR(1) é bastante utilizado na identificação de falhas devido a sua característica preditora, ou seja, é possível comparar os valores encontrados pelo modelo com os dados reais. Os métodos de previsão baseados nos modelos autoregressivos são utilizados em diversas áreas, não somente na identificação de falhas.

Esse modelo foi proposto por Lawless, Mackay e Robinson (1999), no qual uma observação Y é calculada no estágio i , conforme equação a seguir:

$$Y_i = \beta_0 + \beta_i Y_{i-1} + \varepsilon_i \quad i = 2, \dots, k \quad (2.1)$$

O valor obtido na etapa i , Y_i , segue uma distribuição Normal com média μ_i e variância σ_i^2 . Os parâmetros β_0 e β_i representam os coeficientes linear e angular do modelo,

respectivamente. Os $\varepsilon_{i/s} \sim N(0, \sigma_{ie}^2)$ isto é, os erros aleatórios seguem distribuição normal com média zero e variância constante σ_{ie}^2 . Os erros aleatórios e $Y_{i/s} \forall i \neq j$ apresentam covariância igual a zero, ou seja, são independentes.

O cálculo da variância de Y_i é dado pela equação 2.2, que é composta por uma soma entre duas parcelas, a primeira representa a variância transmitida pelo estágio anterior e a segunda conta com a variação gerada pela própria etapa i . Já a variância total de um processo formado por k estágios pode ser expressa por k equações, conforme a equação 2.3.

$$Var(Y_i) = \sigma_i^2 = \beta_i^2 \sigma_{i-1}^2 + \sigma_{i,A}^2 \quad (2.2)$$

Onde: σ_i^2 é a variância total da etapa;

$\sigma_{i,A}^2$ é a variância adicionada na etapa atual;

σ_{i-1}^2 é a variância na etapa anterior;

β_i^2 é o coeficiente responsável pela transmissão da variabilidade entre estágios.

$$\begin{aligned} \sigma_k^2 &= \beta_k^2 \sigma_{k-1}^2 + \sigma_{k,A}^2 \\ \sigma_{k-1}^2 &= \beta_{k-1}^2 \sigma_{k-2}^2 + \sigma_{k-1,A}^2 \\ \sigma_{k-2}^2 &= \beta_{k-2}^2 \sigma_{k-3}^2 + \sigma_{k-2,A}^2 \\ &\vdots \\ \sigma_2^2 &= \beta_2^2 \sigma_1^2 + \sigma_{2,A}^2 \\ \sigma_1^2 &= \sigma_{1,A}^2 \end{aligned} \quad (2.3)$$

Que ainda pode ser generalizada pela seguinte expressão:

$$\sigma_k^2 = (\beta_k^2 \beta_{k-1}^2 \dots \beta_2^2) \sigma_{1,A}^2 + (\beta_k^2 \beta_{k-1}^2 \dots \beta_3^2) \sigma_{2,A}^2 + \dots + \beta_k^2 \sigma_{k-1,A}^2 + \sigma_{k,A}^2 \quad (2.4)$$

De acordo com Lawless, Mackay e Robinson (1999), há a possibilidade de reduzir a variabilidade em Y_i , através da diminuição em: $\sigma_{i,A}^2$ ou σ_{i-1}^2 ou aproximar β_i^2 para zero. Os estimadores da covariância, da variância e dos coeficientes angular e linear são fornecidos pelas equações 2.5, 2.6, 2.7 e 2.8, respectivamente, baseadas nas estimativas de Máxima Verossimilhança.

$$S_{i-1,i} = \frac{\sum_{j=1}^n (Y_{j,i-1} - \bar{Y}_{i-1})(Y_{j,i} - \bar{Y}_i)}{n} \quad (2.5)$$

$$S_{ii} = \frac{\sum_{j=1}^n (Y_{j,i} - \bar{Y}_i)^2}{n} \quad (2.6)$$

$$\hat{\beta}_i = \frac{S_{i-1,i}}{S_{i-1,i-1}} \quad (2.7)$$

$$\hat{\beta}_0 = \bar{Y}_i - \hat{\beta}_i \bar{Y}_{i-1} \quad i=2,\dots,k \quad (2.8)$$

Assim, a equação 2.9 representa o estimador da variância adicionada à etapa atual.

$$\hat{\sigma}_{i,A}^2 = S_{ii} - \hat{\beta}_i(S_{i-1,i}) \quad i=2,\dots,k \quad (2.9)$$

É importante ressaltar que o modelo proposto por Lawless, Mackay e Robinson (1999) nada mais é que uma regressão linear simples, a qual utiliza dados de estágios atual e do imediatamente anterior, por isso é denominado de autoregressivo. Portanto, é necessário avaliar se os pressupostos desse modelo estão sendo atendidos. Dessa forma, para a verificação da adequação do modelo podem ser utilizados gráficos e testes estatísticos sobre os resíduos. Entende-se por resíduo a diferença entre os valores observados (y_i) e os estimados pelo modelo, conforme pode ser observado pela equação 2.10. As principais suposições que os erros devem apresentar para a validação do modelo são:

- Distribuição normal;
- Aleatoriedade (média nula e variância constante);
- Independência dos resíduos (não existe correlação entre eles).

$$r_i = y_i - \hat{\beta}_0 - \hat{\beta}_i Y_{i-1} \quad (2.10)$$

Segundo Fernandes (1999), os resíduos podem ser classificados em: original, estandardizado, de *Student* e cancelado. Os erros estandardizados têm como objetivo retirar as

diferenças entre as variações das variáveis. Já os de *Student* e cancelados, são capazes de detectar a presença de *outliers*. Através da standardização dos resíduos, equação 2.11, é possível a comparação direta dos erros com os coeficientes da reta de regressão estimados, no entanto, esse tipo de resíduo não segue a distribuição normal standardizada, pois o mesmo não é dividido pelo seu desvio padrão.

$$RP = r_i / \hat{\sigma} \quad (2.11)$$

Onde:

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n r_i^2}{n-p-1} \quad (2.12)$$

$n - p - 1$ representam os graus de liberdade.

A condição de normalidade dos resíduos pode ser analisada por:

- Teste de Anderson-Darling;
- Histograma de Resíduos Standardizados ou Padronizados;
- Gráfico Q-Q plot dos resíduos.

O teste de Anderson-Darling é calculado a partir de N observações e da distribuição cumulativa de dados, como apresentado pela equação 2.13. Esse teste estatístico tem sua origem no teste de Kolmogorov-Smirnov (que calcula a distância máxima entre a função distribuição acumulada esperada e observada). As hipóteses deste teste são: H_0 a variável segue a distribuição normal e H_1 a variável não segue a distribuição normal. O valor-p é a probabilidade de um valor de teste ser tão extremo como o que resulta da amostra, considerando a hipótese nula verdadeira. Se o valor-p for maior que o nível de significância, α , pode-se afirmar que os dados apresentam distribuição normal. O nível de significância mais utilizado é de 5%.

$$A^2 = -N - S \quad (2.13)$$

Onde:

$$S = \sum_{i=1}^N \frac{(2i-1)}{N} [\log F(Y_i) + \log(1 - F(Y_{N+1-i}))] \quad (2.14)$$

Para o histograma, basta apenas observar se ocorre simetria em torno do zero, como

apresentado na FIG.2.1, porém esse método gráfico não é eficiente ao lidar com amostras pequenas. Já o gráfico Q-Q plot dos resíduos, está relacionado com o quantil de probabilidade esperado, eixo das ordenadas, e com os erros estandardizados, eixo das abscissas. Se os pontos do gráfico estão aproximadamente sobre uma linha reta, verifica-se a normalidade dos erros, conforme FIG.2.2.




FIG.2. 1 – Exemplo de um Histograma dos Resíduos.

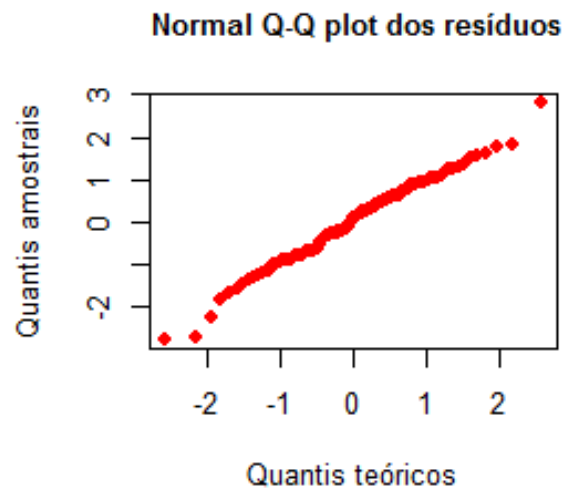


FIG.2. 2 – Exemplo de um Gráfico Q-Q plot dos resíduos.

A condição de variância constante dos resíduos pode ser observada no gráfico dos resíduos versus valores ajustados, o qual deve ter a aparência de uma nuvem de pontos sem um padrão específico, aleatória, indicando variância constante (modelo homocedástico), como na FIG.2.3. Caso contrário, se a variância não for constante, a condição de homocedasticidade do modelo é violada.




FIG.2. 3 – Exemplo de um Gráfico de Resíduos x Valores ajustados.

Para a verificação da independência dos erros, pode-se utilizar o gráfico dos resíduos versus a ordem de coleta. A principal condição para o uso deste gráfico é que os dados devem ser coletados sequencialmente. A não existência de um padrão revela a independência dos erros, como apresentado na FIG. 2.4.

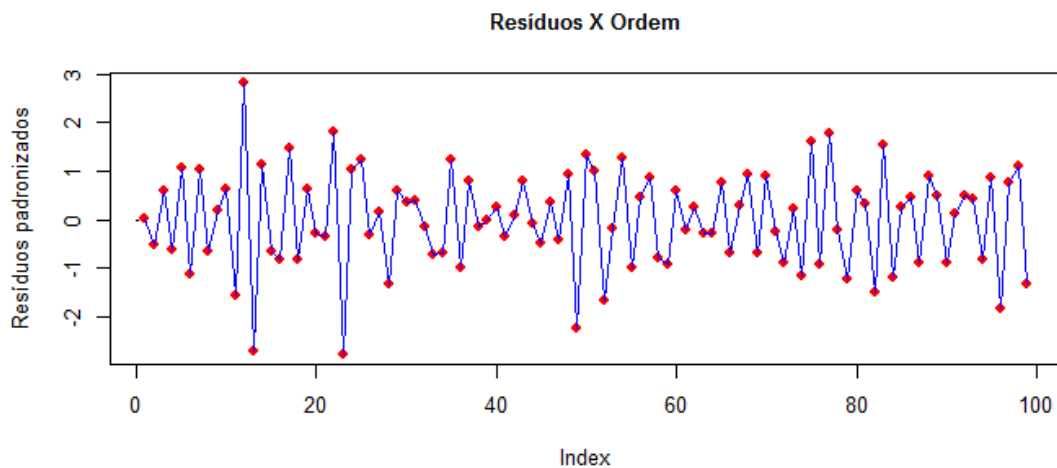


FIG.2. 4 – Exemplo de um Gráfico de Resíduos x Ordem de coleta.

Além disso, a validação do modelo pode ser dada através da estatística de ajuste do modelo, utilizando o coeficiente de determinação (R^2) e testes de significância da variável explicativa. O R^2 é calculado pela equação 2.15 e fornece uma informação referente à análise de variância do modelo. Essa medida de ajuste é importante, pois indica o quão bem a reta de regressão obtida se ajusta aos dados. Os valores de R^2 estão sempre entre zero e um. Quando

R^2 é próximo de 1, pode-se afirmar que o modelo proposto é adequado, dado que esse valor indica a proporção da variação de Y_i que é explicada pela equação.

$$R^2 = \frac{\text{Variação explicada}}{\text{Variação total}} = \frac{SQE}{SQT} = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \quad (2.15)$$

De acordo com Gujarati (2000), o coeficiente de correlação (R) está relacionado com R^2 , porém são conceitos diferentes. O coeficiente de correlação revela apenas o grau de associação entre duas variáveis (relação linear), já o coeficiente de determinação indica se os valores estimados pela equação de regressão estão próximos ou não de seus reais valores.

Em relação aos testes de significância, têm-se duas hipóteses relacionadas à variável explicativa e em relação ao intercepto (β_0):

$$H_0: \beta_i = 0 \quad (2.16)$$

$$H_1: \beta_i \neq 0$$

Se H_0 for verdadeiro, pode-se concluir que não há relação linear entre Y_i e Y_{i-1} . Para rejeitar ou não essa hipótese, deve-se obter uma comparação entre o valor F calculado, conforme equação 2.17, e o fornecido pela tabela da estatística F com nível de significância, dado por α .

$$F_{\text{calculado}} = \frac{SQE/1}{SQR/(n-2)} \sim F_{\alpha,1,n-2} \quad (2.17)$$

$$SQR = SQT - SQE \quad (2.18)$$

Se $F_{\text{calculado}}$ for maior que $F_{\alpha,1,n-2}$, deve-se rejeitar H_0 . Assim, quando o valor-p dos dois testes de significância para os coeficientes linear e angular dos modelos autoregressivos forem menores que o nível de significância, α , adotado como sendo de 5%, pode-se dizer que a variável explicativa e o intercepto são significativos.

2.2 ANÁLISE DE COMPONENTES PRINCIPAIS

As primeiras descrições da Análise de Componentes Principais (ACP) foram realizadas por Pearson em 1901 e Hotelling em 1933. A partir do artigo de Hotelling ocorreu um crescimento de publicações sobre a ACP e suas aplicações, especialmente devido ao advento dos computadores (Jolliffe, 2002).

A Análise de Componentes Principais é uma técnica estatística multivariada, em que um número de variáveis relacionadas é transformado em um conjunto menor de variáveis não correlacionadas. As principais características da ACP são: diminuição na dimensionalidade dos dados, sem perda significativa de informações, surgimento de novas variáveis e retirada de variáveis que não contribuem significativamente para o conjunto de dados. A ACP é uma técnica estatística com aplicações em diversas áreas e seu objetivo é encontrar padrões em dados de alta dimensão e cuja distribuição de probabilidade não precisa ser conhecida. Isto é possível pela transformação dos dados originais em um novo conjunto de variáveis independentes e ordenadas em ordem decrescente dos valores das variâncias, denominadas Componentes Principais (CPs). Assim, a primeira CP é uma combinação linear com variância máxima, a segunda CP retrata a segunda maior variabilidade do todo e a última CP representa a variabilidade mínima.

Vicini e Souza (2005) afirmam que a redução de variáveis só é possível se elas forem dependentes e possuírem coeficientes de correlação não nulos. Caso, não exista correlação significativa entre os dados, a ACP não é recomendada.

Essa técnica estatística funciona da seguinte forma: a partir de um conjunto de dados, é realizado o cálculo da matriz de correlação ou de covariância; através dessa matriz, são obtidos os autovalores que correspondem ao grau de variância explicada pelas futuras componentes, por sua vez, as componentes são calculadas pela combinação linear entre os autovetores e as variáveis originais. Os autovetores devem ser ortonormalizados para que o sistema tenha uma única solução e as componentes principais sejam independentes. Por fim, o conjunto original de dados é transformado em componentes principais, conforme apresentado na FIG.2.5.

Geometricamente, a ACP realiza uma rotação de eixos em um espaço p-dimensional, de forma que a primeira componente seja o novo eixo com maior poder de explicação da variabilidade total, a segunda CP é o segundo novo eixo com maior variabilidade e não

correlacionado com a CP1, assim, sucessivamente até a última componente. Se N componentes representam a variabilidade total de um sistema, a maior parte desta variabilidade pode ser explicada por um número menor K de componentes. Logo, K componentes substituem as N variáveis iniciais, reduzindo o conjunto de dados. A redução no número de variáveis facilita a avaliação dos dados, pois as componentes principais não são correlacionadas. A grande desvantagem da ACP é a redução da sua capacidade de explicar o conjunto de dados por uma única CP, quando há baixa dependência linear entre as variáveis.

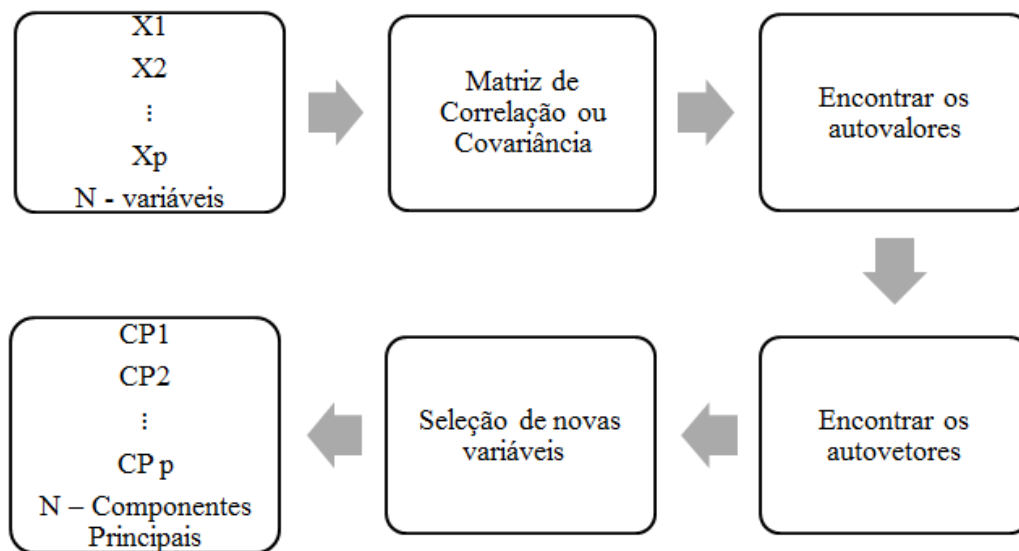


FIG.2. 5– Esquema do método ACP.

Se cerca de 80-90% da variância total pode ser explicada por duas ou três componentes, então estas componentes podem substituir as variáveis originais sem perda de informação (Johnson; Wichern, 2007).

Geralmente, quando se utiliza a Matriz de Correlação, o número de componentes principais é maior do que em relação ao uso da Matriz de Covariância (Mingoti, 2013).

O procedimento a seguir retrata ACP pela Matriz de Covariâncias. A Matriz de Covariância é positiva definida, ou seja, os seus autovalores não são negativos. Seja X um vetor aleatório com vetor de médias μ e matriz de covariâncias $\Sigma_{p \times p}$ com λ_i autovalores e e_i os autovetores (normalizados) que obedecem às condições: $e_i' e_j = 0$ ($i \neq j$); $e_i' e_i = 1$ (para todo i) e $\Sigma_{p \times p} e_i = \lambda_i e_i$ (para todo i). A Matriz de Covariâncias é obtida por meio da equação 2.19:

$$\sum_{p \times p} = \begin{bmatrix} S_{11} & S_{12} & \dots & S_{1p} \\ S_{21} & S_{22} & \dots & S_{2p} \\ S_{p1} & S_{p2} & \dots & S_{pp} \end{bmatrix} \quad (2.19)$$

Onde:

$$S_{ii} = \frac{\sum_{l=1}^n (X_{il} - \bar{X}_i)^2}{n - 1}$$

$$S_{ij} = \frac{\sum_{l=1}^n (X_{il} - \bar{X}_i)(X_{jl} - \bar{X}_j)}{n - 1}$$

A j -ésima componente principal é dada pela equação 2.20:

$$CP_j = e_j' X = e_{j1} X_1 + e_{j2} X_2 + \dots + e_{jp} X_p = \sum_{i=1}^p e_{ji} X_i \quad (2.20)$$

A variância de CP_j é igual a λ_j . Por isso, a proporção entre a variância da componente principal pela total é fornecida pela equação 2.21.

$$\frac{Var [CP_j]}{Variância\ total\ de\ X} = \frac{\lambda_j}{Traço(\sum p \times p)} = \frac{\lambda_j}{\sum_{i=1}^p \lambda_i} \quad (2.21)$$

Se as k primeiras componentes principais representam a maioria da variância total do vetor, deve-se manter a atenção apenas nessas componentes. Já a análise de componentes principais pela Matriz de Correlação é utilizada quando há diferenças acentuadas entre as variâncias (Mingoti, 2013).

A matriz $P_{p \times p}$, de correlação, é obtida por meio da equação 2.22:

$$P_{p \times p} = \begin{bmatrix} R_{11} & R_{12} & \dots & R_{1p} \\ R_{21} & R_{22} & \dots & R_{2p} \\ R_{p1} & R_{p2} & \dots & R_{pp} \end{bmatrix} \quad (2.22)$$

Onde:

$$R_{ij} = \frac{S_{ij}}{\sqrt{S_{ii} S_{jj}}}$$

A componente principal também pode ser dada pela equação 2.23, quando há diferentes unidades de medidas nas variáveis originais e utiliza-se a ACP pela matriz de covariância:

$$CP_j = e_j' Z = e_{j1} Z_1 + e_{j2} Z_2 + \dots + e_{jp} Z_p \quad (2.23)$$

Onde:

$$Z_i = \frac{(X_i - \mu_i)}{\sigma_i}$$

A variância de CP_j é igual a λ_j e a covariância entre CP_j e CP_k é igual à zero.

A correlação entre CP_j e Z_i é feita pela equação 2.24:

$$r_{CP_j Z_i} = e_{ji} \sqrt{\lambda_j} \quad (2.24)$$

A principal vantagem do uso da matriz de correlação ao invés da matriz de covariância é a facilidade na comparação dos resultados em diferentes análises. Os valores das variâncias das componentes principais têm as mesmas implicações para diferentes matrizes de correlação de mesma dimensão, mas não ocorre o mesmo para diferentes matrizes de covariância. A grande desvantagem da ACP por covariância é a sensibilidade das componentes às unidades de medidas em cada variável (Mingoti, 2013).

Para a Matriz de Covariância, pode-se determinar a relação existente entre a CP_i componente e a X_K variável original pela equação 2.25.

$$\rho_{CP_i, X_k} = \frac{e_{ik} \sqrt{\lambda_i}}{\sqrt{\sigma_{kk}}} \quad (2.25)$$

Onde: e_{ik} é o elemento do autovetor que mede a importância da k variável na i -ésima componente principal; λ_i é o autovalor e σ_{kk} é o elemento da diagonal principal da matriz.

Já para a Matriz de Correlação, a relação é dada pela equação 2.26:

$$r_{CP_i, X_k} = e_{ik} \sqrt{\lambda_i} \quad (2.26)$$

2.3 MODELO AUTOREGRESSIVO NAS COMPONENTES PRINCIPAIS

O modelo Autoregressivo de ordem um, descrito na seção (2.1), é a base para o modelo autoregressivo nas componentes principais. Dessa forma, a ideia é modelar a componente principal do estágio i em função da componente principal no estágio anterior, conforme a equação 2.28, já a variância é dada pela equação 2.29. Pela equação 2.28, tem-se que os termos β_0 e β_i representam os coeficientes linear e angular do modelo, respectivamente. Os $\varepsilon_{i/s} \sim N(0, \sigma_{ie}^2)$ são os erros aleatórios do modelo de propagação, com média zero e variância constante. Por fim, os erros e os valores obtidos para CP_i são independentes. De acordo com a equação 2.29, nota-se que variância da CP no estágio i é dada pela soma entre a variância transmitida pela CP na etapa anterior e a variação gerada pelo próprio estágio.

$$CP_i = \beta_0 + \beta_i CP_{i-1} + \varepsilon_i \quad (2.28)$$

$$Var(CP_i) = \sigma_i^2 = \beta_i^2 \sigma_{i-1}^2 + \sigma_{i,A}^2 \quad (2.29)$$

Onde: σ_i^2 é a variância total da CP na etapa;

$\sigma_{i,A}^2$ é a variância adicionada na etapa atual;

σ_{i-1}^2 é a variância na etapa anterior;

β_i^2 é o coeficiente responsável pela transmissão da variabilidade entre estágios.

A variabilidade transmitida à última etapa é determinada pela equação 2.30.

$$\sigma_k^2 = (\beta_k^2 \beta_{k-1}^2 \dots \beta_2^2) \sigma_{1,A}^2 + (\beta_k^2 \beta_{k-1}^2 \dots \beta_3^2) \sigma_{2,A}^2 + \dots + \beta_k^2 \sigma_{k-1,A}^2 + \sigma_{k,A}^2 \quad (2.30)$$

Por analogia às estimativas de parâmetros do modelo desenvolvido por Lawless, Mackay e Robinson (1999), a covariância entre as componentes é fornecida pela equação 2.31.

$$S_{i-1,i} = \frac{\sum_{j=1}^n (CP_{j,i-1} - \overline{CP}_{i-1})(CP_{j,i} - \overline{CP}_i)}{n} \quad (2.31)$$

E a variância é dada pela equação 2.32:

$$S_{ii} = \frac{\sum_{j=1}^n (CP_{j,i} - \overline{CP}_i)^2}{n} \quad (2.32)$$

O estimador do parâmetro de propagação é calculado através da equação 2.33.

$$\hat{\beta}_i = \frac{S_{i-1,i}}{S_{i-1,i-1}} \quad (2.33)$$

Os estimadores do coeficiente linear e da variância adicionada entre etapas também são obtidos por analogia ao modelo de Lawless, Mackay e Robinson (1999) e fornecidos pelas equações 2.34 e 2.35, respectivamente.

$$\hat{\beta}_0 = \overline{CP}_i - \hat{\beta}_i \overline{CP}_{i-1} \quad i=2,\dots,k \quad (2.34)$$

$$\hat{\sigma}_{i,A}^2 = S_{ii} - \hat{\beta}_i (S_{i-1,i}) \quad i=2,\dots,k \quad (2.35)$$

A validação do modelo autoregressivo nas componentes principais se dá por analogia da análise de resíduos descrita na seção (2.1), através de testes estatísticos (Anderson-Darling) e gráficos, tais como, o histograma de resíduos estandardizados, gráfico normal Q-Q plot, dos resíduos versus os valores ajustados e dos resíduos versus a ordem de coleta. Nestes gráficos, devem ser observadas a aleatoriedade, independência e normalidade dos resíduos gerados pelo modelo. Também, pode ser utilizada a estatística de ajuste do modelo, dada por R^2 e os testes de significância dos coeficientes linear e angular do modelo.

2.4 ANÁLISE DE AGRUPAMENTOS

A Análise de Agrupamentos (Conglomerados ou de Cluster) divide os elementos de amostras ou população, a partir de semelhanças ou similaridades presentes nas características de interesse. Contudo, os grupos formados são diferentes entre si (Mingoti, 2013).

A aplicação dessa técnica estatística multivariada é indicada, principalmente, para conjunto de dados que não apresentam todas as variáveis correlacionadas entre si. Existem diversos métodos de agrupamentos que podem ser divididos em dois grandes grupos, como os hierárquicos e não hierárquicos. O agrupamento hierárquico é formado a partir de baixo para

cima, inicialmente, cada objeto é um grupo por si só, em seguida, pequenos grupos são incluídos a grupos maiores a cada nível de hierarquia até o topo, no qual todos os dados estão aglomerados. O processo inverso é denominado agrupamento divisivo. Os métodos hierárquicos realizam agrupamentos ou divisões sucessivas até formar um único grupo. Já os métodos não hierárquicos exigem um número de subgrupos pré-definido e é mais rápido, pois não há necessidade de calcular e armazenar a matriz de similaridade durante o agrupamento.

A Análise de Agrupamentos reúne ferramentas que avaliam todas as combinações possíveis em um enorme volume de dados. Vários elementos são particionados em subgrupos a partir de uma proximidade ou similaridade, ou seja, um conjunto heterogêneo é dividido em subgrupos mais semelhantes. Os resultados são representados em um diagrama de árvore ou dendrograma. A principal diferença entre agrupar e classificar uma população é que não há suposição quanto ao número de grupos (Doni, 2004).

Um dendrograma ou fenograma é a visualização gráfica das técnicas de agrupamento utilizadas na análise. Os dendrogramas podem estar na horizontal ou vertical. Para interpretar um dendrograma com medida de similaridade, basta observar os elementos que apresentam maiores valores, logo, estes são os mais semelhantes. No caso de medida de dissimilaridade, se o valor entre os elementos for alto, significa que são distintos. Dentre as medidas de similaridade, pode-se citar o Coeficiente de Correlação ou de Pearson, a Distância Euclidiana, Distância de Mahalanobis, entre outras.

O coeficiente de Pearson entre dois elementos X e Y, definido pela equação 2.36, deve obedecer às seguintes propriedades:

$$S(X, Y) = \frac{S_{ij}}{\sqrt{S_{ii}S_{jj}}} \quad (2.36)$$

- $S(X, Y) = S(Y, X)$;
- $S(X, Y) \geq 0$;

O procedimento para a análise de Cluster é dividido em etapas, conforme a FIG.2.6. As escolhas da medida de similaridade (dissimilaridade) e do método de agrupamento é uma das dificuldades encontradas pelo pesquisador, já que não há como afirmar qual deles é o mais adequado (Vicini e Souza, 2005).



FIG.2. 6 – Etapas para Análise de Agrupamentos.

As principais características das técnicas, que compõem a análise de agrupamentos, são apresentadas na TAB.2.1.

TAB.2. 1– Resumo dos principais Métodos de Agrupamentos.

MÉTODOS HIERÁRQUICOS	
<i>Métodos Aglomerativos</i>	
Os elementos são dispostos em grupos ligados a outros a partir da similaridade.	
<i>Ligação Simples</i>	Também denominado de ligação por vizinho mais próximo, emprega a distância mínima.
<i>Ligação Completa</i>	Conhecida como ligação por vizinho mais distante, utiliza a distância máxima.
<i>Ligação por Média</i>	Possui menor sensibilidade a ruídos e pode utilizar tanto distância Euclidiana quanto outras.
<i>Ligação por Centroide</i>	Não é bastante utilizado por causa do fenômeno da reversão que torna difícil a interpretação do dendrograma.
<i>Ligação por Mediana</i>	É robusto quanto à presença de <i>outliers</i> , apresenta bom resultado no caso de grupos com diferentes tamanhos.
<i>Ligação de Ward</i>	Não apresenta resultados satisfatórios quando o número de elementos nos grupos é igual e combina grupos com poucos elementos.
<i>Métodos Divisivos</i>	
É o oposto dos métodos aglomerativos. Os elementos são divididos em dois grupos, de maneira, que eles estejam distantes um do outro, o processo continua até que grupo seja composto por um elemento.	
MÉTODOS NÃO HIERÁRQUICOS	
<i>K-médias</i>	A quantidade de grupos permanece inalterada e não é indicado para grupos com tamanhos bastante distintos.
<i>K-medóides</i>	É feito a partir da média dos componentes de um grupo; custo alto.

As FIG. 2.7, 2.8 e 2.9 apresentam exemplos de dendrogramas utilizando alguns dos métodos aglomerativos, descritos na tabela 2.1. Assim, a FIG.2.7 apresenta um dendrograma obtido pelo método de ligação completa e pelo uso da medida de similaridade, Coeficiente de Correlação.




FIG.2. 7 – Exemplo Dendrograma Ligação Completa.

A FIG. 2.8 mostra o agrupamento do método de ligação por média em um dendrograma.




FIG.2. 8 – Exemplo Dendrograma Ligação por Média.

E a FIG.2.9 revela a análise de agrupamento através do método de ligação por centroide.

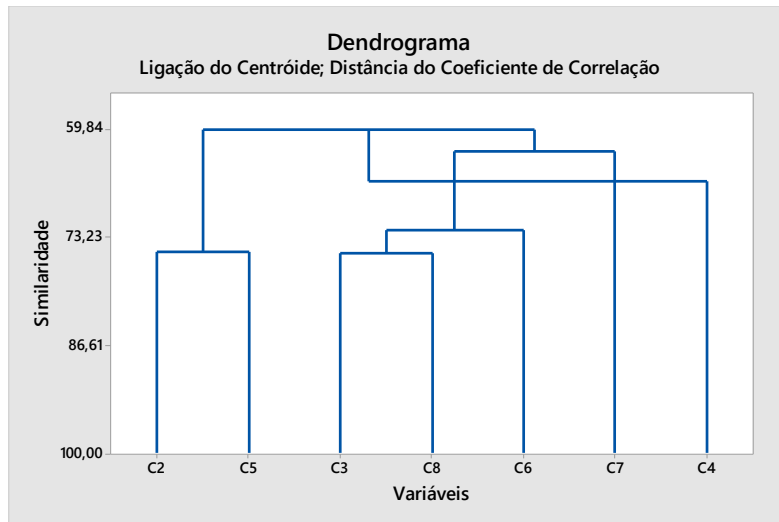


FIG.2. 9 – Exemplo Dendrograma Ligação por Centróide.

3 METODOLOGIA

Neste capítulo, são apresentadas as metodologias utilizadas em dois estudos de caso. O primeiro é realizado por meio de cenários de um processo produtivo formado por dois estágios, em que cada estágio é composto por quatro variáveis, em que as mesmas são correlacionadas em diferentes níveis. Já o segundo estudo considera um caso real de um processo produtivo de montagem de veículos.

3.1 CENÁRIOS

Para os cenários, foram propostas quatro variáveis correlacionadas em dois estágios FIG 3.1. Assim inicialmente foi gerado uma amostra aleatória de tamanho 100 de acordo com uma distribuição normal com média zero e variância 1 para a primeira variável do estágio 1 e em seguida, foram geradas mais 100 amostras aleatórias para cada uma das outras 3 variáveis desse estágio, considerando ainda três tipos de correlações entre essas variáveis, a saber: forte (95%-85%), moderada (45%-35%) e fraca (15%-5%). Posteriormente, foi gerada a primeira variável do estágio 2 por meio da primeira variável do estágio 1, considerando três casos de correlação entre os estágios, conforme pode ser visto na FIG. 3.2. Em seguida, com base nas outras 3 variáveis do primeiro estágio foram geradas mais 100 amostras para cada uma delas no segundo estágio, também utilizando as correlações de 90%, 50% e 30%. O mesmo procedimento foi realizado considerando uma amostra aleatória com distribuição normal com média zero e variância 3 para a primeira variável do estágio 1.

Os dados correlacionados foram gerados por meio da equação 3.1, onde ρ é a correlação entre as variáveis (X_{11} e X_{12}) e a variável aleatória representada por E_1 segue a distribuição normal com média zero e variância um. Dessa forma, X_{12} e X_{11} apresentam correlação ρ aproximada, sendo que X_{12} representa a variável X_1 no estágio 2. Logo, as variáveis do segundo estágio, foram estabelecidas através de relações, tais como, 90%, 50% e 30% com as variáveis do estágio 1. Dessa forma, têm-se os casos 1, 2 e 3, respectivamente (ver em ANEXO 1).

$$X_{12} = \rho X_{11} + \sqrt{1 - \rho^2} E_1 \quad (3.1)$$




FIG.3. 1 – Representação das variáveis em cada estágio.

Assim, para o primeiro cenário FIG. 3.2, supõe-se que as variáveis em cada estágio são fortemente correlacionadas entre si considerando ainda três tipos de correlação entre os estágios.

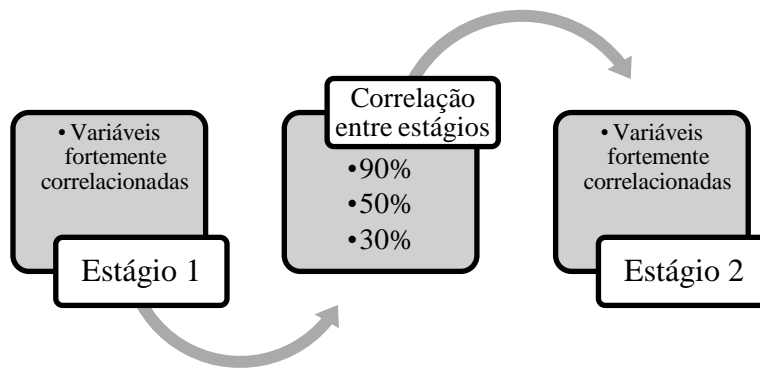


FIG.3. 2 – Cenário 1.

Para o cenário 2, as variáveis são moderadamente correlacionadas entre si em cada estágio, e a correlação entre estágios está dividida em 3 casos, como a FIG.3.3.

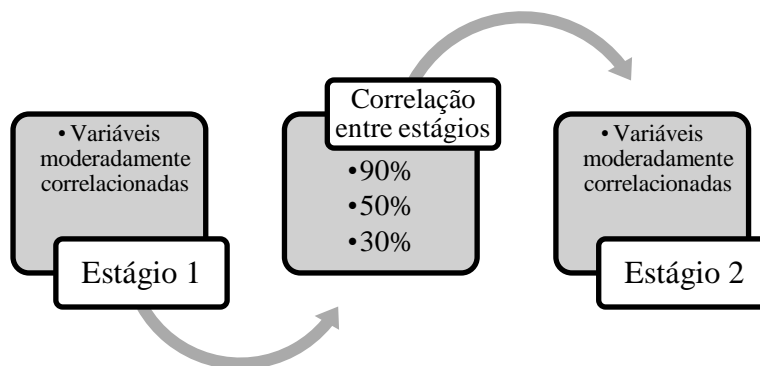


FIG.3. 3 – Cenário 2.

Já no cenário 3, as variáveis são fracamente correlacionadas entre si em cada estágio, e a correlação entre estágios está dividida em 3 casos, como na FIG.3.4.

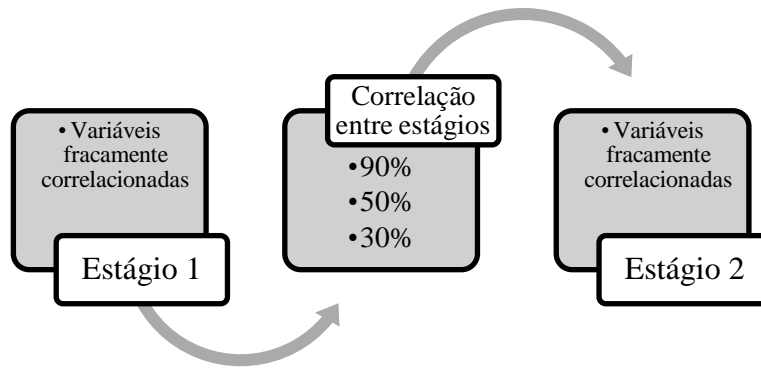


FIG.3. 4 – Cenário 3.

A partir de cada grupo de variáveis em cada estágio foram geradas componentes principais, através do MINITAB17®, selecionando a primeira componente principal, já que ela explica a maior parte da variabilidade das variáveis originais. Em seguida, é aplicado o modelo proposto entre as primeiras componentes de cada estágio, onde a componente do segundo estágio é regredida em função da componente do primeiro estágio, conforme FIG. 3.5. Já a análise de resíduos do modelo foi feita por meio do programa R.




FIG.3. 5 – Representação das componentes principais em cada estágio.

3.2 PROCESSO PRODUTIVO DE VEÍCULOS.

Um processo produtivo de um veículo envolve três grandes etapas: chaparia, pintura e montagem. A chaparia é também denominada de estruturação, onde chapas metálicas são soldadas para formar a carroceria ou chassi do carro. Com a carroceria pronta, ela vai para a fase da pintura. A última etapa é da montagem, na qual são adicionados os bancos, carpetes e demais acessórios. O estudo foi realizado com os dados dos estágios de Chaparia e Montagem da porta traseira de um veículo.

A escolha pela porta traseira foi devido a um número considerável de anomalias nesse componente. As informações necessárias foram retiradas a partir da análise da folga, medida em milímetros, em 12 pontos marcados ao longo da porta de 17 veículos, conforme FIG.3.6 (Gaio e Sá, 2004).




FIG.3. 6 – Carro analisado (Gaio e Sá, 2004).

Primeiramente, é necessário aplicar a análise de agrupamento nesse estudo de caso, devido ao número elevado de variáveis e da baixa correlação entre os dados. A partir da divisão dos dados em grupos com elementos correlacionados entre si, é possível aplicar o método das componentes principais, obtendo assim a máxima redução de variáveis originais. Em seguida, o modelo proposto de propagação em cada grupo é gerado ao regressir a primeira componente da Montagem em função da primeira CP da etapa da Chaparia. Os dados coletados nos estágios da Chaparia e Montagem encontram-se no ANEXO 2.

4 RESULTADOS

Neste capítulo, são apresentados os resultados dos modelos e as técnicas estatísticas abordadas na fundamentação teórica que foram aplicadas nos estudos de caso.

4.1 MODELOS AUTOREGRESSIVOS PARA OS CENÁRIOS

A TAB.(4.1) retrata um resumo com as principais características dos dados de cada um dos cenários analisados.

TAB.4. 1 – Resumo dos Cenários.

Cenários	Estágio 1	Correlação entre estágios	Estágio 2
Cenário 1 caso 1	Variáveis fortemente correlacionadas	90%	Variáveis fortemente correlacionadas
Cenário 1 caso 2	Variáveis fortemente correlacionadas	50%	Variáveis fortemente correlacionadas
Cenário 1 caso 3	Variáveis fortemente correlacionadas	30%	Variáveis fortemente correlacionadas
Cenário 2 caso 1	Variáveis moderadamente correlacionadas	90%	Variáveis moderadamente correlacionadas
Cenário 2 caso 2	Variáveis moderadamente correlacionadas	50%	Variáveis moderadamente correlacionadas
Cenário 2 caso 3	Variáveis moderadamente correlacionadas	30%	Variáveis moderadamente correlacionadas
Cenário 3 caso 1	Variáveis fracamente correlacionadas	90%	Variáveis fracamente correlacionadas
Cenário 3 caso 2	Variáveis fracamente correlacionadas	50%	Variáveis fracamente correlacionadas
Cenário 3 caso 3	Variáveis fracamente correlacionadas	30%	Variáveis fracamente correlacionadas

4.1.1 MODELOS AUTOREGRESSIVOS NAS COMPONENTES PRINCIPAIS - CENÁRIO 1.

Conforme explicitado na metodologia, inicialmente foi aplicada a Análise de Componentes Principais nos dados dos estágios 1 e 2 do cenário 1, no qual as variáveis estão fortemente correlacionadas entre si. Pela ACP, tem-se que os percentuais das variâncias explicadas pelas componentes no cenário 1 para os primeiros estágios com variâncias iguais a 1 e a 3 são dadas pela TAB.4.2. Para os dados com variância igual a um, observa-se que 95.80% da variância total, referente às quatro variáveis do estágio 1, é representada por uma única componente principal, ou seja, é possível substituir as quatro variáveis por uma única componente sem perda significativa de informação. Para o estágio 1 com variância 3, tem-se um aumento na variância explicada pela primeira componente em relação ao estágio 1 com variância 1. Nesse caso, a primeira CP representa 99.60% da variância das variáveis originais.

TAB.4. 2 - Percentual total da variância explicada pelas CPs Cenário 1 Estágios 1.

Estágio 1 - N(0,1)			
% CP1	% CP2	% CP3	%CP4
95.8%	4.20%	0.00%	0.00%
Estágio 1 - N(0,3)			
% CP1	% CP2	% CP3	%CP4
99.6%	0.40%	0.00%	0.00%

Nos estágios 2 com variância iguais a 1 e 3, foram realizadas três análises de componentes principais para cada caso de correlação entre os estágios, conforme TAB. 4.3.

TAB.4. 3 - Percentual total da variância explicada pelas CPs Cenário 1 Estágios 2.

Estágio 2 - N(0,1)				
Caso	% CP1	% CP2	% CP3	%CP4
1 (90%)	83.10%	8.70%	5.00%	3.20%
2 (50%)	46.40%	24.20%	17.90%	11.50%
3 (30%)	39.10%	26.50%	21.00%	13.40%
Estágio 2 - N(0,3)				
Caso	% CP1	% CP2	% CP3	%CP4
1 (90%)	98.00%	1.00%	0.60%	0.40%
2 (50%)	82.90%	7.90%	5.90%	3.30%
3 (30%)	63.50%	16.70%	12.50%	7.30%

Para o caso 1 com variância 1, a primeira componente principal representa 83.10% da variância total. No caso 2, a CP1 possui 46.40% das variações presentes no estágio 2. Enquanto que, no caso 3, esse valor cai para 39.10%, devido a correlação de apenas 30% entre os estágios. Em relação aos resultados referentes ao estágio 2 com variância igual a 3, nota-se que mesmo para a correlação de 30%, a primeira componente possui um elevado grau de explicação.

A TAB.4.4 contém os valores dos coeficientes dos modelos autoregressivos de propagação de erros nas componentes principais (CP1) para o caso 1.

TAB.4. 4 – Parâmetros Modelo de Propagação – Caso 1 - Cenário 1.

Modelo Autoregressivo de Propagação – CP1 – Caso 1				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	0.8812	-	0.8938
$\sigma_{i,A}^2$	-	0.2200	-	0.2181
S_{ii}	3.2548	2.7476	35.4923	28.5696
$S_{i-1,i}$	-	2.8682	-	31.7216
CP12 = 0.8812 * CP11 + 0.0742			CP12 = 0.8938 * CP11 + 0.0794	
Estatística de ajuste do modelo				
$R^2_{\text{estágio 2}}$	0.9199		0.9924	
<i>Coeficientes</i>	<i>Valor- P</i>		<i>Coeficientes</i>	<i>Valor- P</i>
β_i	1.57E-55		β_i	1.40E-105
β_0	0.1238		β_0	0.0955

Pela TAB.4.4, percebe-se que os modelos autoregressivos nas componentes principais apresentam os coeficientes de propagação significativos, visto que os respectivos valores-p serem inferiores a α , que nessa dissertação é adotado como 0.05. Enquanto que, pelo mesmo critério o coeficiente linear pode ser desconsiderado de ambos os modelos.

Já a TAB.4.5, contém os valores das variâncias para cada estágio e entre os respectivos estágios para o caso 1.

TAB.4. 5 – Variâncias em Estágios – Caso 1 – Cenário 1.

Etapas	N(0,1)		N(0,3)	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	3.2548	2.5276	35.4923	28.3515
Estágio 2	-	0.2200	-	0.2181
Total	3.2548	2.7476	35.4923	28.5696

No mesmo caso, a FIG.4.1 revela o comportamento dos erros nos dois estágios, bem como a sua propagação para o segundo estágio, que é de 91.99% para caso 1 com variância igual a 1 e 99.24% para caso 1 com variância 3. As propagações dos erros nas componentes principais foram altas devido a forte correlação entre as variáveis originais e os estágios.




FIG.4. 1 – Propagação de Erros – Caso 1 - Cenário 1.

Para a análise de resíduos do modelo do caso 1, são aplicados o teste Anderson-Darling (AD) e os gráficos para a verificação da normalidade, aleatoriedade e independência dos erros. O valor-p do teste AD para o caso 1 com variância 1 é de 0.7202 e para o caso 1 com variância 3 é de 0.7402, ambos sinalizando a não rejeição da hipótese de normalidade (H_0) dos resíduos. Pelas FIG.4.2 e 4.3, verifica-se que há simetria em torno do zero no histograma; no gráfico normal Q-Q plot, os pontos estão sobre uma linha reta; no gráfico dos resíduos versus valores ajustados, existe uma nuvem de pontos aleatória com variabilidade constante; no gráfico dos resíduos versus ordem de coleta, não há um padrão específico, logo,

não existe correlação entre os erros.

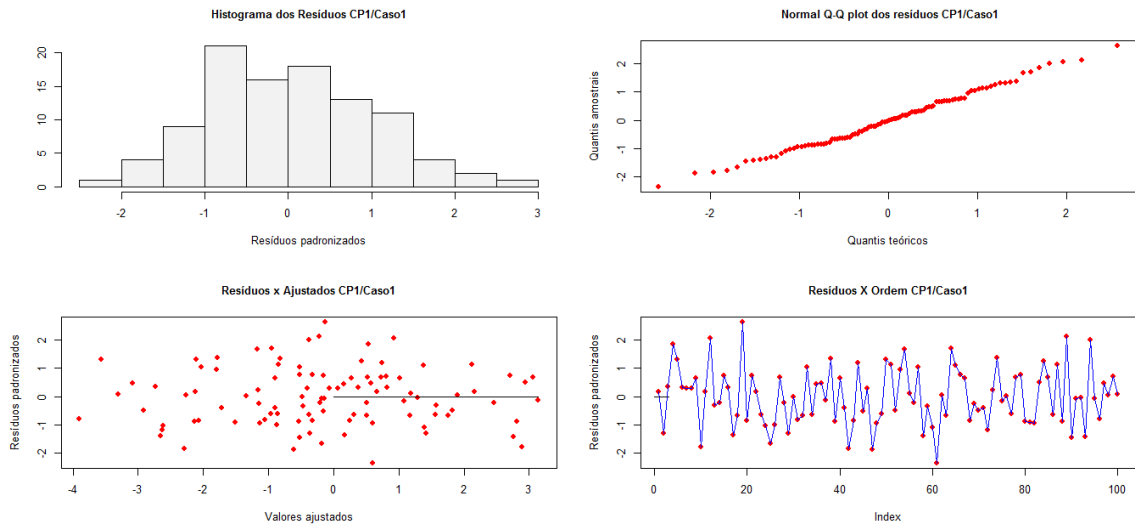


FIG.4. 2 – Análise de Resíduos CP1 – Caso 1 – Variância 1 – Cenário 1.

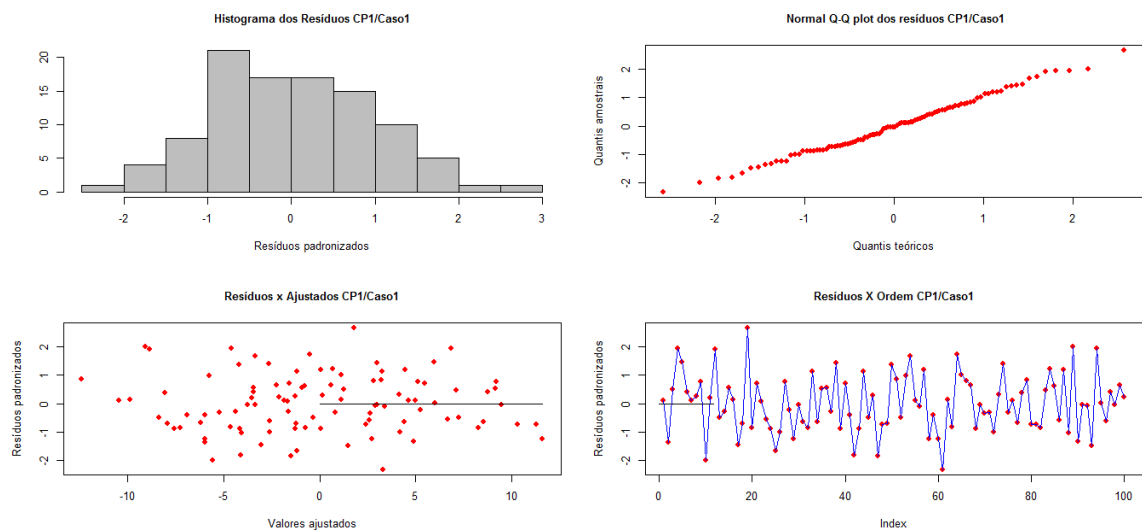


FIG.4. 3 - Análise de Resíduos CP1 – Caso 1 – Variância 3 – Cenário 1.

Os resultados do caso 2 são apresentados na TAB.4.6, na qual os coeficientes de transmissão dos modelos são de 0.4542 e 0.4883 para os casos 2 com variâncias 1 e 3, respectivamente. Já os coeficientes lineares são de 0.1514 e 0.1573 . Também neste caso, os modelos encontrados são significativos, já que os valores-p dos parâmetros de transmissão das variâncias são inferiores a α , que é adotado como 5%, e os coeficientes de determinação (R^2) são de aproximadamente 41% para o primeiro modelo e de 91% para o segundo modelo.

TAB.4. 6 – Parâmetros Modelo de Propagação – Caso 2 – Cenário 1.

Modelo Autoregressivo de Propagação – CP1 – Caso 2				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	0.4542	-	0.4883
$\sigma_{i,A}^2$	-	0.9364	-	0.8675
S_{ii}	3.2548	1.6077	35.4923	9.3310
$S_{i-1,i}$	-	1.4782	-	17.3316
CP1 = 0.4542 * CP11 + 0.1514			CP12 = 0.4883 * CP11 + 0.1573	
Estatística de ajuste do modelo				
$R^2_{\text{estágio 2}}$	0.4176		0.9070	
<i>Coeficientes</i>	<i>Valor- P</i>		<i>Coeficientes</i>	<i>Valor- P</i>
β_i	3.86E-13		β_i	2.38E-52
β_0	0.1281		β_0	0.0977

A TAB.4.7 revela que a variância entre os estágios é de 0.6713 e o valor da variância gerado no próprio estágio 2 é de 0.9364 para o caso 2 com dados que seguem a distribuição Normal com média zero e variância um. Enquanto que para o outro caso 2, a variância transmitida entre os estágios é de 8.4634.

TAB.4. 7– Variâncias em Estágios – Caso 2 – Cenário 1.

<i>Etapas</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	3.2548	0.6713	35.4923	8.4634
Estágio 2	-	0.9364	-	0.8675
Total	3.2548	1.6077	35.4923	9.3309

Pela FIG.4.4, nota-se que a transmissão de erros entre os estágios é de 41.76% para a correlação de 50% entre as fases 1 e 2 com variância 1. Enquanto que, o caso 2 com variância 3 apresenta 90.70% dos desvios no estágio 2 são gerados pela etapa anterior.




FIG.4. 4 – Propagação de Erros – Caso 2 – Cenário 1.

Para o caso 2, os resultados da análise de resíduos estão nas FIG.4.5 e 4.6, pelas quais, pode-se afirmar que os resíduos são: normalmente distribuídos; a variância é constante e não há correlação entre eles. O valor-p do teste AD foi de 0.5349 e 0.7281, para o caso 2 com variância 1 e caso 2 com variância 3, respectivamente.

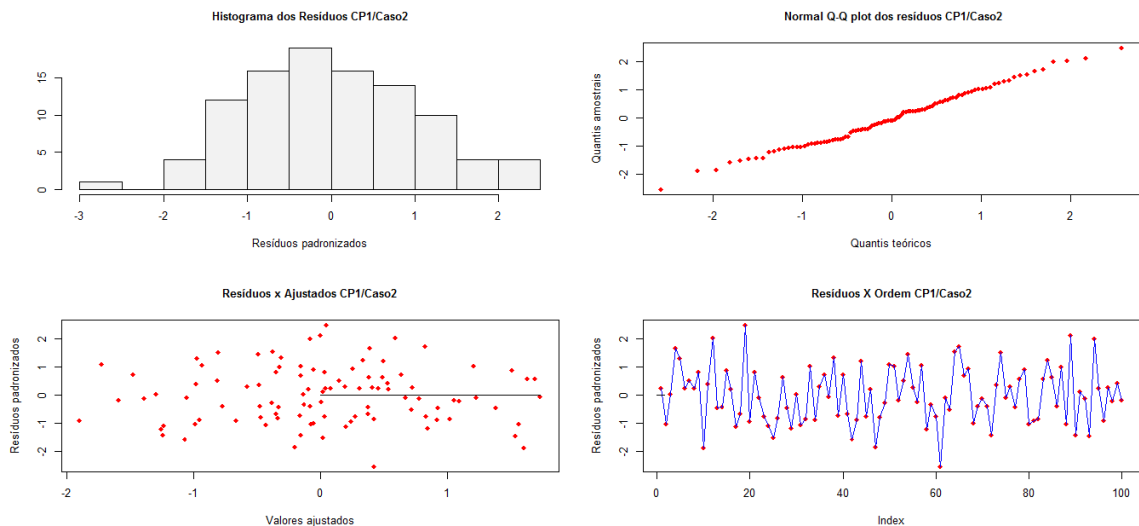


FIG.4. 5 – Análise de Resíduos CP1 – Caso 2 – Variância 1 – Cenário 1.

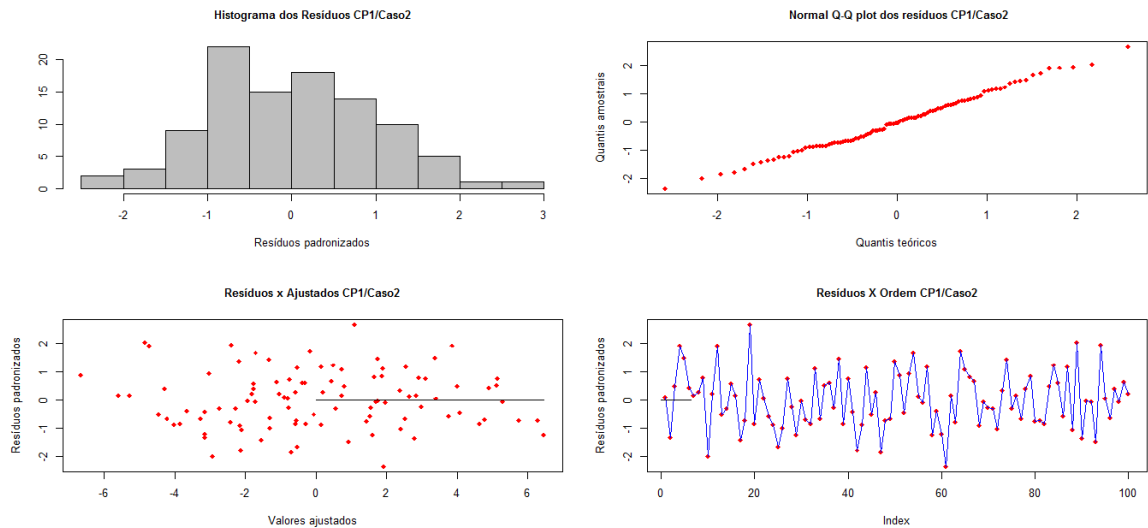


FIG.4. 6 - Análise de Resíduos CP1 – Caso 2 – Variância 3 – Cenário 1.

Para a correlação de 30% entre as etapas, a TAB.4.8 revela os valores dos principais parâmetros dos modelos autoregressivos nas componentes principais, assim como, as equações dos modelos e as suas respectivas estatísticas de ajuste, pelas quais se pode afirmar que ambas apresentam coeficientes angulares significativos, sendo que para o caso 3 com variância 3, 73.13% da variação da CP no estágio 2 pode ser explicada pelo modelo.

TAB.4. 8 – Parâmetros Modelo de Propagação – Caso 3 – Cenário 1.

Modelo Autoregressivo de Propagação – CP1 – Caso 2				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	0.2311	-	0.2874
$\sigma_{i,A}^2$	-	1.2141	-	1.0770
S_{ii}	3.2548	1.3880	35.4923	4.0090
$S_{i-1,i}$	-	0.7523	-	10.2011
$CP12 = 0.2311 * CP11 + 0.1709$			$CP12 = 0.2874 * CP11 + 0.1739$	
Estatística de ajuste do modelo				
R^2 estágio 2	0.1253		0.7313	
<i>Coeficientes</i>	<i>Valor- P</i>		<i>Coeficientes</i>	<i>Valor- P</i>
β_i	0.0003		β_i	1.00E-29
β_0	0.1313		β_0	0.1004

Já, os valores das variâncias presentes nos estágios do caso 3 estão na TAB.4.9.

TAB.4. 9– Variâncias em Estágios – Caso 3 – Cenário 1.

Etapas	N(0,1)		N(0,3)	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	3.2548	0.1739	35.4923	2.9319
Estágio 2	-	1.2141	-	1.0770
Total	3.2548	1.3880	35.4923	4.0089

A FIG.4.7 mostra que a variabilidade transmitida do estágio 1 com variância 1 para a etapa posterior é de 12.53% . No caso 3 com variância 3, essa propagação de erros é de 73.13%, devido a variância na primeira variável original ser maior que no caso 3 com variância 1. Em relação aos casos anteriores, nota-se que quanto menor a correlação entre as etapas do processo simulado, menor será a propagação dos erros entre as mesmas.




FIG.4. 7 – Propagação de Erros – Caso 3 – Cenário 1.

Nas FIG. 4.8 e 4.9, é fácil verificar as pressuposições dos modelos autoregressivos nas componentes principais do caso 3. Observa-se que as propriedades da aleatoriedade, independência e normalidade dos resíduos são obedecidas. Além disso, os p-valores dos testes

de Anderson – Darling são de 0.4568 no caso 3 com variância 1 e 0.7281 para o 3 com variância 3, indicando assim a normalidade dos resíduos.

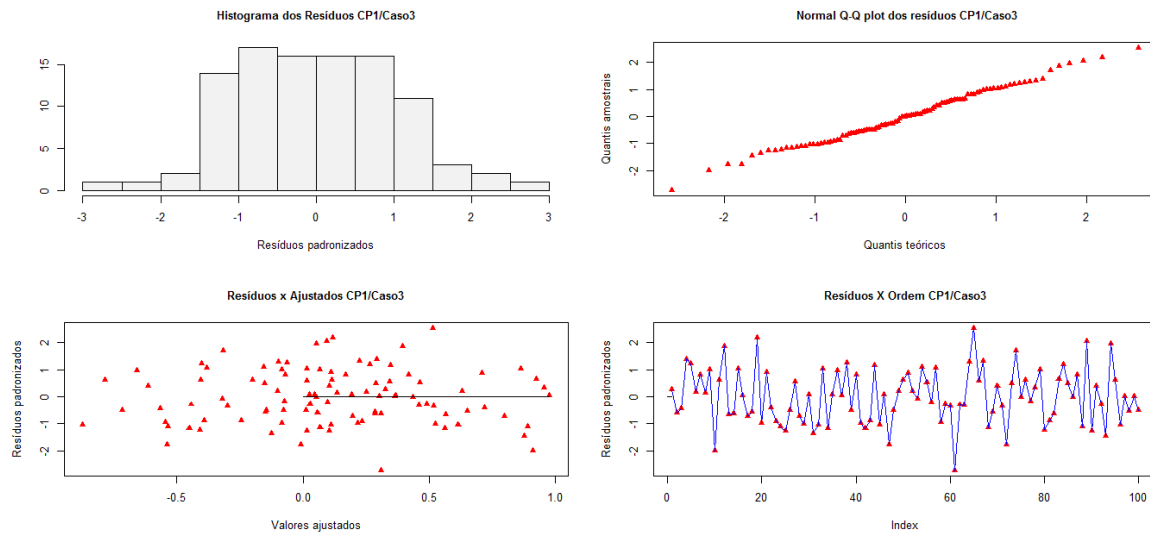


FIG.4. 8 – Análise de Resíduos CP1 – Caso 3 – Variância 1 - Cenário 1.

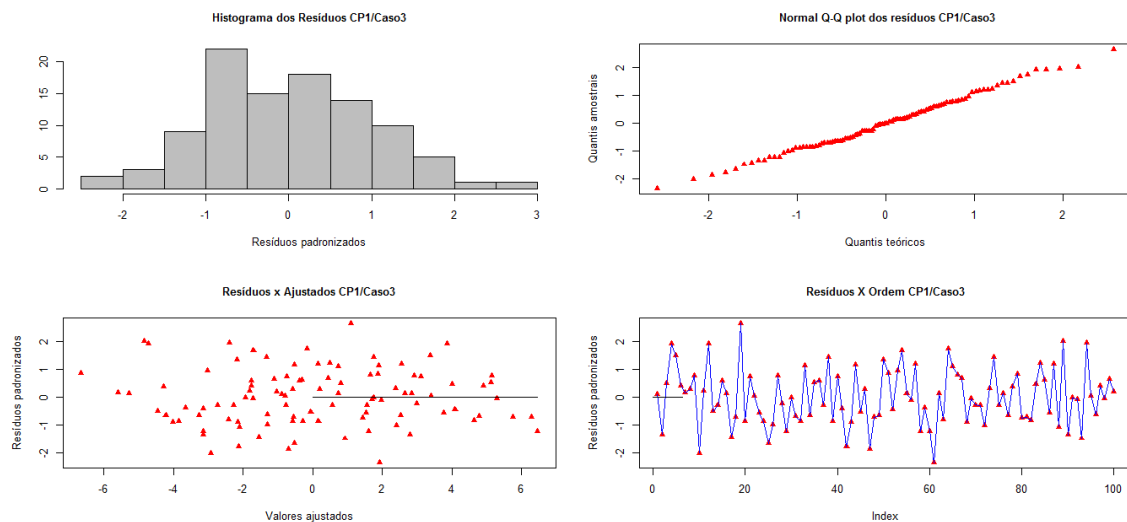


FIG.4. 9 - Análise de Resíduos CP1 – Caso 3 – Variância 3 - Cenário 1.

Pode-se afirmar que, no cenário 1, a maior parte da variabilidade presente no caso 1 estágio 2 foi gerada pelo estágio anterior, devido a forte correlação entre as variáveis analisadas. Para os outros casos, ocorreu menor propagação de erros devido a menor correlação entre os estágios.

4.1.2 MODELOS AUTOREGRESSIVOS NAS COMPONENTES PRINCIPAIS - CENÁRIO 2

O método multivariado, Análise de Componentes Principais, foi aplicado também no cenário 2 e em cada estágio 1, que é comum a todos os diferentes casos de correlação entre as etapas. Pela TAB.4.10, verifica-se que a primeira componente principal representa 78.60% da variabilidade do conjunto das quatro variáveis com distribuição normal com média zero e variância um, sendo assim a redução de quatro variáveis para uma única componente. A TAB.4.10 também revela que a primeira componente possui 92% da variância dos dados originais para o estágio 1 com variância igual a 3.

TAB.4. 10 - Percentual total da variância explicada pelas CPs Cenário 2 Estágios 1.

Estágio 1 - N(0,1)			
% CP1	% CP2	% CP3	%CP4
78.60%	21.40%	0.00%	0.00%
Estágio 1 - N(0,3)			
% CP1	% CP2	% CP3	%CP4
92.00%	8.00%	0.00%	0.00%

Já para o estágio 2, foram necessárias três ACP, uma para cada situação avaliada. De acordo com a TAB.4.11, é possível afirmar que as primeiras componentes principais dos casos 1, 2 e 3 com variância igual a 1 correspondem a 68.10% ,34.60% e 31.00% do todo, respectivamente. Já para os casos 1, 2 e 3 com variância igual a 3, elas são capazes de explicar 87.50% , 59.40% e 43% do todo, respectivamente, como mostra a TAB.4.11.

TAB.4. 11 - Percentual total da variância explicada pelas CPs Cenário 2 Estágios 2.

Estágio 2 - N(0,1)				
Caso	% CP1	% CP2	% CP3	%CP4
1 (90%)	68.10%	22.30%	5.40%	4.20%
2 (50%)	34.60%	28.00%	21.60%	15.80%
3 (30%)	31.00%	26.00%	24.60%	18.40%
Estágio 2 - N(0,3)				
Caso	% CP1	% CP2	% CP3	%CP4
1 (90%)	87.50%	8.30%	2.30%	1.90%
2 (50%)	59.40%	18.40%	13.80%	8.40%
3 (30%)	43.00%	25.10%	19.30%	12.60%

Para a correlação de 90% entre os estágios, foi aplicada a ACP, obtendo-se, assim, os parâmetros dos modelos autoregressivos para o caso 1 na TAB.4.12. No caso 1 com variância 1, o coeficiente linear do modelo é de -0.0225, já o angular é igual a 0.8351. O valor da variância adicionada a etapa atual é de 0.2045. A variância estimada no estágio 1 nesse caso é de 3.4199, enquanto que, para o estágio 2 é 2.5894. Os valores-p para os coeficientes angular e linear, são 7.98E-56 e 0.6250, respectivamente, indicando que apenas o coeficiente angular é significativo. O coeficiente de determinação apresenta valor de 92%, ou seja, próximo de 1. Para o caso 1 com variância 3, tem-se que o parâmetro de propagação de erros é de 0.9353 e o de adição da variância é de -0.0047, sendo apenas o primeiro significativo. O elevado valor de R^2 indica a variância da CP no estágio 2 explicada pela equação regressiva desse caso. As variâncias estimadas desse caso são de 13.2680 para o estágio 1 e 11.8101 para a etapa 2.

TAB.4. 12 – Parâmetros Modelo de Propagação – Caso 1 – Cenário 2.

Modelo Autoregressivo de Propagação – CP1 – Caso 1				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	0.8351	-	0.9353
$\sigma_{i,A}^2$	-	0.2045	-	0.2031
S_{ii}	3.4199	2.5894	13.2680	11.8101
$S_{i-1,i}$	-	2.8559	-	12.4098
$CP12 = 0.8351 * CP11 - 0.0225$			$CP12 = 0.9353 * CP11 - 0.0047$	
Estatística de ajuste do modelo				
$R^2_{\text{estágio 2}}$	0.9210		0.9828	
<i>Coefficientes</i>	<i>Valor- P</i>		<i>Coefficientes</i>	<i>Valor- P</i>
β_i	7.98E-56		β_i	2.78E-88
β_0	0.6250		β_0	0.9185

Já a TAB.4.13, contém os valores das variabilidades em cada etapa e entre elas. Esses valores são utilizados para a construção de gráficos, como mostra a FIG.4.10.

TAB.4. 13 – Variâncias em Estágios – Caso 1 – Cenário 2.

Etapas	N(0,1)		N(0,3)	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	3.4199	2.3849	13.2680	11.6070
Estágio 2	-	0.2045	-	0.2031
Total	3.4199	2.5894	13.2680	11.8101

A FIG.4.10 mostra que a maior parte dos erros presentes nas etapas 2 com variâncias 1 e 3 foram originadas nas etapas anteriores, aproximadamente 92% e 98% para cada uma das situações simuladas. Ademais, a transmissão dos desvios foi alta devido a forte correlação dos estágios (90%).




FIG.4. 10 – Propagação de Erros – Caso 1- Cenário 2.

A verificação dos resultados do caso 1 com variância 1 encontra-se na FIG.4.11, na qual consta que os resíduos gerados pelo modelo apresentam simetria em torno de zero no histograma de resíduos, não são correlacionados e a homoscedasticidade não é violada. O resultado do valor-p do teste de Anderson-Darling foi de 0.1437, portanto, os resíduos são normalmente distribuídos.

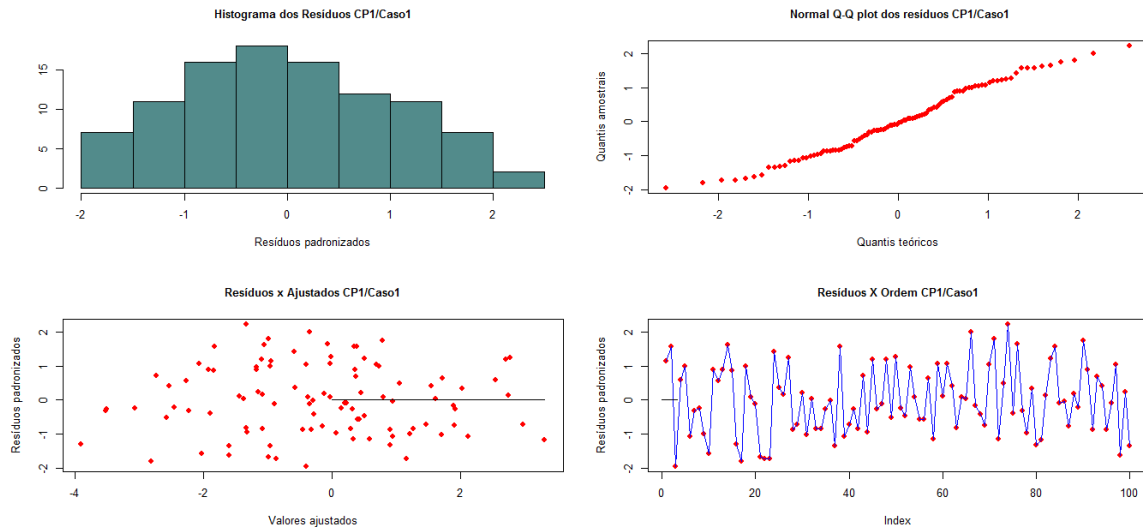


FIG.4. 11 – Análise de Resíduos CP1 – Caso 1 – Variância 1 – Cenário 2.

A análise de resíduos do caso 1 com variância 3 do segundo cenário encontra-se na FIG.4.12, pela qual se observa a aleatoriedade, linearidade e independência dos resíduos. O resultado do teste Anderson-Darling é 0.1018, ou seja, superior a α , adotado como 0.05, evidenciando a normalidade dos mesmos.

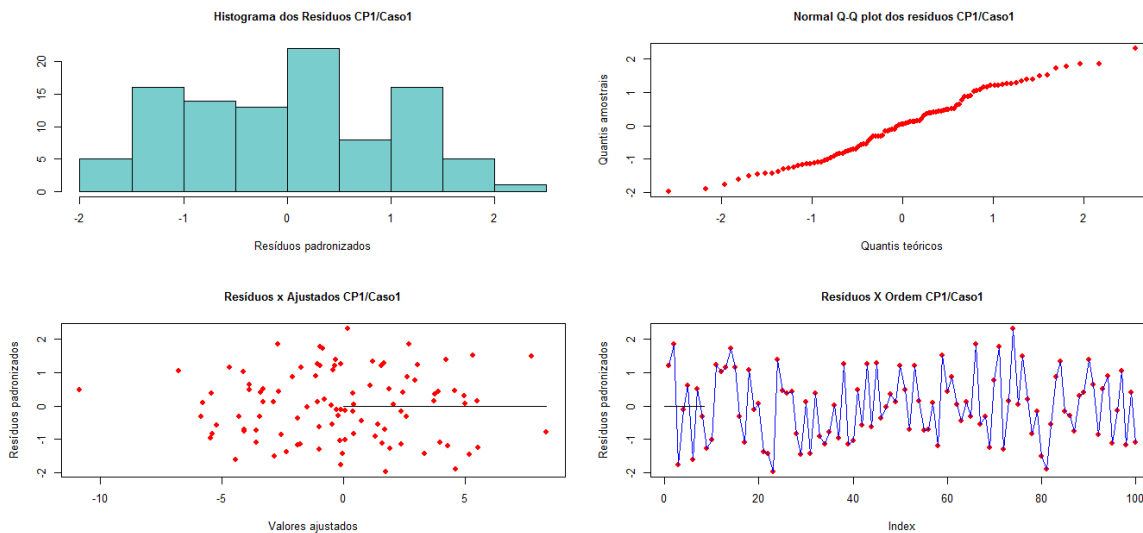


FIG.4. 12 - Análise de Resíduos CP1 – Caso 1- Variância 3 – Cenário 2.

Para a correlação de 50% entre os estágios, foi aplicada a Análise de Componentes Principais e os resultados referentes aos principais elementos constituintes dos modelos autoregressivos de propagação nas componentes principais e as variâncias estimadas em cada etapa e a covariância existente entre elas encontram-se na TAB.4.14. Os p-valores para cada

parâmetro do modelo caso 2 com variância 1 são de: 1.06E-10 para o β_i e 0.7393 para β_0 . O coeficiente linear pode ser desconsiderado desse modelo, pois o seu valor está acima de α , sendo considerado igual a 0.05. Além disso, o valor de R^2 é cerca de 35%. A equação de propagação de erros para o caso 2 com variância 3 apresenta o coeficiente angular significativo e um alto grau de variância explicada pela equação, em torno de 85%. Na TAB.4.15, verificam-se as variâncias dos estágios.

TAB.4. 14 – Parâmetros Modelo de Propagação – Caso 2 – Cenário 2.

Modelo Autoregressivo de Propagação – CP1 – Caso 2				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	0.3678	-	0.5969
$\sigma_{i,A}^2$	-	0.8666	-	0.7777
S_{ii}	3.4199	1.3291	13.2680	5.5057
$S_{i-1,i}$	-	1.2577	-	7.9203
$CP12 = 0.3678 * CP11 - 0.0316$			$CP12 = 0.5969 * CP11 - 0.0046$	
Estatística de ajuste do modelo				
R^2 estágio 2	0.3480		0.8587	
<i>Coeficientes</i>	<i>Valor- P</i>		<i>Coeficientes</i>	<i>Valor- P</i>
β_i	1.06E-10		β_i	1.94E-43
β_0	0.7393		β_0	0.9587

TAB.4. 15– Variâncias em Estágios – Caso 2 – Cenário 2.

<i>Etapas</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	3.4199	0.4626	13.2680	4.7280
Estágio 2	-	0.8666	-	0.7777
Total	3.4199	1.3291	13.2680	5.5057

Esse segundo caso apresentou uma redução na transmissão dos desvios de um estágio para o outro. Na FIG.4.13, observa-se que, no estágio 2 com variância 1, 34.80% das variações possuem origem na etapa anterior e 65.20% no próprio estágio. No estágio 2 com

variância 3, a propagação de erros foi bastante acentuada, aproximadamente 86%.




FIG.4. 13 – Propagação de Erros – Caso 2 – Cenário 2.

As condições para a validação do modelo do caso com dados normalmente distribuídos com média 0 e variância 1 podem ser observadas na FIG.4.14. As propriedades de independência e aleatoriedade dos resíduos são obedecidas devido ao aspecto de não existência de um padrão na disposição dos resultados. O valor-p do teste AD foi de 0.0476, logo, não apresentam distribuição Normal.

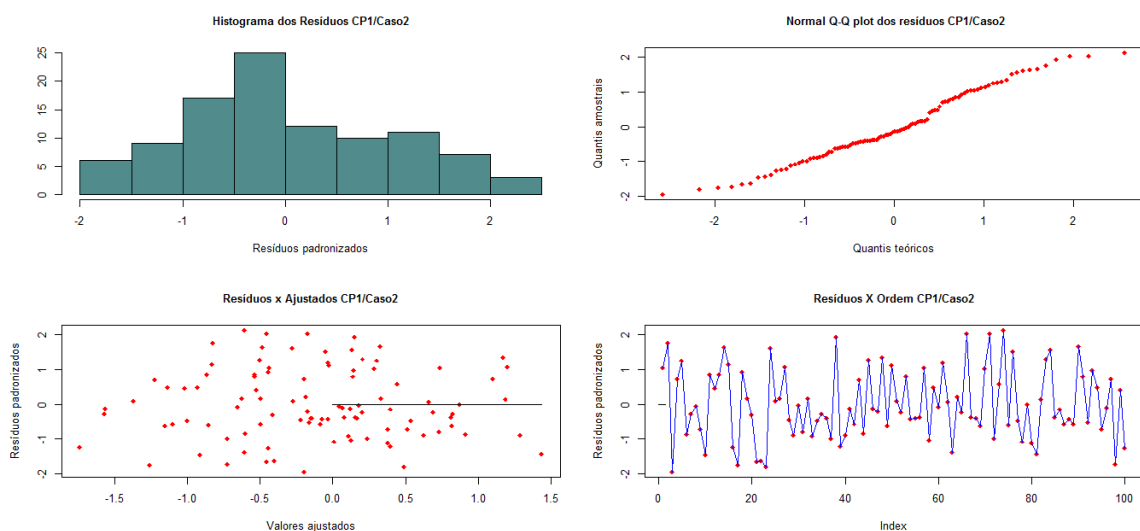


FIG.4. 14 – Análise de Resíduos CP1 – Caso 2 – Variância 1 – Cenário 2.

Pela FIG.4.15, é possível verificar as condições de normalidade, aleatoriedade e independência dos resíduos para o caso 2 com distribuição N(0,3). O valor-p do teste AD é de 0.1212, constatando assim, a presença da distribuição normal nos resíduos.

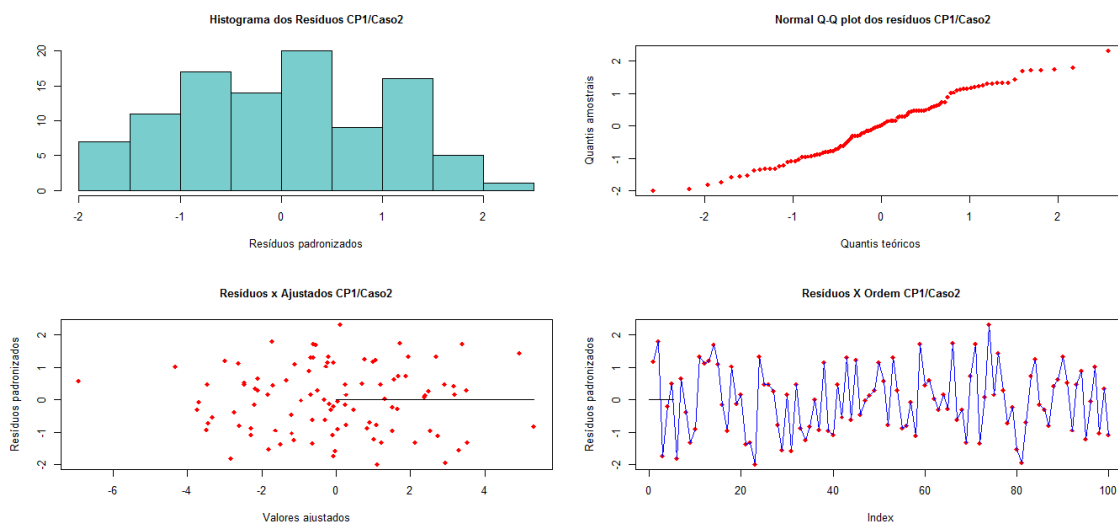


FIG.4. 15 - Análise de Resíduos CP1 – Caso 2 – Variância 3 – Cenário 2.

Os resultados obtidos com a correlação entre as etapas de 30% encontram-se nas TAB. 4.16, 4.17 e nas FIG.4.16 e 4.17.

TAB.4. 16 – Parâmetros Modelo de Propagação – Caso 3 – Cenário 2.

Modelo Autoregressivo de Propagação – CP1 – Caso 3				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	-0.0854	-	0.4209
$\sigma_{i,A}^2$	-	1.2459	-	0.8787
S_{ii}	3.4199	1.2709	13.2680	3.2288
$S_{i-1,i}$	-	-0.2920	-	5.5841
$CP12 = -0.0854 * CP11 - 0.0045$			$CP12 = 0.4209 * CP11 - 0.0007$	
Estatística de ajuste do modelo				
R^2 estágio 2	0.0196		0.7279	
<i>Coeficientes</i>	<i>Valor- P</i>		<i>Coeficientes</i>	<i>Valor- P</i>
β_i	0.1646		β_i	1.89E-29
β_0	0.9683		β_0	0.9944

Os principais resultados dos modelos dados pelas primeiras componentes principais do terceiro caso estão na TAB. 4.16. Nota-se que o valor do coeficiente R^2 do caso 3 com

variância 1 está próximo de zero, logo, a variável não explica a variável resposta. Além do mais, os p- valores dos coeficientes angular e linear da equação desse caso não são inferiores a α , considerado como 5%. Enquanto que, a equação regressiva obtida para o caso 3 com variância 3 apresenta o coeficiente angular significativo, devido ao valor-p ser menor que α (0.05), já o valor do coeficiente de determinação é de 72.79%. Já a TAB.4.17 apresenta as variâncias totais e transmitidas entre os estágios 1 e 2 para o caso 3 com distribuição normal com média 0 e variância 1 e caso 3 também normalmente distribuído com média 0 e variância igual a 3.

TAB.4. 17 - Variâncias em Estágios – Caso 3 – Cenário 2.

Etapas	N(0,1)		N(0,3)	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	3.4199	0.0250	13.2680	2.3501
Estágio 2	-	1.2459	-	0.8787
Total	3.4199	1.2709	13.2680	3.2288

A FIG.4.16 permite a melhor visualização da propagação da variabilidade entre as etapas analisadas, revelando que somente 1.96% dos desvios do estágio 2 com variância 1 foram gerados pela etapa anterior, já no caso 3 com variância 3, essa propagação é bastante elevada, cerca de 73%.




FIG.4. 16 - Propagação de Erros – Caso 3 – Cenário 2.

No caso 3 com variância 1, o modelo autoregressivo multivariado de propagação não apresentou coeficiente angular significativo, já que o valor-p do parâmetro de propagação é superior a α , adotado como 5%. Isso se deve ao fato dos dados estarem moderadamente correlacionados entre si e com baixa correlação entre as etapas. Além disso, os dados originais desse caso possuem menor variância em relação ao caso 3 com distribuição $N(0,3)$. A análise de resíduos para o caso 3 com variância igual a 3 encontra-se na FIG.4.17, pela qual se verifica que os estão dispostos em torno de uma reta; há uma nuvem aleatória de pontos ao redor do zero e não há nenhum padrão entre os pontos. Além disso, o valor do teste de normalidade é de 0.2559.

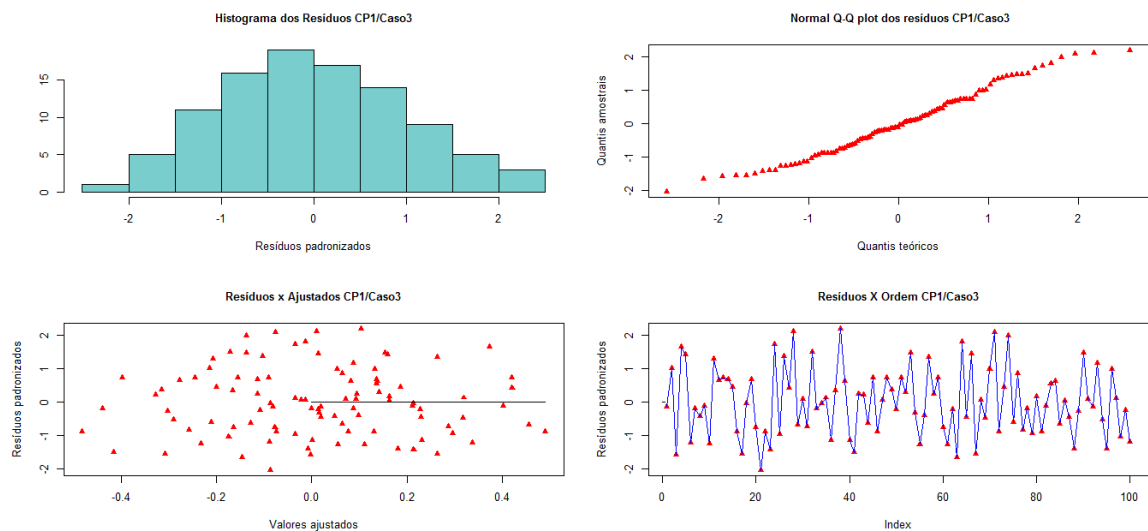


FIG.4. 17 - Análise de Resíduos - Caso 3 - Variância 3 – Cenário 2.

Em comparação aos casos do cenário 1, o cenário 2 apresentou uma maior redução dos desvios propagados entre etapas, principalmente, nos casos 2 e 3, pois as variáveis presentes nesse cenário estão moderadamente correlacionadas. Os modelos encontrados nessa simulação apresentam coeficientes angulares significativos e os lineares não significativos em termos do nível de significância adotado, exceto para o caso 3 com distribuição Normal média zero e variância 1. Nesse caso, o modelo não apresentou coeficiente angular significativo devido à baixa correlação entre as etapas e menor variância nos dados originais.

4.1.3 MODELOS AUTOREGRESSIVOS NAS COMPONENTES PRINCIPAIS - CENÁRIO 3

A partir da Análise de Componentes Principais, percebe-se que no cenário 3 também é necessário o uso de uma única CP para representar mais de 70% da variância total nas primeiras etapas, conforme TAB.4.18.

TAB.4. 18 - Percentual total da variância explicada pelas CPs Cenário 3 Estágios 1.

Estágio 1 - N(0,1)			
% CP1	% CP2	% CP3	%CP4
75.10%	24.90%	0.00%	0.00%
Estágio 1 - N(0,3)			
% CP1	% CP2	% CP3	%CP4
77.30%	22.70%	0.00%	0.00%

Também para os estágios 2 com variâncias um e três, são necessárias a utilização de uma componente principal. Pela TAB.4.19, nota-se que as primeiras CPs representam, 62.50%, 31.90% e 29.10% do todo para os casos 1,2 e 3 com variâncias iguais a um, respectivamente. Para os casos 1, 2 e 3 com variâncias iguais a três, as primeiras componentes explicam 66.90%, 37.80% e 31.10% da variância total dos dados originais, respectivamente.

TAB.4. 19 - Percentual total da variância explicada pelas CPs Cenário 3 Estágios 2.

Estágio 2 - N(0,1)				
Caso	% CP1	% CP2	% CP3	%CP4
1 (90%)	62.50%	25.60%	6.70%	5.20%
2 (50%)	31.90%	28.00%	22.40%	17.70%
3 (30%)	29.10%	26.10%	24.60%	20.20%
Estágio 2 - N(0,3)				
Caso	% CP1	% CP2	% CP3	%CP4
1 (90%)	66.90%	22.40%	6.10%	4.60%
2 (50%)	37.80%	24.40%	19.70%	18.10%
3 (30%)	31.10%	26.50%	21.80%	20.50%

Pela ACP no caso 1, o modelo autoregressivo para a CP1 do caso 1 com variância 1 está na TAB.4.20. Os parâmetros linear e angular são iguais a -0.0088 e 0.8607, e os p-valores iguais a 0.8421 e 1.0E-53, respectivamente. Na mesma tabela, também consta os principais

parâmetros da equação regressiva para o caso 1 normalmente distribuído com média 0 e variância 3, assim como, a estatística de ajuste do modelo, pela qual, pode-se afirmar que a equação apresenta coeficiente angular significativo, devido ao baixo valor-p desse parâmetro de propagação.

TAB.4. 20 – Parâmetros Modelo de Propagação – Caso 1 – Cenário 3.

Modelo Autoregressivo de Propagação – Caso 1				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	0.8607	-	0.9059
$\sigma_{i,A}^2$	-	0.1908	-	0.2244
S_{ii}	2.6979	2.1896	4.2139	3.6830
$S_{i-1,t}$	-	2.3222	-	3.8176
$CP12 = 0.8607 * CP11 - 0.0088$			$CP12 = 0.9059 * CP11 - 0.0115$	
Estatística de ajuste do modelo				
$R^2_{\text{estágio 2}}$	0.9128		0.9391	
<i>Coefficientes</i>	<i>Valor- P</i>		<i>Coefficientes</i>	<i>Valor- P</i>
β_i	1.0E-53		β_i	2.35E-61
β_0	0.8421		β_0	0.8110

Na TAB.4.21, têm-se as variâncias obtidas relacionadas à CP1 em cada estágio.

TAB.4. 21 – Variâncias em Estágios – Caso 1 – Cenário 3.

<i>Etapas</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	2.6979	1.9988	4.2139	3.4586
Estágio 2	-	0.1908	-	0.2244
Total	2.6979	2.1896	4.2139	3.6830

A partir dos valores da TAB.4.21, a FIG.4.18 foi gerada para melhor visualização da propagação dos erros entre as etapas. Na segunda etapa para a CP1 caso 1 com variância 1, percebe-se que 91.28% dos erros são da etapa anterior e apenas 8.72% das variações são da

própria etapa. A alta propagação dos erros deve-se ao fato de que a primeira CP explica 62.50% da variabilidade total do estágio 2 com variância 1. Para o segundo estágio do caso 1 com variância 3, tem-se que a propagação dos erros é de 93.91%, como mostra a FIG.4.18.




FIG.4. 18 – Propagação de Erros – Caso 1 - Cenário 3.

A análise de resíduos para o caso 1 com variância 1 encontra-se na FIG.4.19. Os resultados encontrados para o modelo indicam homoscedasticidade e não há correlação entre os resíduos. Enquanto que, o valor-p do teste de Anderson-Darling de 0.0319 evidencia a não normalidade dos erros.

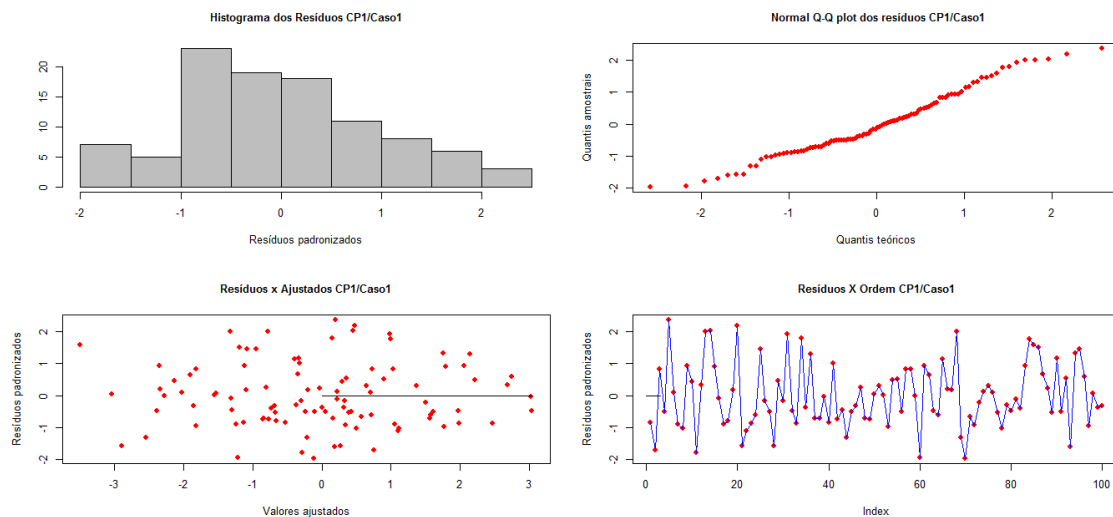


FIG.4. 19 – Análise de Resíduos CP1 – Caso 1 – Variância 1 – Cenário 3.

A FIG.4.20 retrata a análise de resíduos referentes ao modelo da CP1 do caso 1 com variância 3. Nesse caso, os resíduos obedecem às condições de aleatoriedade e independência

impostas pelo modelo. Entretanto, o valor-p do teste AD é de 0.01472, logo, os resíduos não são normalmente distribuídos, levando em consideração o nível de significância α , adotado como 0.05. Logo, os resíduos padronizados não necessariamente obedecem a condição de normalidade.

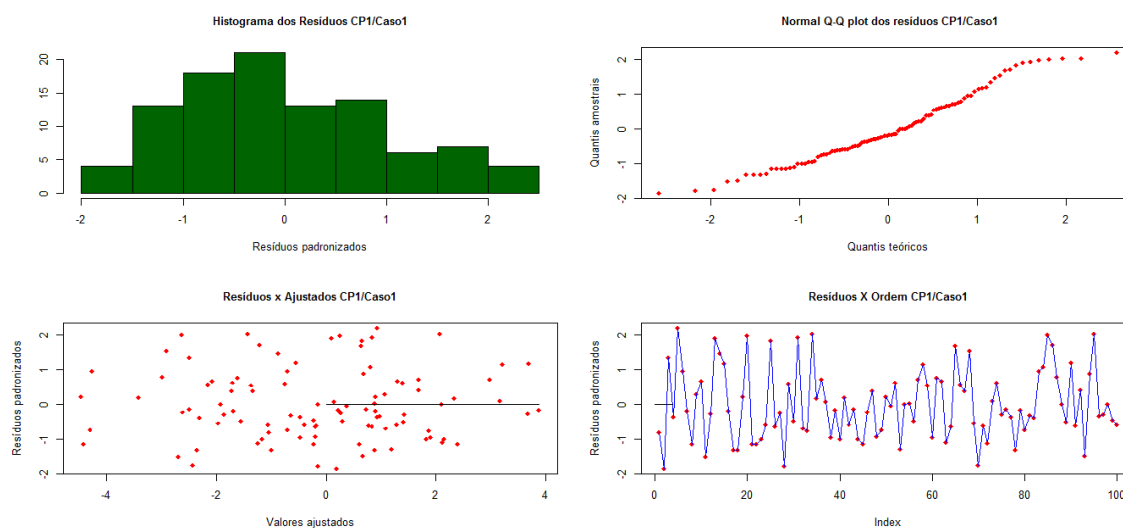


FIG.4. 20 - Análise de Resíduos CP1 – Caso 1 – Variância 3 – Simulação 3.

Os resultados do segundo caso para a CP1 são fornecidos pelas TAB.4.22, 4.23 e pelas FIG.4.21, 4.22 e 4.23.

TAB.4. 22 – Parâmetros Modelo de Propagação – Caso 2 – Cenário 3.

Modelo Autoregressivo de Propagação – Caso 2				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	0.4258	-	0.5218
$\sigma_{i,A}^2$	-	0.7666	-	1.0126
S_{it}	2.6979	1.2557	4.2139	2.1598
$S_{i-1,i}$	-	1.1488	-	2.1987
$CP12 = 0.4258 * CP11 + 0.0046$			$CP12 = 0.5218 * CP11 - 0.0122$	
Estatística de ajuste do modelo				
R^2 estágio 2	0.3895		0.5312	
<i>Coefficientes</i>	<i>Valor- P</i>		<i>Coefficientes</i>	<i>Valor- P</i>
β_i	3.99E-12		β_i	8.29E-18
β_0	0.9584		β_0	0.9053

A TAB.4.22 apresenta os dados relacionados aos modelos autoregressivos encontrados, como, os valores dos coeficientes, as variâncias em cada estágio, covariâncias entre eles e a estatística de ajuste dos modelos, pela qual pode-se verificar a validação dos coeficientes das equações obtidas. Pelos valores-p dos parâmetros β_0 e β_1 , pode-se afirmar que os modelos apresentam as variáveis explicativas significativas nos casos 2 com variâncias 1 e 3, considerando nível de significância de 5%.

Pela TAB.4.23, verifica-se o quanto da variância presente nos primeiros estágios com dados normalmente distribuídos com média 0 e variância 1 ou média 0 e variância 3 foi propagado para as etapas posteriores e o quanto foi gerado pelos próprios estágios 2.

TAB.4. 23– Variâncias em Estágios – Caso 2 – Cenário 3.

Etapas	N(0,1)		N(0,3)	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	2.6979	0.4891	4.2139	1.1472
Estágio 2	-	0.7666	-	1.0126
Total	2.6979	1.2557	4.2139	2.1598

Os resultados da CP1 mostram que grande parte da variabilidade é fornecida pela segunda etapa, cerca de 40% é referente ao estágio anterior para o caso 2 com variância 1, conforme apresentado pela FIG.4.21. Porém, no caso 2 com variância 3, 53.12% dos erros presentes no estágio 2 foram gerados no estágio 1.




FIG.4. 21 – Propagação de Erros – Caso 2 – Cenário 3.

Pela FIG.4.22, fica evidenciado que os resultados obtidos pelo modelo para a primeira componente principal do caso 2 com variância 1 apresentam a não violação dos pressupostos de independência e aleatoriedade. Através do teste de AD, valor-p de 0.0288, é possível rejeitar a hipótese de normalidade dos resíduos padronizados.

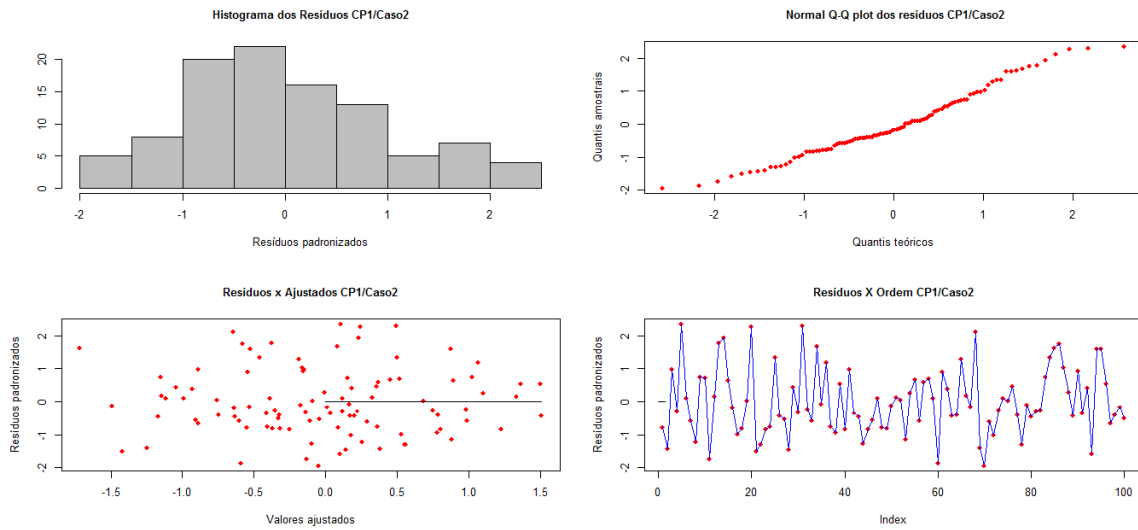


FIG.4. 22 – Análise de Resíduos CP1 – Caso 2 – Variância 1 – Cenário 3.

Para o caso 2 com variância 3, os resultados da análise de resíduos encontram-se na FIG.4.23. A FIG.4.23 revela a tendência de aleatoriedade e independência dos resíduos gerados pelo modelo de propagação da primeira CP. Entretanto, o resultado do teste de AD mostra que os resíduos gerados não possuem distribuição normal, devido ao valor-p de 0.0395 ser menor que o nível de significância de 5%.

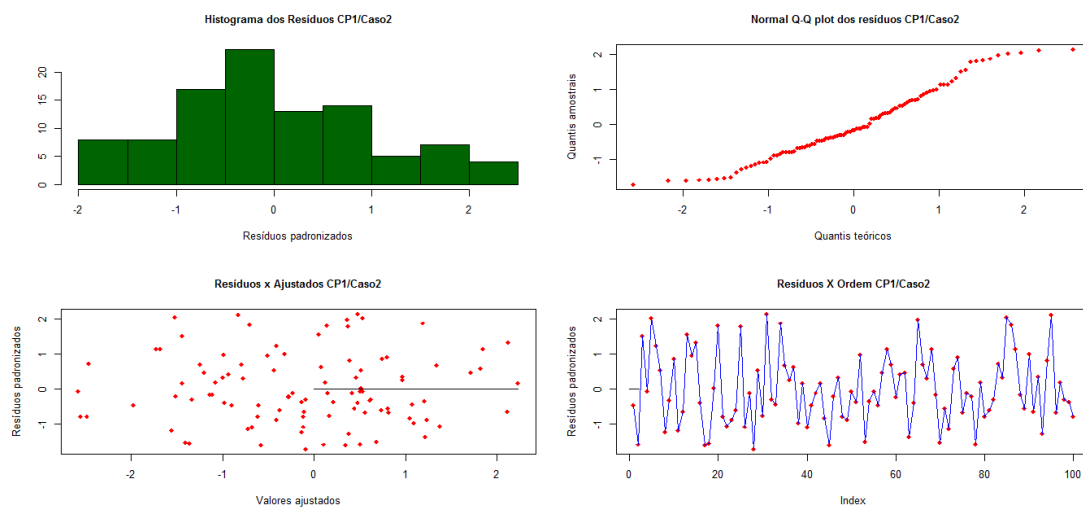


FIG.4. 23 - Análise de Resíduos CP1 – Caso 2 – Variância 3 – Cenário 3.

Os principais resultados dos modelos fornecidos pelas componentes principais dos casos 3 com variâncias 1 e 3 estão na TAB. 4.24, na qual são encontrados os parâmetros de adição e de propagação de variância e seus respectivos p-valores. Ao verificar a estatística de ajuste do modelo obtido no caso 3 com variância 3, pode-se concluir que não apresenta coeficiente angular significativo, pois o p-valor está acima do nível de significância de 5%. No entanto, no caso 3 com variância 3, a equação regressiva encontrada apresenta o coeficiente angular significativo.

TAB.4. 24 – Parâmetros Modelo de Propagação – Caso 3 – Cenário 3.

Modelo Autoregressivo de Propagação – Caso 3				
<i>Parâmetros</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	<i>Estágio 1</i>	<i>Estágio 2</i>	<i>Estágio 1</i>	<i>Estágio 2</i>
β_i	-	0.0434	-	0.2784
$\sigma_{i,A}^2$	-	1.1433	-	1.1784
S_{ii}	2.6979	1.1484	4.2139	1.5050
$S_{i-1,i}$	-	0.1170	-	1.1732
CP12 = 0.5075 * CP11 – 0.0041			CP12 = 0.2784 * CP11 + 0.0212	
Estatística de ajuste do modelo				
$R^2_{\text{estágio 2}}$	0.0044		0.2170	
<i>Coeficientes</i>	<i>Valor- P</i>		<i>Coeficientes</i>	<i>Valor- P</i>
β_i	0.5112		β_i	1.04E-06
β_0	0.4025		β_0	0.8474

Os valores das variâncias presentes em cada um dos estágios estão dispostos na TAB.4.25, pela qual são gerados os gráficos da FIG.4.24.

TAB.4. 25 - Variâncias em Estágios – Caso 3 – Cenário 3.

<i>Etapas</i>	<i>N(0,1)</i>		<i>N(0,3)</i>	
	Variância Estágio 1	Variância Estágio 2	Variância Estágio 1	Variância Estágio 2
Estágio 1	2.6979	0.4891	4.2139	0.3267
Estágio 2	-	0.7666	-	1.1784
Total	2.6979	1.2557	4.2139	1.5050

De acordo com a FIG.4.24, tem-se que somente 0.44% dos erros do estágio 1 são transmitidos para o estágio 2 no caso 3 com variância 3. Já no caso 3 com variância 3, a propagação de erros entre as etapas é de 21.70%.




FIG.4. 24 – Propagação de Erros – Caso 3 – Cenário 3.

Como visto anteriormente, o modelo autoregressivo de propagação do caso 3 com variância 3 não apresentou β_1 significativo. Isso ocorreu pelo fato das variáveis estarem fracamente correlacionadas e pela menor variância dos dados. Já o caso 3 com variância 3, apresentou um modelo com coeficiente significativo e os principais gráficos de análise de resíduos estão na FIG.4.25. Observa-se que os pontos não são correlacionados, pois não apresentam nenhum padrão. O teste de normalidade AD apresenta valor-p de 0.0395, indicando a não normalidade dos resíduos.

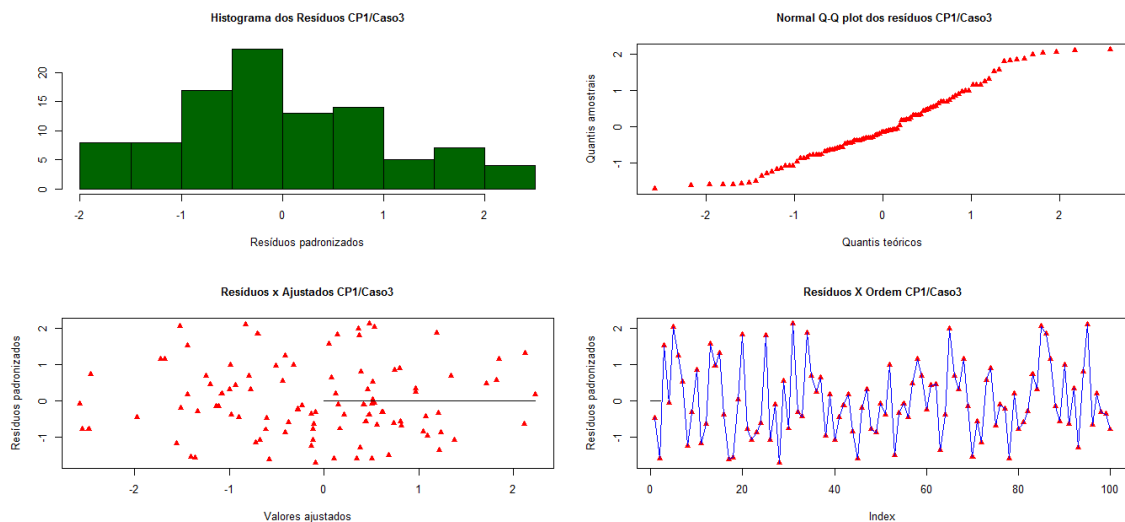


FIG.4. 25 - Análise de Resíduos – Caso 3 – Variância 3 – Cenário 3.

Em comparação com os cenários 1 e 2, o cenário 3 apresentou uma considerável redução dos erros propagados entre dois estágios, pois as variáveis presentes em cada uma delas são fracamente correlacionadas. Todos os modelos apresentados para os casos 1 e 2 com distribuição $N(0,1)$ apresentam coeficientes angulares significativos, pois os seus respectivos p-valores são menores que o nível de significância de 5%, exceto no terceiro caso. Enquanto que, todos os casos com distribuição $N(0,3)$ possuem modelos com coeficientes angulares significativos.

4.2 ESTUDO DE CASO: MODELOS AUTOREGRESSIVOS NO PROCESSO PRODUTIVO DE VEÍCULOS

Conforme apresentado na metodologia, quando um conjunto de dados não apresenta todas as variáveis correlacionadas entre si, é necessário dividir os dados em grupos cujos elementos sejam correlacionados entre si. Por isso nesse estudo de caso, foi utilizada a análise de agrupamento devido ao número elevado de variáveis e para formar grupos com elementos semelhantes entre si. Para tanto será empregada a técnica de análise de agrupamento denominada de ligação por média, devido a sua menor sensibilidade a ruídos. O dendrograma apresentado pela FIG.4.26 permite a visualização dos agrupamentos entre os 12 pontos da porta traseira nos 17 veículos analisados.




FIG.4. 26 - Dendrograma Ligação Média - Carro.

Pela FIG.4.26, foi possível dividir os dados em cinco grupos, conforme TAB.4.26, pois os valores dos coeficientes de correlação em cada grupo formado são elevados, acima de 70%, assim maior é a similaridade entre os seus elementos.

TAB.4. 26 – Agrupamentos dos dados - Carro.

GRUPOS	PONTOS	MÉDIA	VARIÂNCIA
G1	1 e 12	6.0735	2.6811
G2	2 e 3	6.1618	2.0033
G3	4, 8 e 9	6.1176	3.5504
G4	10 e 11	6.5956	1.4870
G5	5, 7 e 6	6.0735	3.4871

Após a análise de agrupamento dos pontos da porta, foram obtidas as componentes principais para cada um dos cinco grupos. A TAB. 4.27 apresenta as variâncias explicadas por cada componente de cada grupo em cada etapa, Chaparia e Montagem.

TAB.4. 27 - Percentual da Variância explicada pelas CP's - Carro.

GRUPO	Componente Principal	% Variância Explicada
G1	CP1 Chaparia	68.10%
	CP2 Chaparia	31.90%
	CP1 Montagem	70.80%
	CP2 Montagem	29.20%
G2	CP1 Chaparia	84.30%
	CP2 Chaparia	15.70%
	CP1 Montagem	83.40%
	CP2 Montagem	16.60%
G3	CP1 Chaparia	60.90%
	CP2 Chaparia	34.20%
	CP3 Chaparia	4.90%
	CP1 Montagem	80.80%
	CP2 Montagem	15.40%
	CP3 Montagem	3.90%
G4	CP1 Chaparia	58.60%
	CP2 Chaparia	41.40%
	CP1 Montagem	81.10%
	CP2 Montagem	18.90%
G5	CP1 Chaparia	72%
	CP2 Chaparia	16.90%
	CP3 Chaparia	11.10%
	CP1 Montagem	48.50%
	CP2 Montagem	30.40%
	CP3 Montagem	21.10%

Analisando a TAB.4.27 verificou-se que os grupos 1, 2, 3, 4 e 5 podem ser representados por uma única componente, visto que cerca de 60-80% da proporção da variância total é explicada por estas componentes. Assim, é plausível que as cinco componentes possam substituir as doze variáveis originais sem perda de informação.

Para o primeiro grupo, os resultados obtidos estão nas TAB. 4.28, 4.29 e nas FIG. 4.27 e 4.28. A TAB. 4.28 apresenta os resultados do modelo autoregressivo na primeira componente principal para o grupo 1. Por essa tabela, nota-se que β_1 é significativo, pois o valor-p desse coeficiente é de 0.0010, já o coeficiente de determinação é de aproximadamente 50%.

TAB.4. 28 - Parâmetros Modelo de Propagação – Grupo 1 – Carro.

Modelo Autoregressivo de Propagação – CP1 – Grupo 1		
<i>Parâmetros</i>	<i>Chaparia</i>	<i>Montagem</i>
β_i	-	0.7779
$\sigma_{i,A}^2$	-	0.2412
S_{ii}	0.4402	0.5076
$S_{i-1,i}$	-	0.3424
$CP1Mont. = 0.7779 * CP1Chap. + 0.6125$		
Estatística de ajuste do modelo		
$R^2_{montagem}$	0.524849	
<i>Coefficientes</i>	<i>Valor- P</i>	
β_1	0.0010	
β_0	0.7362	

Os valores referentes às variâncias totais de cada estágio e a variância transmitida entre eles são apresentados na TAB.4.29.

TAB.4. 29 - Variâncias em Estágios – Grupo 1 – Carro.

<i>Etapas</i>	<i>Variância Chaparia</i>	<i>Variância Montagem</i>
Chaparia	0.4402	0.2664
Montagem	-	0.2412
Total	0.4402	0.5076

Observa-se que grande parte dos desvios gerados na Chaparia é propagada para a etapa da Montagem. Pela FIG.4.27, observa-se que 52.48% da variância na etapa da Montagem

correspondem aos erros gerados na etapa da Chaparia. Neste grupo, ocorreu a maior propagação de erros entre essas etapas do processo produtivo.




FIG.4. 27 - Propagação de Erros – Grupo 1 – Carro.

De acordo com a FIG.4.28, o histograma dos resíduos não apresenta simetria em torno do zero devido à amostra ser pequena, apenas 17 valores. O p-valor do teste de Anderson-Darling é de 0.4054, confirmando a condição de normalidade dos resultados do modelo para a primeira componente do grupo 1 do veículo, considerando α igual a 0.05. Além disso, os gráficos de resíduos versus valores ajustados e o de resíduos versus a ordem de coleta indicam aleatoriedade e independência dos resíduos, respectivamente.

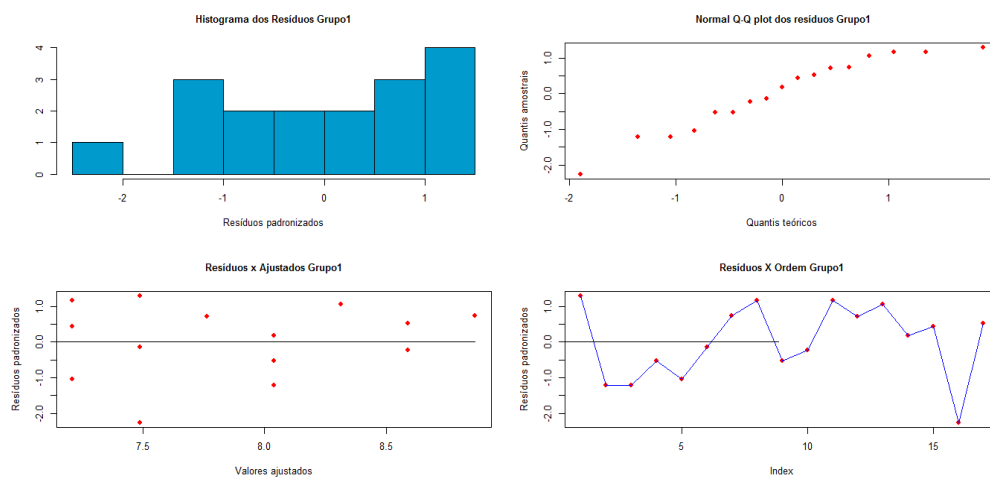


FIG.4. 28 – Análise de Resíduos - Grupo 1 – Carro.

Para o grupo 2, os resultados encontram-se nas TAB.4.30, 4.31 e nas FIG 4.29 e 4.30. A TAB.4.30 contém a equação do modelo e os p-valores dos coeficientes angular e linear. Nota-se que o modelo autoregressivo obtido apresenta β_1 significativo, pois o p-valor é menor que o nível de significância adotado, α igual a 5%.

TAB.4. 30 - Parâmetros Modelo de Propagação – Grupo 2 – Carro.

Modelo Autoregressivo de Propagação – CP1 – Grupo 2		
<i>Parâmetros</i>	<i>Chaparia</i>	<i>Montagem</i>
β_i	-	0.6131
$\sigma_{i,A}^2$	-	0.7825
S_{ii}	0.8561	1.1043
$S_{i-1,i}$	-	0.5249
$CP1Mont = 0.6131 * CP1Chap + 2.1295$		
Estatística de ajuste do modelo		
$R^2_{montagem}$	0.291441	
Coeficientes	Valor- P	
β_i	0.0253	
β_0	0.3795	

A TAB.4.31 apresenta a variabilidade entre as etapas avaliadas e a variância total de cada uma delas.

TAB.4. 31 - Variâncias em Estágios – Grupo 2 – Carro.

<i>Etapas</i>	<i>Chaparia</i>	<i>Montagem</i>
Chaparia	0.8561	0.3218
Montagem	-	0.7825
Total	0.8561	1.1043

Segundo a FIG. 4.29, nota-se que 70.86% da variância total da Montagem correspondem a própria etapa, ou seja, ainda ocorre pouca transferência de erros da Chaparia para a Montagem.




FIG.4. 29 - Propagação de Erros – Grupo 2 – Carro.

Pela FIG.4.30, observa-se que o histograma também não apresentou simetria. O gráfico de Resíduos x Ajustados e o gráfico de Resíduos x Ordem de coleta validam a homoscedasticidade e a não correlação dos erros. O teste de AD também foi aplicado e o valor-p foi de 0.0026, sendo inferior a 5%, significando que os resíduos não seguem distribuição normal para o grupo 2.

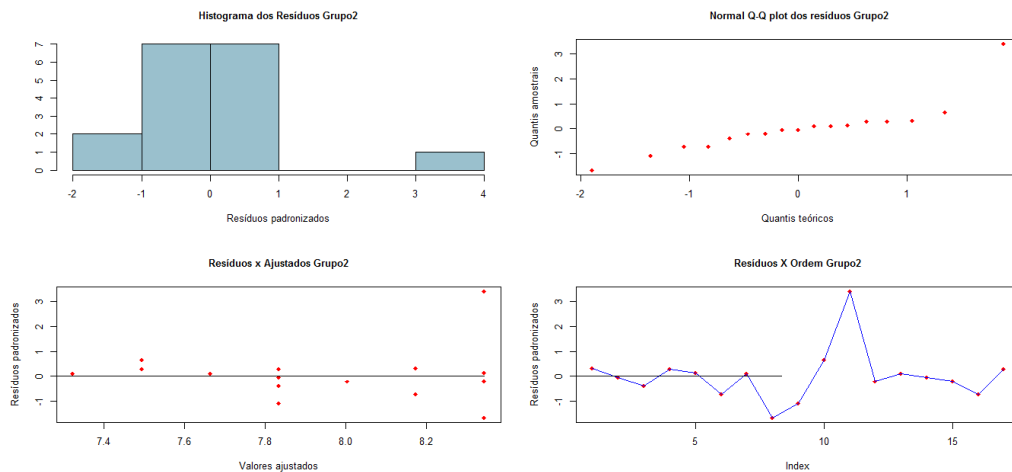


FIG.4. 30 – Análise de Resíduos - Grupo 2 – Carro.

As TAB.4.32, 4.33, e as FIG.4.31 e 4.32 revelam as principais informações obtidas pela aplicação do modelo autoregressivo na primeira componente do grupo 3. A TAB.4.32 apresenta os parâmetros e a equação do modelo. Pela estatística de ajuste do modelo, pode-se afirmar que o coeficiente angular é significativo nesse grupo, já que o valor-p desse parâmetro é inferior ao nível de significância de 5%.

TAB.4. 32 - Parâmetros Modelo de Propagação – Grupo 3 – Carro.

Modelo Autoregressivo de Propagação – CP1 – Grupo 3		
<i>Parâmetros</i>	<i>Chaparia</i>	<i>Montagem</i>
β_i	-	0.7715
$\sigma_{i,A}^2$	-	1.5432
S_{ii}	0.8183	2.0302
$S_{i-1,i}$	-	0.6313
$CP1Mont. = 0.7715 * CP1Chap. + 0.4642$		
Estatística de ajuste do modelo		
$R^2_{montagem}$	0.2399	
<i>Coefficientes</i>	<i>Valor- P</i>	
β_i	0.0459	
β_0	0.9112	

Já, a TAB.4.33 revela as variâncias presentes em cada fase do processo.

TAB.4. 33 - Variâncias em Estágios – Grupo 3 – Carro.

<i>Etapas</i>	<i>Chaparia</i>	<i>Montagem</i>
Chaparia	0.8183	0.4870
Montagem	-	1.5432
Total	0.8183	2.0302

De acordo com a FIG.4.31, 23.99% dos erros são propagados entre os estágios.




FIG.4. 31 - Propagação de Erros – Grupo 3 – Carro.

Para o grupo 3, a FIG.4.32 revela os principais gráficos que auxiliam na análise de resíduos da qualidade de ajuste do modelo obtido pela regressão linear da primeira CP. Nesse

grupo, não se pode afirmar que os resíduos apresentam aleatoriedade e são independentes, devido a presença de um padrão nos pontos. Quanto à normalidade dos resíduos, pode-se afirmar que os mesmos não são normais, pois o valor-p do teste de AD é de 0.0468, levando em consideração α igual a 0.05.

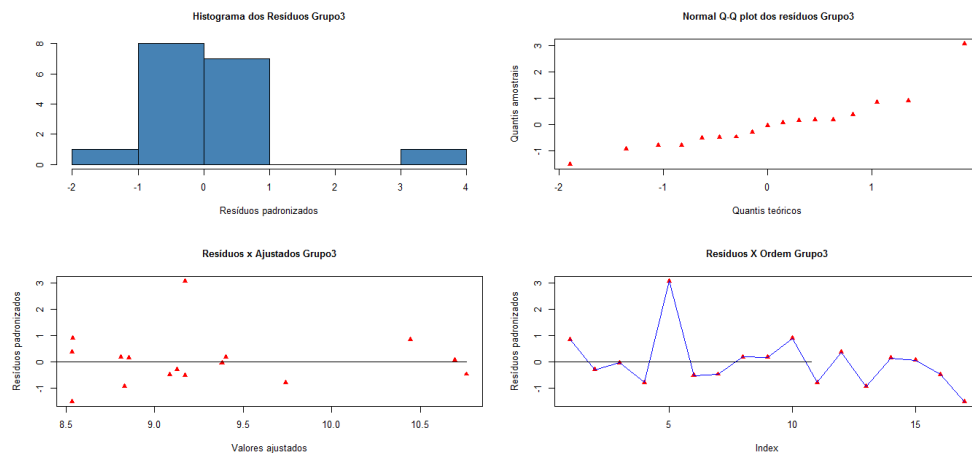


FIG.4. 32 – Análise de Resíduos - Grupo 3 – Carro.

Para o grupo 4, a TAB. 4.34 apresenta os valores dos coeficientes angular e linear do modelo autoregressivo na componente principal, sendo o p-valor de cada um deles de 0.8599 e 7.12E-10, respectivamente. Por isso, a equação encontrada não apresenta coeficiente angular significativo, já que valor-p de β_i é superior a 5%.

TAB.4. 34 - Parâmetros Modelo de Propagação – Grupo 4 – Carro.

Modelo Autoregressivo de Propagação – CP1 – Grupo 4		
<i>Parâmetros</i>	<i>Chaparia</i>	<i>Montagem</i>
β_i	-	-0.0912
$\sigma_{i,A}^2$	-	1.0286
S_{ii}	0.2655	1.0308
$S_{i-1,i}$	-	-0.0242
$CP1_{Mont.} = -0.0912 * CP1_{Chap.} + 9.1138$		
Estatística de ajuste do modelo		
$R^2_{montagem}$	0.0021	
<i>Coefficientes</i>	<i>Valor- P</i>	
β_i	0.8599	
β_0	7.12E-10	

As variâncias em cada estágio e a transmitida encontram-se na TAB.4.35.

TAB.4. 35 - Variâncias em Estágios – Grupo 4 – Carro.

<i>Etapas</i>	<i>Chaparia</i>	<i>Montagem</i>
Chaparia	0.2655	0.0022
Montagem	-	1.0286
Total	0.2655	1.0308

Nesse grupo, a etapa da Montagem contém a menor propagação de erros em relação a todos os grupos analisados, somente 0.21%, sendo assim, maior atenção deve ser dada a própria etapa para redução da variância, conforme FIG.4.33.




FIG.4. 33 - Propagação de Erros – Grupo 4 – Carro.

Como analisado anteriormente, o modelo obtido para o grupo 4 não é adequado para avaliar a propagação da variância para esses pontos. Isso ocorreu pelo fato desse grupo apresentar menor correlação em relação aos outros grupos formados, como apresentado no dendrograma da ligação média, FIG.4.26. Além disso, esse grupo é formado por apenas dois pontos, 10 e 11. Ao verificar a FIG.4.26, nota-se que mesmo a inclusão desses pontos em outro grupo, não teria um grupo com maior correlação entre os seus elementos.

Por fim, estão os resultados da equação de transmissão da variância gerada para o grupo 5 na TAB.4.36. Os p-valores dos coeficientes β_i e β_0 são de 0.0937 e 9.66E-06, respectivamente. Portanto, o parâmetro de propagação da equação obtida não é significativo.

TAB.4. 36 - Parâmetros Modelo de Propagação – Grupo 5 – Carro.

Modelo Autoregressivo de Propagação – CP1 – Grupo 5		
<i>Parâmetros</i>	<i>Chaparia</i>	<i>Montagem</i>
β_i	-	0.2191
$\sigma_{i,A}^2$	-	0.6066
S_{ii}	2.6969	0.7361
$S_{i-1,i}$	-	0.5910
$CP1Mont. = 0.2191 * CP1Chap. + 8.4812$		
Estatística de ajuste do modelo		
$R^2_{montagem}$	0.1759	
<i>Coefficientes</i>	<i>Valor- P</i>	
β_i	0.0937	
β_0	9.66E-06	

Como o modelo autoregressivo obtido para esse grupo não é válido, também devido a menor correlação entre os pontos. O grupo 5 foi dividido em um novo grupo formado apenas pelos pontos 5 e 7 com média 5.3529 e variância de 3.3586, por ser um grupo com maior correlação em relação ao grupo anterior. No novo grupo, foi aplicada a ACP e os resultados desse grupo estão nas TAB. 4.37, 4.38, 4.39 e nas FIG.4.34 e 4.35. Pela TAB.4.37, observa-se que a primeira CP corresponde a 83.30% da variabilidade do todo na etapa da Chaparia, enquanto que, a mesma representa 55.90% na Montagem. Com relação a TAB.4.27, nota-se que os percentuais das variâncias explicadas pelas componentes do grupo 5 são de 72% e 48.50% na Chaparia e Montagem, respectivamente. Logo, com a retirada do ponto 6, houve um aumento na capacidade da primeira CP em explicar o novo conjunto de dados formado pelos pontos 5 e 7.

TAB.4. 37 – Percentual da Variância explicada – Pontos 5 e 7 – Carro.

Grupo – Pontos 5 e 7		
	Chaparia	Montagem
%CP1	83.30%	55.90%
%CP2	16.70%	44.10%

A TAB.4.38 revela os parâmetros do modelo autoregressivo de propagação. Pela estatística de ajuste do modelo, pode-se afirmar que a variável explicativa da equação é

significativa. Para avaliar a propagação de erros, basta verificar as variâncias de cada estágio, conforme a TAB.4.39.

TAB.4. 38 – Parâmetros do Modelo de Propagação – Pontos 5 e 7 – Carro.

Modelo Autoregressivo de Propagação – CP1 – Pontos 5 e 7		
<i>Parâmetros</i>	<i>Chaparia</i>	<i>Montagem</i>
β_i	-	0.3385
$\sigma_{i,A}^2$	-	0.3447
S_{ii}	2.5010	0.6313
$S_{i-1,i}$	-	0.8466
$CP1Mont. = 0.3385 * CP1Chap. + 4.9789$		
Estatística de ajuste do modelo		
$R^2_{montagem}$	0.4540	
<i>Coefficientes</i>	<i>Valor- P</i>	
β_i	0.0030	
β_0	7.11E-06	

TAB.4. 39 - Variâncias em Estágios – Pontos 5 e 7 – Carro.

<i>Etapas</i>	<i>Variância Chaparia</i>	<i>Variância Montagem</i>
Chaparia	2.5010	0.2866
Montagem	-	0.3447
Total	2.5010	0.6313

Pela FIG.4.34, 45.40% dos erros da etapa da Montagem foram originados na etapa anterior.




FIG.4. 34 - Propagação de Erros – Pontos 5 e 7 – Carro.

Conforme apresentado na FIG.4.35, percebe-se que os resíduos do modelo fornecido pela primeira CP do novo grupo apresentam aleatoriedade e independência entre si. Fora isso, o p-valor do teste de AD foi superior a 5%, cerca de 0.14, sinalizando que os erros são normalmente distribuídos.

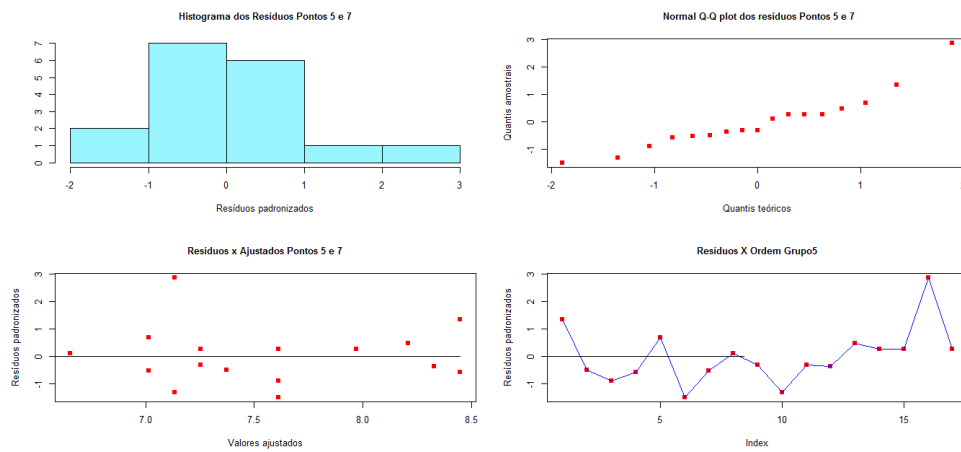


FIG.4. 35 – Análise de Resíduos Pontos 5 e 7 – Carro.

5 CONCLUSÃO

Após analisar os casos simulados, conclui-se que o modelo autoregressivo nas Componentes Principais foi capaz de captar a variação vinda do estágio anterior, principalmente nas simulações com maior variância, mostrando-se promissor para aplicação em casos reais. Observou-se que quanto maior for a correlação entre os dados, maior será a capacidade do modelo proposto em reduzir o número de variáveis, devido ao elevado percentual da variância explicada pelas componentes, em especial pela primeira componente, conforme consta na fundamentação teórica. Em consequência, maior será a captação da propagação dos desvios entre as etapas.

Já para o processo produtivo, tornou-se necessária a utilização de uma técnica estatística, como a Análise de Agrupamentos, para obter grupos mais homogêneos com intuito de auxiliar ainda mais na capacidade de redução da Análise de Componentes Principais. Através da Análise de Agrupamentos, o conjunto de 12 pontos foi dividido em 5 grupos com elementos semelhantes entre si. Com a aplicação da Análise de Componentes Principais em cada grupo, foi possível substituir os dados originais por uma única componente em cada grupo. Logo, as 12 variáveis iniciais foram reduzidas para 5 componentes, sem perda de informação. Ficou evidenciado que a etapa da Montagem contém uma parcela significativa de desvios da etapa da Chaparia no grupo 1. Já para os grupos 2,3,4 e 5, ocorreu menor transmissão da variabilidade entre as etapas, principalmente no grupo 4.

Entretanto, ocorreram situações em que os modelos nas componentes principais não foram válidos para avaliar a transmissão de erros, devido a baixa correlação entre os dados, como nos casos 3 das simulações 2 e 3 com dados normalmente distribuídos com média zero e variância igual a um e dos grupos 4 e 5 do processo produtivo. Além disso, os dados simulados nesses casos apresentavam menores valores de variância nas características iniciais, ou seja, menor presença de erros.

Em resumo, pode-se inferir que os modelos autoregressivos nas componentes principais são válidos para avaliar o comportamento da propagação de erros em processos com grande ou pequeno volume de dados, principalmente com dados fortemente correlacionados. Através deles, é possível identificar qual a etapa é responsável pela maior variabilidade do processo.

Como sugestões para trabalhos futuros têm-se:

- Expandir o estudo para múltiplos estágios;
- Desenvolver modelos multivariados que possam trabalhar com mais de uma componente principal, como por exemplo, mínimos quadrados parciais;
- O uso de modelos de propagação capazes de lidar com outras distribuições de probabilidade;
- Agregar Gráficos de Controle para monitorar o erro de propagação.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- AGRAWAL, R., LAWLESS, J.F., MACKAY, R. J. **Analysis of Variation Transmission in Manufacturing Processes – Part 2.** Journal of Quality Technology, v.31, n.2, 1999.
- ANDRIOTTI, J.L.S. **Análise de Componentes Principais: Fundamentos de uma Técnica de Análise de Dados Multivariada Aplicável a Dados Geológicos.** 1989.
- ALVES, C.C. **Gráficos de controle CUSUM: um enfoque dinâmico para a análise estatística de processos.** Dissertação de Mestrado (Programa de Pós-Graduação em Engenharia de Produção). UFSC. Florianópolis. 2003.
- ARIF, F., SURYANA, N., HUSSIN, B. **Cascade Quality Prediction Method Using Multiple PCA+ID3 for Multi-Stage Manufacturing System.** International Conference on Electronic Engineering and Computer Science. IERI Procedia 4, p.201-207, 2013.
- CAMELIO, J. A., HU S. J., CEGLAREK, D. **Impact of Fixture Design on Sheet Metal Assembly Variation.** Journal of Manufacturing Systems, v.23, n.3, 2004.
- CAMELIO, J., HU, S. J., ZHONG, W. **Diagnosis of Multiple Fixture Faults in Machining Processes Using Designated Component Analysis.** Journal of Manufacturing Systems, v.23, n.4, 2004.
- CEGLAREK, D.J. **Multivariate Analysis and Evaluation of Adaptive Sheet Metal Assembly Systems.** The University of Michigan. 1998.
- COSTA, A.F.B., EPPRECHT, E. K., CARPINETTI, L.C.R. **Controle Estatístico da Qualidade.** 2ªed. Editora Atlas. São Paulo. 2011.
- DONI, M.V. **Análise de Cluster: Métodos Hierárquicos e de Particionamento.** Trabalho de Graduação Interdisciplinar II (Bacharelado em Sistemas de Informação). Universidade Presbiteriana Mackenzie. São Paulo. 2004.
- DU, S., YAO, X., HUANG, D., WANG, M. **Three-dimensional variation propagation modeling for multistage turning process of Rotary workpieces.** Computers & Industrial Engineering 82, p.41-53, 2015.
- FERNANDES, E.M.G.P; VAZ, A.I.F. **Estatística Aplicada.** Universidade do Minho Braga, 1999.
- GAIO, A. P.C., SÁ, F.C. **O Uso da Metodologia Seis Sigma em um Processo da Indústria Automotiva por Meio de um Estudo de Caso.** Trabalho Graduação em Engenharia de Produção. UERJ. Resende. 2004.
- GUJARATI, D.N. **Econometria Básica.** 3ªed. Pearson Makron Books. 2000.

- HAN, K., WANG, K. **Coordination and control of batch-based multistage processes.** Journal of Manufacturing Systems 32, p.372-381, 2013.
- HUANG, Q., ZHOU, S., SHI, J. **Diagnosis of multi-operational machining processes through variation propagation analysis.** Robotics and Computer Integrated Manufacturing 18, p.233-239, 2002.
- JACKSON, J. E. **A User's Guide to Principal Components.** John Wiley & Sons, INC. 1991.
- JOHNSON, R.A., WICHERN, D.W. **Applied Multivariate Statistical Analysis.** 6^a ed. Pearson Prentice Hall. 2007.
- JOLLIFFE, I.T. **Principal Component Analysis.** 2^a ed. Springer. 2002.
- JUNIOR, F.J.M., TEN CATEN, C.S. **Estudo sobre o Efeito da Autocorrelação de Modelos AR(1) no Controle Estatístico de Processo.** ENEGEP. Florianópolis. 2004.
- LAWLESS, J.F., MACKAY, R.J., ROBINSON, J.A. **Analysis of variation transmission in manufacturing processes – Part 1.** Journal of Quality Technology, v.31, n.2, 1999.
- LIAO, X.G., WANG, G. **Employing fractals and FEM for detailed variation analysis of non-rigid assemblies.** International Journal of Machine Tools & Manufacture 45, p.445-454, 2005.
- LINDEN, R. **Técnicas de Agrupamento.** Revista de Sistemas de Informação da FSMA. 2009.
- LIU, N., LI G., WU, L., WU, Z. **Research on the variation propagation model for complex mechanical product processing.** 13th CIRP conference on Computer Aided Tolerancing. Procedia CIRP 27, p.270-275, 2015.
- MINGOTI, S.A. **Análise de Dados através de Métodos de Estatística Multivariada: uma Abordagem Aplicada.** 2^a reimpressão. Editora UFMG. Belo Horizonte. 2013.
- MONTGOMERY, D.C. **Introdução ao Controle Estatístico de Qualidade.** 4^aed. Gen/LTC. Rio de Janeiro. 2013.
- OLIVEIRA, M.A. **Monitoramento de Integridade Estrutural Baseada em Sensores Piezelétricos e Análise de Sinais no Domínio do Tempo.** Tese de Doutorado (Programa de Pós-Graduação em Engenharia Elétrica). UNESP. Ilha Solteira. 2013.
- PIRHOOSHYARAN, M., NIAKI, S.T.A. **A double-max MEWMA scheme for simultaneous monitoring and fault isolation of multivariate multistage auto-correlated processes based on novel reduced-dimension statistics.** Journal of Process Control 29, p.11-22, 2015.
- RODRIGUES, S.C.A. **Modelo de Regressão Linear e suas Aplicações.** Dissertação de Mestrado em Estatística. Universidade da Beira Interior – Covilhã. 2012.
- ROSA, A.F.P. **Método para Controle Estatístico Multivariado de Processos em Batelada.** Dissertação de Mestrado (Programa de Pós-Graduação em Engenharia de Produção). UFRGS. Porto Alegre. 2001.

- SAMOHYL, R.W. **Controle Estatístico de Qualidade**. Editora Elsevier. Rio de Janeiro. 2009.
- SCUDINO, P.A. **A Utilização De Alguns Testes Estatísticos Para Análise Da Variabilidade Do Preço Do Mel Nos Municípios De Angra Dos Reis E Mangaratiba – RJ**. Monografia Licenciatura e Bacharelado em Matemática. UFRRJ. Seropédica. 2008.
- SMITH, L.I. **A Tutorial on Principal Components Analysis**. 2002.
- SOUZA, A.M. **Componentes Principais: Aplicação Na Redução Das Variáveis Econômicas Para O Estudo De Séries Temporais**. Dissertação de Mestrado em Engenharia de Produção. UFSM. Santa Maria. 1993.
- TRIOLA, M.F. **Introdução à Estatística**. 9ª edição. LTC. Rio de Janeiro. 2005.
- VAZ JUNIOR, C.A. **Detecção e Diagnóstico de Falhas com Base em Dados Históricos de Processo: Aplicação em Dutovias**. Tese de Doutorado (Programa de Tecnologia de Processos Químicos e Bioquímicos). UFRJ. Rio de Janeiro. 2010.
- VICINI, L., SOUZA, A.M. **Análise Multivariada da Teoria à Prática**. UFSM. Rio Grande do Sul. 2005.
- WANG,P., ZHANG, D., LI S., CHEN, B. **Machining Error Control by Integrating Multivariate Statistical Process Control and Stream of Variations Methodology**. Chinese Journal of Aeronautics 25, p.937-947, 2012.
- WAGNER, R.R. **Monitoramento Estatístico de Processos Baseado na Análise de Componentes Principais e Cartas de Controle**. Trabalho de diplomação em Engenharia Química. UFRGS. Porto Alegre. 2011.
- YANG, Z., McWILLIAM, S., POPOV, A.A., HUSSAIN, T.,YANG, H. **Dimensional variation propagation analysis in straight-build mechanical assemblies using a probabilistic approach**. Journal of Manufacturing Systems 32, p.348-356, 2013.
- YANG,Z., POPOV,A.A., McWILLIAM, S. **Variation propagation control in mechanical assembly of cylindrical components**. Journal of Manufacturing Systems 31, p 162-176, 2012.
- ZAIANE, O.R., FOSS, A., LEE, C., WANG, W. **On Data Clustering Analysis: Scalability, Constraints and Validation**. University of Alberta, Edmonton, Alberta, Canada. 2003.
- ZHANG, M., DJURDJANOVIC, D., NI, J. **Diagnosibility and sensitivity analysis for multi-station machining processes**. International Journal of Machine Tools & Manufacture 47,p.646-657, 2007.

7 ANEXOS

7.1 ANEXO 1

SIMULAÇÃO 1

Equações Geradoras dos dados iniciais:

$$X_{11} = \text{aleatoriamente } N(0,1) \text{ ou } X_{11} = \text{aleatoriamente } N(0,3)$$

$$E_1 = \text{aleatoriamente } N(0,1)$$

$$X_{21} = 0.95 * X_{11} + \sqrt{1 - (0.95)^2} E_1$$

$$X_{31} = 0.90 * X_{11} + \sqrt{1 - (0.90)^2} E_1$$

$$X_{41} = 0.85 * X_{11} + \sqrt{1 - (0.85)^2} E_1$$

$$X_{12} = \rho * X_{11} + \sqrt{1 - \rho^2} E_1$$

$$X_{22} = \rho * X_{21} + \sqrt{1 - \rho^2} E_1$$

$$X_{32} = \rho * X_{31} + \sqrt{1 - \rho^2} E_1$$

$$X_{42} = \rho * X_{41} + \sqrt{1 - \rho^2} E_1$$

Onde: $\rho = 0.90$ ou 0.50 ou 0.30 .

SIMULAÇÃO 2

Equações Geradoras dos dados iniciais:

$$X_{11} = \text{aleatoriamente } N(0,1) \text{ ou } X_{11} = \text{aleatoriamente } N(0,3)$$

$$E_1 = \text{aleatoriamente } N(0,1)$$

$$X_{21} = 0.45 * X_{11} + \sqrt{1 - (0.45)^2} E_1$$

$$X_{31} = 0.40 * X_{11} + \sqrt{1 - (0.40)^2} E_1$$

$$X_{41} = 0.35 * X_{11} + \sqrt{1 - (0.35)^2} E_1$$

$$X_{12} = \rho * X_{11} + \sqrt{1 - \rho^2} E_1$$

$$X_{22} = \rho * X_{21} + \sqrt{1 - \rho^2} E_1$$

$$X_{32} = \rho * X_{31} + \sqrt{1 - \rho^2} E_1$$

$$X_{42} = \rho * X_{41} + \sqrt{1 - \rho^2} E_1$$

Onde: $\rho = 0.90$ ou 0.50 ou 0.30 .

SIMULAÇÃO 3

Equações Geradoras dos dados iniciais:

$$X_{11} = \text{aleatoriamente } N(0,1) \text{ ou } X_{11} = \text{aleatoriamente } N(0,3)$$

$$E_1 = \text{aleatoriamente } N(0,1)$$

$$X_{21} = 0.15 * X_{11} + \sqrt{1 - (0.15)^2} E_1$$

$$X_{31} = 0.10 * X_{11} + \sqrt{1 - (0.10)^2} E_1$$

$$X_{41} = 0.05 * X_{11} + \sqrt{1 - (0.05)^2} E_1$$

$$X_{12} = \rho * X_{11} + \sqrt{1 - \rho^2} E_1$$

$$X_{22} = \rho * X_{21} + \sqrt{1 - \rho^2} E_1$$

$$X_{32} = \rho * X_{31} + \sqrt{1 - \rho^2} E_1$$

$$X_{42} = \rho * X_{41} + \sqrt{1 - \rho^2} E_1$$

Onde: $\rho = 0.90$ ou 0.50 ou 0.30 .

Dados referentes às primeiras componentes em cada estágio das simulações:

CP – Simulação 1 ~ N(0,1)			
CPI est.1	CPI est.2 caso 1	CPI est2.caso 2	CPI est.2 caso 3
0,674226	0,755382	0,693261	0,628914
-0,48913	-0,96121	-1,0671	-0,59495
-3,18542	-2,56549	-1,27335	-1,05169
0,516841	1,396381	2,027153	1,83805
-2,47788	-1,49873	0,284089	0,936149
0,338892	0,518466	0,551444	0,45063
-0,01249	0,197944	0,659155	1,07779
-0,15292	0,073873	0,320633	0,308775
-1,10694	-0,58834	0,443617	1,010314
3,194957	2,067431	-0,19637	-1,26688
-2,49479	-2,03825	-0,60603	0,290131
0,970587	1,90186	2,576468	2,472152
1,707634	1,435474	0,476404	-0,14766
0,495631	0,406744	-0,03199	-0,42281
2,995855	3,063744	2,371146	2,005829
0,842339	0,961263	0,731426	0,422034
0,107134	-0,47553	-0,88562	-0,61329
0,488048	0,191347	-0,26541	-0,33992
-0,23427	1,101798	2,465167	2,538815
0,199047	-0,15125	-0,66247	-0,88046
-0,25428	0,20397	0,848275	1,111366
2,36306	2,233826	1,124847	0,26818
0,278324	0,025826	-0,45602	-0,76812
-3,04984	-3,09186	-2,27721	-1,75335
-0,29345	-0,96031	-1,46676	-1,31181
-1,07368	-1,33879	-1,12825	-0,6158
0,747089	1,053893	1,116142	0,953121
2,703204	2,359194	0,953394	0,011077
1,527513	0,813862	-0,31272	-0,60269
-0,62342	-0,47607	-0,10052	0,112896
-1,28035	-1,43696	-1,46213	-1,61799
1,919009	1,446445	0,19398	-0,52699
-0,67195	-0,02544	0,867101	1,172705
1,683885	1,25487	0,063835	-0,74141
0,090248	0,362014	0,490431	0,265541
-3,5799	-2,86469	-0,78775	0,415718
3,483921	3,085104	1,6752	1,017647
-1,01264	-0,1798	1,000652	1,332716
-0,69245	-0,95314	-0,88305	-0,53026
1,065794	1,327125	1,354592	1,319365
-1,09832	-1,07803	-1,00237	-1,16346
-2,69027	-3,15509	-2,60872	-1,73793
-2,42526	-2,46486	-1,80331	-1,35961
0,765206	1,313663	1,690177	1,638522
-0,26021	-0,39356	-0,69373	-1,02745
-0,54157	-0,27217	0,108135	0,147813
-0,7827	-1,48988	-2,01892	-1,96506
-1,37019	-1,5747	-1,22906	-0,71009
-1,17894	-1,25652	-0,66211	0,115184
-4,13587	-2,96339	-0,69506	-0,10259
2,327077	2,647649	2,19822	1,67132
1,983591	1,599954	0,88229	0,860133
-2,11847	-1,34807	-0,30596	-0,3947
-1,41592	-0,38481	0,939875	1,056509
1,266477	1,243489	1,003727	1,03594

-0,3231	-0,30755	-0,22963	-0,13891
-2,394	-1,55008	0,094893	0,792595
-3,09379	-3,29646	-2,42943	-1,57342
-0,62178	-0,63027	-0,44729	-0,2883
1,496392	0,888604	0,089552	0,155539
0,595613	-0,50007	-2,05523	-2,71332
-2,65898	-2,24344	-1,12972	-0,76152
1,241257	0,848935	0,207717	0,107338
-1,15558	-0,14397	1,132425	1,316764
1,487867	1,901719	2,512584	3,318392
-0,67779	-0,15732	0,54066	0,654784
0,221865	0,581045	1,180503	1,687151
-0,44484	-0,71455	-1,04067	-1,20432
-1,38973	-1,2649	-0,85912	-0,76139
-3,38666	-3,13253	-1,49491	-0,18126
-2,02718	-1,90223	-1,15568	-0,68007
-3,06665	-3,17676	-2,62543	-2,46402
-1,39656	-1,04545	-0,1296	0,395867
-2,10791	-1,13797	0,681767	1,557476
1,149203	1,015751	0,597782	0,40962
-1,59761	-1,32259	-0,28474	0,470026
-1,0599	-1,1386	-0,74002	-0,26398
3,383412	3,372156	2,246866	1,325261
-0,45759	0,038084	0,820555	1,164673
-2,50329	-2,54082	-1,99176	-1,74786
-1,79013	-1,93344	-1,54876	-1,2147
0,592214	0,151149	-0,3969	-0,36915
3,256415	3,178642	2,190002	1,63407
0,405307	1,015638	1,559718	1,598181
0,509451	0,840498	1,008329	0,840777
-0,50443	-0,66506	-0,46368	0,025028
-1,04262	-0,3121	0,650859	0,834869
3,110454	2,402573	0,580993	-0,32667
-0,32835	0,782517	2,084955	2,360844
-0,68001	-1,21243	-1,55139	-1,38417
-0,28963	-0,21927	0,135233	0,537515
1,383706	1,275777	0,660553	0,204527
3,045516	2,107695	0,141443	-0,6934
-0,51785	0,554323	1,876963	2,240094
-0,23985	-0,1638	0,268921	0,792671
-4,50798	-4,25355	-2,74804	-1,98284
0,572881	0,797744	0,666164	0,311589
2,06906	1,923782	0,899819	0,064327
0,838646	1,146511	0,94764	0,363272
-3,84092	-3,26825	-1,76592	-1,2705

CP – Simulação 2 ~ N(0,1)			
CPI est1	CPI est2. caso 1	CPI est2. caso 2	CPI est2. caso 3
-1,09604	-0,42509	0,534983	-0,36264
-2,16419	-1,12319	0,80444	-1,94645
-0,45178	-1,28231	-2,01707	1,547102
3,073922	2,802051	1,765128	-1,28569
0,912094	1,185398	1,475253	-1,69199
2,575279	1,647725	0,106806	-0,42906
-4,18403	-3,65666	-1,82634	0,364694
0,212798	0,039295	-0,01105	-0,99335

1,475663	0,754532	-0,16959	-0,46887
-2,40307	-2,74359	-2,26492	0,760941
-2,26728	-1,51263	-0,0687	0,037768
-2,67935	-2,00917	-0,59848	0,188857
-1,37416	-0,76422	0,266457	-0,82219
-1,23086	-0,31952	1,040373	-1,3809
-2,17689	-1,45385	0,241504	-1,76288
-4,63944	-4,47473	-2,85998	1,027047
-3,3409	-3,6226	-2,89076	1,786326
-1,1168	-0,50841	0,427797	-0,46451
0,991786	0,845977	0,490624	-0,57273
-1,03375	-0,94284	-0,70015	1,036836
-1,14686	-1,73779	-1,99579	1,092558
-1,00677	-1,65112	-1,92409	0,989166
1,426222	0,384065	-1,18997	1,620648
-0,6783	0,055194	1,220638	-1,64889
-0,66271	-0,40925	-0,20444	1,038614
-1,25564	-0,99567	-0,33579	0,231814
3,350477	3,331254	2,17427	-0,30562
-0,51669	-0,85426	-0,65353	-0,42779
3,593002	2,653499	0,464723	1,168636
0,572779	0,545838	0,145704	0,525384
2,076708	1,255093	-0,00665	-0,30711
-1,61204	-1,35463	-0,4637	-0,64065
0,383029	-0,0904	-0,75891	1,109478
1,54917	0,894104	0,08437	-1,07929
2,322513	1,795518	0,563557	0,431598
-0,31557	-0,29438	-0,51813	1,593899
-1,89253	-2,20936	-1,651	-0,21993
0,498661	1,107581	1,965994	-2,5965
1,168267	0,467896	-0,73733	1,281349
1,78298	1,142253	-0,20726	0,96921
-4,17404	-3,62528	-1,6969	-0,06479
-1,26844	-1,46246	-1,04582	-0,48362
-3,24499	-2,4132	-0,58076	-0,1858
-1,55544	-1,75252	-1,39384	0,453427
-1,27773	-0,54608	0,679701	-0,86496
0,413296	0,195322	0,004829	-0,80801
-0,38878	-0,39485	-0,37746	0,565964
3,269663	3,238722	2,403648	-1,66001
-3,05686	-2,80932	-1,73255	1,121834
0,009439	0,564278	1,012782	-0,64261
-3,63621	-3,1723	-1,28568	-1,34054
0,643346	0,297903	-0,02217	-0,32667
-1,37209	-0,72678	0,218544	0,103069
-0,00041	0,01245	-0,43723	2,115246
0,547707	0,179504	-0,21839	-0,41639
0,509517	0,146004	-0,19649	-0,5487
2,082808	2,00558	1,696813	-2,52263
0,436887	-0,17911	-0,85691	0,708145
-2,44803	-1,58387	-0,49064	2,240662
-1,6973	-1,38671	-0,74363	0,756382
0,001902	0,461538	1,078983	-1,54156
1,879105	1,734558	0,726044	0,82754
-1,56732	-1,70541	-1,90841	3,133391
-0,42428	-0,34253	0,004154	-0,39051
1,960836	1,625507	0,465932	0,669935

-0,38752	0,564264	1,722696	-1,24909
2,298863	1,825145	0,461177	0,285735
-0,31171	-0,47238	-0,52522	-0,03681
2,317142	1,575642	0,24062	0,05958
0,859036	1,168839	1,2411	-0,65491
-1,15033	-0,16839	1,43447	-1,92127
0,730984	0,065756	-0,69587	0,147697
1,293216	1,27391	0,99416	-0,86239
-1,56814	-0,33097	1,366484	-0,90728
-2,24244	-2,07243	-1,42267	1,495262
-0,04784	0,68816	1,35791	-0,07613
-2,63218	-2,36097	-1,43402	1,096944
0,107151	-0,37685	-1,00391	0,623951
2,458189	2,181009	0,859066	0,768042
1,116305	0,306153	-0,65425	-0,04766
3,99519	2,798695	0,124269	1,796174
3,310453	2,798544	1,321006	-0,61718
0,644614	1,067815	1,402695	-0,95661
0,449411	1,062909	1,592109	-1,27969
0,30418	0,187692	-0,27946	1,206637
1,164744	0,93608	0,259578	0,385222
-0,15205	-0,50359	-0,63289	-0,39806
-0,11839	-0,03559	-0,48293	2,248869
-2,91156	-2,55068	-1,62656	1,952365
0,967226	1,577857	1,864095	-0,69643
0,466568	0,770446	0,876359	-0,33904
-0,35282	-0,71686	-0,6558	-0,68916
0,474629	0,685399	1,04719	-1,73067
-3,01029	-2,35285	-0,69358	-0,36171
1,109611	0,513951	-0,29143	-0,07823
0,276322	0,163575	-0,03688	0,135167
-0,4501	0,071695	0,490694	0,238036
-1,88833	-2,33479	-2,34807	1,894341
-1,33927	-1,03775	-0,14805	-0,92333
-1,11847	-1,57258	-1,61952	0,537104

CP – Simulação 3 ~ N(0,1)			
CP1 est.1	CP1 est2 caso 1	CP1 est2 caso2	CP1 est2 caso 3
-1,30084	-1,49641	-1,23766	0,360002
0,888349	0,010165	-0,87656	0,490727
-2,09809	-1,45487	-0,02183	1,265393
0,513696	0,212909	-0,02299	1,428088
0,238922	1,228067	2,167539	0,868484
-2,33019	-1,97789	-0,88792	0,040145
-1,42365	-1,62185	-1,10758	1,546774
0,58637	0,042838	-0,81029	-0,84105
2,401993	2,457057	1,674462	-1,0555
0,352698	0,484908	0,785443	0,993492
-0,31304	-1,06124	-1,66048	0,629656
3,11919	2,819874	1,457006	-0,41419
-0,89362	0,097269	1,191819	-0,01133
0,533176	1,340918	1,929678	0,900159
2,085454	2,179338	1,452995	0,07431
-1,51116	-1,34735	-0,80164	-0,69764
1,229743	0,662437	-0,33315	-0,75581
-0,75335	-1,00293	-1,02203	0,414053

-0,22005	-0,11791	-0,0714	-1,60735
0,558217	1,422738	2,241155	1,495692
-3,35085	-3,57131	-2,7262	0,424518
1,289608	0,620869	-0,58153	-1,07363
2,878666	2,097344	0,521009	0,545409
0,836715	0,444553	-0,30053	-0,75943
-1,09593	-0,32315	0,716999	0,338952
0,391136	0,248676	-0,19696	-1,82718
-0,10419	-0,32317	-0,50177	-0,39076
0,318699	-0,42974	-1,14083	-0,64489
-2,45926	-1,92786	-0,6529	-1,42355
-0,34044	-0,3789	-0,42478	-1,25871
1,14666	1,817558	2,522261	2,885782
2,300537	1,758461	0,782034	2,432791
2,310111	1,605893	0,489528	0,606374
0,190266	0,944677	1,563399	0,45723
0,386718	0,154552	0,105759	1,008706
2,489632	2,693916	2,109385	0,317621
-0,96485	-1,15007	-1,07161	0,927627
1,820096	1,251534	-0,0332	-0,48495
3,517892	3,007007	1,9689	1,925936
-0,60618	-0,89727	-0,99003	-0,95311
-0,35478	0,129565	0,7097	0,05619
-0,97148	-1,17518	-0,70138	1,450592
-1,50206	-1,49741	-1,01054	0,487163
-0,23818	-0,78544	-1,20239	-1,18184
1,876318	1,390844	0,080586	-1,70275
-2,13888	-1,98773	-1,38891	-0,15937
-0,92522	-0,69201	-0,30138	0,119138
0,197726	-0,15692	-0,60273	-0,2318
-0,87738	-1,08519	-1,0823	-1,2929
-3,50997	-3,01302	-1,59754	-1,54722
0,758007	0,770338	0,439256	-0,43203
-1,79325	-1,54395	-0,72085	1,373366
2,057275	1,335967	-0,11872	-1,13939
2,57688	2,41843	1,327267	-0,52601
1,051663	1,115102	1,036322	-0,03616
-0,26424	-0,45344	-0,60462	-0,03229
0,856231	1,087654	0,900839	-1,52922
1,201246	1,388404	1,121267	-0,41008
-2,62575	-2,27614	-1,02398	0,44322
-1,39487	-2,05651	-2,22661	1,382398
-1,29291	-0,72096	0,247037	-0,59114
-2,19087	-1,6132	-0,58135	-1,43196
3,537862	2,829875	1,148797	0,116333
1,842185	1,312019	0,442908	1,757687
-0,44568	0,105059	0,955791	1,930616
-2,69796	-2,24904	-0,99552	-0,11743
-1,25913	-1,02176	-0,67066	-0,57781
-1,51755	-0,44582	1,222504	0,670548
-2,94263	-3,11384	-2,46889	-0,38791
-0,12784	-0,9778	-1,74909	-0,16842
0,677132	0,284628	-0,23475	-0,09081
0,40412	-0,06954	-0,70047	0,248187
1,746733	1,399515	0,522382	0,987622
0,269873	0,27323	0,202692	1,061293
1,593792	1,49739	0,713725	-0,9815

0,831814	0,748826	0,768143	0,663697
-0,77071	-0,90936	-0,67044	0,763881
1,299055	0,657591	-0,57	-1,43665
-0,42372	-0,50313	-0,25765	1,329111
-2,76149	-2,59881	-1,5456	-0,16742
0,267733	0,175907	-0,14318	-0,82796
-0,83301	-0,90353	-0,58285	0,231027
-2,71932	-1,94492	-0,49486	-0,33427
1,166054	1,768855	1,686992	-1,09362
-4,03896	-2,8134	-0,32372	0,234304
-1,36478	-0,5319	0,96939	2,187836
-0,39054	-0,05313	0,747399	2,288926
-0,02621	0,071459	0,253475	0,326239
0,466462	0,162897	-0,16459	-0,51882
-0,37818	0,173067	0,668676	0,017639
0,067893	-0,17635	-0,25483	-0,5555
0,429463	0,591885	0,552951	-0,48359
0,227711	-0,52002	-1,29307	-0,32482
2,042025	2,325505	2,275965	2,112167
-1,24746	-0,44447	0,889146	1,135821
3,19855	2,99194	1,825884	0,577408
-2,1046	-2,2328	-1,46365	0,639014
-1,76937	-1,50715	-1,09677	-2,83767
0,01074	-0,16812	-0,139	0,465326
-0,77823	-0,81881	-0,77033	-1,23519

CP – Simulação 1 ~ N(0,3)			
CPI EST1	CPI est.2 caso 1	CPI est.2.caso 2	CPI est.2 caso 3
-2,16945	-1,81538	-0,80913	-0,33142
-6,75876	-6,60059	-4,39315	-3,09101
1,31646	1,496879	1,247358	0,957981
7,599251	7,771291	5,647072	4,299331
6,588535	6,656837	4,754816	3,611306
9,696432	8,94104	5,26902	3,351628
-11,7931	-10,409	-5,46592	-2,98136
-1,48595	-1,12412	-0,31786	0,020674
5,643691	5,477218	3,629825	2,625367
-6,341	-6,51987	-4,80726	-3,75204
-4,02263	-3,42567	-1,6054	-0,69701
-9,9861	-7,96593	-2,96471	-0,74688
-9,47131	-8,6135	-4,94018	-3,11344
-4,97008	-4,4899	-2,54178	-1,61312
-3,9561	-3,1946	-1,23477	-0,31657
-11,1635	-9,83337	-5,17072	-2,9137
-3,49412	-3,7258	-2,88621	-2,25416
-1,44575	-1,54313	-1,21961	-0,99881
1,903107	3,025377	3,560447	3,457405
-0,92397	-1,15042	-1,09991	-0,99279
-1,84794	-1,23762	-0,0709	0,416564
-1,96192	-1,63515	-0,7602	-0,44108
7,364731	6,405232	3,225256	1,658489
0,005428	-0,33143	-0,66561	-0,7458
-1,40538	-1,95994	-2,08358	-1,94036
-2,98795	-3,05825	-2,22537	-1,68372
10,21333	9,565	5,844022	3,856683
5,786248	5,148497	2,751659	1,514168

12,91297	11,04842	5,323865	2,629959
-4,28677	-3,76814	-1,96276	-1,08536
9,46302	8,235392	4,14331	2,108795
-8,20429	-7,64625	-4,6501	-3,12055
3,535914	3,765661	2,927559	2,346302
4,857597	4,118117	1,902654	0,805247
10,17071	9,421185	5,605103	3,586363
-1,13217	-0,67377	0,158458	0,547349
-1,89117	-1,75016	-1,0357	-0,64099
3,24294	3,651431	3,088471	2,602254
-1,49378	-1,66811	-1,37469	-1,10033
6,030211	5,802846	3,789539	2,723676
-6,75159	-6,14053	-3,5405	-2,28684
-4,69415	-4,96352	-3,8054	-2,97367
-8,55006	-7,97384	-4,83985	-3,20253
-1,39956	-0,64025	0,54555	0,994296
-0,44102	-0,54573	-0,55117	-0,58442
0,083488	0,289749	0,460988	0,470716
-1,77498	-2,37425	-2,44597	-2,2841
12,53555	10,94357	5,622133	3,090512
-8,98221	-8,27787	-4,84146	-2,97902
-4,79777	-3,57183	-0,93171	0,143305
-13,9496	-11,9897	-5,87249	-2,9921
8,050149	7,046493	3,670849	2,112879
-6,51354	-5,28352	-2,15235	-0,8419
-3,81799	-2,54574	-0,1532	0,758366
5,090212	4,678554	2,758037	1,818
3,725793	3,359993	1,877957	1,127136
4,906182	5,016781	3,655098	2,814807
2,950297	2,133902	0,444838	-0,23068
-7,79579	-7,07509	-4,01824	-2,47707
-6,76864	-6,55841	-4,28685	-2,95497
3,603815	2,213603	-0,27863	-1,30664
1,163732	1,190864	0,854255	0,613866
-5,27793	-5,02342	-3,16616	-2,11977
-0,67833	0,291798	1,44635	1,750916
1,193624	1,618724	1,753056	1,830907
3,060342	3,196311	2,401722	1,869979
0,598187	0,915117	1,082168	1,128944
-4,73224	-4,55803	-3,00116	-2,20134
10,51944	9,464549	5,244982	3,093123
2,86128	2,481618	1,288294	0,808236
0,840985	0,686043	0,278903	0,095218
4,598629	3,723995	1,448699	0,365008
4,57079	4,30764	2,683328	1,847958
-3,06607	-2,00077	-0,00256	0,834943
-5,91567	-5,35414	-3,01412	-1,82012
5,507463	5,048171	2,97116	1,976189
-7,02543	-6,51806	-3,89892	-2,5038
-9,09446	-7,87014	-3,93315	-2,0648
3,528549	3,615478	2,661173	2,096014
2,62914	2,088303	0,742372	0,089148
11,43594	9,967648	5,076132	2,70534
9,160478	7,869858	3,84676	1,961533
7,862902	7,318867	4,429085	2,94296
0,656546	1,236831	1,62123	1,646749
-0,95715	-0,49008	0,265719	0,538862

2,792346	2,300413	0,989423	0,436944
-0,03269	0,612005	1,246238	1,349008
-4,65234	-4,56802	-3,11334	-2,31784
-10,2584	-8,16123	-2,99623	-0,69648
5,412468	4,286033	1,537707	0,318699
3,277392	2,985829	1,735425	1,157014
3,166399	2,878526	1,633426	0,980209
1,588337	0,805179	-0,4614	-0,94475
-5,23442	-3,69096	-0,58698	0,697252
6,631409	6,010051	3,434737	2,201582
-3,00245	-2,89581	-1,90942	-1,41187
-3,94651	-3,25429	-1,40872	-0,61707
-3,83486	-3,36774	-1,77092	-1,04683
-2,61162	-1,94578	-0,52215	0,015313
-2,43716	-1,98823	-0,8444	-0,40052

CP – Simulação 2 ~ N(0,3)			
CP1 est1	CP1 est2. caso 1	CP1 est2. caso 2	CP1 est2. caso 3
1,683037	2,118355	2,036754	1,753658
-2,88447	-1,87294	-0,12966	0,456089
-0,12045	-0,92281	-1,61401	-1,67883
-0,12471	-0,17145	-0,24616	-0,20275
1,198177	1,39685	1,156933	0,964119
-4,72251	-5,14901	-4,41653	-3,7716
-3,5167	-3,06112	-1,52818	-0,82873
-4,60008	-4,44968	-3,08767	-2,33677
2,051353	1,33341	0,051742	-0,36971
0,078829	-0,38884	-0,75388	-0,78747
3,253996	3,592588	3,103089	2,668306
-4,3794	-3,63658	-1,62829	-0,74839
-5,01392	-4,17619	-1,93246	-0,95923
-0,91239	-0,07832	0,949913	1,172807
-1,83709	-1,20577	-0,13218	0,218643
-3,66399	-3,57219	-2,32274	-1,63264
4,262311	3,492587	1,700627	0,932522
-0,45033	0,06239	0,642971	0,735081
-0,27814	-0,32024	-0,27859	-0,20604
5,361508	5,045198	3,330443	2,400188
-2,4881	-2,95711	-2,70216	-2,37298
3,558889	2,680163	0,972178	0,333149
1,84937	0,836927	-0,65154	-1,08991
-0,32749	0,314554	0,98814	1,136369
4,908011	4,7917	3,348861	2,476793
0,438918	0,572521	0,675894	0,72056
4,192589	4,104019	2,730952	1,950101
0,469011	0,052225	-0,41534	-0,40137
5,554027	4,538902	1,966515	0,886887
-1,14654	-1,02441	-0,5355	-0,29624
-0,01455	-0,67232	-1,40039	-1,52658
-5,80499	-5,27047	-3,0452	-1,89321
1,416343	0,903468	0,06147	-0,19562
-1,87592	-2,27656	-2,20915	-1,95617
8,942793	8,012218	4,628972	3,02568
-0,52809	-0,49594	-0,31495	-0,25658
-5,83962	-5,90086	-4,29441	-3,24926
-0,1222	0,454672	0,947378	1,037001

2,535063	1,848595	0,659828	0,298304
-0,15863	-0,62437	-1,05858	-1,12217
-4,14221	-3,66128	-2,05968	-1,37207
-5,58643	-5,48648	-3,80213	-2,80132
-1,13641	-0,5007	0,481012	0,761698
-1,03892	-1,26692	-1,15857	-0,99477
1,788738	2,247155	2,159685	1,895419
-2,00726	-2,05357	-1,60761	-1,34004
-1,56815	-1,49313	-0,951	-0,64985
4,021583	3,914296	2,526765	1,757153
-3,5272	-3,25294	-1,85908	-1,12705
-0,35987	0,203319	0,81095	0,881201
-11,59	-10,6332	-6,43618	-4,31178
1,825984	1,38555	0,400797	0,040042
-1,01689	-0,41557	0,546585	0,879694
5,87321	5,5527	3,766393	2,808154
-3,82703	-3,91836	-3,06958	-2,53384
-4,34581	-4,39059	-3,30335	-2,61387
-6,16532	-5,7251	-3,74229	-2,68633
4,607304	3,767039	1,769552	0,978283
5,685688	5,992463	4,903014	4,089061
-2,83023	-2,4592	-1,28497	-0,77934
-2,23297	-1,70585	-0,79579	-0,54607
2,216204	2,086776	1,35637	0,963296
0,787412	0,528405	0,190012	0,054018
-3,07727	-2,83411	-1,69211	-1,04085
2,785165	2,459128	1,402989	0,898258
2,909194	3,548128	3,279946	2,838452
-0,4701	-0,69647	-0,83395	-0,86034
-6,26031	-6,00648	-3,99639	-2,8807
5,91805	4,977241	2,38164	1,251241
3,140832	3,280186	2,522078	2,016777
-1,02348	-0,15507	0,899706	1,182455
-1,04508	-1,56863	-1,82599	-1,73889
3,989566	3,791891	2,452747	1,742916
0,213769	1,238337	2,167441	2,282902
0,481085	0,466583	0,417421	0,371717
8,270482	8,384333	6,161213	4,759893
-0,82062	-0,68239	-0,244	-0,07682
-5,75864	-5,77053	-4,06835	-3,02084
2,546297	2,304056	1,322624	0,807683
-3,04286	-3,53539	-3,16345	-2,66435
4,935545	3,763494	1,249985	0,280685
1,538986	1,179681	0,310839	-0,04051
2,803724	3,014902	2,321648	1,810624
1,306561	1,819797	1,879772	1,672426
0,42446	0,317471	0,118108	0,028008
-0,23179	-0,3512	-0,41077	-0,37994
-4,36335	-4,42876	-3,31359	-2,60097
5,319924	5,104455	3,546878	2,632923
2,621482	2,632868	2,111824	1,765426
4,539796	4,863915	3,873194	3,14748
-4,11863	-3,5651	-1,99852	-1,30314
-2,71462	-2,93776	-2,45416	-2,03581
2,012646	2,109112	1,619856	1,306607
-1,21599	-0,73891	0,053774	0,27593
1,722068	1,103268	-0,05773	-0,50083

0,077722	0,006508	-0,00355	0,062372
-7,23109	-6,30291	-3,44222	-2,14319
-1,98569	-2,38944	-2,10869	-1,76138
-3,61896	-3,21031	-1,86873	-1,25686
-3,84492	-4,09637	-3,25275	-2,64081

CP – Simulação 3 ~ N(0,3)			
CP1 est.1	CP1 est2 caso 1	CP1 est2 caso2	CP1 est2 caso 3
-1,13932	-1,42546	-1,08333	-0,31727
0,222222	-0,6897	-1,50784	-1,04189
-2,74456	-1,86359	0,080282	0,90726
1,046075	0,766907	0,467227	0,667431
1,038991	1,972562	2,59264	2,338322
-0,76827	-0,24941	0,844614	0,895589
1,002009	0,809368	1,045172	1,472489
-0,23833	-0,77391	-1,39158	-1,4597
1,191724	1,209672	0,283901	-0,5588
1,444068	1,607972	1,611023	1,523071
-2,95816	-3,40633	-2,73845	-1,54756
4,074205	3,552814	1,471606	0,213222
0,128114	1,019397	1,642733	1,155141
-0,9455	-0,1668	0,470019	0,494361
4,088564	4,244444	3,429798	2,415653
-1,85153	-1,78317	-1,36959	-1,1595
-1,08101	-1,61762	-2,2087	-2,09941
-2,58853	-2,98232	-2,93797	-2,2444
1,009731	1,008541	0,54092	-0,18812
0,293632	1,201498	1,99043	2,018474
-4,86065	-4,95136	-3,31464	-1,7424
2,660428	1,855845	0,298084	-0,39746
2,390673	1,681032	0,359444	0,112492
1,428712	1,009162	0,118328	-0,39851
0,731719	1,519919	2,195082	1,762942
-0,20977	-0,50046	-1,21471	-1,69452
0,313697	0,161583	0,040151	-0,06303
-0,15216	-0,99633	-1,82424	-1,62502
-0,81692	-0,47106	0,106575	-0,00199
0,338182	0,063271	-0,61412	-1,06318
0,944788	1,769075	2,641466	3,037861
1,215619	0,759867	0,311827	0,977134
2,075962	1,51348	0,640759	0,624942
2,305421	3,04107	3,08001	2,161602
2,591408	2,41872	2,021137	1,814363
1,869081	2,014912	1,217791	0,543446
0,16806	0,179306	0,715315	1,045755
2,117043	1,455255	0,1196	-0,34825
4,300754	3,808797	2,395172	2,079125
-1,2669	-1,63775	-1,77884	-1,55111
-3,76214	-3,32735	-2,43713	-1,78778
-0,41765	-0,66912	-0,35472	0,458732
-2,74065	-2,56786	-1,26891	-0,18115
2,032766	1,35706	0,203623	-0,45661
0,681501	0,058847	-1,26799	-1,81165
-2,87418	-2,72375	-1,71062	-0,99873
-1,88386	-1,53199	-0,66635	-0,30923
-0,19789	-0,63347	-0,91475	-0,54905

-0,75853	-1,04319	-1,30343	-1,47881
-4,91102	-4,36245	-2,64467	-1,99481
0,424252	0,351947	-0,16832	-0,56705
-1,87872	-1,41641	0,007212	0,791717
1,335633	0,585222	-0,84154	-1,39196
2,331665	2,107644	0,853779	0,006192
0,988698	0,898088	0,425575	0,351486
-1,70289	-1,78621	-1,36068	-0,83636
3,30402	3,319347	2,178132	0,861183
3,567231	3,755153	2,994855	1,857294
-1,49271	-1,10112	-0,09067	0,166855
-0,50125	-0,91958	-0,5113	0,138196
-1,76575	-1,24669	-0,49762	-0,44775
-2,27573	-1,75581	-0,73457	-0,5862
2,360659	1,613556	-0,14889	-0,70318
0,930687	0,531816	0,074161	0,41117
0,711537	1,438113	2,368551	2,480894
-2,36788	-1,88792	-0,54572	0,007802
-1,45888	-1,15111	-0,45235	-0,35688
-3,19724	-2,18484	-0,52663	0,196441
-2,16839	-2,23541	-1,29843	-0,72468
-2,67748	-3,27276	-2,95791	-2,02392
0,862611	0,483737	-0,12868	-0,32357
-1,35407	-1,77122	-1,87763	-1,38847
3,505856	3,213001	2,390975	2,043035
1,547803	1,686643	1,707998	1,49725
1,581501	1,282766	0,12398	-0,56252
0,828097	0,668201	0,307551	0,410908
-0,50239	-0,63947	-0,48703	-0,17648
0,992765	0,260263	-1,10133	-1,71059
0,260079	0,148017	0,32398	0,813829
-4,74021	-4,64351	-3,25339	-1,9469
-0,70084	-0,80158	-0,97649	-1,08817
-2,53343	-2,48787	-1,63304	-0,78286
-4,69737	-3,81908	-1,73781	-0,82669
0,912246	1,324381	0,793011	-0,15876
-2,89135	-1,67923	0,546497	1,091195
-1,31761	-0,39112	1,17278	1,839943
-3,29081	-2,62234	-0,58647	1,066134
-2,10164	-1,9126	-1,27124	-0,71264
1,570517	1,166166	0,236312	-0,30536
-0,6003	0,011602	0,683901	0,578443
-0,18735	-0,46967	-0,75962	-0,72577
1,87509	1,887089	1,317807	0,737623
0,749407	-0,04464	-0,91907	-0,93536
0,770207	1,107922	1,20808	1,471936
-1,56611	-0,46948	1,310147	1,698204
1,094893	0,814375	-0,12052	-0,15532
-2,04926	-2,00653	-0,88979	0,009158
-0,14855	-0,14611	-0,39731	-1,09445
-0,24165	-0,45012	-0,50986	-0,19008
-1,15511	-1,3348	-1,41547	-1,37629

7.2 ANEXO 2

<i>CHAPARIA (mm)</i>												
<i>CARROS</i>	<i>PONTOS</i>											
	1	2	3	4	5	6	7	8	9	10	11	12
1	5.5	8.0	6.0	4.0	9.5	8.0	5.0	8.5	9.5	5.5	7.5	7.0
2	5.5	8.0	6.0	5.0	7.5	7.5	2.5	7.5	8.0	5.5	7.5	8.0
3	5.5	7.5	6.0	4.5	7.0	6.5	4.0	8.0	8.0	5.5	8.5	8.0
4	5.5	9.0	7.0	6.5	9.0	9.0	5.5	8.0	8.5	6.0	7.0	8.0
5	4.0	8.0	5.0	6.0	5.5	6.5	3.0	7.5	8.0	6.0	7.5	8.0
6	5.0	7.5	6.5	6.0	7.0	9.5	4.0	7.5	8.0	6.5	7.0	7.5
7	6.5	8.0	5.5	5.0	6.0	8.0	2.5	9.0	9.5	6.0	7.0	8.5
8	4.5	7.0	5.5	5.0	5.5	6.5	1.5	8.0	8.0	6.0	7.0	7.5
9	5.5	7.0	5.0	4.0	6.5	7.0	3.0	7.0	8.0	6.0	8.0	8.0
10	6.0	7.5	5.0	4.0	6.0	7.0	3.0	7.0	7.5	6.5	7.5	8.5
11	4.0	9.5	6.5	6.5	7.0	8.0	2.5	8.0	8.5	6.5	8.0	8.0
12	5.5	7.0	5.0	4.0	7.5	8.0	6.5	6.5	8.0	5.0	8.0	7.5
13	6.0	8.0	6.5	4.5	8.0	8.0	5.5	7.0	8.0	5.5	8.0	8.0
14	5.5	7.5	4.5	5.0	7.0	8.0	5.5	7.0	8.0	5.5	8.0	8.0
15	5.0	7.0	4.5	3.5	6.0	7.5	3.5	9.0	9.5	7.0	8.0	7.0
16	5.0	7.5	5.0	4.0	6.5	6.5	2.5	7.5	8.0	6.5	8.0	7.5
17	6.5	8.5	6.0	4.0	7.5	7.0	3.5	6.5	8.0	6.0	8.0	8.0
<i>MONTAGEM (mm)</i>												
<i>CARROS</i>	<i>PONTOS</i>											
	1	2	3	4	5	6	7	8	9	10	11	12
1	4.0	7.0	5.0	3.5	8.0	7.5	5.0	7.5	8.5	5.0	7.5	7.5
2	3.5	6.5	4.5	3.5	7.0	7.0	3.0	5.0	6.5	4.0	7.0	7.0
3	4.0	6.0	4.5	3.5	6.0	6.0	4.0	5.5	7.0	4.0	7.5	6.5
4	4.5	7.0	4.5	3.5	7.0	7.0	4.5	5.0	6.5	4.0	6.5	6.5
5	2.5	6.0	6.0	5.5	6.5	8.0	4.0	8.5	8.5	8.5	8.5	7.0
6	3.5	6.5	4.0	2.5	7.0	8.0	2.5	5.0	7.0	5.5	7.0	7.0
7	5.5	6.5	4.0	3.5	6.0	8.0	3.5	6.0	8.0	4.5	7.0	7.5
8	4.0	5.5	4.0	3.5	6.5	6.0	3.0	6.0	7.0	4.5	7.0	7.0
9	4.0	6.0	3.5	3.5	6.0	7.5	4.0	5.0	7.0	5.5	7.5	7.0
10	4.5	6.5	5.0	3.5	5.5	7.0	3.5	6.0	7.0	6.0	7.5	7.5
11	3.5	9.5	7.0	3.5	7.0	7.5	3.0	5.0	6.5	5.0	8.0	7.5
12	4.0	6.5	4.5	4.0	7.0	7.0	4.5	4.5	7.0	5.0	7.5	7.5
13	4.5	6.5	4.5	2.0	7.0	8.0	5.0	4.5	6.5	5.5	7.5	8.0
14	4.0	6.5	4.5	3.5	6.5	8.0	5.0	5.0	7.0	4.5	8.0	7.5
15	4.0	6.5	5.0	4.5	7.5	8.5	3.0	6.0	8.0	6.5	7.5	6.5

16	2.5	6.5	4.0	3.0	7.5	8.5	5.0	5.0	6.5	5.5	7.5	6.5
17	5.0	7.0	4.0	3.0	6.0	7.5	5.0	3.5	5.0	6.5	7.5	7.5