

UNIVERSIDADE FEDERAL DO PARANÁ

MARCOS AUGUSTO MENDES MARQUES

ESTIMAÇÃO DOS INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE
TAGUCHI, RAZÃO SINAL RUÍDO E DOS ÍNDICES DE CAPACIDADE POTENCIAL
DO PROCESSO, POR MEIO DE MÉTODO DE REAMOSTRAGEM

CURITIBA

2015

MARCOS AUGUSTO MENDES MARQUES

ESTIMAÇÃO DOS INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE
TAGUCHI, RAZÃO SINAL RUÍDO E DOS ÍNDICES DE CAPACIDADE POTENCIAL
DO PROCESSO, POR MEIO DE MÉTODO DE REAMOSTRAGEM

Tese apresentada como requisito parcial à
obtenção do grau de Doutor em Ciências no
Programa de Pós-Graduação em Métodos
Numéricos em Engenharia, dos Setores de
Tecnologia e de Ciências Exatas da
Universidade Federal do Paraná.

Orientador: Dr. Anselmo Chaves Neto

CURITIBA

2015

M357e

Marques, Marcos Augusto Mendes

Estimação dos intervalos de confiança para a função perda de Taguchi, razão sinal ruído e dos índices de capacidade potencial do processo, por meio de método de reamostragem/ Marcos Augusto Mendes Marques. – Curitiba, 2015.

174 f. : il. color. ; 30 cm.

Tese - Universidade Federal do Paraná, Setor de Tecnologia e Setor de Ciências Exatas, Programa de Pós-graduação em Métodos Numéricos em Engenharia, 2015.

Orientador: Anselmo Chaves Neto .

Bibliografia: p. 136-141.

1. Qualidade. 2. Taguchi, Método de (Controle de qualidade). 3. Ruído - Medição. 4. Processos de fabricação. 5. Bootstrap (Estatística). I. Universidade Federal do Paraná. II. Chaves Neto, Anselmo. III. Título.

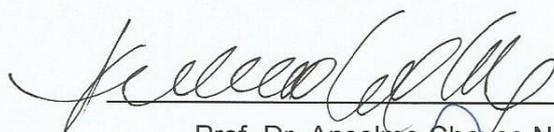
CDD: 658.562

TERMO DE APROVAÇÃO

MARCOS AUGUSTO MENDES MARQUES

ESTIMAÇÃO DOS INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI, RAZÃO SINAL RUÍDO E DOS ÍNDICES DE CAPACIDADE POTENCIAL DO PROCESSO, POR MEIO DE MÉTODO DE REAMOSTRAGEM

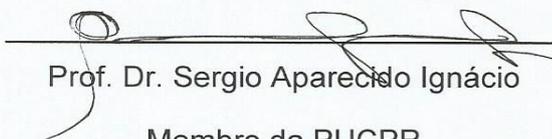
Tese aprovada como requisito parcial para obtenção do grau de doutora no Programa de Pós-Graduação em Métodos Numéricos em Engenharia, da Universidade Federal do Paraná, pela seguinte banca examinadora:



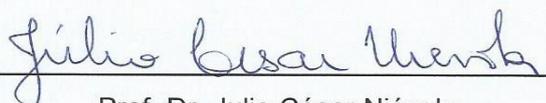
Prof. Dr. Anselmo Chaves Neto
Orientador – Membro do PPGMNE/UFPR.



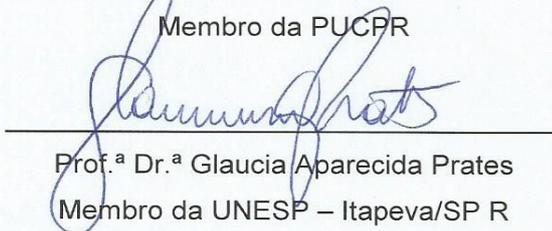
Prof. Dr. Nelson Hein
Membro da FURB



Prof. Dr. Sergio Aparecido Ignácio
Membro da PUCPR



Prof. Dr. Julio César Niévola
Membro da PUCPR



Prof.ª Dr.ª Glauca Aparecida Prates
Membro da UNESP – Itapeva/SP R

Curitiba, 24 de abril de 2015.

AGRADECIMENTOS

Agradeço primeiramente a essa força superior que nos guia a todo instante da nossa vida, nos dando força nos momentos de fraqueza, nos dando luz nos momentos de escuridão, nos dando determinação nos momentos de cansaço, mas principalmente nos dando fé nos momentos de dúvidas. Agradeço a ti Deus pela possibilidade de finalização deste trabalho, mas sou muito grato e feliz pela família que faço parte e pelas pessoas que colocaste no meu caminho, pois sem elas, este trabalho seria impossível de ser finalizado. Agradeço em especial:

Ao professor Dr. Anselmo Chaves Neto pela orientação, ajuda, incentivo, paciência e confiança depositada em mim.

Ao meu pai e grande guru Jair Mendes Marques, pelo constante incentivo e ajuda no desenvolvimento desta tese. Obrigado por não me deixar jamais desistir. Hoje consigo enxergar o que sempre me falou sobre estudar, ser determinado e principalmente sobre ser uma pessoa de bem.

A minha mãe e melhor amiga Erly Mara Marques, por me ajudar e muito nos momentos difíceis dessa caminhada e por me fazer encontrar o bem maior que uma pessoa pode ter que se chama fé em Deus. Muito obrigado mãe por hoje eu ser um vencedor.

A minha querida esposa e parceira de todos os momentos Josiane Belusso Marques. Muito obrigado por sempre acreditar em mim e por fazer meus olhos voltarem a brilhar. Graças a isso eu consegui vencer mais esta etapa na caminhada da vida. Seu apoio é importantíssimo para mim.

A minha irmã Jaqueline Mara Marques pela amizade, acolhimento nos momentos difíceis e constantes incentivos.

A minha afilhada amada Monique Marques do Nascimento por fazer a minha vida muitíssimo mais feliz.

Ao Lucky e a Zara por me fazerem sentir feliz e amado.

Aos amigos que direta ou indiretamente contribuíram para a elaboração deste trabalho.

Aos professores, funcionários e colegas do PPGMNE pela contribuição direta ou indireta para elaboração deste trabalho.

RESUMO

A competitividade na atualidade se faz presente em diversos ramos da manufatura de produtos e uma companhia para ser competitiva neste meio deve fazer investimentos constantes em qualidade. Investir em qualidade envolve uma complexa rede que vai desde a satisfação do cliente ao adquirir um produto, modernização de maquinário por parte das indústrias, preocupação com o meio ambiente e treinamento constante das partes que compõem uma empresa, ou seja, da alta diretoria até ao chão de fábrica. Se faz necessário a conscientização de que alta qualidade está associada a baixos custos, e isto é possível, pela utilização de uma ferramenta utilizada na área de engenharia de qualidade denominada de função perda média de Taguchi. Pela sua utilização, pode-se medir a perda monetária existente devido ao desvio de uma característica funcional do seu valor nominal (*target*), mesmo que tal característica se encontre dentro dos limites de especificação. Assim sendo, se a companhia prezar pela manufatura de seus produtos, centralizando e minimizando a variabilidade da produção de determinada característica funcional, prova-se pela função perda média de Taguchi que alta qualidade efetivamente está atrelada a baixos custos. Outra ferramenta utilizada na área de qualidade é a razão sinal-ruído, idealizada também por Taguchi, onde a mesma mensura a robustez de um produto frente a fontes de ruído, pois quanto mais insensível a essas fontes um produto for, mais robusto e confiável ele será. Confiabilidade e robustez estão altamente correlacionadas a produtos de alta qualidade. Como esses indicadores não possuem estimação por intervalos de confiança e não se conhecem suas distribuições de probabilidade, se propõe nessa tese, a utilização e análise do método estatístico de reamostragem *bootstrap* para estimação das suas variabilidades, suas distribuições *bootstrap* e seus intervalos de confiança através de simulação. O estudo se estende com os mesmos objetivos de estimação para os índices de capacidade potencial do processo C_p , C_{pk} e C_{pkm} , onde os mesmos são muito conhecidos e utilizados como ferramentas do controle estatístico de qualidade. Como suas distribuições não são conhecidas aplicou-se o método *bootstrap* para estimação das mesmas bem como para seus intervalos de confiança. Efetuaram-se cinco técnicas de estimação de intervalos de confiança a *bootstrap*, onde cada uma tem sua peculiaridade e condição para validação do seu uso. Para se efetuar as simulações e cálculos propostos, utilizou-se de um programa (função) cujo algoritmo foi desenvolvido no *software* Matlab. Aplicou-se o algoritmo em três amostras, onde cada uma delas representa uma das características funcionais possíveis, obtendo para as mesmas as suas respectivas distribuições *bootstrap*, variabilidade e intervalos de confiança. O método se mostrou confiável para os cálculos propostos, sendo que se obtiveram com êxito todos os objetivos propostos.

Palavras-chave: Qualidade. Função perda de Taguchi. Razão sinal-ruído. Capacidade de processo. Distribuição *bootstrap*. Intervalo de confiança *bootstrap*.

ABSTRACT

The competitiveness nowadays it is made present in several branches of the manufacture of products and a company to be competitive in this environment should make constant investments in quality. To invest in quality involves a complex network that is going from the customer satisfaction when acquiring a product, machinery modernization on the part of the industry, concern with the environment and constant training of all the parts that a company has, in other words, from the high management to the factory ground. It is necessary the understanding that high quality is associated at low costs, and that is possible, by the use of a tool in the area of engineering of quality denominated of medium loss function of Taguchi. Definitely for its use, the existing monetary loss can be measured due to the variances of a functional characteristic of its nominal value (target), even if such characteristic is inside of the specification limits. In other words, if the company respects for the manufacture of their products, centralizing and minimizing the variability of production of the certain functional characteristic, it is proven by the medium loss function of Taguchi that high quality indeed is tied at low costs. Besides that, another tool used in the quality area is the signal to noise ratio, also idealized by Taguchi, where its measures the robustness of a product before to noise sources, because the more insensitive to those sources a product are, more robust and reliable it will be. Reliability and robustness are highly correlated to products of high quality. As those indicators has not estimate for trusty intervals and it does not know each other its distributions of probability, it is proposed in this doctoral dissertation, the utilization and analysis of the statistical method of re-sample bootstrap for the estimation of their variability, its distributions bootstrap and its trust intervals through simulation. The study extends with the same estimate objectives for the rates of potential capacity of the process C_p , C_{pk} and C_{pkm} , by which the same ones are very known and used as tools of the statistical control of quality. Such as its distributions are not known the method bootstrap was applied to estimate of the same ones as well as for its trusty intervals. Therefore was conducted five techniques of estimate of trusty intervals the bootstrap, by which one has its peculiar and condition for validation of its use. So to make the simulations and proposed calculations, it was used by a program (function) whose algorithm was developed in the Matlab software. The algorithm was applied in three samples, by which one of them represents one of the possible functional characteristics, obtaining for the same ones its respective distributions bootstrap, variability and trusty intervals. The method was shown reliable for the proposed calculations, and it was obtained with success all the proposed objectives.

Keywords: Quality. Taguchi's loss function. Signal to noise ratio. Process capability. Bootstrap distribution. Bootstrap confidence interval.

LISTA DE ILUSTRAÇÕES

FIGURA 2.1	CAUSAS DO PREJUÍZO SOFRIDO PELA SOCIEDADE.....	09
FIGURA 2.2	FILOSOFIA DA META FINAL.....	14
FIGURA 2.3	FUNÇÃO PERDA DE TAGUCHI.....	14
FIGURA 2.4	FUNÇÃO PERDA MENOR É MELHOR.....	24
FIGURA 2.5	FUNÇÃO PERDA MAIOR É MELHOR.....	27
FIGURA 2.6	FUNÇÃO PERDA ASSIMÉTRICA.....	29
FIGURA 2.7	CICLO DE QUALIDADE.....	30
FIGURA 2.8	P-DIAGRAM.....	32
FIGURA 2.9	FUNÇÃO IDEAL E REALIDADE.....	33
FIGURA 2.10	CURVA DA BANHEIRA.....	38
QUADRO 1	PROCEDIMENTOS NA QUALIDADE CONTRA RUÍDOS.....	51
FIGURA 2.11	PROCESSO CENTRADO.....	56
FIGURA 2.12	PROCESSO NÃO-CENTRADO.....	57
FIGURA 2.13	DOIS PROCESSOS COM MESMO VALOR DE C_{pk}	59
FIGURA 2.14	ESQUEMA PARA CÁLCULO DO ERRO PADRÃO.....	72
FIGURA 3.1	FLUXOGRAMA DO FUNCIONAMENTO DO PROGRAMA.....	83
FIGURA 3.2	TELA INICIAL DA FUNÇÃO DESENVOLVIDA NO MATLAB..	84
FIGURA 3.3	TELA PARA ESCOLHA SE K É DADO OU NÃO.....	85
FIGURA 3.4	TELA INICIAL COM A ENTRADA DOS DADOS.....	85
FIGURA 3.5	TELA COM A OPÇÃO DE SE IMPRIMIR AS B AMOSTRAS <i>BOOTSTRAP</i>	85
FIGURA 3.6	TELA DE ESCOLHA DO TIPO DE RAZÃO SINAL-RUÍDO....	86
FIGURA 3.7	TELA PARA A ESCOLHA SE OS LIMITES DE ESPECIFICAÇÃO SÃO DADOS.....	86
FIGURA 3.8	CARACTERÍSTICAS FUNCIONAIS DA FONTE.....	88
FIGURA 3.9	FUNÇÃO PERDA DE TAGUCHI NOMINAL-É- MELHOR.....	91
FIGURA 3.10	FUNÇÃO PERDA DE TAGUCHI MENOR-É-MELHOR.....	92
FIGURA 3.11	FUNÇÃO PERDA DE TAGUCHI MAIOR-É-MELHOR.....	93
GRÁFICO 4.1	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE $\underline{V1}$ ' PARA 10000 AMOSTRAS <i>BOOTSTRAP</i>	97
GRÁFICO 4.2	DISTRIBUIÇÃO <i>BOOTSTRAP</i> DE $\underline{V1}$ ' PARA 20000 AMOSTRAS <i>BOOTSTRAP</i>	98
GRÁFICO 4.3	DISTRIBUIÇÃO <i>BOOTSTRAP</i> DE $\underline{V1}$ ' PARA 30000 AMOSTRAS <i>BOOTSTRAP</i>	98
GRÁFICO 4.4	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE $\underline{V2}$ ' PARA 10000 AMOSTRAS <i>BOOTSTRAP</i>	99

GRÁFICO 4.5	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE $\underline{V_2'}$ PARA 20000 AMOSTRAS <i>BOOTSTRAP</i>	100
GRÁFICO 4.6	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE $\underline{V_2'}$ PARA 30000 AMOSTRAS <i>BOOTSTRAP</i>	100
GRÁFICO 4.7	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE M_1 PARA 10000 AMOSTRAS <i>BOOTSTRAP</i>	101
GRÁFICO 4.8	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE M_1 PARA 20000 AMOSTRAS <i>BOOTSTRAP</i>	102
GRÁFICO 4.9	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE M_1 PARA 30000 AMOSTRAS <i>BOOTSTRAP</i>	102
GRÁFICO 4.10	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE M_2 PARA 10000 AMOSTRAS <i>BOOTSTRAP</i>	103
GRÁFICO 4.11	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE M_2 PARA 20000 AMOSTRAS <i>BOOTSTRAP</i>	104
GRÁFICO 4.12	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE M_2 PARA 30000 AMOSTRAS <i>BOOTSTRAP</i>	104
GRÁFICO 4.13	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE S_1 PARA 10000 AMOSTRAS <i>BOOTSTRAP</i>	105
GRÁFICO 4.14	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE S_1 PARA 20000 AMOSTRAS <i>BOOTSTRAP</i>	106
GRÁFICO 4.15	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE S_1 PARA 30000 AMOSTRAS <i>BOOTSTRAP</i>	106
GRÁFICO 4.16	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE S_2 PARA 10000 AMOSTRAS <i>BOOTSTRAP</i>	107
GRÁFICO 4.17	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE S_2 PARA 20000 AMOSTRAS <i>BOOTSTRAP</i>	107
GRÁFICO 4.18	DISTRIBUIÇÕES <i>BOOTSTRAP</i> DE S_2 PARA 30000 AMOSTRAS <i>BOOTSTRAP</i>	108

LISTA DE TABELAS

TABELA 3.1	DADOS DE PLANICIDADE DAS MÁQUINAS 1 E 2.....	89
TABELA 3.2	DADOS DA FORÇA DE RUPTURA DOS ADESIVOS S_1 e S_2	89
TABELA 4.1	RESULTADOS PARA A FUNÇÃO PERDA MÉDIA PARA O CASO NTB.....	109
TABELA 4.2	RESULTADOS PARA A RAZÃO SINAL-RUÍDO PARA O CASO NTB.....	109
TABELA 4.3	RESULTADOS PARA O ÍNDICE C_p SINAL-RUÍDO PARA O CASO NTB.....	110
TABELA 4.4	RESULTADOS PARA O ÍNDICE C_{pK} SINAL-RUÍDO PARA O CASO NTB.....	110
TABELA 4.5	RESULTADOS PARA O ÍNDICE C_{pKM} SINAL-RUÍDO PARA O CASO NTB.....	110
TABELA 4.6	RESULTADOS PARA A FUNÇÃO PERDA MÉDIA PARA O CASO STB.....	111
TABELA 4.7	RESULTADOS PARA A RAZÃO SINAL-RUÍDO PARA O CASO STB.....	111
TABELA 4.8	RESULTADOS PARA O ÍNDICE C_p SINAL-RUÍDO PARA O CASO STB.....	112
TABELA 4.9	RESULTADOS PARA O ÍNDICE C_{pK} SINAL-RUÍDO PARA O CASO STB.....	112
TABELA 4.10	RESULTADOS PARA O ÍNDICE C_{pKM} SINAL-RUÍDO PARA O CASO STB.....	112
TABELA 4.11	RESULTADOS PARA A FUNÇÃO PERDA MÉDIA PARA O CASO LTB.....	113
TABELA 4.12	RESULTADOS PARA A RAZÃO SINAL-RUÍDO PARA O CASO LTB.....	113
TABELA 4.13	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA MÉDIA DE TAGUCHI PARA O CASO NTB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	114
TABELA 4.14	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA MÉDIA DE TAGUCHI PARA O CASO NTB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	115
TABELA 4.15	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA MÉDIA DE TAGUCHI PARA O CASO NTB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	115
TABELA 4.16	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO NTB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	116
TABELA 4.17	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO NTB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	117
TABELA 4.18	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO NTB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	117
TABELA 4.19	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO NTB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	118

TABELA 4.20	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO NTB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	118
TABELA 4.21	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO NTB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	119
TABELA 4.22	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pK} PARA O CASO NTB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	119
TABELA 4.23	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pK} PARA O CASO NTB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	120
TABELA 4.24	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pK} PARA O CASO NTB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	120
TABELA 4.25	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO NTB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	121
TABELA 4.26	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO NTB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	121
TABELA 4.27	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO NTB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	122
TABELA 4.28	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO STB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	122
TABELA 4.29	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO STB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	123
TABELA 4.30	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO STB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	123
TABELA 4.31	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO STB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	124
TABELA 4.32	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO STB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	125
TABELA 4.33	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO STB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	125
TABELA 4.34	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO STB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	126
TABELA 4.35	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO STB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	127
TABELA 4.36	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO STB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	127
TABELA 4.37	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pK} PARA O CASO STB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	128
TABELA 4.38	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pK} PARA O CASO STB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	128
TABELA 4.39	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pK} PARA O	

	CASO STB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	129
TABELA 4.40	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO STB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	130
TABELA 4.41	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO STB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	130
TABELA 4.42	INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO STB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	131
TABELA 4.43	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO LTB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	131
TABELA 4.44	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO LTB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	132
TABELA 4.45	INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO LTB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	132
TABELA 4.46	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO LTB COM 10000 AMOSTRAS <i>BOOTSTRAP</i>	133
TABELA 4.47	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO LTB COM 20000 AMOSTRAS <i>BOOTSTRAP</i>	133
TABELA 4.48	INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO LTB COM 30000 AMOSTRAS <i>BOOTSTRAP</i>	134

SUMÁRIO

RESUMO	v
ABSTRACT	vi
LISTA DE ILUSTRAÇÕES	vii
LISTA DE TABELAS	ix
1 INTRODUÇÃO	1
1.1 JUSTIFICATIVA.....	3
1.2 OBJETIVOS.....	5
1.2.1 Objetivo Geral.....	5
1.2.2 Objetivos Específicos.....	5
1.3 ESTRUTURA DA TESE.....	6
2 REVISÃO DE LITERATURA	7
2.1 SIGNIFICADO DE QUALIDADE.....	7
2.2 FUNÇÃO PERDA DE TAGUCHI.....	11
2.2.1 Função Perda Nominal-é-Melhor (NTB).....	18
2.2.2 Função Perda Menor-é-Melhor (STB).....	24
2.2.3 Função Perda Maior-é-Melhor (LTB).....	26
2.2.4 Função Perda Assimétrica.....	28
2.2.5 CONSIDERAÇÕES A RESPEITO DA FUNÇÃO PERDA.....	29
2.3 CONTROLE DE QUALIDADE FORA DA LINHA DE PRODUÇÃO (<i>OFF-LINE</i>).....	31
2.4 CONTROLE DE QUALIDADE NA LINHA DE PRODUÇÃO (<i>ONLINE</i>).....	31
2.5 DEFINIÇÃO DE PROJETO ROBUSTO.....	32
2.5.1 Projeto por Parâmetros e Projetos por Tolerâncias.....	34
2.5.2 Fatores de Controle e Fatores de Ruído.....	37
2.5.3 Fator de Ajuste, Fator de Escala e Métrica.....	39
2.6 RAZÃO SINAL-RUÍDO.....	40
2.6.1 Razão Sinal-Ruído para o caso Menor-é-Melhor (STB).....	44
2.6.2 Razão Sinal-Ruído para o caso Maior-é-Melhor (LTB).....	45
2.6.3 Razão Sinal-Ruído para o caso Nominal-é-Melhor (NTB).....	46
2.6.3.1 Tipo I.....	47
2.6.3.2 Tipo II.....	48
2.7 PROCESSO DE OTIMIZAÇÃO EM DOIS PASSOS.....	48
2.8 APLICAÇÕES CONTRA RUÍDOS.....	50
2.9 CAPACIDADE DE UM PROCESSO.....	52
2.9.1 Razão da Capacidade Potencial de um Processo.....	53
2.9.1.1 Razão unilateral da capacidade potencial de um processo.....	54
2.9.2 Coeficiente Potencial de um Processo Não-Centrado.....	55
2.9.3 O Índice C_{pkn}	58
2.9.4 Considerações a respeito dos índices C_p , C_{pk} e C_{pkn}	62
2.10 MÉTODOS DE REAMOSTRAGEM.....	62
2.10.1 O Método <i>Jackknife</i>	63
2.10.2 <i>Bootstrap</i>	65
2.10.2.1 Introdução.....	65
2.10.2.2 O método <i>bootstrap</i>	70
2.10.3 Intervalo de confiança.....	73
2.10.3.1 Introdução.....	73

2.10.3.2	Cálculo usando o escore z	74
2.10.3.3	Cálculo usando o escore t	74
2.10.3.4	Intervalos de confiança <i>bootstrap</i>	75
2.10.3.4.1	O intervalo de confiança <i>bootstrap</i> padrão.....	76
2.10.3.4.2	O intervalo de confiança <i>bootstrap</i> t	76
2.10.3.4.3	O intervalo de confiança percentil.....	77
2.10.3.4.4	Intervalo de confiança pelos métodos do viés corrigido (BC e BCa).....	78
3	MATERIAL E MÉTODOS	81
3.1	DESCRIÇÃO DO PROGRAMA DESENVOLVIDO.....	81
3.1.1	Fluxograma do Algoritmo Desenvolvido no Matlab.....	83
3.1.2	Telas de Entrada de Dados do <i>Software</i> Matlab.....	84
3.2	CARACTERIZAÇÃO E DESCRIÇÃO DAS AMOSTRAS MESTRES.....	87
3.2.1	Descrição da Amostra Mestre Para a Característica Nominal-é-Melhor.....	87
3.2.2	Descrição da Amostra Mestre Para a Característica Menor-é-Melhor.....	88
3.2.3	Descrição da Amostra Mestre Para a Característica Maior-é-Melhor.....	89
3.3	REAMOSTRAGEM UTILIZANDO O MÉTODO BOOTSTRAP.....	90
3.4	CÁLCULOS DA FUNÇÃO PERDA MÉDIA DE TAGUCHI.....	90
3.4.1	Função Perda Média Nominal-é-Melhor.....	90
3.4.2	Função Perda Média Menor-é-Melhor.....	91
3.4.3	Função Perda Média Maior-é-Melhor.....	92
3.5	CÁLCULOS DA RAZÃO SINAL-RUÍDO.....	93
3.5.1	Razão Sinal-Ruído Nominal-é-Melhor.....	94
3.5.2	Razão Sinal-Ruído Menor-é-Melhor.....	94
3.5.3	Razão Sinal-Ruído Maior-é-Melhor.....	95
3.6	CÁLCULOS DOS ÍNDICES C_p , C_{pk} e C_{pkm}	95
4	RESULTADOS E ANÁLISES	97
4.1	DISTRIBUIÇÕES <i>BOOTSTRAP</i>	97
4.1.1	Distribuições <i>Bootstrap</i> Para o Caso Nominal-é-Melhor.....	97
4.1.2	Distribuições <i>Bootstrap</i> Para o Caso Menor-é-Melhor.....	101
4.1.3	Distribuições <i>Bootstrap</i> Para o Caso Maior-é-Melhor.....	105
4.2	VARIABILIDADE.....	108
4.2.1	Resultados da Variabilidade Para o Caso Nominal-é-Melhor... ..	109
4.2.2	Resultados da Variabilidade Para o Caso Menor-é-Melhor.....	111
4.2.3	Resultados da Variabilidade Para o Caso Maior-é-Melhor.....	113
4.3	INTERVALOS DE CONFIANÇA.....	114
4.3.1	Intervalos de Confiança Para o Caso Nominal-é-Melhor.....	114
4.3.2	Intervalos de Confiança Para o Caso Menor-é-Melhor.....	122
4.3.3	Intervalos de Confiança Para o Caso Maior-é-Melhor.....	131
5	CONSIDERAÇÕES FINAIS	135
	REFERÊNCIAS.....	136
	APÊNDICE 1- FUNÇÃO MATLAB.....	142

1 INTRODUÇÃO

Para uma companhia ser competitiva na venda de seus produtos e serviços, deve-se investir na melhoria constante da qualidade de manufatura dos seus produtos. O objetivo da melhoria constante é oferecer produtos de alta qualidade para o consumidor. Quando se fala em alta qualidade, a primeira imagem que nos vem à mente é a de um produto com um *design* agradável, resistente, funcional e de fácil manuseio. Porém, definir qualidade não é tão simples quanto se parece, pois cada pessoa possui um conceito do que vem ser um produto de alta qualidade.

Apesar de não ser de fácil definição, pode-se dizer que alta qualidade está intimamente ligada à satisfação do cliente, e mesmo estando intimamente ligada a sua satisfação, tal conceito não se restringe somente aos mesmos. A qualidade de um produto também está correlacionada com as companhias envolvidas no processo, ou por melhor dizer, a toda sociedade. Envolve toda a sociedade nos seguintes aspectos: retrabalho e refugo (sucata), custos com garantia, insatisfação e reclamação de clientes, tempo e dinheiro gastos por clientes, perda de clientes para concorrentes. Os cinco aspectos citados estão diretamente relacionados à má qualidade e ao seu impacto na sociedade.

Retrabalho e refugo impactam diretamente na perda de matéria-prima, energia e tempo por parte das indústrias. Os custos com garantia geram um adicional às indústrias, que por sua vez estão diretamente relacionados com a insatisfação e reclamação de clientes que perdem seu tempo e seu dinheiro levando a companhia a perder uma fatia no mercado.

Desta forma, as companhias para se manter no mercado, devem investir em qualidade e mensurar financeiramente a mesma, pois desta forma pode-se justificar o investimento feito de maneira direta.

O conhecimento dos custos totais envolvidos no processo produtivo é de extrema importância para as indústrias. Quando se trata de custo, não se leva em consideração somente o custo direto do processo produtivo, mas também, todos os custos indiretos envolvidos desde a manufatura, até a entrega e utilização do produto pelos clientes.

Neste âmbito confrontam-se duas diferentes filosofias no que diz respeito à definição de um produto com alta qualidade. Uma delas levando em consideração

somente o processo produtivo e seus limites de especificação para definição de qualidade superior. A outra levando em consideração o processo produtivo e as perdas geradas pela manufatura de um produto que possua um desvio do valor alvo para uma determinada característica funcional. É importante quantificar a perda imposta pelo desvio de uma determinada característica do seu valor alvo, podendo-se assim justificar o investimento em alta qualidade, desde a manufatura até a entrega do produto.

A perda devido ao desvio do valor alvo nem sempre fica evidente no momento da compra de um bem, ou seja, no ato da compra a qualidade tende a ser incerta, pois esta só vai se mostrar após algum tempo de uso e de comparação com outros produtos similares ao adquirido. Neste contexto, a quantificação em unidades monetárias devido ao desvio de alguma característica funcional de um produto, além de justificar investimentos em alta qualidade, também serve para medir a “má” qualidade do mesmo. A quantificação é realizada através da função perda de Taguchi para características mensuráveis do produto.

Almeida e Toledo (1989) afirmam que “a perda é definida como o valor esperado da perda monetária causada por desvios da característica de desempenho em relação ao valor desejado (ou esperado).” Sendo assim, fica implícito que qualquer variação de alguma característica funcional do produto implica em uma perda para o consumidor, podendo esta ser uma perda monetária, um simples inconveniente ou até mesmo um dano físico.

Outro conceito introduzido por Taguchi para verificação da qualidade de um produto é a robustez do mesmo em relação à variação de fatores externos (fontes de ruídos). As fontes de ruídos que podem ser variadas sistematicamente em um experimento são denominadas de fatores de ruídos. O objetivo do experimento, neste caso, é verificar quais são os valores ideais dos parâmetros de projeto que minimizem a ação das fontes externas na variabilidade de alguma característica funcional tornando o produto robusto. A medida de robustez idealizada por Taguchi é denominada de razão sinal-ruído.

Em conjunto com a função perda de Taguchi e a razão sinal-ruído, pode-se fazer uma análise da capacidade de um processo atender as especificações através dos índices C_p , C_{pk} e C_{pkm} , onde os mesmos verificam a uniformidade de um

processo produtivo, visto que o mesmo é indispensável para a manutenção de qualidade de um produto.

A função perda de Taguchi, a razão sinal-ruído, os índices C_p , C_{pk} e C_{pkm} em conjunto com outras técnicas estatísticas já existentes são ferramentas importantes para a obtenção de produtos com qualidade superior e devem ser utilizadas amplamente para a obtenção da mesma.

1.1 JUSTIFICATIVA

Quase todo processo produtivo possui características funcionais mensuráveis, onde as mesmas são alvo de análise para manutenção da qualidade de um produto. A manutenção desta qualidade é feita através de amostras, visto que pode ser muito caro, ou até mesmo impossível, utilizar-se da população. Assim, utilizam-se de conceitos estatísticos para diagnosticar, monitorar, modelar e melhorar processos produtivos.

Segundo Chaves Neto (2013), as técnicas estatísticas podem ser úteis em todo ciclo produtivo, pois são amplamente empregadas na quantificação da variabilidade do processo, na análise desta variabilidade em relação às especificações do produto e, no auxílio à administração na eliminação ou redução dessa variabilidade.

Segundo Samohyl (2009), através dos conceitos estatísticos pode-se escolher o tamanho de uma amostra e verificar qual ferramenta é a mais apropriada para a solução de um determinado problema, onde o mesmo é recriado através de um experimento.

De acordo com Marques e Marques (2009) “pode-se dizer que toda ciência que manipula dados experimentais necessita de Estatística como método de análise destes dados, para que o pesquisador possa tirar conclusões que tenham validade científica.” Desta maneira, medidas estatísticas obtidas a partir de amostras têm como principal objetivo representar o mais fielmente possível um parâmetro através de uma estimativa. A estimativa do parâmetro em questão pode ser efetuada através de alguns métodos, tais como: método da máxima verossimilhança, método dos

momentos, método dos mínimos quadrados e através de simulações computacionais. Através de simulações consegue-se fazer inferências estatísticas a respeito de uma medida de incerteza qualquer.

A dedução de informações relativas a uma população, mediante a utilização de amostras aleatórias dela extraídas, diz respeito à inferência estatística (MARQUES; MARQUES, 2009).

Ao longo de aproximadamente trinta anos os métodos de simulação e reamostragem não paramétrica tornaram-se poderosas ferramentas para estimação de medidas de incerteza, criação de intervalos de confiança, testes de hipóteses entre outros. Segundo Hesterberg (2006), os métodos baseados em simulação computacional podem ser utilizados para fazer do abstrato algo mais palpável, fornecendo alternativas visuais para procedimentos clássicos estatísticos.

Um dos métodos de simulação e reamostragem muito conhecido é o *bootstrap*, introduzido por Bradley Efron em 1979. A justificativa para a grande utilização e sucesso desse método estatístico de reamostragem é determinada pela existência de soluções baseadas em considerações assintóticas para vários problemas, de forma que é possível aplicar o método *bootstrap* em situações onde existam poucas observações amostrais ou que dependam da suposição de Gaussianidade.

Nesse contexto surge a pergunta: Por que ou quando se deve usar o *bootstrap*? Segundo Schmidheiny (2012) deve-se usá-lo por duas razões principais:

- 1^a) Quando a distribuição assintótica é muito complicada de se obter;
- 2^a) Pelo fato do *bootstrap* obter “melhores” aproximações para determinadas propriedades.

No segundo caso, pode ser demonstrado que as aproximações que utilizam o *bootstrap* convergem mais rapidamente para determinadas estatísticas do que as aproximações feitas pelas teorias assintóticas. Essas aproximações utilizando-se do *bootstrap* são denominadas de refinamentos assintóticos.

No que se diz respeito à inferência estatística pode-se citar que “O *bootstrap* oferece uma solução muito poderosa para inferência estatística quando a estatística tradicional não pode ser aplicada” (DUTANG *et al.*, 2008).

Neste contexto pode-se utilizar o *bootstrap* para estimação da distribuição, dos intervalos de confiança e da variabilidade para a função perda de Taguchi, razão sinal-ruído e dos índices C_p , C_{pk} e C_{pkm} , visto que o mesmo não é feito atualmente, tornando esses indicadores de qualidade e robustez de produtos (serviços) mais confiáveis, sendo que os resultados obtidos em uma amostra poderão ser estendidos para a população.

Desta forma esses indicadores, em conjunto com o método *bootstrap* e suas inferências, podem e devem ser utilizados no controle estatístico de qualidade, uma vez que este envolve todos os setores de uma empresa visando a obtenção de produtos em níveis econômicos plausíveis e que satisfaçam seus respectivos consumidores.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Analisar o uso do método *bootstrap* para realização de inferências estatísticas nos indicadores de qualidade função perda de Taguchi, razão sinal-ruído e índices C_p , C_{pk} e C_{pkm} para uma determinada característica funcional de um produto.

1.2.2 Objetivos Específicos

Para uma determinada característica funcional de um produto:

- 1) Estimar a variabilidade, os intervalos de confiança de 95% e 99% e as distribuições de probabilidade da função perda média de Taguchi por meio do método *bootstrap* ;
- 2) Estimar a variabilidade, os intervalos de confiança de 95% e 99% e as distribuições de probabilidade da razão sinal-ruído por meio do método *bootstrap* ;

3) Estimar a variabilidade, os intervalos de confiança de 95% e 99% e as distribuições de probabilidade dos índices de capacidade do processo C_p , C_{pk} e C_{pkn} por meio do método *bootstrap*.

1.3 ESTRUTURA DA TESE

Além dessa introdução, esta tese apresenta uma Fundamentação Teórica no capítulo 2, que é composta de uma Revisão de Literatura onde são abordados os principais livros e vários artigos recentes. No capítulo 3 são descritos o Material e os Métodos a serem usados. No capítulo 4 são descritos os Resultados e Análises referentes aos objetivos propostos. No capítulo 5, denominado de Considerações Finais, apresentam-se as conclusões referentes aos objetivos propostos e, adiante, se apresenta as Referências Bibliográficas e o Apêndice.

2 REVISÃO DE LITERATURA

2.1 SIGNIFICADO DE QUALIDADE

O conceito de qualidade não é novo. Essa noção foi evoluindo ao longo do tempo, dadas as especificidades que cada período apresentou na história do desenvolvimento humano (PALADINI, 1995).

O conceito de qualidade não é algo que seja de fácil definição, visto que cada pessoa possui uma definição própria de acordo com o que julga ser mais importante em um produto ou serviço oferecido. Alguns julgam importante o visual ou apresentação de um produto, outros as funcionalidades ou até mesmo a resistência às quedas do mesmo, entre outros.

Segundo Toledo (1987) qualidade é uma das palavras mais difundidas no meio empresarial e, ainda assim, existe pouco entendimento sobre a mesma. Os próprios teóricos da área admitem a dificuldade de uma definição precisa do que vem a ser qualidade, visto que a mesma possui diferentes conceitos para cada pessoa e cada situação específica.

Oakland (1994) afirma que o conceito de qualidade depende da percepção individual do indivíduo, ou seja, o que é considerado de qualidade superior para algumas pessoas pode não suprir as necessidades de outras.

Outra questão que deve ser considerada, como fazendo parte de um conjunto de determinações que definem a qualidade superior de um produto é com relação aos meios de comercialização, pois o produto (serviço) deve chegar na quantidade, local, tempo e preço adequado atendendo a expectativa do cliente.

Um produto de qualidade, na visão do consumidor, é aquele que atende às suas necessidades e que esteja dentro de sua possibilidade de compra, ou seja, tenha preço justo (CSILLAG, 1991).

E ainda assim, após adquirir o produto, o cliente deve se tornar cada vez mais satisfeito com o mesmo, pois isso refletirá em um número baixo de solicitações de assistências técnicas e reclamações, tendo como uma das consequências o aumento de vendas do mesmo no mercado.

Robles Junior (1996) define controle da qualidade total (*Total Quality Control* – TQC) como a preocupação em todos os processos industriais e administrativos que a empresa se utiliza para satisfação do cliente.

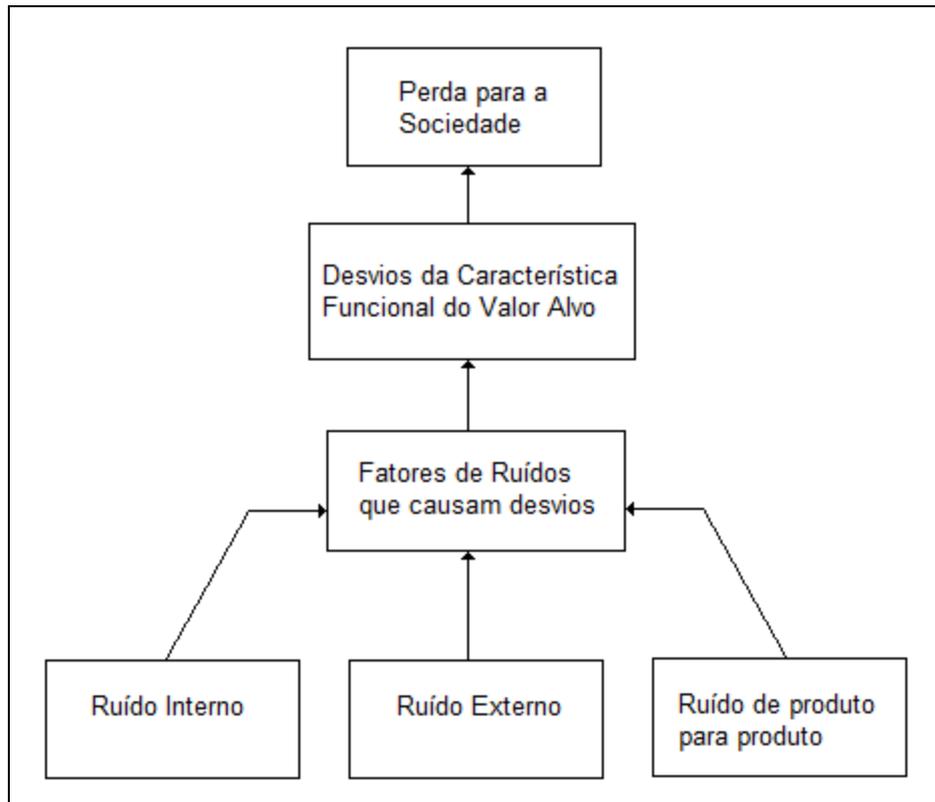
Seguindo a mesma linha de raciocínio para denominar qualidade superior, Juran e Gryna (1991) conceituam qualidade como a adequação do cliente ao uso do produto. Neste conceito, torna-se claro que quanto melhor a adequação ao produto, melhor é a qualidade do mesmo.

Outra definição de qualidade é a seguinte: “qualidade é uma característica do processo de produção que deve ser medida pela proporção de bens ou serviços produzidos que atingem as propriedades especificadas do projeto” (CHAVES NETO, 2013). Esta é a definição técnica de qualidade, e pode ser considerada como inerente do processo de produção. Esta definição também é conhecida como filosofia da meta final, na qual não se leva em consideração as exigências do consumidor, mas somente características do projeto e os limites de tolerância do mesmo, ou seja, considera-se qualidade como uma medida de fração de defeituosos.

Taguchi considera essa medida incompleta e não considera que todos os produtos que atendam as especificações de projeto possuam a mesma qualidade, assim, definiu qualidade de uma maneira “mais completa” que a definição de qualidade dada pela filosofia da meta final.

A definição de qualidade, segundo Taguchi, é o prejuízo sofrido pela sociedade como consequência da variação funcional do produto (ou serviço) e seus efeitos adversos a partir do momento em que o produto (ou serviço) é recebido pelo consumidor (CHAVES NETO, 2013).

FIGURA 2.1 – CAUSAS DO PREJUÍZO SOFRIDO PELA SOCIEDADE



FONTES: O AUTOR

Variação funcional é definida como o desvio do desempenho do produto, geralmente causada por ruídos como demonstra a figura 2.1, com relação ao seu valor nominal, sendo este, o valor desejado pelo consumidor para um melhor desempenho do produto (serviço).

Pela filosofia da meta final basta que as especificações estejam dentro dos limites de tolerância do projeto para que o produto seja definido como de qualidade superior, ou seja, se existir uma variação funcional, e esta estiver dentro dos limites de tolerância, o produto é considerado de qualidade igual àquele que supostamente possui as especificações nos valores nominais de projeto. Os custos gerados por este conceito são relacionados aos produtos que não atendem às especificações, ou seja, custos com retrabalho e sucateamento.

De acordo com a filosofia de Taguchi, quanto mais próximo uma característica funcional do produto estiver do valor nominal de projeto, maior será a qualidade do mesmo, independentemente de estar ou não dentro dos valores de tolerância do projeto, pois o mesmo leva em consideração essa variação funcional. Quanto menor a variação funcional, menor o prejuízo sofrido pela sociedade e

consequentemente maior a qualidade do produto, ou seja, se produz um produto mais uniforme com relação a algumas características do mesmo.

Os custos gerados por produtos que atendam as especificações, mas que possuam uma grande variação funcional (não uniformidade com relação à algumas características) serão detectados somente quando o produto estiver nas mãos do consumidor, gerando custos de acionamento de garantia, reparo do produto e assim por diante.

A diferença entre o conceito convencional de qualidade e o conceito de Taguchi é que para o primeiro, qualidade superior de um produto ou serviço implica em custos mais elevados ao passo que para o outro, qualidade superior implica em custos menores tanto para os fabricantes quanto para os consumidores. Desta maneira verifica-se que o conceito de qualidade superior não é algo trivial de se definir.

Sendo assim, de acordo com a filosofia de Taguchi um produto com qualidade superior é barato, com alta confiabilidade e desempenho consistente, pois os fatores causadores da variação funcional de alguma característica do mesmo são minimizados.

Tornar um produto confiável e consequentemente de qualidade, é torná-lo insensível ou pouco sensível a ação de fatores externos (ruídos). Com isto, desenvolve-se um conceito em engenharia de qualidade, denominado de projeto robusto. No projeto robusto utiliza-se da pesquisa e do desenvolvimento para criar e produzir produtos, com custo mínimo, alta qualidade e confiabilidade, de tal maneira que os mesmos sejam insensíveis ou pouco sensíveis aos ruídos.

De acordo com Ribeiro e Elsayed¹ (1993, *apud* Caten, 1995), os objetivos da engenharia de qualidade são:

- 1) minimizar os desvios do valor alvo (*target*);
- 2) maximizar a robustez ao ruído;
- 3) maximizar a robustez a possíveis oscilações em fatores controláveis.

¹RIBEIRO, J. L.; ELSAYED, E. A. A gradient loss function for process optimization. IE Working Paper, p. 1-23. Department of Industrial Engineering Rutgers University. USA: 1993

Neste trabalho é considerado um produto (ou serviço) de qualidade superior àquele que for robusto e que estiver de acordo com a definição de qualidade de Taguchi. Sendo assim, as medidas da função perda de Taguchi, da razão sinal-ruído e dos índices C_p , C_{pk} e C_{pkm} tornam-se indispensáveis nesse processo.

2.2 FUNÇÃO PERDA DE TAGUCHI

De uma maneira geral as empresas classificam os custos com qualidade em três categorias:

- 1) Custos com prevenção, que dizem respeito à manutenção do sistema de qualidade;
- 2) Custos de avaliação, referentes aos custos para manutenção do sistema de garantia de qualidade;
- 3) Custos com falhas internas e falhas externas, que correspondem aos custos referentes a perdas de fabricação, refugo, retrabalho, garantia do produto, reparo do produto e assim por diante.

O conhecimento dos custos envolvidos em um processo produtivo é de importância para as indústrias, pois somente assim pode justificar investimentos em qualidade. Com isso surgem as perguntas: Qual o custo da ausência da qualidade? O aperfeiçoamento contínuo do produto é eficaz na redução dos custos?

Essas perguntas podem ser respondidas de forma quantificada através da função perda de Taguchi, onde a mesma exprime numericamente as perdas monetárias oriundas de desvios do desempenho do produto em relação ao valor nominal de projeto. Tais desvios levam a uma perda para o consumidor, para o fabricante do produto e para a sociedade.

De acordo com Taguchi, Elsayed e Hsiang (1990), a relação entre qualidade e preço de um produto é de extrema importância, pois o preço representa uma perda para o consumidor na hora da compra e má qualidade representa uma perda adicional durante o seu uso.

Segundo Almeida e Toledo (1989) essa perda é definida como o valor esperado da perda monetária causada por desvios das características de desempenho em relação ao valor desejado (ou especificado).

Taguchi, *apud* Nakagawa (1993), desenvolveu um método que permite quantificar o impacto da má qualidade, em unidades monetárias, através da função perda. Desta maneira, se consegue medir o impacto das perdas em um produto não somente para o consumidor, mas também para à sociedade a longo prazo.

O tempo desperdiçado no reparo de pequenas falhas, aluguel de máquinas em substituição a uma que esteja sendo reparada, diminuição no lucro devido ao fato de uma linha de produção estar parada, são exemplos de perdas para o consumidor. No que diz respeito ao fabricante, tem-se perdas com inspeção, retrabalho, sucateamento, custos com garantia, perdas de clientes em potencial, entre outros.

Segundo a filosofia de Taguchi, a perda para a sociedade é composta de custos que podem ser identificados de forma direta e de forma “indireta”. Os custos que podem ser identificados de forma direta dizem respeito a aqueles que são verificados no processo produtivo de um bem, ou na execução de um serviço, que envolve desde gasto com matérias-primas, mão de obra, maquinário, sucateamento, reposição de produto, reposição de algum serviço mal feito e assim por diante. Os custos “indiretos” ou subjetivos são aqueles que não se consegue ver de maneira direta o valor monetário envolvido em um processo de baixa qualidade e geralmente estão relacionados com insatisfação do cliente, visto que a quantificação monetária das perdas só será diretamente identificada, quando o produto ou serviço perder mercado para seus concorrentes. Assim, através da função perda demonstra-se que alta qualidade está livre de custos associados à baixa qualidade.

Tal afirmação é amplamente verificada na indústria japonesa e americana, que através da função perda conseguiram quantificar os benefícios obtidos pela redução de variabilidade de uma característica do produto em torno do seu valor alvo.

De acordo com Ealey (1988), com a utilização da função perda, consegue-se justificar investimentos na melhoria da qualidade, priorizando-se o desenvolvimento do produto e conseqüente equilíbrio entre custo e qualidade.

“A função perda de Taguchi reconhece o desejo do consumidor em adquirir produtos que sejam mais duradouros, em todos os aspectos, e o desejo do fabricante em fabricar produtos com custo menor” (ROSS, 1991).

Sendo assim, tal função mede a qualidade e pressupõe que o objetivo seja produzir itens, sob um processo controlado, de tal forma que se atendam as expectativas do consumidor com a menor variabilidade possível de alguma característica do mesmo, levando em consideração o prejuízo sofrido pela sociedade de uma maneira geral. Assim, de uma maneira geral, isto quer dizer que tanto da parte do fabricante quanto da parte do consumidor existe prejuízo, como exemplificado anteriormente.

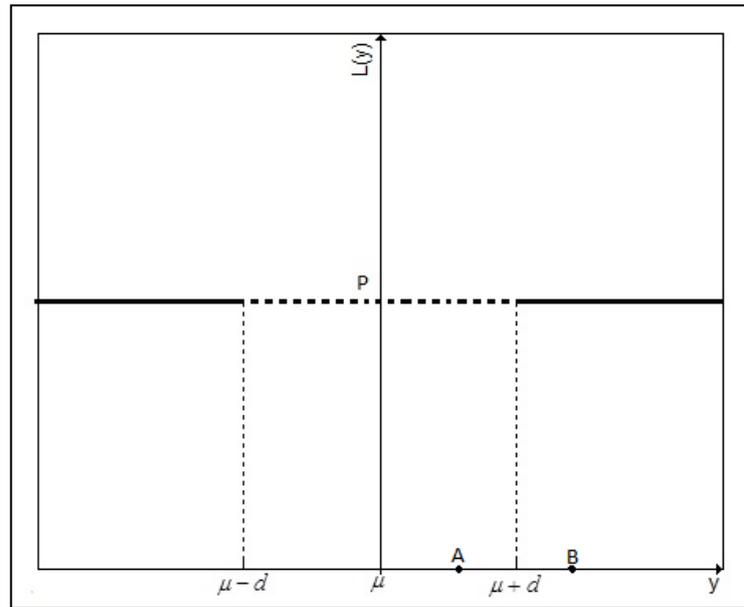
Com esta filosofia procura-se produzir um bem ou serviço minimizando essa perda para a sociedade, ou seja, procurar-se-á produzir bens mais uniformes ou bens que possuam uma variação funcional mínima. “Taguchi afirma que a perda para a sociedade, como um todo, é mínima quando o desempenho do produto atende ao valor nominal (desempenho desejado) e a quantificação desta perda em valor monetário faz com que todos compreendam a importância do aperfeiçoamento do processo de produção do produto (serviço), desde o operário mais simples até o presidente da empresa” (CHAVES NETO, 2013).

Segundo Byrne e Taguchi (1987) a perda ocorre também quando acontece uma falha no produto, mesmo que o mesmo esteja dentro das especificações, e a perda aumenta continuamente conforme a característica funcional do produto se afasta do valor alvo.

R. N. Kackar (1989) ampliou o conceito de perda para a sociedade em seu trabalho *Taguchi's Quality Philosophy*, incorporando como perda para a sociedade situações durante a fabricação de um produto ou execução de um serviço. Tais perdas podem ser vistas como matéria prima gasta, tempo com mão de obra, poluição ambiental e assim por diante.

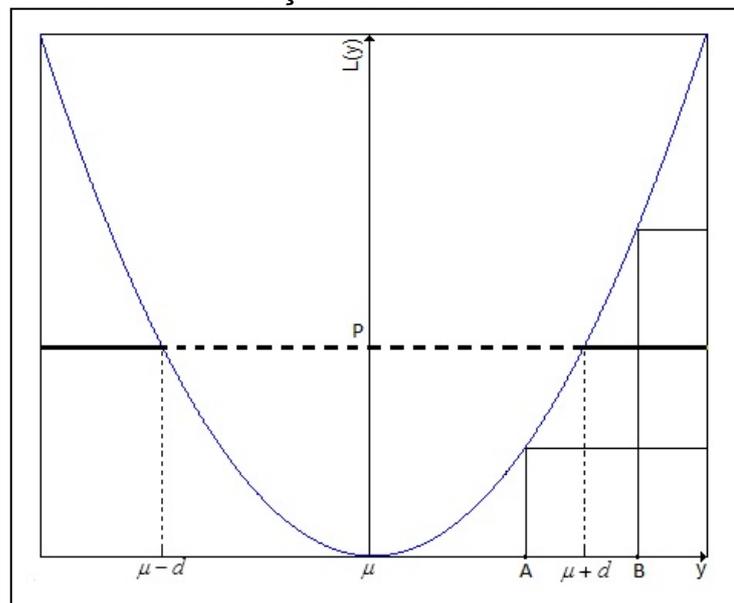
Uma comparação entre a filosofia da meta final e a filosofia de Taguchi pode ser melhor visualizada através das figuras 2.2 e 2.3.

FIGURA 2.2 – FILOSOFIA DA META FINAL



FONTE: O AUTOR

FIGURA 2.3 – FUNÇÃO PERDA DE TAGUCHI



FONTE: O AUTOR

A figura 2.2 tem $L(y)=0$ para $y \in [\mu - d, \mu + d]$ e $L(y)=P$ para $y \notin [\mu - d, \mu + d]$, assim, representando a filosofia da meta final em termos de qualidade. A figura demonstra que produtos que estejam dentro dos limites de

tolerância do projeto $[\mu - d, \mu + d]$ para alguma característica funcional são considerados de qualidade superior, independente de estarem próximos, ou não, do valor nominal de projeto para determinada característica. Verifica-se presença de um custo P para os produtos que estiverem com a característica funcional fora do intervalo de tolerância, e tal custo, geralmente representa um custo relacionado ao refugo ou reposição do produto, visto que essa filosofia leva em consideração somente o que diz respeito ao processo de produção (fabricante).

Em compensação na figura 2.3 observa-se que independentemente da característica funcional estar dentro dos limites de tolerância, existe um custo envolvido, e que este aumenta conforme o valor da característica observada vai se afastando do valor nominal μ . Essa função denominada de função perda de qualidade, proposta por Taguchi, aponta o custo devido a variação no desempenho do produto como proporcional ao quadrado do desvio d . Se observa que “a função oriunda desta idéia é chamada de função perda quadrática” (CHAVES NETO, 2013).

De acordo com Ealey (1988), Taguchi encontrou a representação quadrática dessa função e demonstrou que a mesma é eficiente e que permite fazer uma estimativa realista para baixa qualidade (desvio do valor nominal μ).

A função perda quadrática é uma aproximação da expansão da série de Taylor em torno do valor alvo μ , excluindo-se os termos de maior ordem. Assim, tem-se que

$$L(y) = L(\mu) + \frac{L'(\mu)}{1!}(y - \mu) + \frac{L''(\mu)}{2!}(y - \mu)^2 + \dots \text{termos de maior ordem} \quad (2.1)$$

onde $L(y)$ representa a perda; μ representa o valor alvo; y representa a característica mensurada em relação ao valor μ e $(y - \mu)$ o desvio de y em relação ao valor alvo.

Assim para todos os valores da característica mensurável y , a perda pode ser expressa como uma função de $y - \mu$, e ainda, assume-se que sua perda é mínima quando $y = \mu$.

Quando se assume que a perda é mínima para $y = \mu$, temos que $L'(\mu) = 0$, e ainda, considerando-se perdas devido à variação em relação ao valor alvo μ , tem-se que $L(\mu) = 0$.

Ignorando os termos de maior ordem da expansão da série de Taylor em torno do valor alvo μ , a série (2.1) torna-se

$$L(y) = \frac{L''(\mu)}{2!} (y - \mu)^2 \quad (2.2)$$

ou ainda

$$L(y) = k(y - \mu)^2 \quad (2.3)$$

onde $k = \frac{L''(\mu)}{2!}$ é uma constante que representa a proporção da importância financeira da característica de qualidade testada para o cliente, em termos do valor alvo μ . A equação (2.3) representa a função perda nominal-é-melhor vista adiante nesta tese.

Taguchi, assim, reconheceu a função perda como uma função contínua, pois nessa filosofia a perda não acontece de maneira súbita e a sua representação quadrática possui as quatro características seguintes.

- (1) $L(y)$ é mínimo quando $y = \mu$;
- (2) $L(y)$ aumenta na medida em que y se distancia do valor alvo μ ;
- (3) $L(y)$ aumenta lentamente enquanto o valor mensurável de y está nas proximidades do valor alvo μ , e começa a aumentar mais rapidamente quanto mais se afasta de μ ;
- (4) $L(y)$ é expresso em unidades monetárias.

Dessa maneira Taguchi desenvolveu fórmulas padrões para cada um dos três tipos de características contínuas mensuráveis de qualidade.

Pelas figuras 2.2 e 2.3 observou-se uma diferença significativa com relação aos custos envolvidos quando y é igual a A ou igual a B.

De acordo com a figura 2.2, observou-se que no ponto A o produto (serviço) é considerado de qualidade igual aos que estão dentro do intervalo $[\mu - d, \mu + d]$, ou seja, não possui nenhum custo envolvido e conseqüentemente nenhum prejuízo para a sociedade, pois a mesma não está levando em conta a variação funcional de alguma característica e suas conseqüências no que diz respeito à qualidade.

No ponto B verificou-se, na figura 2.2, que existe um custo P (custo de refugo ou reposição) envolvido no processo, pois o mesmo encontra-se fora do intervalo $[\mu - d, \mu + d]$ e o produto (serviço) é considerado não conforme ou defeituoso.

No entanto, na figura 2.3 verificou-se uma filosofia diferente da encontrada na figura 2.2, e isto fica evidenciado comparando os pontos A de ambas as figuras.

No ponto B da figura 2.3 observou-se que além do custo de reparo, sucateamento ou reposição, de um produto defeituoso representado por P, existe um custo adicional que seria a representação do prejuízo sofrido pela sociedade como um todo.

Do ponto de vista comparativo entre as duas filosofias representadas pelas figuras 2.2 e 2.3, verificou-se que em relação ao custo P, existe uma pequena diferença de custos comparando os pontos A e B da figura 2.3 em relação aos custos referentes aos pontos A e B da figura 2.2. Com isto confirma-se a necessidade de se produzir bens uniformes e com sua característica funcional no valor alvo, reduzindo os prejuízos de uma maneira geral para o fabricante, para o consumidor e para a sociedade.

De acordo com Ross (1991) outro atributo da função perda, fora quantificar em valores monetários a perda de qualidade, é auxiliar na fixação de níveis de tolerância nas fábricas.

De uma maneira sucinta, pode-se afirmar que para tal, é necessário conhecer o custo gerado por um produto que esteja fora das especificações e o valor nominal de projeto para determinada característica do produto. Assim, aplicando-se a função perda, de acordo com o tipo de tolerância utilizada para a característica funcional do produto, podem-se fixar níveis de tolerância nas fábricas para se realizar um reajuste em determinada característica do produto, antes mesmo

dele sair para o mercado. Com isso evita-se gastos com garantia e “prejuízos” indiretos, tal como, descontentamento dos clientes.

Assim verifica-se que a função perda é uma poderosa ferramenta para quantificar de maneira direta a perda de qualidade de um produto (serviço), além de ser utilizada como uma ferramenta para fixação de limites de tolerância de fábrica. Com isso, se evita custos de sucateamento, troca de produto, acionamento da garantia, entre outros custos indiretos referentes a baixa qualidade.

Taguchi definiu três tipos de função perda, que estão de acordo com o tipo das características funcionais analisadas no produto. Tais funções perda são denominadas de: 1) Função Perda Nominal-é-Melhor (NTB); 2) Função Perda Menor-é-Melhor (STB); 3) Função Perda Maior-é-Melhor.

2.2.1 Função Perda Nominal-é-Melhor (NTB)

A função perda nominal é melhor está representada na figura 2.3 onde a variável em questão y assume o seu valor nominal de projeto em μ , onde $L(y)$ assume o valor nulo para $y = \mu$, ou seja, não existe perda. A função perda, neste caso, é representada por:

$$L(y) = k(y - \mu)^2 \quad (2.4)$$

Esta função é denominada de função perda quadrática. De acordo com a função perda (2.4), em conjunto com a figura 2.3, observa-se que existe uma perda conforme a variável y se afasta de μ .

A constante de proporcionalidade k é denominada de coeficiente de perda de qualidade (representa a proporção da importância financeira para o cliente em termos do valor alvo μ), e seu valor pode ser calculado considerando-se a tolerância funcional do produto e a perda do consumidor devido a esse desvio.

Tolerância funcional (Δ_0) é definida como o desvio máximo permissível de alguma característica funcional em relação ao valor alvo. Se o valor mensurável (da

característica em questão) estiver fora deste intervalo, o funcionamento do produto é afetado, gerando custos aos consumidores, ou seja, perdas para a sociedade.

Perda do consumidor (P) é uma perda média gerada quando o valor da característica medida excede o limite de tolerância do produto. Tal perda representa um custo médio para o consumidor de reparo ou reposição do produto, associado a uma insatisfação. Sendo assim, torna-se complicado mensurar a perda do consumidor, pois a mesma além do custo referente ao reparo (reposição do produto), também pode contemplar custos indiretos, tais como, o tempo gasto pelo consumidor levar o produto para reparo, combustível gasto pelo mesmo, desgaste do veículo, tempo de espera para o reparo, tempo sem usar o produto adquirido e assim por diante.

Tanto a tolerância funcional (Δ_0) quanto a perda do consumidor (P) podem ser determinados pelo marketing, serviços e informações de clientes.

Assim, para o cálculo de k , de acordo com a definição de tolerância funcional e perda do cliente temos que $L(\Delta_0) = P$, $\Delta_0 = \mu + d$ ou $\Delta_0 = \mu - d$.

Desta maneira, pode-se demonstrar que $L(y) = k(y - \mu)^2 \Rightarrow L(\Delta_0) = k(\Delta_0 - \mu)^2 \Rightarrow P = k(\mu + d - \mu)^2 \Rightarrow P = kd^2$, que resulta em

$$k = \frac{P}{d^2} \quad (2.5)$$

Com isso, pode-se reescrever a função perda (2.4) como

$$L(y) = \frac{P}{d^2} (y - \mu)^2 \quad (2.6)$$

Este tipo de função perda, onde o valor nominal é o melhor, é empregada para muitos produtos, peças, elementos e componentes quando se deseja que uma característica do produto (serviço) esteja centrada no seu valor alvo. Pode-se citar como exemplo para aplicação dessa função perda de qualidade a dimensão de um produto, viscosidade entre outros.

Frequentemente os fabricantes precisam avaliar a qualidade média do seu produto, em relação a uma característica do mesmo, ao longo de um período de tempo. Esta pode ser mensurada através do desenvolvimento da função perda média para n unidades de um produto (serviço). Isto pode ser realizado de dois modos.

O primeiro deles, quando se está trabalhando com algum produto, é utilizar sua distribuição de frequência com seu respectivo histograma. Assim, tem-se a perda associada a cada valor de y , bem como a frequência para aquele respectivo valor de perda. Com isso, pode-se calcular a perda $L(y)$ para cada valor y , denominado de $L(y_i)$, e multiplicá-lo pela sua frequência, denominada de f_i .

Admitindo-se b classes, efetua-se $\sum_{i=1}^b L(y_i)f_i$ e divide-se pelo total de produtos

amostrados $\sum_{i=1}^b f_i = n$. O resultado obtido é denominado de perda média, que nada mais é do que a média aritmética para uma distribuição de frequências com b classes da função perda $L(y)$.

O segundo método para se estimar a perda média para n produtos, é desenvolvido usando-se a média aritmética de $(y - \mu)^2$, que é denominada de desvio médio quadrático (MSD – *Mean Square Deviation*). Assim, tem-se que

$$MSD = \frac{(y_1 - \mu)^2 + (y_2 - \mu)^2 + \dots + (y_N - \mu)^2}{n} \quad (2.7)$$

ou

$$MSD = \frac{\sum_{i=1}^n (y_i - \mu)^2}{n} \quad (2.8)$$

Uma forma equivalente de se escrever (2.8) é

$$MSD = \frac{(y_1 - \bar{y})^2 + (y_2 - \bar{y})^2 + \dots + (y_N - \bar{y})^2}{n} + (\bar{y} - \mu)^2 \quad (2.9)$$

ou

$$MSD = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n} + (\bar{y} - \mu)^2 \quad (2.10)$$

Assim, tem-se que \bar{y} é a média aritmética da característica funcional y , definida por

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n} \quad (2.11)$$

e a variância em torno da média \bar{y} é dada por

$$\sigma^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n} \quad (2.12)$$

Neste caso, em específico, utiliza-se a variância populacional no lugar da amostral por estar se usando para o cálculo do MSD o valor n . Assim, pode-se reescrever (2.10) como

$$MSD = \sigma^2 + (\bar{y} - \mu)^2 \quad (2.13)$$

O valor do desvio médio quadrático (MSD) em (2.13) representa uma medida da variância (variabilidade em torno da média) e o desvio do valor médio em relação ao valor nominal μ .

Desta forma, a função perda média, definida por $\bar{L}(y)$ pode ser escrita como

$$\bar{L}(y) = k[MSD] \quad (2.14)$$

ou

$$\bar{L}(y) = k \frac{[(y_1 - \mu)^2 + (y_2 - \mu)^2 + (y_3 - \mu)^2 + \dots + (y_N - \mu)^2]}{N} \quad (2.15)$$

que é equivalente a

$$\bar{L}(y) = k[\sigma^2 + (\bar{y} - \mu)^2] \quad (2.16)$$

onde σ^2 é a variância relativa à média \bar{y} ; \bar{y} é o valor da média aritmética de y no conjunto amostral; k é o coeficiente de perda de qualidade; $(\bar{y} - \mu)$ é o desvio da média das amostras em relação ao valor nominal μ .

Matematicamente pode-se provar que a função (2.8) e (2.10) são equivalentes. Assim, tem-se que

$$\sigma_{y;\mu}^2 = \sigma_{y;\bar{y}}^2 + (\bar{y} - \mu)^2 \quad (2.17)$$

onde: $\sigma_{y;\mu}^2$ é a variância de y com base em μ ; $\sigma_{y;\bar{y}}^2$ é a variância de y com base em \bar{y} ; $(\bar{y} - \mu)^2$ é o quadrado da diferença média em μ .

A função (2.17) pode ser reescrita como

$$\frac{\sum_{i=1}^n (y_i - \mu)^2}{n} = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n} + (\bar{y} - \mu)^2 \quad (2.18)$$

que multiplicando por n , tem-se

$$\sum_{i=1}^n (y_i - \mu)^2 = \sum_{i=1}^n (y_i - \bar{y})^2 + n(\bar{y} - \mu)^2 \quad (2.19)$$

Assim, desenvolvendo os quadrados dos termos, tem-se

$$\sum_{i=1}^n (y_i^2 - 2\mu y_i + \mu^2) = \sum_{i=1}^n (y_i^2 - 2\bar{y} y_i + \bar{y}^2) + n(\bar{y}^2 - 2\mu\bar{y} + \mu^2) \quad (2.20)$$

que de acordo com a propriedade distributiva, tem-se

$$\sum_{i=1}^n y_i^2 - 2\mu \sum_{i=1}^n y_i + N\mu^2 = \sum_{i=1}^n y_i^2 - 2\bar{y} \sum_{i=1}^n y_i + n\bar{y}^2 + n\bar{y}^2 - 2n\mu\bar{y} + n\mu^2 \quad (2.21)$$

Reduzindo os termos semelhantes, tem-se

$$-2\mu \sum_{i=1}^n y_i = -2\bar{y} \sum_{i=1}^n y_i + 2n\bar{y}^2 - 2n\mu\bar{y} \quad (2.22)$$

e simplificando (2.22), tem-se

$$-\mu \sum_{i=1}^n y_i = -\bar{y} \sum_{i=1}^n y_i + n\bar{y}^2 - n\mu\bar{y} \quad (2.23)$$

Por definição

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n} \quad (2.24)$$

Assim (2.23) fica,

$$-\mu \sum_{i=1}^n y_i = -\frac{\left(\sum_{i=1}^n y_i\right) \sum_{i=1}^n y_i}{n} + n \left(\frac{\sum_{i=1}^n y_i}{n}\right)^2 - n\mu \left(\frac{\sum_{i=1}^n y_i}{n}\right) \quad (2.25)$$

com isso tem-se que

$$0 = -\frac{\left(\sum_{i=1}^n y_i\right)^2}{n} + \frac{\left(\sum_{i=1}^n y_i\right)^2}{n} \quad (2.26)$$

então

$$0 = 0 \quad (2.27)$$

Assim, prova-se que (2.8) e (2.10) são equivalentes para o cálculo da função perda média.

2.2.2 Função Perda Menor-é-Melhor (STB)

A função perda menor-é-melhor é análoga a função perda nominal-é-melhor, sendo a principal diferença entre elas o tipo de variável utilizada por ambas. No caso menor-é-melhor a variável utilizada é do tipo não negativa, ou seja, $y \geq 0 \forall y \in \mathfrak{R}$. Assim, pode-se afirmar que a função perda menor-é-melhor é idêntica a nominal-é-melhor para $\mu = 0$, sendo este o melhor valor para produtos (serviços) com alguma característica funcional maior ou igual à zero.

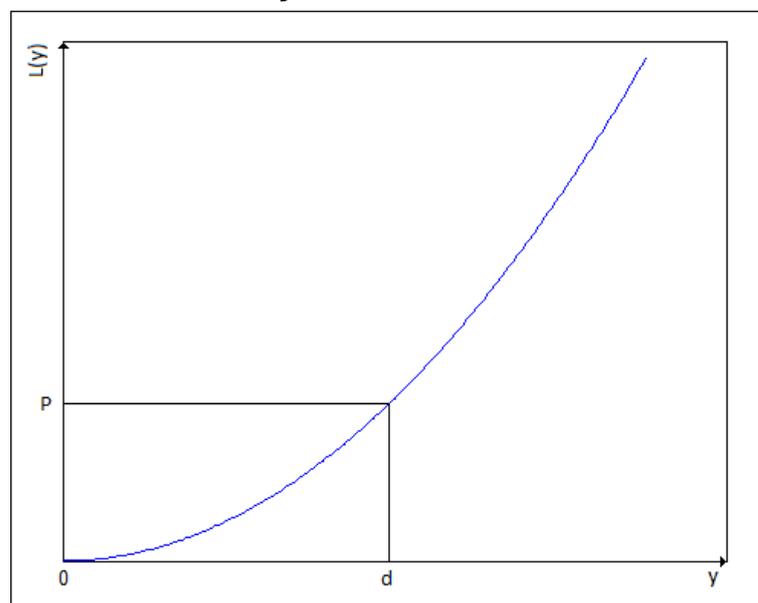
Alguns exemplos podem ser citados para este tipo de função perda, tais como: o tempo de espera para uma determinada refeição a ser servida, consumo de algum tipo de combustível, quantidade de impurezas em uma determinada solução, perda por fricção, desgaste entre outros.

A função perda menor é melhor possui a forma quadrática

$$L(y) = ky^2 \quad (2.28)$$

A figura 2.4 demonstra o comportamento da função perda descrita em (2.28).

FIGURA 2.4 – FUNÇÃO PERDA MENOR É MELHOR



FONTE: O AUTOR

De maneira análoga a função perda nominal é melhor, a constante de proporcionalidade k é denominada de coeficiente de perda de qualidade, e seu valor pode ser calculado considerando a perda do consumidor em relação a tolerância funcional para a função perda em questão. Assim para a perda do consumidor, tem-se que $L(\Delta_0) = P$, onde $\Delta_0 = d$. Assim, pode-se demonstrar que $L(\Delta_0) = kd^2 \Rightarrow P = kd^2$, resultando em

$$k = \frac{P}{d^2} \quad (2.29)$$

Desta forma, pode-se reescrever (2.28) como

$$L(y) = \frac{P}{d^2} y^2 \quad (2.30)$$

De maneira análoga a utilizada na função perda nominal-é-melhor, pode-se demonstrar que a função perda média para o caso menor-é-melhor, considerando $\mu = 0$, pode ser escrita como

$$\bar{L}(y) = k[\sigma^2 + \bar{y}^2] \quad (2.31)$$

onde: σ^2 é a variância relativa à média \bar{y} ; \bar{y} é o valor médio de y no conjunto amostral; k é o coeficiente de perda de qualidade.

Em (2.31) considera-se o MSD dado por $MSD = \sigma^2 + \bar{y}^2$, onde a mesma é estimada por

$$MSD = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n} + \left(\frac{\sum_{i=1}^n y_i}{n} \right)^2 \quad (2.32)$$

ou

$$MSD = \frac{\sum_{i=1}^n y_i^2}{n} \quad (2.33)$$

Assim, pode-se afirmar que (2.32) e (2.33) são equivalentes, ou seja

$$\frac{\sum_{i=1}^n y_i^2}{n} = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n} + \left(\frac{\sum_{i=1}^n y_i}{n} \right)^2 \quad (2.34)$$

A metodologia empregada para a prova da equivalência de (2.33) e (2.34) é análoga à prova da equivalência de (2.8) e (2.10).

2.2.3 Função Perda Maior-é-Melhor (LTB)

A função perda maior é melhor é utilizada quando o produto (serviço) possui alguma característica funcional cujo valor ideal seja não negativo, ou seja, $y \geq 0 \forall y \in \mathfrak{R}$ e sempre assume o maior valor possível. Assim, a variável representativa dessa característica funcional é mais fielmente representada pela função perda maior-é-melhor (LTB).

Os exemplos para este tipo de função perda são aqueles em que o valor de alguma característica do produto (serviço) assuma o maior valor possível. Sendo assim, tem-se como exemplo a força de ruptura de um cabo, a força de aderência de uma cola, resistência de uma blindagem, entre outros exemplos que exijam o maior valor possível de alguma característica funcional.

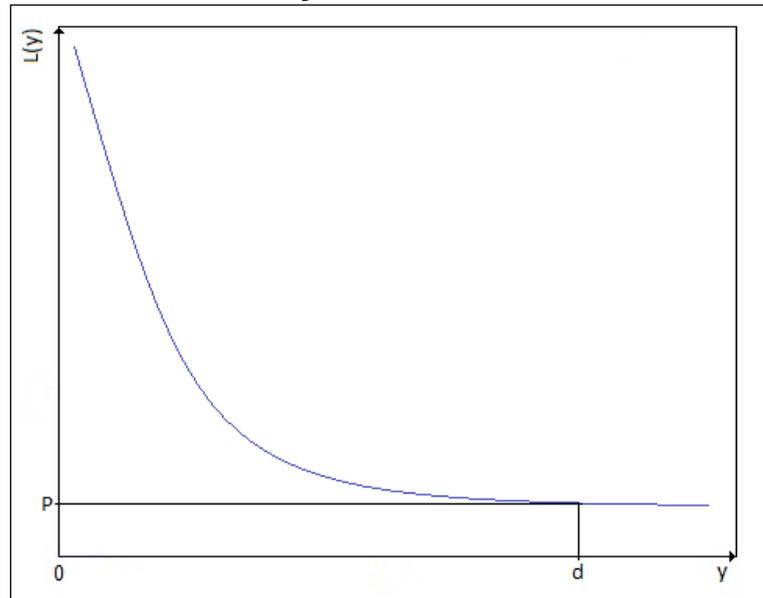
A função perda que representa este caso é dada por

$$L(y) = k \left(\frac{1}{y^2} \right) \quad (2.35)$$

e de maneira análoga às outras duas funções perda, representadas em (2.4) e (2.28), pode-se calcular o coeficiente de perda de qualidade k utilizando como base uma determinada perda associada (perda do consumidor) a um valor específico de y (tolerância funcional).

A figura 2.5 demonstra o comportamento da função perda descrita em (2.35), sendo que quanto maior o valor que y assume menor é a perda.

FIGURA 2.5 – FUNÇÃO PERDA MAIOR É MELHOR



FONTES: O AUTOR

De acordo com a figura 2.5, quando $\Delta_0 = d$ tem-se que a perda $L(\Delta_0) = P$. Assim, substituindo esses valores em (2.35) encontra-se o valor de k . Então

$$L(\Delta_0) = k \left(\frac{1}{\Delta_0^2} \right) \Rightarrow P = k \left(\frac{1}{d^2} \right), \text{ que resulta em}$$

$$k = Pd^2 \quad (2.36)$$

Assim, pode-se reescrever (2.35) como

$$L(y) = Pd^2 \left(\frac{1}{y^2} \right) \quad (2.37)$$

Pode-se demonstrar que a função perda média para o caso maior-é-melhor pode ser escrita como

$$\bar{L}(y) = k \left[\frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \right] \quad (2.38)$$

considerando-se para este caso o

$$MSD = \frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \quad (2.39)$$

A maneira equivalente de representar (2.39) é

$$\bar{L}(y) = k \left(\frac{1}{\bar{y}^2} \right) \left[1 + \left(\frac{3\sigma^2}{\bar{y}^2} \right) \right] \quad (2.40)$$

onde: σ^2 é a variância relativa à média \bar{y} ; \bar{y} é o valor médio de y no conjunto amostral; k é o coeficiente de perda de qualidade (ROSS, 1991).

2.2.4 Função Perda Assimétrica

Além das três funções perdas já vistas, pode-se ter uma quarta função perda denominada de função perda assimétrica.

Essa função perda pode ser exemplificada na figura 2.6, e suas funções são dadas por

$$L_1(y) = k_1 (y - \mu)^2 \text{ para } y < \mu \quad (2.41)$$

e

$$L_2(y) = k_2 (y - \mu)^2 \text{ para } y \geq \mu \quad (2.42)$$

De maneira análoga às funções de perda vistas anteriormente, pode-se calcular os valores dos coeficientes de perda de qualidade k_1 e k_2 . Assim, tem-se

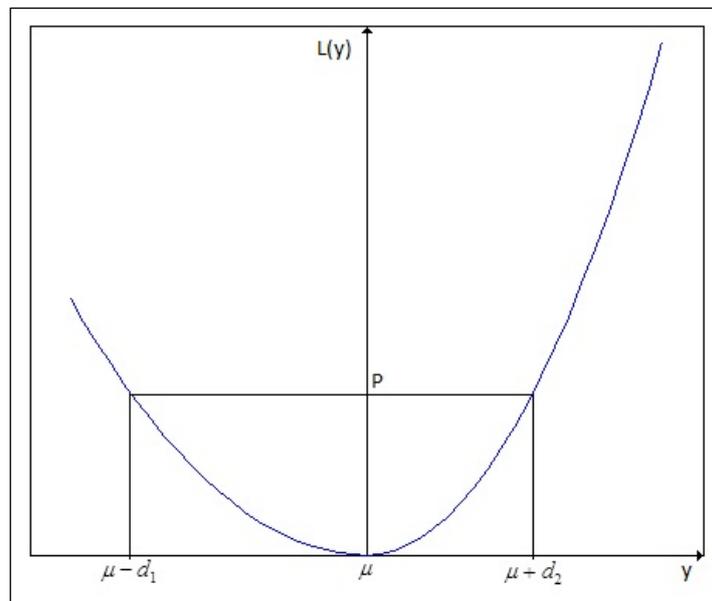
que $k_1 = \frac{P}{d_1}$ e $k_2 = \frac{P}{d_2}$, de maneira que as funções (2.41) e (2.42) podem ser reescritas como

$$L_1(y) = \frac{P}{d_1}(y - \mu)^2 \text{ para } y < \mu \quad (2.43)$$

e

$$L_2(y) = \frac{P}{d_2}(y - \mu)^2 \text{ para } y \geq \mu \quad (2.44)$$

FIGURA 2.6 – FUNÇÃO PERDA ASSIMÉTRICA



FONTE: O AUTOR

2.2.5 CONSIDERAÇÕES A RESPEITO DA FUNÇÃO PERDA

De acordo com as funções perdas média (2.16), (2.31) e (2.38) pode-se observar que as funções perdas são compostas basicamente por dois elementos: a variância de alguma característica funcional e a posição relativa da média desta característica em relação ao valor nominal.

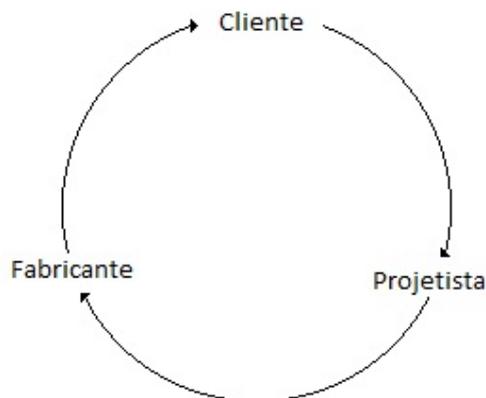
Utilizando como exemplo a função perda média para o caso nominal-é-melhor, descrita em (2.16), observa-se que para se minimizar a perda para a sociedade, deve-se centralizar a característica funcional em questão no valor nominal de projeto e, também, deve-se minimizar a variância desta mesma característica, ou seja, quanto mais uniforme for determinada característica de um produto, menor será a perda por parte da sociedade. Este conceito de uniformidade é estendido para as outras funções perdas também.

De acordo com Ross (1991) a função perda exige dois aspectos do gerenciamento dentro de uma fábrica, sendo que o primeiro aspecto, a variância, é o trabalho concernente a engenheiros de produto e de processo, e deve ser implantado antes do início da produção e aperfeiçoamento do produto (serviço) no decorrer do tempo.

O segundo aspecto, que seria a centralização da distribuição, utilizando como referência o valor nominal, seria de responsabilidade do pessoal da área de produção em suas atividades diárias.

Estes dois aspectos definem o controle de qualidade fora da linha de produção (*off-line*), que seria a fase de projeto, e o controle de qualidade na linha de produção (*online*), que seria a fase de produção. Ambos os aspectos fazem parte do ciclo de qualidade representada pela figura 2.7.

FIGURA 2.7 – CICLO DE QUALIDADE



FONTE: ROSS, P. J. (1991)

2.3 CONTROLE DE QUALIDADE FORA DA LINHA DE PRODUÇÃO (OFF-LINE)

O controle de qualidade fora da linha de produção tem como principal objetivo minimizar a variabilidade de algumas características funcionais de um produto (serviço) na fase de projeto.

A fase de projeto pode ser dividida em três fases: 1) Projeto por sistemas ou concepção do projeto; 2) Projeto por parâmetros; 3) Projeto por tolerâncias.

De acordo com Ross (1991):

O objetivo do desenvolvimento de um produto ou processo é aperfeiçoar características de desempenho do produto de acordo com as necessidades e expectativas do consumidor. O propósito da experimentação consiste na redução do produto ou processo: subsequentemente, podem ser tomadas decisões quanto aos parâmetros que afetam o desempenho do produto ou processo. A função perda quantifica a necessidade de entendimento de quais fatores de projeto que influenciam na média e variação da característica de desempenho do produto ou processo. Ajustando adequadamente a média e reduzindo a variação, as perdas referentes ao produto são minimizadas.

Assim, de acordo com a citação, se reforça a importância do controle de qualidade fora da linha de produção e da importância da utilização da função perda de Taguchi.

2.4 CONTROLE DE QUALIDADE NA LINHA DE PRODUÇÃO (ONLINE)

De acordo com Peace (1993), os esforços no controle de qualidade *online* envolvem todo o sistema de manufatura de um produto. Neste ponto são utilizadas as técnicas que monitoram a produção, medem a qualidade de saída do produto, fornecem sinais de problemas em potencial e que permitem a ação corretiva direta.

O controle de qualidade na linha de produção (*online*) é responsável pela manutenção e consistência de qualidade de produto para produto, ou seja, cada produto deve ter as suas características funcionais centralizadas no valor nominal de

projeto. Com isso, existe minimização da variação dessas características de unidade para unidade e conseqüente aumento na qualidade e confiabilidade do produto em questão, sempre considerando o equilíbrio entre qualidade alta e custos baixos.

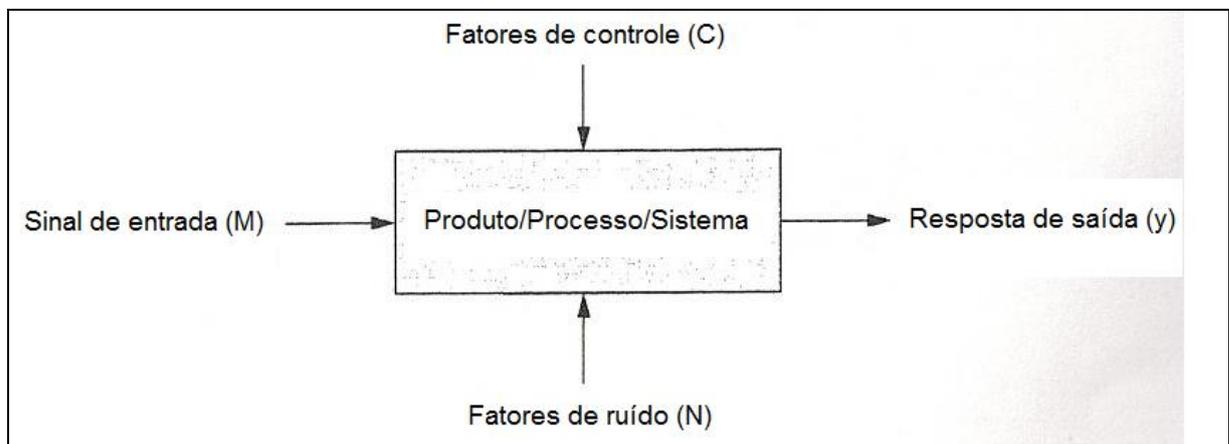
O controle de qualidade na linha de produção é de responsabilidade do pessoal da área de produção em suas atividades diárias e as ferramentas mais utilizadas para tal são as técnicas utilizadas no Controle Estatístico do Processo (CEP).

2.5 DEFINIÇÃO DE PROJETO ROBUSTO

Uma vez definido o controle de qualidade fora da linha de produção, faz-se necessário a definição de projeto robusto em engenharia de qualidade.

A figura 2.8 representa um diagrama de parâmetro (*P-diagram*) muito útil na representação de um processo, de um produto ou de um sistema.

FIGURA 2.8 – P-DIAGRAM



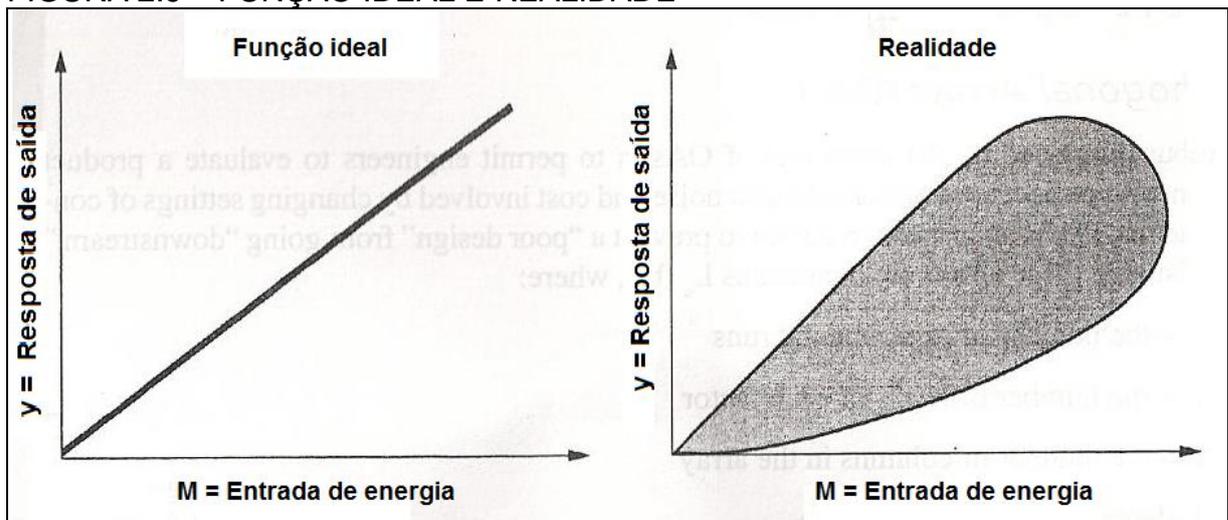
FONTE: ADAPTADO TAGUCHI, G.; JUGULUM, R.; TAGUCHI, S. (2004)

Na figura 2.8 é feita uma representação em blocos da transformação de energia entre o sinal de entrada (M) e a resposta de saída (y), sendo que a meta é maximizar tal transformação de energia pelo ajuste de fatores de controle (C) na presença de fatores de ruído (N). Pode-se afirmar que um sistema consiste em uma gama de atividades ou funções que são designadas para realização de uma determinada operação, com o intuito de produzir um resultado desejado através da

minimização das variações funcionais dos fatores de ruídos. Esta é a idéia chave de um projeto robusto.

Sistemas em engenharia são projetados para produzir resultados específicos para os clientes, e tais sistemas são governados por uma relação ideal entre a entrada e a saída denominada de função ideal, conforme figura 2.9.

FIGURA 2.9 – FUNÇÃO IDEAL E REALIDADE



FONTE: ADAPTADO TAGUCHI, G.; JUGULUM, R.; TAGUCHI, S. (2004)

A idéia em um projeto robusto é aproximar a realidade do estado ideal (*ideal function*), minimizando a perda de energia no processo.

Projeto robusto de um produto diz respeito a procedimentos aplicados durante as fases de pesquisa e desenvolvimento, que tem como principal objetivo, alta qualidade a um custo mínimo.

Existem variações que infelizmente não podem ser controladas pelos fabricantes, e como exemplo, pode-se citar a variação da temperatura em um ambiente. Dentro de uma fábrica vários testes podem ser feitos em um ambiente com temperatura controlada, porém quando o mesmo é colocado no mercado existe esse fator de variação de temperatura envolvido. A pergunta que se faz é: Como eliminar essa variação, visto que ela não é controlada pelo fabricante? A resposta está em não eliminar essa variação, mas tornar o produto ou serviço pouco sensível a essa variação. Assim, exige-se um novo conceito de qualidade onde as fontes de

variação não são eliminadas ou muitas vezes nem controladas, já que o mesmo pode se tornar muito dispendioso. Este conceito foi intitulado de projeto robusto.

De acordo com Creveling e Fowlkes (1995), uma definição fundamental de produto robusto pode ser enunciada como: Um produto ou processo é dito robusto quando é insensível aos efeitos da variabilidade, mesmo que as fontes de ruídos, propriamente ditas, não tenham sido totalmente eliminadas. De acordo com Taguchi et al. (2000), outra definição de projeto robusto é o estado em que a tecnologia, produto ou o desempenho do processo é minimamente sensível a fatores que causam variabilidade (ou no ambiente de produção ou no ambiente do usuário) e envelhecimento com o menor custo de produção da unidade.

Estes procedimentos, para tornar um produto robusto, são aplicados em delineamento de experimentos, com o intuito de reduzir de maneira econômica a variabilidade de uma função do produto em seu ambiente de uso, e também para garantir que o mesmo tenha um desempenho ótimo quando estiver sendo usado pelo consumidor, assim como nos experimentos feitos antes de sua produção e comercialização.

Uma vez que projeto robusto se preocupa em melhorar a qualidade de um produto reduzindo os efeitos das causas de variabilidade sem eliminá-las, faz-se pertinente definir projetos por parâmetros e projetos por tolerâncias.

2.5.1 Projeto por Parâmetros e Projetos por Tolerâncias

Uma das maneiras de se conseguir que um produto se torne insensível ou pouco sensível às variações, devido a fatores de ruído, é utilizar-se de um conceito intitulado por Taguchi como projeto por parâmetros.

De acordo com Ross (1991) este tipo de projeto é utilizado para aperfeiçoamento da qualidade sem controlar ou eliminar as causas de variação. Assim, o conceito de projeto por parâmetros é uma metodologia utilizada em projeto robusto.

Em sua metodologia, Taguchi considera que o projeto de um produto (serviço) é dividido em três fases, sendo estas: 1. Projeto do sistema; 2. Projeto por parâmetros; 3. Projeto por tolerâncias.

O projeto do sistema ou concepção do projeto é a fase em que a equipe de desenvolvimento do produto (serviço) define um sistema que funcione sob determinadas condições iniciais. Tais condições devem ser controladas pela equipe de tal maneira a representar o mais fielmente possível alguma situação real.

Esta é a fase em que se desenvolvem novos conceitos e idéias com o intuito de se fornecer ao consumidor um novo produto ou, até mesmo, algum produto já conhecido, mas com aperfeiçoamento, sendo esta etapa muito importante para manter o fabricante competitivo no mercado, visto que sempre existe a necessidade de melhoria e inovação para tal. Assim, no projeto de um produto, pode-se citar como exemplo o desenvolvimento de um protótipo de um produto, onde o mesmo deve atender as necessidades dos clientes e possuir desvios mínimos dos valores nominais para o qual foi projetado. Nesta fase é que se escolhem os materiais, peças e componentes para constituição do produto e é nesta fase também que a equipe pode utilizar alguma tecnologia que se tenha mostrado robusta anteriormente.

Resumindo, é nessa etapa que a equipe de desenvolvimento do projeto do produto analisa uma variedade de concepções, tecnologias, projetos, arquiteturas com o objetivo de tomar a decisão ótima com relação à viabilidade de cada um dos projetos.

O projeto por parâmetros tem como principal objetivo uniformizar as características de desempenho do produto, isto sempre atrelado a nenhum custo ou a um custo mínimo. Como o próprio nome já diz, o projeto por parâmetros tem como objetivo identificar, analisar e fixar parâmetros para algumas características funcionais, de tal maneira que a mesma se torne pouco sensível ou até mesmo insensível às fontes de variações sem perder a qualidade.

Um exemplo que pode ser citado, para justificar a utilização do projeto por parâmetros, é que o desempenho de um produto pode ser afetado por variáveis ambientais, tais como a temperatura e a umidade. Tais variáveis são fontes de variabilidade externa, que podem levar o produto a uma deterioração precoce e a redução do desempenho de alguma característica funcional. Neste caso, o projeto

por parâmetros é muito utilizado para melhorar a robustez, e conseqüentemente o desempenho, de um produto quando este é utilizado em campo.

De acordo com Simpson et al. (2000), no projeto por parâmetros, existem dois tipos de fatores que afetam uma característica funcional de um produto: os fatores de controle e os fatores de ruído. Ambos os fatores serão definidos posteriormente neste presente trabalho.

O projeto por tolerâncias procura aperfeiçoar a qualidade de um produto aumentando ou reduzindo o intervalo de tolerância de algum parâmetro quando necessário, de tal maneira que o produto (serviço) tenha um desempenho satisfatório do ponto de vista do consumidor, a um custo mínimo. Para tal, é feito um balanceamento criterioso entre a redução de qualidade e o aumento no custo da manufatura, pois a utilização de tolerâncias mais apertadas pode levar a custos mais altos com matérias primas e com processos de manufaturas. Esses conceitos estão intimamente relacionados com o controle de qualidade fora da linha de produção.

De uma maneira geral, quando algum problema é detectado na fase de desenvolvimento de um produto, o projetista vai diretamente para a fase de projeto por tolerâncias sem passar pela fase de projeto por parâmetros. Isto pode levar a um aumento no custo do produto, visto que se fosse feito ajustes nos valores dos parâmetros relacionados às características funcionais em questão, o custo seria menor.

Os projetos por parâmetros e por tolerância adquirem um significado adicional em conjunto com o conceito de função perda, visto que ambos são empregados para reduzir as perdas para a sociedade como um todo. Isto fica evidenciado, como visto anteriormente, ao se aplicar a função perda. Assim, utilizando-se de tais projetos, temos que as verdadeiras características de desempenhos críticos podem ser identificadas e minimizadas em termos de número.

Assim, verifica-se que os problemas encontrados estão intimamente relacionados com variações em alguma característica funcional do produto ou processo, definindo-se então fatores de ruídos em controle de qualidade.

2.5.2 Fatores de Controle e Fatores de Ruído

De acordo com o conceito de projeto robusto, Taguchi distingue os fatores de desenvolvimento de um produto em dois grupos principais: Fatores de controle e fatores de ruído.

Fatores de controle são os fatores que podem ser facilmente controlados e que são estabelecidos pelo fabricante, portanto não podem ser modificados de maneira direta pelo consumidor. Podem-se citar como exemplos, a escolha de uma matéria-prima para confecção de um produto, peças utilizadas na fabricação de um motor, temperatura de um molde em um processo de injeção para moldagem entre outros que não podem ser modificados pelo consumidor, pois estes fatores, dizem respeito, a priori, ao fabricante.

No seu ambiente de uso, a qualidade de um produto pode variar e ter seu desempenho afetado por diversas razões. As causas dessa variabilidade são denominadas de fatores de ruído. Segundo Simpson et al. (2000) os fatores de ruído são os fatores que são difíceis, impossíveis ou muito caros de se controlar.

De acordo com Ross (1991) os fatores de ruído são aqueles sobre os quais o fabricante não possui controle direto, mas que variam de acordo com o ambiente e hábito do consumidor. Assim, fatores de ruído são definidos como qualquer coisa que faça com que uma característica funcional desvie-se do seu valor nominal.

Portanto, no desenvolvimento de um produto torna-se necessário conhecer a natureza do ruído e entendê-lo, visto que no delineamento e desenvolvimento de um produto se busca maximizar o desempenho de todas as suas características funcionais frente à variabilidade.

São definidos três fatores de ruído: 1. Fatores de ruído externo; 2. Fatores de ruído interno ou de deterioração; 3. Fatores de ruído do produto ou de unidade para unidade.

Os fatores de ruído externo são aquelas fontes de variabilidade que vem de fora do produto, tais como, fatores ambientais, umidade, temperatura, oscilação na energia elétrica, magnetismo em redes de alta tensão entre outros. Assim, o ruído externo está diretamente ligado à variação de qualidade de um produto devido à ação externa de algum agente.

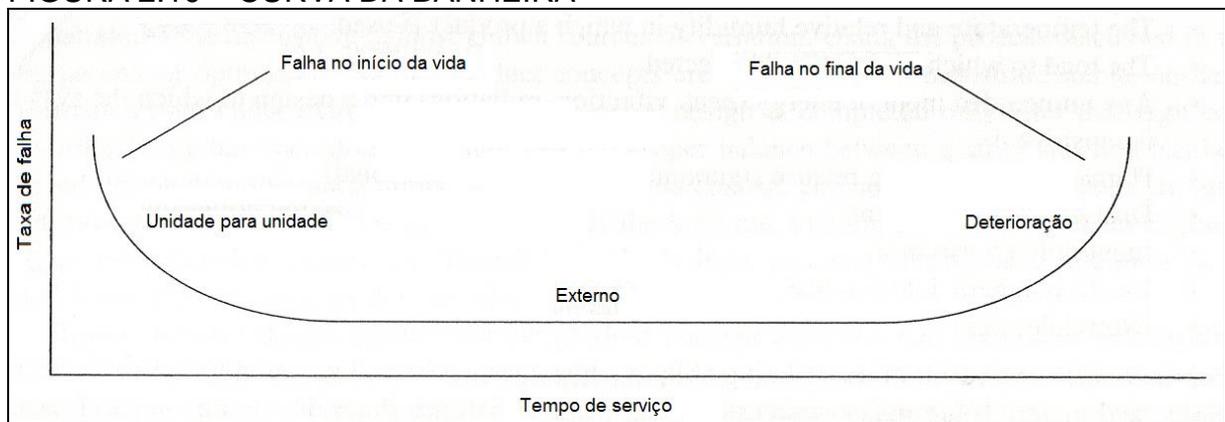
Os fatores de ruído interno estão ligados com a deterioração do produto ou processo. É muito comum haver uma deterioração do desempenho devido ao tempo de uso de um produto e ao próprio material que ele é composto. Pode-se citar como exemplos de fatores de ruídos internos a deterioração de filamentos em lâmpadas incandescentes, desgaste de peças mecânicas em carros, voltagem em uma pilha e assim por diante.

A qualidade de um projeto está intimamente relacionada com o efeito sobre as características de desempenho de um produto que os fatores de ruído externo e interno causam, lembrando que ambos os fatores estão interligados com o controle de qualidade fora da linha de produção.

Os fatores de ruído do produto ou de unidade para unidade tem como resultado a impossibilidade de se produzir dois itens exatamente iguais, onde o processo de fabricação e os materiais utilizados são as maiores fontes de variação do mesmo. Esse tipo de fator se manifesta em processos de fabricação não uniformes e tendenciosos. Tem-se como exemplos a espessura de uma peça mecânica, a resistência de resistores, espessura de tecidos entre outros.

De acordo com Creveling e Fowlkes (1995) o resultado da presença de ruídos é usualmente caracterizado como um problema de confiabilidade e a falha de um produto pode ser caracterizada em relação ao tempo. Neste caso distinguem-se três categorias: 1) Falhas no início da vida; 2) Falhas durante a vida normal do projeto; 3) Falhas no fim da vida. Métodos clássicos de confiabilidade descrevem essas falhas em um gráfico denominado de “curva da banheira”, demonstrada na figura 2.10.

FIGURA 2.10 – CURVA DA BANHEIRA



FONTE: ADAPTADO CREVELING, C. M.; FOWLKES, W. Y. (1995)

A figura 2.10 relaciona os três tipos de fatores de ruído em relação ao seu tempo de vida.

Sempre se deve ter em mente que a qualidade da produção está diretamente ligada com a uniformidade do processo de fabricação, ou seja, está relacionada aos fatores de ruído e a robustez do produto frente a esses fatores.

2.5.3 Fator de Ajuste, Fator de Escala e Métrica

Neste ponto se torna necessário introduzir as definições de fator de ajuste, fator de escala e métrica, visto que os mesmos serão citados no decorrer desta tese.

Um fator de ajuste é aquele fator que pode ser utilizado para direcionar o valor da resposta média no sentido do valor nominal de projeto. Fator de escala ocorre quando um fator de ajuste possui a propriedade de fazerem ambos, a média e o desvio padrão, aumentarem ou diminuir proporcionalmente a ele.

Assim, um exemplo da utilização do fator de escala na otimização de um processo que segue uma tolerância de nominal-é-melhor (NTB) é dividido em duas fases.

Em uma primeira fase, a variabilidade (desvio-padrão) poderia ser determinada para um determinado valor do fator de escala, reduzindo o mesmo, o máximo possível. A segunda fase consiste em ajustar determinada característica funcional no valor alvo projetado, mesmo que o desvio padrão varie proporcionalmente à medida que se ruma ao valor alvo.

Apesar de não ser o ideal aumentar a variabilidade ao passo que se desloca para o valor alvo, esse é um preço que se paga para minimizar a função perda, desde que se tenha exaurido todos os recursos possíveis para a redução da variabilidade.

Métricas de controle de qualidade indicam de forma simplificada o momento em que um modelo estatístico não está apresentando um desempenho satisfatório, e pelo fato de todo modelo utilizar como base um conjunto de dados históricos para a situação estudada, o mesmo com o passar do tempo pode sofrer alterações. Essas alterações podem prejudicar o desempenho do modelo e, o mesmo, precisar

de uma “calibração”. Esta “calibração” e monitoração da aderência (assertividade) do modelo são feitas utilizando-se as métricas de controle de qualidade.

Uma métrica muito utilizada e conhecida é o coeficiente de variação de Pearson, cuja equação é dada por

$$CV(\%) = \frac{\sigma}{\mu} \times 100 \quad (2.45)$$

e estimada por

$$CV(\%) = \frac{s}{\bar{y}} \times 100 \quad (2.46)$$

Onde s representa o desvio padrão (variabilidade) e \bar{y} o valor médio do processo em questão.

2.6 RAZÃO SINAL-RUÍDO

A avaliação de desempenho de um produto é parte importante do processo de medição de qualidade do mesmo. Se o desempenho é avaliado apenas por uma lista específica de problemas detalhados e difusos, o processo de melhoria da qualidade torna-se muito superficial. Neste caso, torna-se imperativo desenvolver uma métrica eficiente para avaliação do desempenho de um produto.

Tal métrica deve levar em consideração dois tipos de saída de um sistema de produção de um produto, a saída do sistema que se deseja alcançar e a saída do sistema que é indesejável. Desta maneira a métrica deve englobar simultaneamente os aspectos desejáveis e indesejáveis do desempenho em um único valor.

Com isso, torna-se de extrema importância estudar o efeito da variação de alguma característica do produto (serviço) com o intuito de verificar a sua influência no desempenho do mesmo.

Taguchi et al. (2004) idealizou uma transformação dos dados na repetição de um experimento, de tal maneira que essa transformação represente a medida da variação existente e sua influência em alguma característica funcional do produto ou

processo. Essa transformação é denominada de razão sinal-ruído (S/N) e, essa relação combina diversas repetições com o intuito de verificar o quanto de variação está presente no desempenho do produto.

De acordo com Bendell (1988) a razão sinal-ruído foi uma das maiores fontes de críticas e confusão da metodologia de Taguchi, onde sua medida quer demonstrar simplesmente uma medida de desempenho a para escolha de níveis de controle que melhor lidam com o ruído.

Segundo Taguchi et al. (2004) a razão sinal-ruído é uma medida de robustez, uma vez que mede a transformação de energia no produto e tem como escala o decibel (dB).

Basicamente a razão sinal-ruído mede a magnitude da verdadeira informação (sinal) após algumas variações incontroláveis (ruído). Neste caso, denomina-se como sinal o desempenho desejado e como ruído o desempenho indesejado.

De acordo com o tipo de característica funcional a ser monitorada, existe um tipo de razão sinal-ruído adequada.

Assim a razão sinal-ruído é uma medida utilizada para otimizar e medir a robustez de um produto ou processo. E como medida, ela reflete a variabilidade de resposta de um sistema causada por fatores de ruídos, independentemente de ajustes na média, ou seja, ela é útil para prever a qualidade mesmo se o valor nominal projetado mudar.

Outra utilidade da razão sinal-ruído é na comparação de propostas, visto que ela é uma medida de qualidade relativa que não leva em consideração interações entre fatores, e isto é muito útil quando muitos fatores são utilizados para medir e analisar a qualidade de um produto (serviço).

O procedimento para construir a razão sinal-ruído é baseado no desvio médio quadrático (MSD) da função perda média de qualidade, que é calculado através de medidas de dispersão, tal qual a variância. O desvio médio quadrático é modificado para fazer a razão sinal-ruído independente dos ajustes do valor alvo de projeto.

Na expressão modificada utiliza-se o logaritmo pelo fato de melhorar a propriedade de aditividade e também para ajudar na redução da interação entre os fatores de controle, onde ambas as propriedades são bastante desejáveis. Além

dessas duas propriedades, utiliza-se do logaritmo no cálculo da razão sinal-ruído pelo fato da mesma utilizar a escala decibel para relacionar dois valores. A escala decibel, denotada por dB, indica a proporção de uma quantidade física (energia ou intensidade) em relação a um nível de referência especificado e sempre descreve a razão entre duas quantidades. Uma relação em decibéis é igual a dez vezes o logaritmo de base 10 da razão entre duas quantidades de energia. Assim,

$$dB = 10 \log \left(\frac{Q_1}{Q_2} \right) \quad (2.47)$$

onde Q_1 e Q_2 são quantidades de energia que serão comparadas.

A definição do decibel é dada primordialmente pela definição da escala bel, denotada por B, que é uma escala raramente usada e definida por

$$B = \log \left(\frac{Q_1}{Q_2} \right) \quad (2.48)$$

que também relaciona duas quantidades de energias Q_1 e Q_2 . O bel tem seu nome em homenagem ao físico Alexander Graham Bell.

Uma vez que se entenda o uso do logaritmo na razão sinal-ruído, se faz pertinente definir que existem diversos tipos de razão sinal-ruído, onde as mesmas se diferenciam de acordo com o tipo de característica funcional envolvida. Podem ser citadas as seguintes razões sinal-ruído: Menor-é-melhor (STB); Maior-é-melhor (LTB); Nominal-é-melhor (NTB), onde esta última se divide em dois tipos.

Assim, de acordo com Ross (1991) a razão sinal-ruído é tratada como resultado do experimento, que constitui uma medida da variação dentro de um ensaio, quando os fatores de ruído estão presentes. A razão sinal-ruído consiste em um resultado que concentra as repetições e o efeito dos níveis de ruído em um único valor observado.

Outro aspecto a ser comentado é que a razão sinal-ruído é uma métrica que leva em conta o efeito do fator de ajuste. Ela pode não mudar quando o valor do fator de ajuste é alterado, porém pode ser sensível ao tamanho do desvio padrão para um determinado valor do fator de ajuste. Uma métrica que satisfaz essas

condições é o coeficiente de variação de Pearson descrito em (2.45) e estimado em (2.46).

A razão sinal-ruído separa os efeitos do ruído na resposta e o ideal é que seja baseada nas seguintes propriedades: 1) A métrica deve refletir a variabilidade da resposta e deve ser independente do ajuste na média, pois muitas vezes, após o projeto ser otimizado, deseja-se ajustar o desempenho do mesmo para algum valor preferido. Este ajuste feito não deve perturbar a otimização. 2) A métrica deve também medir a qualidade relativa e não deve induzir a complicações desnecessárias, tais como interações entre fatores de controle, no caso em que muitos fatores de controle na qualidade do produto sejam analisados. 3) Caso existam diversos fatores de ruído e cada um individualmente possua um efeito sobre o desempenho do produto, deseja-se que o efeito total dos diversos efeitos sejam simplesmente a soma dos mesmos. Esta propriedade é denominada de aditividade. 4) A maximização da métrica de desempenho deve corresponder a minimização da perda de qualidade. Assim, deseja-se que a métrica de desempenho utilizada possua uma significância econômica que facilite os procedimentos de otimização.

Nesta altura torna-se importante classificar as características funcionais de um produto (serviço), que se dividem em duas classes: A classe estática e a classe dinâmica.

A classe estática se aplica aos casos onde as características alvo de qualidade tem um nível fixo, por exemplo, a força de fechamento de uma capota, a dimensão de um produto, ou em outras palavras, se busca um valor constante que pode ser definido antes de começarmos efetivamente o experimento.

A classe dinâmica se aplica a casos onde a característica de qualidade opera em um intervalo de valores, ou simplesmente aquela característica que não pode ser representada por uma constante. Pode ser citado como exemplo, a escala de tonalidades na cor preta das impressoras, o carregador de um aparelho eletrônico, onde o valor de sua saída esta diretamente ligada com o valor de entrada.

Com isto, definem-se três tipos de razões sinal-ruído, as quais são utilizadas para medições do desempenho de características estáticas. A escolha, ou não, de alguma delas está relacionada com a classe e característica funcional a ser testada.

A utilização da razão sinal-ruído mede o desempenho de um processo e o foco de atividades para otimização dos valores de parâmetros críticos, tornando-se essencial no que diz respeito a melhorias significativas em qualidade, e assim, pode-se afirmar que é um grande avanço em relação a outras expressões mais comuns de desempenho de um produto ou serviço.

Neste presente trabalho será considerada a classe funcional estática.

2.6.1 Razão Sinal-Ruído para o caso Menor-é-Melhor (STB)

Muitas características de desempenho possuem o zero como valor alvo. Isto sugere que essas características possam ser os próprios ruídos dentro de um sistema.

Neste caso, em específico, torna-se conveniente tratar essas características como menor-é-melhor. A razão sinal-ruído menor-é-melhor (STB) é baseada na função perda menor-é-melhor.

Assim, utiliza-se esta razão sinal-ruído para produtos (serviços) que possuam respostas ou características de qualidade contínuas e não negativas de valor nominal é igual a zero. Neste caso, não existe a utilização de fatores de ajuste, pois o objetivo é minimizar o máximo possível a média (pois o valor alvo é zero) e a variância da característica de desempenho em questão.

Como não se utiliza fator de ajuste, não se aplica o processo de otimização em dois passos, visto adiante na presente tese.

No caso da razão sinal-ruído menor-é-melhor minimiza-se o desvio médio quadrático, tendo como consequência a redução da variação, e simultaneamente, o deslocamento do valor da característica funcional para o valor mais próximo do valor alvo.

A razão sinal-ruído nesse caso é dada por

$$S / N_{STB} = -10 \log \left[\frac{1}{n} \sum_{i=1}^n y_i^2 \right] \quad (2.49)$$

Onde n é o tamanho da amostra e y_i é a resposta influenciada pelos fatores de ruído.

Para se chegar em (2.49), deve-se lembrar de que para o caso menor-é-melhor deve-se minimizar o erro médio quadrático. Onde o mesmo é dado por

$$MSD_{STB} = \frac{1}{n} \sum_{i=1}^n y_i^2 \quad (2.50)$$

Minimizar o MSD dado em (2.50) é o mesmo que maximizar a razão sinal-ruído definida por

$$S/N_{STB} = -10 \log[MSD] \quad (2.51)$$

assim obtendo (2.51).

Então observa-se que a medida de desempenho neste caso nada mais é do que a variância do zero, ou a medição do erro médio quadrático (MSD) do zero.

2.6.2 Razão Sinal-Ruído para o caso Maior-é-Melhor (LTB)

A razão sinal-ruído para o caso maior-é-melhor é baseada na função perda maior-é-melhor.

Utiliza-se esse tipo de razão sinal-ruído para os casos onde a variável resposta é composta de números reais não negativos, ou seja, $y \in \mathfrak{R}^+$, ou seja, temos uma variável aleatória contínua não negativa.

Neste caso, o valor ideal para a variável resposta é o maior possível ou infinito e da mesma maneira que no caso menor-é-melhor, não existe fator de escala para um problema do tipo LTB. De maneira análoga ao STB não se aplica a otimização em dois passos no processo.

De maneira análoga ao caso STB, encontra-se a razão sinal-ruído através da minimização do MSD (Desvio Médio Quadrático). O desvio médio quadrático para este caso é dado por

$$MSD = \frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \quad (2.52)$$

que minimizado, torna-se equivalente a maximização da razão sinal-ruído, que é dada por

$$S / N_{LTB} = -10 \log \left[\frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \right] \quad (2.53)$$

2.6.3 Razão Sinal-Ruído para o caso Nominal-é-Melhor (NTB)

Em muitos sistemas produtivos se deseja que a característica de saída do mesmo seja um valor nominal de projeto e valores diferentes do mesmo são menos desejáveis. Neste caso a característica de saída a ser avaliada pode ser denominada de nominal-é-melhor.

Processos de produção direcionados para se produzir algum produto com uma dimensão específica é um exemplo clássico para o caso nominal-é-melhor.

A medição do desempenho de um sistema em vários experimentos pode ser feita pelo cálculo do valor médio e do desvio padrão para esse conjunto de dados. A razão do valor médio pelo seu desvio padrão é sugerida como uma boa métrica de desempenho.

Através desta razão tem-se uma referência onde se pode alcançar uma perspectiva razoável sobre a magnitude do desvio padrão para uma determinada característica mensurada. Outra propriedade desejável é a de ser independente a um ajuste feito posteriormente.

A função perda nominal-é-melhor, em conjunto com a razão do valor médio com o desvio padrão, é a base para a formação da razão sinal-ruído NTB. Neste caso, se tem dois tipos de razões sinal-ruído, e o motivo para isto, é que para cada um dos tipos as variáveis respostas possuem valores específicos.

Os tipos de razões sinal-ruído para o caso NTB são definidos como do TIPO I e do TIPO II.

2.6.3.1 Tipo I

Neste tipo, a variável resposta é composta por números reais não negativos, ou seja, a variável resposta é definida como uma variável aleatória contínua não negativa.

Este caso se diferencia do tipo STB pelo fato do valor alvo ou desejado ser diferente de zero e ter variância nula quando a resposta média é zero.

Exemplos deste tipo de razão sinal-ruído podem ser em casos de densidade de imagem e alcance de um projétil.

A razão sinal-ruído para o caso NTB – TIPO I é dada por

$$S / N_{\text{tipo I-NTB}} = 10 \log \left[\frac{\bar{y}^2}{s^2} \right] \quad (2.54)$$

onde

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n} \quad (2.55)$$

e

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 \quad (2.56)$$

É comum que as n observações sejam obtidas de n diferentes condições de ruído.

2.6.3.2 Tipo II

Neste tipo de razão sinal-ruído NTB os valores assumidos pela variável resposta são números reais, ou seja, $y \in \Re$, assim definindo a variável resposta como uma variável aleatória contínua.

Outro fator que diferencia os dois tipos NTB de razões sinal-ruído é que neste caso o valor alvo pode ser igual a zero.

Como é possível valor negativo para uma determinada característica, pode acontecer de o valor médio ser menor que o desvio padrão, e neste caso torna-se desejável que a razão sinal-ruído seja dada por

$$S / N_{\text{tipo II-NTB}} = -10 \log[s^2] \quad (2.57)$$

Neste caso se tem os exemplos: dimensões de peças torneadas, dimensões de peças fundidas ou moldadas, entre outros.

A interpretação segundo Mori (1995), do valor dado pela razão sinal-ruído, é de que uma pequena componente de sinal, denotada por S (*signal*), e uma grande componente de ruído, denotada por N (*noise*), fornece um pequeno valor para a razão sinal-ruído e no caso, onde se tem uma grande componente de sinal S e uma pequena componente de ruído N, tem-se um grande valor para a razão sinal-ruído, ou seja, quanto maior o seu valor mais robusto será o produto para determinadas condições de ruído.

2.7 PROCESSO DE OTIMIZAÇÃO EM DOIS PASSOS

Quando se busca a produção seguindo um modelo de delineamento robusto, uma das coisas mais importantes é verificar como está o desempenho do produto com relação ao valor nominal de projeto.

De uma maneira geral, através de uma análise verifica-se por um protótipo que o produto está com a sua resposta, para determinada característica, muito próxima do valor alvo, porém, quando este é exposto a certos tipos de ruídos o mesmo apresenta uma grande variação.

Quando este tipo de problema aparece, a área de engenharia deve tomar providências no que diz respeito a colocar o valor desta característica de desempenho no valor alvo que se dá através de um procedimento que é denominado de Processo de Otimização em Dois Passos.

Este processo baseia-se na seguinte metodologia.

Passo 1: Antes de colocar a distribuição de alguma característica do produto sobre o alvo, utilizam-se técnicas para reduzir ao máximo a variabilidade dessa característica sem se preocupar em colocar a mesma no alvo. Tornando, assim, esta distribuição a mais delgada possível.

Para isto, ser possível, é necessário que os engenheiros encontrem pontos dos fatores de controle que produzam uma resposta, a mais apertada possível, para determinada função do produto na presença de fatores de ruído.

Passo 2: Basicamente consiste em usar algum fator para se ajustar a média, onde este fator seja escolhido de tal maneira a afetar o mínimo possível a variabilidade da característica otimizada.

Assim o método de otimização em dois passos transforma o problema de se colocar alguma característica sobre um valor alvo em dois problemas mais simples.

Operacionalmente o método pode ser resumido em:

Passo 1: Maximizar a relação S/N minimizando os efeitos dos ruídos em determinada característica.

Isto é feito identificando-se os fatores de controle que possuem elevações significativas nos gráficos de S/N. Uma vez identificado os fatores, escolhe-se o fator que corresponde ao valor máximo de S/N.

Passo 2: Ajustar a resposta sobre o alvo.

Para tal, escolhe-se o fator que possui simultaneamente, maior elevação no gráfico da média e menor elevação no gráfico de S/N.

2.8 APLICAÇÕES CONTRA RUÍDOS

Uma vez definido o projeto do sistema, o projeto por parâmetros e o projeto por tolerâncias, tem-se no quadro 1, a descrição resumida da eficácia de cada um para a minimização de ruídos.

QUADRO 1 – PROCEDIMENTOS NA QUALIDADE CONTRA RUÍDOS

ÁREA DO CONTROLE DA QUALIDADE	DEPARTAMENTO	PROCEDIMENTO	Ruídos		
			EXTERNO	INTERNO	PRODUTO
Controle da Qualidade fora da linha	Pesquisa e Desenvolvimento	Projeto do Sistema	1	1	1
		Projeto por Parâmetros	1	1	1
		Projeto por Tolerâncias	2	1	1
	Engenharia de Produção	Projeto do Sistema	3	3	1
		Projeto por Parâmetros	3	3	1
		Projeto por Tolerâncias	3	3	1
Controle de Qualidade Na Linha	Fabricação	Diagnóstico e Ajuste do Processo	3	3	1
		Previsão e Correção	3	3	1
		Medição e Disposição (destino)	3	3	1
	Vendas	Assistência Técnica	3	3	3

FONTE: ROSS, 1991, p. 245

NOTA: 1 – Eficaz; 2 – Eficaz, mas não recomendado; 3 – Impossível.

2.9 CAPACIDADE DE UM PROCESSO

Além da função perda de Taguchi e da razão sinal-ruído, pode-se utilizar como medida de qualidade a capacidade de um processo. A capacidade de um processo tem a ver com a uniformidade do mesmo em uma linha de produção, pois quanto mais uniforme for a produção de um bem, maior a qualidade do mesmo, desde que o processo esteja centrado no valor nominal de projeto (*target*). Se mede a uniformidade de um processo pela variabilidade existente no mesmo, pois quanto menor for esta, mais uniforme o processo se encontra.

Sendo assim, a capacidade de um processo está diretamente relacionada com o desempenho do processo produzir bens com alta qualidade.

Para o cálculo da capacidade de um processo, deve-se conhecer os limites de especificação da característica funcional do produto em questão, a distribuição de probabilidade desta característica, o valor médio e a variância da amostra a ser testada. Sendo assim, pode-se estimar a porcentagem de produtos que estão dentro dos limites de especificação do mesmo (conformes). O valor dessa estimativa é definida como capacidade de um processo.

De acordo com Chaves Neto (2013) a análise da capacidade de um processo é definida como o estudo de engenharia para estimar a capacidade de um processo, sendo que a estimativa pode ser feita por meio de uma distribuição de probabilidade com uma forma conhecida.

Segundo Samohyl (2009) a suposição de normalidade dos dados é fundamental para o cálculo do índice de capacidade, pois a sensibilidade do índice é muito grande quando a suposição não é respeitada. Caso não seja possível supor a normalidade dos dados analisados, a variável não normal deve ser transformada em uma variável com a suposição de normalidade aceita, através de alguma transformação matemática válida e apropriada. Após o cálculo dos índices serem efetuados, uma retransformação dos dados é efetuada.

De acordo com Silva e Ferreira (2008) para amostras com distribuição normal, tamanhos amostrais a partir de tamanho dez podem ser usados para os testes de normalidade de Shapiro Wilk, Anderson-Darling, Lilliefors e Shapiro-

Francia. Neste presente trabalho é utilizado o teste de normalidade de Lilliefors e Kolmogorov-Smirnov para verificar a normalidade das amostras.

2.9.1 Razão da Capacidade Potencial de um Processo

Uma forma alternativa e mais simples de se expressar a capacidade de um processo é através da razão de capacidade potencial de um processo ou coeficiente potencial de um processo, sendo denotada por PCR ou C_p . Sua equação é dada por

$$C_p = \frac{LSE - LIE}{6\sigma} \quad (2.58)$$

cujo valor é estimado pela equação

$$\hat{C}_p = \frac{LSE - LIE}{6\hat{\sigma}} \quad (2.59)$$

O índice C_p chamado de índice de capacidade potencial do processo mede quanto o processo pode produzir produtos satisfazendo as especificações, considerando que o processo esteja centrado no valor nominal de especificação (GONZALEZ, 2013).

O índice C_p mede a capacidade potencial de um processo produtivo, onde o mesmo é definido pela razão da medida de dispersão (amplitude) que a especificação do projeto tolera e a medidade de dispersão real do processo, neste caso dada por 6σ .

Segundo Samohyl (2009), o índice de capacidade de um processo é uma medida da relação numérica entre os limites de especificação e os limites de controle, onde o limite de especificação é uma medida da tolerância permitida da variabilidade de uma característica importante do produto ou processo. Assim, a

tolerância é calculada pelo engenheiro ou projetista na hora da concepção do projeto, ou seja, é um conceito teórico. O limite de controle, por sua vez, são valores calculados dos dados observados, portanto práticos e não teóricos, ou seja, a tolerância é um intervalo do que deve ser, enquanto os limites de controle medem o que realmente é.

O valor do valor da razão de capacidade potencial de um processo é inversamente proporcional ao desvio padrão real do processo σ , assim, fica evidente que conforme se aumenta a variabilidade do processo o coeficiente C_p sofre essa influência de maneira direta através de σ , tendo como consequência sua diminuição de valor e respectiva diminuição de capacidade de processo. De forma contrária, conforme se eliminam as fontes de variabilidade, o processo torna-se mais uniforme (padronizado), tendo como consequência direta o aumento da capacidade do processo fazendo com que a empresa torne-se mais competitiva no mercado.

Quando maior a capacidade de um processo, mais competitiva a empresa é e vice-versa. Pode-se tomar como medida padrão para a razão da capacidade de um processo o valor um, pois se o valor da C_p for menor que um, diz-se que o processo é potencialmente incapaz de satisfazer as exigências da especificação. Caso o valor de C_p seja maior do que um, diz-se que o processo é potencialmente capaz de satisfazer as exigências de especificação.

2.9.1.1 Razão unilateral da capacidade potencial de um processo

Em muitos casos, dependendo da característica funcional do produto, o processo possui somente um limite de especificação, podendo ser somente o limite inferior de especificação (LIE) ou o limite superior de especificação (LSE). Nestes casos específicos tem-se a razão unilateral da capacidade potencial do processo ou coeficiente unilateral potencial.

Quando se possui somente a especificação superior para o coeficiente unilateral potencial, o mesmo é denotado por C_{p_s} , ou PCR_s , e sua equação é dada por

$$C_{p_s} = \frac{LSE - \mu}{3\sigma} \quad (2.60)$$

e quando se possui somente a especificação inferior para o coeficiente unilateral potencial, o mesmo é denotado por C_{p_i} , ou PCR_i , cuja equação é dada por

$$C_{p_i} = \frac{\mu - LIS}{3\sigma} \quad (2.61)$$

Os respectivos estimadores para o coeficiente unilateral potencial, denotados por \hat{C}_{p_s} e \hat{C}_{p_i} , são respectivamente

$$\hat{C}_{p_s} = \frac{LSE - \hat{\mu}}{3\hat{\sigma}} \quad (2.62)$$

e

$$\hat{C}_{p_i} = \frac{\hat{\mu} - LIS}{3\hat{\sigma}} \quad (2.63)$$

2.9.2 Coeficiente Potencial de um Processo Não-Centrado

Quando se tem um processo não-centrado na média (valor nominal), o valor da razão potencial da capacidade de um processo pode indicar um mesmo desempenho para dois processos produtivos com desempenhos diferentes, pois para o cálculo do valor da C_p não se considera o valor médio do processo. O cálculo da C_p , utilizando a equação 2.58 é feito considerando-se a medida da amplitude

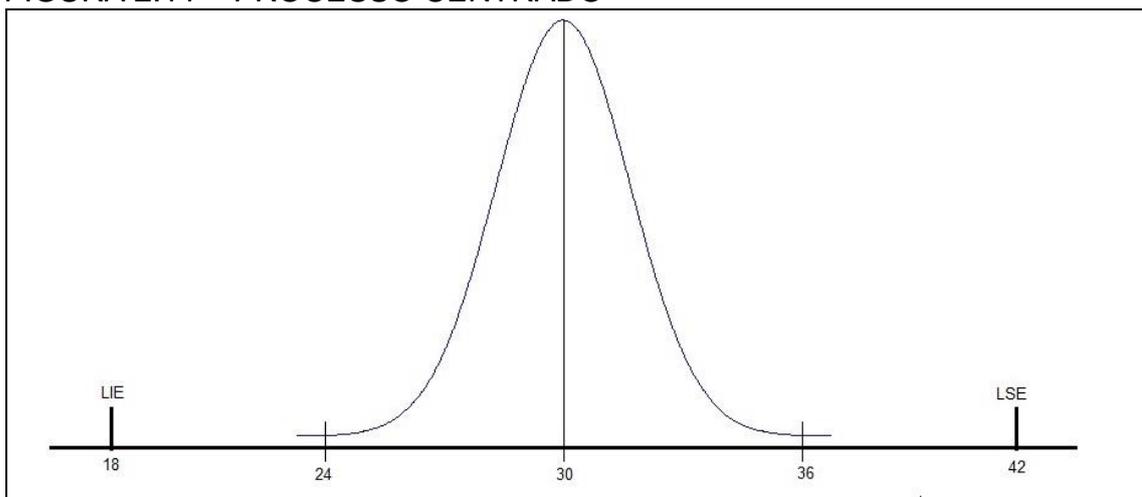
das especificações com relação à medida de dispersão real do processo, denotada por 6σ .

Desta maneira podem-se ter dois processos com um mesmo valor de C_p , mas devido a descentralidade de um dos processos, o mesmo possuir capacidade inferior ao outro. Uma maneira de se contornar esse problema é usando o seguinte cálculo para a razão de capacidade

$$\hat{C}_{pk} = \min(\hat{C}_{p_i}, \hat{C}_{p_s}) \quad (2.64)$$

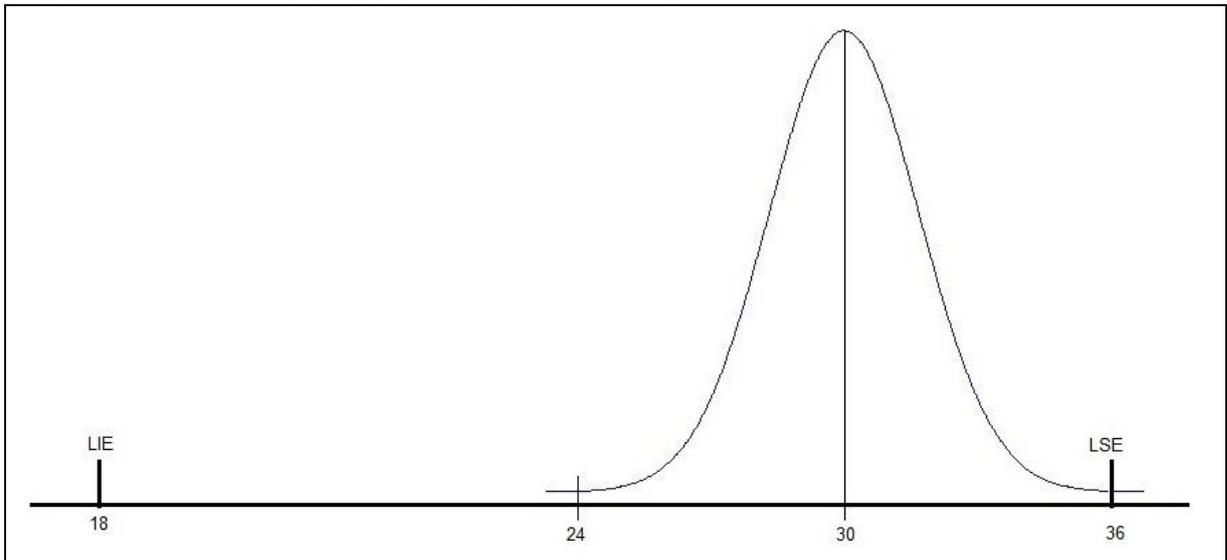
As figuras 2.11 e 2.12 exemplificam dois processos produtivos onde se tem o mesmo valor de C_p , mas com diferentes desempenhos no processo, supondo que o desvio padrão de ambos os processos seja $\sigma = 2$ e que se tenha testado a hipótese de normalidade dos processos, onde a mesma não possa ser rejeitada em ambos os processos.

FIGURA 2.11 – PROCESSO CENTRADO



FONTE: O AUTOR

FIGURA 2.12 – PROCESSO NÃO-CENTRADO



FONTA: O AUTOR

De acordo com a equação (2.59) verifica-se que se tem o mesmo valor para a razão de capacidade potencial de um processo ($C_p = 2,0$) nas figuras 2.11 e 2.12, mesmo com o processo, exemplificado na figura 2.1, ser declaradamente mais eficiente que o exemplificado na figura 2.12, pois o mesmo se encontra centrado na média.

Desta maneira, o valor da C_p isoladamente não é uma medida suficiente para se medir o desempenho do processo. Assim, torna-se necessário uma nova medida que em conjunto com a C_p possa medir o desempenho do processo. O cálculo dessa nova medida, já denominada anteriormente como C_{pk} , é calculada pela equação (2.64).

O valor de C_{pk} para a figura 2.11 é 2,0 e para a figura 2.12 é de 1,0. Quanto menor o valor da C_{pk} , mais descentralizado o processo se encontra. Desta maneira, fica evidente através desse índice que os processos das figuras 2.11 e 2.12 possuem desempenhos diferentes, sendo o da figura 2.11 mais eficiente.

Assim, pode-se afirmar que:

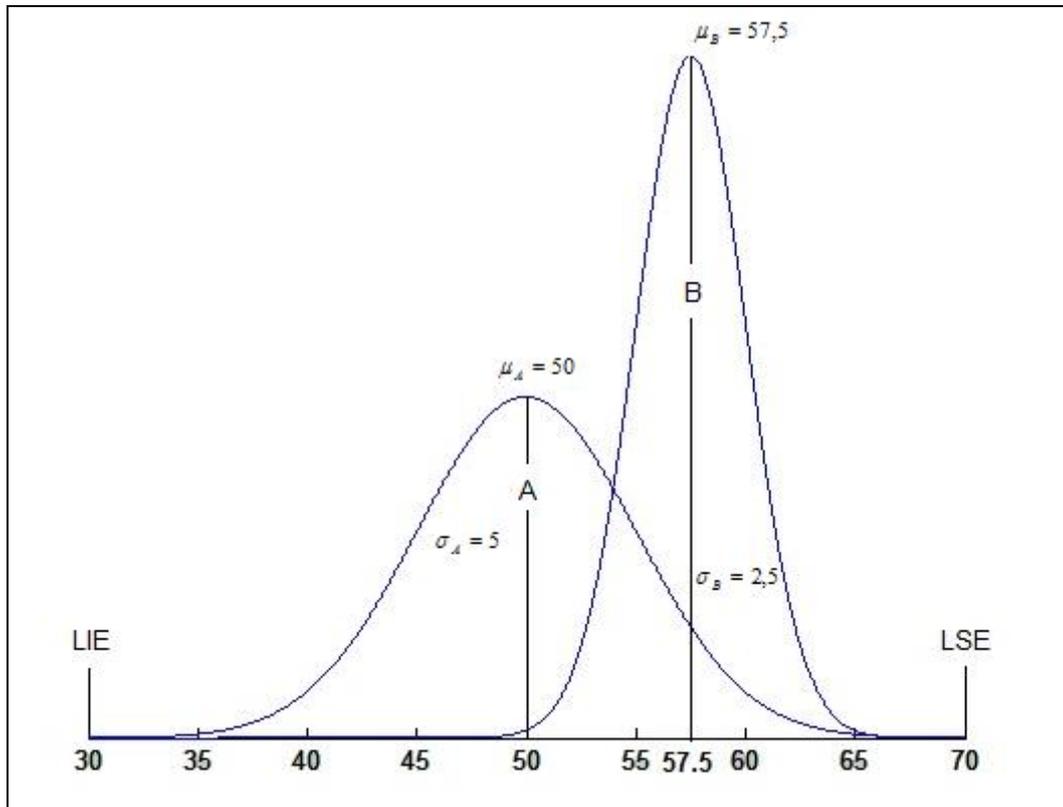
- (1) $C_p = C_{pk}$, quando o processo se encontra centrado no ponto médio das especificações;
- (2) $C_p > C_{pk}$, quando o processo não se encontra centrado no ponto médio das especificações.

2.9.3 O Índice C_{pkm}

O objetivo da criação do índice C_{pk} , foi pelo motivo do índice C_p não levar em consideração se o processo está centrado ou não no valor médio das especificações. Mesmo com C_{pk} levando em consideração a centrabilidade do processo, o mesmo apresenta falhas dependendo da configuração dos processos a serem comparados.

A figura 2.13 apresenta dois processos que possuem o mesmo valor de C_{pk} , mesmo com um dos processos fora do centro das especificações. Os processos A e B possuem um valor de $C_{pk} = 1,0$, mesmo com os centros de ambos os processos serem claramente diferentes.

Para o processo A temos que a $C_p = C_{pk}$ com valor igual a 1,0, enquanto que para o processo B temos que $C_p > C_{pk}$, onde a $C_p = 2,0$ e a $C_{pk} = 1,0$, mostrando que o processo B está descentralizado.

FIGURA 2.13 – DOIS PROCESSOS COM MESMO VALOR DE C_{pk} 

FONTES: O AUTOR

De acordo com as equações (2.62), (2.63) e (2.64), observa-se que para um valor fixo de μ no intervalo de LIE até LSE, o cálculo de C_{pk} é inversamente proporcional ao valor de σ , e que o mesmo torna-se exageradamente grande quando σ aproxima-se de zero. Sendo assim, C_{pk} não reflete bem a questão da localização da média μ no intervalo de LIE até LSE. Devido a este fato criou-se outro índice que é um melhor indicador de centrabilidade que o índice C_{pk} , pois o mesmo considera a variabilidade medida por σ^2 e o afastamento do alvo (*target*) medido por $(\mu - T)^2$.

Tal índice é definido como C_{pkn} e sua expressão é definida por

$$C_{pkn} = \frac{LSE - LIE}{6\sigma} \quad (2.65)$$

onde τ é definido como a raiz quadrada do desvio médio quadrático esperado do ponto médio (alvo)

$$T = \frac{LSE - LIE}{2} \quad (2.66)$$

O desvio médio quadrático esperado do ponto médio é dado por

$$\tau^2 = E(x - T)^2 \quad (2.67)$$

onde,

$$E(x - T)^2 = E[(x - \mu)^2] + (\mu - T)^2. \quad (2.68)$$

Assim,

$$\tau^2 = \sigma^2 + (\mu - T)^2 \quad (2.69)$$

e a equação (2.65) pode ser reescrita como

$$C_{pkn} = \frac{LSE - LIE}{6\sqrt{\sigma^2 + (\mu - T)^2}} \quad (2.70)$$

Considerando que

$$\varepsilon = \frac{(T - \mu)}{\sigma} \quad (2.71)$$

e colocando em evidência σ no numerador da equação (2.70), tem-se

$$C_{pkm} = \frac{LSE - LIE}{6\sqrt{\sigma^2 \left(1 + \frac{(\mu - T)^2}{\sigma^2}\right)}} \quad (2.72)$$

Reescrevendo (2.72), tem-se que

$$C_{pkm} = \frac{LSE - LIE}{6\sigma \sqrt{1 + \left(\frac{(\mu - T)}{\sigma}\right)^2}} \quad (2.73)$$

Substituindo na equação (2.73), pelas equações (2.58) e (2.71) se tem que

$$C_{pkm} = \frac{C_p}{\sqrt{1 + \varepsilon^2}} \quad (2.74)$$

O estimador de C_{pkm} , dado pela equação (2.74) é

$$\hat{C}_{pkm} = \frac{\hat{C}_p}{\sqrt{1 + V^2}} \quad (2.75)$$

onde

$$V = \frac{T - \bar{x}}{s} \quad (2.76)$$

com \hat{C}_p dado pela equação (2.59).

2.9.4 Considerações a Respeito dos Índices C_p , C_{pk} e C_{pkm}

Os valores dos índices C_{pk} e C_{pkm} são iguais ao do índice C_p quando o processo está centrado, ou seja, quando $\mu = T$ e decrescem quando μ se afasta de T . Sendo assim, se tem que:

- (1) $C_{pk} < 0$ quando $\mu > LSE$ ou $\mu < LIE$;
- (2) C_{pkm} tende assintoticamente a zero quando $|\mu - T| \rightarrow \infty$;
- (3) $C_{pkm} < \frac{LSE - LIE}{6|\mu - T|}$;
- (4) A condição necessária para $C_{pkm} \geq 1$ é que $|\mu - T| < \frac{LSE - LIE}{6}$.

A consideração final a respeito do índice C_p é dada segundo Samohyl (2009), que afirma que:

Quando o processo é capaz, então os limites de controle ficam inteiramente dentro dos limites de especificação, e o valor do índice é maior que 1. Índice igual a 1 significa que a taxa de rejeição do produto não-conforme fica em 27 de 10.000 itens. Geralmente, indústrias hoje em dia querem processos com índices maiores que 1,33 e se for chegar ao valor admirável de 2, isso significa que os limites de tolerância estão a 12 desvios-padrão de distância entre si, ou seis desvios-padrão da linha central. Com esse índice, a taxa de rejeição de peças defeituosas fica em dois itens em 1 bilhão produzidos.

2.10 MÉTODOS DE REAMOSTRAGEM

Suponha que se deseje estimar um parâmetro θ que dependa de uma amostra aleatória de tamanho n definida por $\underline{x}' = [x_1, x_2, \dots, x_n]$, onde θ pode ser um o valor do coeficiente de correlação de Pearson, uma variância de \underline{x}' ou qualquer

outra representação de parâmetro. Considerando que se tem um estimador $\hat{\theta}$ de θ mas não se conhece a distribuição de probabilidade de $\hat{\theta}$ dado o parâmetro θ . Assim, não se pode estimar o erro envolvido na estimação de θ por $\hat{\theta}$ e não se pode concluir que $\theta \neq 0$ de uma estimativa $\hat{\theta} \neq 0$, não importando quão grande seja esse valor.

Sawyer (2005) questiona: “é possível construir um intervalo de confiança dependendo somente das observações x_1, x_2, \dots, x_n , ou testar a hipótese $H_0: \theta = \theta_0$ somente usando as observações x_1, x_2, \dots, x_n ?”

A resposta ao questionamento é sim. Para esses tipos de cálculos, utilizados na inferência estatística, necessita-se do cálculo de viés, variabilidade e de outros estimadores de $\hat{\theta}$ pelo uso de valores de $\hat{\theta}$ encontrados em subamostras x_1, x_2, \dots, x_n . Os métodos que se utilizam de valores de estimativas $\hat{\theta}$ de subamostras são denominados de métodos de reamostragem. Os dois métodos mais conhecidos são o *Jackknife* e *bootstrap*.

2.10.1 O Método *Jackknife*

O método conhecido como *Jackknife* foi proposto por Maurice H. Quenouille em 1949 que mais tarde foi refinado, e dado o seu nome atual, por John Tukey em 1956. De acordo com Quenouille (1949) o método foi originalmente desenvolvido como um procedimento para redução do viés de um estimador de correlação serial baseado na divisão da amostra em duas meias amostras.

Suponha que se tenha uma amostra com elementos independentes e identicamente distribuídos, ou seja, $x_1, x_2, \dots, x_n \stackrel{iid}{\sim} f$, onde f é uma distribuição de probabilidade desconhecida em algum espaço. Observando-se x_1, x_2, \dots, x_n , calcula-se a estatística de interesse, dada por

$$\hat{\theta} = \hat{\theta}(x_1, x_2, \dots, x_n) \quad (2.77)$$

onde $\hat{\theta}$ é um estimador do parâmetro θ .

De acordo com Efron (1980) o método de Quenouille é baseado na retirada sequencial de observações x_i , onde $i = 1, \dots, n$, e em um novo cálculo de $\hat{\theta}$ para cada retirada efetuada, ou seja,

$$\hat{\theta}_i = \hat{\theta}(x_1, x_2, \dots, x_{i-1}, x_{i+1}, \dots, x_n) \quad (2.78)$$

Quenouille (1956) apresentou uma generalização do método anteriormente desenvolvido por ele e definido como *Jackknife* agrupado. Segundo Miller (1974) a ideia desenvolvida em 1956 foi generalizada pela divisão da amostra original em g subamostras de tamanho h cada, onde $n = gh$, e a partir daí explorou-se a sua aplicabilidade. A partir dessa divisão em g grupos e supondo $h = 1$ calcula-se para cada um desses grupos o i -ésimo pseudovalor do mesmo, dado por

$$\tilde{\theta}_i = g\hat{\theta} - (g-1)\hat{\theta}_i \quad (2.79)$$

onde $i = 1, 2, \dots, g$.

Segundo Sawyer (2005) a ideia básica do *Jackknife* é tratar os pseudovalores $\tilde{\theta}_i$ como variáveis aleatórias independentes com média θ . Assim, calcula-se a partir dos pseudovalores o estimador *Jackknife* do parâmetro θ e dado pela equação (2.80).

$$\tilde{\theta} = \frac{\sum_{i=1}^g \tilde{\theta}_i}{g} \quad (2.80)$$

A partir do cálculo de (2.80) utilizando-se do Teorema Central do Limite aplica-se o *Jackknife* para o cálculo de intervalos de confiança e realização de testes estatísticos.

2.10.2 *Bootstrap*

2.10.2.1 Introdução

“O ensino e a aprendizagem da estatística tem permeado todos os níveis de educação e ganhou reconhecimento em muitas disciplinas ao longo das últimas duas décadas” (MILLS, 2006).

A demonstração e reconhecimento explícito de incertezas é o principal objetivo da ciência estatística, onde aplicações de suas técnicas podem ser observadas no reconhecimento de incertezas, adequação dos dados que originaram as mesmas em modelos de probabilidade, em cálculo de erros padrões, em intervalos de confiança entre outras técnicas, e tem como principal função formalizar analiticamente e sintetizar essas incertezas, e com isso, utilizar as mesmas para tomada de decisões.

Em experimentos mais simples, para um conjunto de dados disponíveis, a incerteza de uma estimativa pode ser calculada analiticamente baseada em um modelo de probabilidade conhecido.

No entanto, para experimentos mais complexos a obtenção dessa estimativa para a incerteza pode ser complicada e muito extensa. Com isso, pode-se chegar a resultados potencialmente errôneos, caso sejam feitas hipóteses ou simplificações inapropriadas para um determinado modelo estatístico.

Segundo Babu (2011), os métodos estatísticos clássicos concentram-se principalmente nas propriedades estatísticas de estimadores que possuam uma forma relativamente simples e que possam ser analisados matematicamente, sendo que os métodos envolvidos na sua análise, muitas vezes, utilizam-se de simplificações e pressuposições não realistas.

Buche e Glover (1988) afirmam que estudantes universitários interessados em se tornar profissionais competentes precisam ser capazes de compreender, apreciar e aplicar a pesquisa estatística.

Segundo Hesterberg (2011) algumas ideias em estatística e em probabilidade são muito complexas para estudantes, incluindo as distribuições amostrais, e neste âmbito a simulação computacional faz com que os mesmos ganhem no sentido intuitivo desses conceitos.

Toda e qualquer pesquisa realizada, em algum momento, precisa da validação dos dados, e para tal utilizam-se técnicas estatísticas. Para validação dos dados utilizam-se indicadores estatísticos referentes ao experimento em questão, seja com o intuito: de sintetizar e organizar dados; de tomada de decisão a partir de uma amostra; de modelagem de uma função a partir de uma amostra; de verificar a qualidade de um produto; de comparação de propostas; de análise e desenvolvimento de produtos, entre outros.

Para tal, torna-se necessário a obtenção de amostras com um número mínimo de elementos para validação dos indicadores e do próprio experimento.

O assunto em estatística que trata da validação de dados, comparação de amostras, previsão de experimentos, entre outros, é denominado de inferência estatística. Seu principal objetivo é extrair e resumir as principais características de um conjunto de dados (amostra) e estender os resultados para o parâmetro em questão.

Algumas medidas em estatística são amplamente utilizadas, sendo a média aritmética e o desvio padrão as estatísticas mais simples de se obter de maneira explícita. No entanto, para algumas estatísticas mais complexas, não existem fórmulas disponíveis para o cálculo da mesma ou, a maneira de obtê-la é muito complexa se utilizado os meios tradicionais em estatística.

Neste contexto que se deve usar uma das técnicas estatísticas com maior sucesso, denominada de método de reamostragem *bootstrap*. A vantagem de se utilizar essa técnica de reamostragem, além de ser de fácil entendimento, é a generalidade com que se pode aplicá-la, pois a mesma necessita que poucas suposições sejam feitas, fornecendo respostas mais precisas que outros métodos de reamostragem.

A proposta central do método *bootstrap* é demonstrar através do uso computacional a obtenção de erros padrões, intervalos de confiança, a distribuição estimada de probabilidade e o cálculo de outras medidas de incertezas estatísticas para uma variedade de problemas.

Em 1979, Bradley Efron publicou seu primeiro artigo sobre o método *bootstrap*, e assim, revolucionou a ideia de reamostragem, pois o mesmo sintetizou algumas ideias anteriores de reamostragem e estabeleceu um novo quadro para

análises estatísticas baseadas em simulações. Neste novo paradigma, o método *bootstrap* se mostrou mais eficiente que os métodos anteriormente usados.

Devido ao seu grande sucesso, tal método, contribuiu e ainda contribui muito para produções acadêmicas.

“O *bootstrap* é uma técnica estatística relacionada ao *jackknife*, introduzida por Efron em 1979 e se mostra versátil no tratamento de uma variedade de problemas estatísticos” (CHAVES NETO, 1985).

De acordo com Davison e Hinkley (1997) a ideia chave do *bootstrap* é a reamostragem dos dados originais para criar um conjunto de dados replicados, sendo que a partir deles, a variabilidade das quantidades de interesse possa ser avaliada sem um cálculo analítico extenso e propenso a erros.

“A técnica de reamostragem *bootstrap* permite precisamente usar uma amostra para estimar a quantidade de interesse através de uma estatística e avaliar também as propriedades da distribuição dessa estatística, ou seja, fornecem também estimativas para a distribuição, viés, desvio padrão e intervalos de confiança da estatística” (LUCIO, LEANDRO e PAULA, 2006).

Reamostrar, neste caso, consiste em sortear uma nova amostra, de uma amostra já conhecida, com reposição do conjunto de dados originais.

Segundo Schmidheiny (2012) a reamostragem utilizando-se do *bootstrap* é muito semelhante às técnicas de Monte Carlo com a diferença que em vez de especificar totalmente o processo gerador de dados, usa-se a informação da amostra.

Tal técnica é muito útil quando se tem uma amostra de tamanho pequeno, ou quando os cálculos de estimadores por meios analíticos se tornam extremamente complicados e até mesmo impossíveis de se obter, visto que nem sempre se tem de maneira explícita a distribuição de probabilidade que gerou a amostra. Nesse caso o *bootstrap* torna-se útil, visto que o mesmo pode ser utilizado mesmo não se conhecendo a distribuição original que gerou a amostra da estatística do parâmetro a ser estudado.

Para se realizar a estimação de um parâmetro pelo *bootstrap* torna-se necessário um grande número de reamostragens, e para tal é necessário o auxílio de programas computacionais e de computadores velozes.

Segundo Davison e Hinkley (1997) “como esta abordagem consiste em repetir o procedimento de análises de dados com muitos grupos replicados, este procedimento é denominado de computacionalmente intensivo”. Assim o método é muito utilizado para estimação de distribuições amostrais.

Historicamente o método se tornou viável após o surgimento da computação mais veloz e com preço acessível, assim tornando o tempo de operações computacionais complexas reduzidos.

O principal objetivo na utilização do *bootstrap* como técnica de reamostragem é demonstrar, através do computador, o aproveitamento de dados para a obtenção de um erro padrão confiável, intervalos de confiança confiáveis e outras medidas estatísticas confiáveis para uma gama de problemas.

Na utilização do método, visto de uma maneira simplificada, se faz a reamostragem através dos dados coletados do experimento. Com isso, uma variedade de problemas em estatística podem ser evitados, tais como simplificações excessivas em problemas mais complexos.

Conforme Wood (2005) afirma, a simulação como o *bootstrap* "oferece a promessa de estatísticas libertadoras das algemas dos argumentos simbólicos que muitas pessoas acham tão difícil”.

A reamostragem, além de ser muito útil para problemas complexos e com poucos dados amostrais, também pode ser aplicada para problemas mais simples para a verificação da adequação de medidas padrões de incerteza, e também, para estimativas aproximadas rápidas. Tais estimativas podem ser estimadas pontualmente e por intervalos.

HOROWITZ (2001) descreve que:

O *bootstrap*, sob leves condições de suposições, produz uma aproximação para a distribuição de um estimador ou teste estatístico que é pelo menos tão preciso que a aproximação obtida pela teoria assintótica de primeira ordem. Dessa forma, o *bootstrap* fornece uma maneira de substituir a computação para análise matemática se o cálculo da distribuição assintótica de um estimador ou estatística é difícil de se obter. A estatística desenvolvida por Hirdle *et al.* (1991) para testar *positive-definiteness* da matriz *income-effect*, o teste condicional Kolmogorov de Andrews (1997), teste de especificação de Stute (1997) para modelos de regressão paramétricos e certas funções de Blanchard e Quah (1989), Runkle (1987) e West (1990) de séries temporais são exemplos a avaliação da distribuição assintótica é difícil e o *bootstrap* foi utilizado como alternativa.

De fato, a técnica *bootstrap* se mostra mais precisa em amostras pequenas do que as aproximações assintóticas de primeira ordem, sem a implicação de expansões algébricas complexas de ordens maiores. Sendo assim, pode-se utilizá-lo para aperfeiçoamento de aproximações de primeira ordem, onde tais aperfeiçoamentos são denominados de refinamentos assintóticos, sendo uma de suas aplicações a redução do viés. Deve-se ter em mente que tanto a teoria assintótica quanto o *bootstrap* só fornecem aproximações em amostras finitas.

Em muitas aplicações tem-se a certeza da aplicação de um modelo paramétrico particular conhecido e das análises padrões referentes a este modelo. Mas de qualquer maneira, o método *bootstrap* pode ser utilizado para se realizar inferências sem as hipóteses de um modelo paramétrico em particular, e com isto consegue-se a validação de análises estatísticas com objetividade e robustez.

Existem dois casos para a aplicação do método, sendo estes: 1) O *bootstrap* não paramétrico; 2) O *bootstrap* paramétrico, que serão descritos mais detalhadamente.

O *bootstrap* não paramétrico é utilizado quando a distribuição de probabilidade da estatística do parâmetro de interesse não é conhecida, sendo a reamostragem baseada na amostra mestre. Através desta reamostragem é possível obter a distribuição amostral do parâmetro em questão, sendo esta a forma a mais utilizada.

“Na prática, os procedimentos de testes não paramétricos se beneficiam dos grandes esforços computacionais da nova geração de computadores” (JANSSEN; PAULS, 2003)

O *bootstrap* paramétrico é utilizado quando se conhece a distribuição de probabilidades dos parâmetros de interesse da população da qual a amostra mestre foi retirada.

O caso paramétrico tem como uma de suas aplicações estimar o vício das estimativas dos parâmetros para então efetuar as correções necessárias. Outra aplicação seria a comparação dos intervalos de confiança obtidos através da técnica *bootstrap* e o intervalo de confiança obtido pela distribuição de probabilidade obtida através da distribuição de probabilidade conhecida do estimador.

Apesar de sua grande utilidade, a reamostragem deve ser usada com cautela, principalmente se algumas ideias básicas não forem compreendidas. Assim,

o método de forma alguma, pode substituir um pensamento crítico e claro, um desenvolvimento apropriado de investigação dos dados e uma conclusão concisa a respeito do mesmo.

2.10.2.2 O método *bootstrap*

Para se iniciar o método *bootstrap*, deve-se tirar uma amostra mestre de tamanho n , $\underline{x}' = [x_1, x_2, \dots, x_n]$ que seja representativa da população. A amostra mestre é definida, também, como amostra original da população que a gerou. Para tal, esta amostra deve ser colhida de maneira planejada para não se cometer erros de cálculo e com isso obter resultados não confiáveis.

As reamostragens dessa amostra mestre devem equivaler a muitas amostras da população de interesse e a distribuição obtida de uma estatística de interesse, através destas reamostragens, representa a distribuição amostral desta estatística.

Grande parte dos autores recomenda a utilização de pelo menos 1000 reamostras. Outra maneira de se definir o número adequado de reamostras é monitorando a variação do desvio padrão da estimativa do parâmetro. No momento que este desvio padrão se estabilizar, tem-se o tamanho das B “amostras bootstrap”. Essas B amostras devem ter o mesmo tamanho n $\underline{x}_1^*, \underline{x}_2^*, \dots, \underline{x}_B^*$ da amostra mestre, tal que os valores escolhidos a partir da amostra mestre devem ser feitos de forma aleatória.

Dadas as reamostras, deve-se calcular a estatística $\hat{\theta}_i^*$ para cada uma delas. Sendo assim, segundo Bussab e Morettin (2012) “a idéia básica do *bootstrap* é reamostrar o conjunto disponível de dados para estimar o parâmetro θ , com o fim de criar dados replicados. A partir dessas replicações pode-se avaliar a variabilidade de um estimador proposto para θ , sem recorrer a cálculos analíticos”.

A reamostragem é feita de maneira aleatória e com reposição dos elementos da amostra mestre, e a partir dessas reamostras deve-se calcular a estatística $\hat{\theta}_i^*$ de interesse de cada reamostra. O sobrescrito “*” indica que se tem o cálculo de uma estatística a partir de uma amostra *bootstrap*. A estatística da amostra mestre será representada por $\hat{\theta}$.

Essas estimativas do parâmetro em questão devem ser precisas, e para tal, deve-se calcular uma estimativa de precisão da mesma. Uma das estimativas de precisão mais conhecidas é a do cálculo do erro padrão da média, que é uma medida de variabilidade da mesma.

A estimativa do erro padrão da média \bar{x} baseada em n dados independentes x_1, x_2, \dots, x_n , $\bar{x} = \sum_{i=1}^n \frac{x_i}{n}$, é dada pela equação

$$\sqrt{\frac{s^2}{n}} \quad (2.81)$$

onde

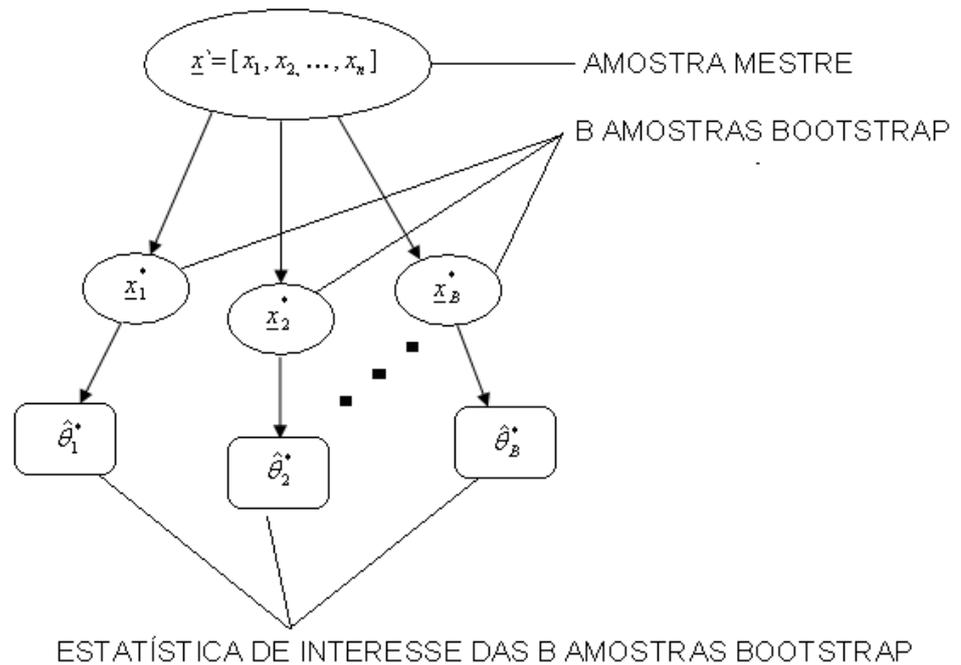
$$s^2 = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1} \quad (2.82)$$

O erro padrão para qualquer estimador é definido como a raiz quadrada da sua variância, ou seja, a raiz quadrada desse estimador significa a variabilidade ao quadrado da expectativa em torno do valor de interesse. “Esta é a medida de precisão mais comum para um determinado estimado” (EFRON e TIBSHIRANI, 1993).

Segundo Efron e Tibshirani (1993) os erros padrões possuem uma grande desvantagem: para a maioria dos estimadores estatísticos diferentes da média aritmética não existem fórmulas que forneçam uma estimação para os erros padrões. É nesse âmbito que a utilização do método *bootstrap* torna-se extremamente interessante.

O cálculo fundamenta-se basicamente em calcular a estatística de interesse $\hat{\theta}_i^*$ para cada das “B amostras *bootstrap*”, conforme figura 2.14.

FIGURA 2.14 – ESQUEMA PARA CÁLCULO DO ERRO PADRÃO



FONTE: O AUTOR

A figura 2.14 mostra o processo para o cálculo do erro padrão para a estimativa do erro padrão de uma estatística $\hat{\theta}$.

O processo baseia-se na utilização de um algoritmo para gerar um número de B amostras *bootstrap* independentes de tamanho n (mesmo tamanho que a amostra mestre) denominadas de $\underline{x}_1^*, \underline{x}_2^*, \dots, \underline{x}_B^*$, e a partir dessas B amostras, calcular a estatística de interesse para cada uma das B amostras, denominadas de $\hat{\theta}_1^*, \hat{\theta}_2^*, \dots, \hat{\theta}_B^*$.

Para finalizar o cálculo do erro padrão calcula-se o desvio padrão das estatísticas $\hat{\theta}_1^*, \hat{\theta}_2^*, \dots, \hat{\theta}_B^*$, e esse desvio padrão é a estimativa do erro padrão da estatística de interesse.

O cálculo do desvio padrão *bootstrap* (erro padrão) é dado por

$$SE_{\text{boot}} = \sqrt{\frac{1}{B-1} \sum_{i=1}^B \left(\hat{\theta}_i^* - \frac{1}{B} \sum_{i=1}^B \hat{\theta}_i^* \right)^2} \quad (2.83)$$

Outra definição importante é com relação ao vício da estimativa de um parâmetro. De acordo com Montgomery e Runger (2003), a estatística utilizada para estimar um parâmetro é viciada quando sua distribuição amostral não está centrada no verdadeiro valor do parâmetro.

A estimação do vício *bootstrap* pode ser verificada. Pode-se calcular o vício, comparando se a distribuição *bootstrap* da estatística em questão está centrada na estatística da amostra mestre. Assim o estimador do vício é dado por:

$$\text{vício}_{boot} = \overline{\hat{\theta}^*} - \hat{\theta} \quad (2.84)$$

O cálculo do vício é essencial para verificação da validade dos intervalos de confiança obtidos pelo método *bootstrap*.

2.10.3. Intervalo de confiança

2.10.3.1 Introdução

De acordo com Bennett (2009) a definição a seguir é retirada do *The Cambridge Dictionary of Statistics* (Everitt, 1998):

Um intervalo de confiança é uma gama de valores, calculado a partir das observações da amostra, com uma probabilidade conhecida de conter o verdadeiro valor do parâmetro. Um intervalo de confiança de 95%, por exemplo, indica que este processo de estimação foi repetido várias vezes, até que seja esperado que 95% dos intervalos calculados contenham o verdadeiro valor do parâmetro. Verifica-se que o nível de confiança (probabilidade conhecida do intervalo) se refere às propriedades do intervalo e não para o parâmetro em si, que é considerado uma variável aleatória.

2.10.3.2 Cálculo usando o escore z

Algumas vezes, intervalos de confiança são calculados usando o escore padrão z , que é definido por

$$z = \frac{\bar{X} - \mu}{\sigma_{\bar{X}}}, \quad (2.85)$$

ou reescrevendo (2.85), temos que

$$z = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}, \quad (2.86)$$

onde \bar{X} é a média da amostra, μ é a média da população, σ é o desvio padrão populacional e n é o número de itens da amostra.

Assim

$$P\left(\bar{X} + z_{\alpha/2}\sigma_{\bar{X}} \leq \mu \leq \bar{X} - z_{\alpha/2}\sigma_{\bar{X}}\right) = 1 - \alpha \quad (2.87)$$

e o intervalo de confiança, utilizando-se do escore z , é dado por

$$\bar{X} + z_{\alpha/2}\sigma_{\bar{X}} \leq \mu \leq \bar{X} - z_{\alpha/2}\sigma_{\bar{X}} \quad (2.88)$$

2.10.3.3 Cálculo usando o escore t

O intervalo de confiança em (2.88) assume que o desvio padrão populacional σ é conhecido, porém σ geralmente não é conhecido e é estimado a partir da amostra. A equação para a estatística t é similar ao cálculo do escore padrão z , exceto no que diz respeito ao cálculo do desvio padrão estimado s :

$$t = \frac{\bar{X} - \mu}{s_{\bar{X}}} \quad (2.89)$$

que reescrito fica como

$$t = \frac{\bar{X} - \mu}{\frac{s}{\sqrt{n}}}. \quad (2.90)$$

A diferença entre os elementos que compõem (2.86) e (2.90), reside no fato de se calcular o desvio padrão amostral s .

Assim

$$P\left(\bar{X} + t_{(df, \alpha/2)} s_{\bar{X}} \leq \mu \leq \bar{X} - t_{(df, \alpha/2)} s_{\bar{X}}\right) = 1 - \alpha \quad (2.91)$$

e o intervalo de confiança, utilizando-se do escore t , é dado por

$$\bar{X} + t_{(df, \alpha/2)} s_{\bar{X}} \leq \mu \leq \bar{X} - t_{(df, \alpha/2)} s_{\bar{X}} \quad (2.92)$$

Para amostras de pequeno tamanho ($n \leq 20$), intervalos de confiança baseados no escore t são mais exatos que os baseados no escore z . Na prática, para $n \geq 30$ os intervalos de confiança baseados nos escores z e t são indistinguíveis.

2.10.3.4 Intervalos de confiança *bootstrap*

De acordo com Chaves (2015), o método *bootstrap* está com todas as suas propriedades comprovadas teoricamente com base em resultados estatísticos. E,

uma das suas mais importantes aplicações é a determinação de intervalos de confiança para os parâmetros estimados.

Os intervalos de confiança baseados no método *bootstrap* são muito utilizados quando não se deseja fazer suposições associadas à estatística clássica, ou quando não se tem explicitamente a distribuição da estatística de interesse. É conhecida, também, que a aplicação do *bootstrap* é útil e eficaz, quando o tamanho da amostra é pequeno.

2.10.3.4.1 O intervalo de confiança *bootstrap* padrão

De acordo com Barreto e Cesário (2003) o intervalo de confiança *bootstrap* padrão para uma estatística de interesse e com uma probabilidade de cobertura $(1 - 2\alpha)$ é definido como

$$IC_{bootpadr\tilde{a}o} = (estatística \pm z_{\alpha} \times SE_{boot}) \quad (2.93)$$

onde z_{α} é o α -ésimo valor do escore da distribuição normal padrão.

2.10.3.4.2. O intervalo de confiança *bootstrap t*

O intervalo de confiança *bootstrap t* para uma estatística é definido por

$$IC_{bootstrapt} = (estatística \pm t_{df} \times SE_{boot}) \quad (2.94)$$

onde n é o tamanho da amostra mestre, df são os graus de liberdade do escore t , sendo este igual à $(n-1)$, t_{df} é o valor do escore t com df graus de liberdade, SE_{boot} é o desvio padrão *bootstrap* (erro padrão) dado por (2.83).

A eficácia deste método para cálculo do intervalo de confiança é confiável desde que a distribuição da estatística de interesse seja aproximadamente normal e pouco viciada. Sendo assim, este intervalo de confiança pode ser utilizado para o cálculo de diversos parâmetros, tais como a média populacional, proporção e coeficiente de correlação.

2.10.3.4.3 O intervalo de confiança percentil

Conforme Rizzo e Cymrot (2006) o intervalo de confiança percentil pode ser calculado de duas maneiras: (1) Encontrar o percentil $(1 - \alpha/2)100\%$ e o percentil $(\alpha/2)100\%$ da média das reamostras da estatística do parâmetro que se deseja estimar; (2) Obter o intervalo de confiança percentil, através dos percentis das diferenças dos valores das estatísticas das reamostras em relação ao valor médio desta mesma estatística nas reamostras.

Para se estimar um intervalo de confiança para uma estatística $\hat{\theta}$, se calcula o valor desta estatística para cada uma das B reamostras *bootstrap* $\hat{\theta}_i^*$ e em seguida se calcula a média aritmética destas estimativas, denominada por $\bar{\hat{\theta}}^*$. Assim, encontra-se para cada reamostra i a diferença entre estes valores, ou seja:

$$\text{diferença} = \hat{\theta}_i^* - \bar{\hat{\theta}}^* \quad (2.95)$$

Para uma confiança de 95%, calculam-se os percentis 97,5% e 2,5% destas diferenças e encontra-se o intervalo de confiança percentil desta forma:

$$\text{IC}_{\text{boot percentil}} = \left[\hat{\theta} - P_{97,5\%} \text{diferenças}, \hat{\theta} - P_{2,5\%} \text{diferenças} \right] \quad (2.96)$$

Uma vez calculado o intervalo de confiança percentil pode-se, através deste, verificar se o intervalo de confiança *bootstrap t* é confiável. Para tanto, se faz necessário que ambos os intervalos possuam vícios pequenos, com valores muito próximos e distribuição *bootstrap* próxima da normal. Caso não sejam verificadas essas condições, nenhum desses dois métodos de estimação para intervalos de confiança devem ser usados.

Segundo Bennett (2009) o método percentil gera intervalos de confiança precisos, desde que a distribuição da estatística *bootstrap* $y = f(\hat{\theta})$ em questão, possua uma distribuição normal com média $f(\theta)$ e variância 1.

2.10.3.4.4 Intervalo de confiança pelos métodos do viés corrigido (BC e BCa)

Os intervalos de confiança t e percentil são válidos, desde que o pressuposto de normalidade na distribuição da estatística *bootstrap* seja comprovado. Caso este pressuposto seja inválido, os intervalos de confiança gerados pelo método percentil e t não são precisos.

O método de estimação para intervalo de confiança BC (*bias corrected*) utiliza como extremos do intervalo os percentis da distribuição *bootstrap* ajustados para corrigir o vício e a assimetria da distribuição em questão. Os valores percentis tradicionais do intervalo de confiança são transformados em outros valores a fim de corrigir o vício e a assimetria do mesmo.

Caso o intervalo esteja viciado para cima, a técnica de estimação BC move os extremos para a esquerda e caso esteja viciado para baixo move os extremos para a direita.

Segundo Borkowski (2013, apud LOIBEL E ALVES, 2013) pode-se considerar o vício pequeno se o mesmo é menor que 25% do desvio padrão do vício que é dado por

$$DP_{\text{vício}} = \sqrt{\frac{\sum_{i=1}^B (\hat{\theta}_i^* - \hat{\theta})^2}{B-1}} \quad (2.97)$$

Basicamente o método para obtenção desse intervalo de confiança pode ser dividido em cinco passos.

Passo 1. Neste passo deve-se ordenar as B 's estimativas $\hat{\theta}_i^*$, onde $i = 1, \dots, B$, e calcular a probabilidade p_0 , que é definida como a probabilidade de uma estimativa ser inferior que a estimativa proveniente da amostra mestre ($\hat{\theta}$). Ou seja

$$p_0 = P(\hat{\theta}_i^* \leq \hat{\theta}) \quad (2.98)$$

Passo 2. Após calcular p_0 , obtém-se o parâmetro de correção do vício definido como z_0 , que é representado por

$$z_0 = \phi^{-1}(p_0) \quad (2.99)$$

Passo 3. Neste passo se escolhe o nível de confiança $(1-\alpha)100\%$ para estimativa do parâmetro e determina-se $z_{\alpha/2}$.

Passo 4. Neste passo calculam-se os percentis inferior e superior, denominados respectivamente de P_I e P_S . Assim

$$P_I = \phi\left(2z_0 - z_{\alpha/2}\right) \quad (2.100)$$

e

$$P_S = \phi\left(2z_0 + z_{\alpha/2}\right) \quad (2.101)$$

Passo 5. Finalmente calcula-se o intervalo de confiança BC, dado por

$$IC_{BC} = \left[P_{P_I}(\hat{\theta}_i^*), P_{P_S}(\hat{\theta}_i^*) \right] \quad (2.102)$$

Outro método de estimação de intervalo de confiança é denominado de BCa, sendo conveniente usá-lo quando a assimetria estiver presente de uma maneira muito forte.

A maneira de calcular o intervalo é semelhante ao método BC, sendo diferenciado por um ajuste por meio de uma constante de aceleração a . O intervalo de confiança BCa é calculado por (2.102), sendo P_I e P_S calculados respectivamente por

$$P_I = \phi \left(z_0 - \frac{(z_0 + z_{\alpha/2})}{1 - a(z_0 + z_{\alpha/2})} \right) \quad (2.103)$$

e

$$P_S = \phi \left(z_0 + \frac{(z_0 + z_{\alpha/2})}{1 - a(z_0 + z_{\alpha/2})} \right) \quad (2.104)$$

De acordo com Andrews e Buchinsky (2002), o cálculo de a torna-se mais simples quando as variáveis aleatórias observadas da amostra mestre forem i.i.d's. Assim, tem-se que

$$a = \frac{\sum_{i=1}^n (\hat{\theta}_{(.)} - \hat{\theta}_{(i)})^3}{\sigma \left(\sum_{i=1}^n (\hat{\theta}_{(.)} - \hat{\theta}_{(i)})^2 \right)^{\frac{3}{2}}} \quad (2.105)$$

Neste caso, $\hat{\theta}_{(i)}$ representa o valor das estimativas do parâmetro estudado para cada amostra i , excetuando-se a observação i da mesma e $\hat{\theta}_{(.)}$ representa o valor da média das estimativas $\hat{\theta}_{(i)}$.

3 MATERIAL E MÉTODOS

No presente capítulo será apresentado o material (amostras) utilizado em cada um dos três casos das funções perda de Taguchi e nas suas respectivas relações sinal-ruído. Para o caso maior-é-melhor não serão calculados os índices C_p , C_{pk} e C_{pkm} , pois não se conhece o limite de especificação superior visto que quanto maior o valor da característica funcional em questão melhor, assim seus cálculos só serão considerados para o casos nominal-é-melhor e menor-é-melhor. Nas seções seguintes serão descritas as entradas e saídas de dados do programa desenvolvido so *software* Matlab, o fluxograma do algoritmo do mesmo, as amostras para cada um dos tipos de características funcionais bem como os respectivos cálculos das suas funções perda-média, razão sinal-ruído e índices C_p , C_{pk} e C_{pkm} .

3.1 DESCRIÇÃO DO PROGRAMA DESENVOLVIDO

O desenvolvimento de todos os cálculos propostos nos objetivos, bem como sua interface, foi programado no *software* Matlab.

Para início dos cálculos definem-se os argumentos de entrada do programa, sendo que estes podem ser executados de duas maneiras: 1) Quando se conhece o valor do coeficiente de perda de qualidade k diretamente; 2) Quando não se conhece o valor do coeficiente de perda de qualidade k .

Quando se conhece o valor de k , a entrada de dados é efetuada na seguinte ordem: 1) Escolha do tipo da característica funcional (NTB – Nominal-é-melhor; STB – Menor-é-melhor; LTB – Maior-é-melhor); 2) Entrada da amostra mestre (Amostra representativa de alguma característica funcional de um produto); 3) Definição da quantidade das B amostras *bootstrap*; 4) Valor nominal de projeto do produto (válido somente para o caso NTB); 5) Entrada do coeficiente de perda de qualidade k ; 6) Escolha do tipo da razão sinal-ruído tipo I ou tipo II (válido somente para o caso NTB); 7) Entrada dos limites de especificação do produto.

Quando não se conhece o valor de k , a entrada de dados é efetuada na seguinte ordem: 1) Escolha do tipo da característica funcional (NTB – Nominal-é-melhor; STB – Menor-é-melhor; LTB – Maior-é-melhor); 2) Entrada da amostra mestre (Amostra representativa de alguma característica funcional de um produto); 3) Definição da quantidade das B amostras *bootstrap*; 4) Entrada do valor nominal de projeto do produto (válido somente para o caso NTB); 5) Entrada da tolerância funcional do produto; 6) Entrada da perda do consumidor; 7) Escolha do tipo da razão sinal-ruído tipo I ou tipo II (válido somente para o caso NTB). 8) Entrada dos limites de especificação do produto.

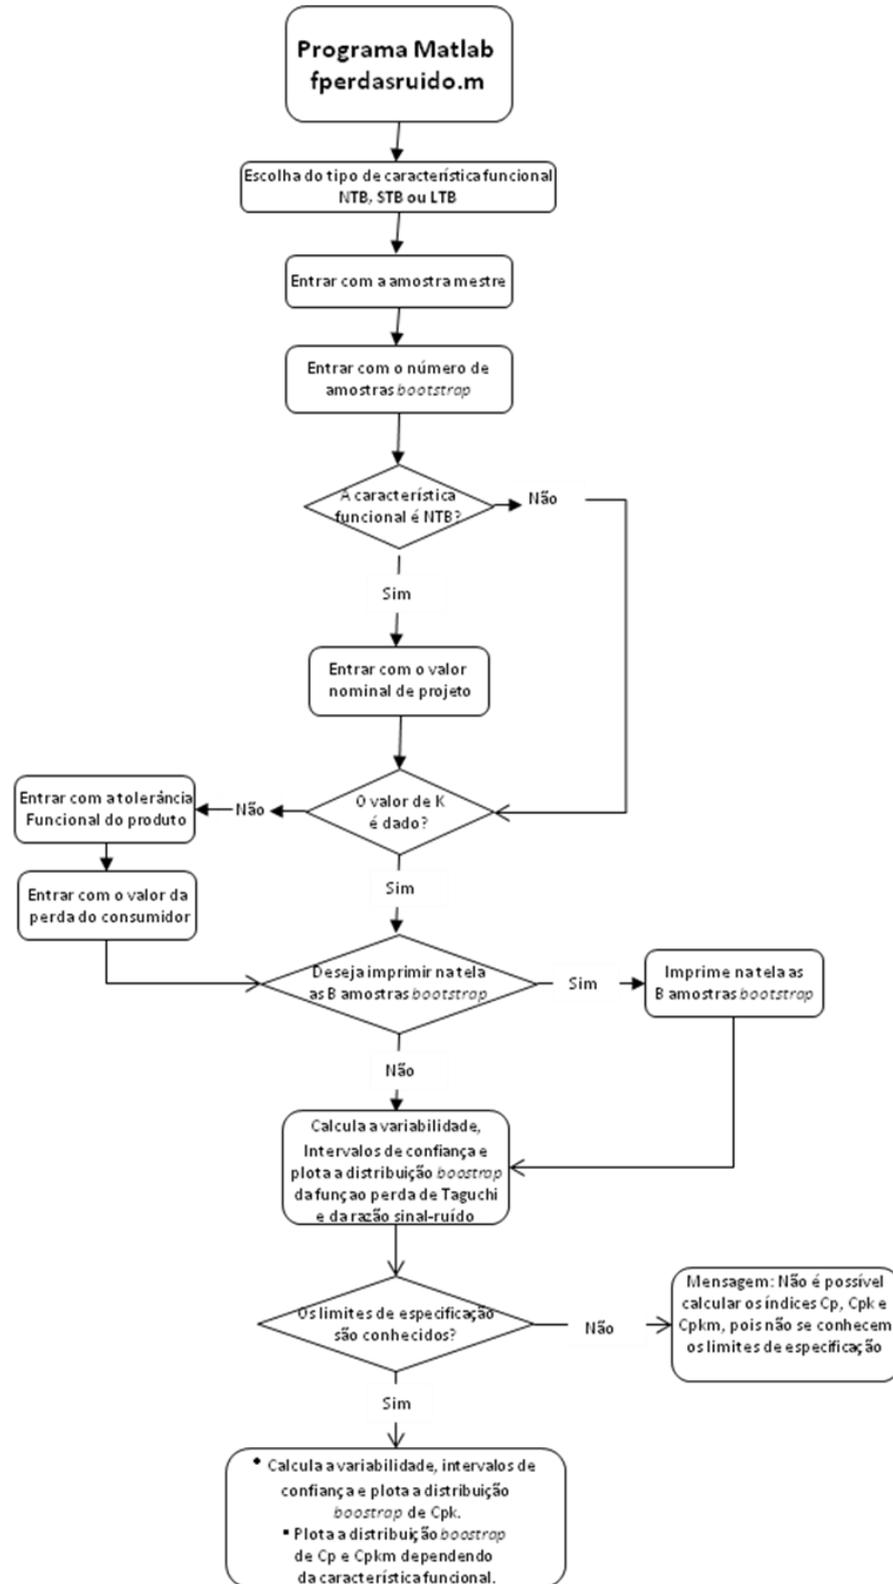
O programa (função Matlab) possui como argumentos de saída: 1) o cálculo da função perda média de Taguchi para a amostra mestre; 2) o cálculo da variabilidade da função perda de Taguchi; 3) os intervalos de confiança de 95% e 99% da função perda média de Taguchi pelo método *bootstrap*; 4) distribuição *bootstrap* da função perda de Taguchi; 5) o cálculo da razão sinal-ruído para a amostra mestre; 6) o cálculo da variabilidade da razão sinal-ruído; 7) os intervalos de confiança de 95% e 99% da razão sinal-ruído pelo método *bootstrap*; 8) distribuição *bootstrap* da razão sinal-ruído; 9) cálculo dos índices C_p , C_{pk} e C_{pkm} , para a amostra mestre; 10) os intervalos de confiança de 95% e 99% dos índice C_p , C_{pk} e C_{pkm} pelo método *bootstrap*; 11) as distribuições *bootstrap* dos índices C_p , C_{pk} e C_{pkm} .

O programa desenvolvido calcula e imprime na tela cinco tipos de intervalos de confiança para a função perda média de Taguchi, para a razão sinal-ruído e para dos índices C_p , C_{pk} e C_{pkm} . Os cinco tipos de intervalos são: 1) O *bootstrap* padrão; 2) O *bootstrap* t; 3) O *bootstrap* percentil; 4) O *bootstrap* BC; 5) O *bootstrap* BCa.

Na seção seguinte se apresenta o fluxograma do algoritmo programado no *software* Matlab.

3.1.1 Fluxograma do Algoritmo Desenvolvido no Matlab

FIGURA 3.1 – FLUXOGRAMA DO FUNCIONAMENTO DO PROGRAMA

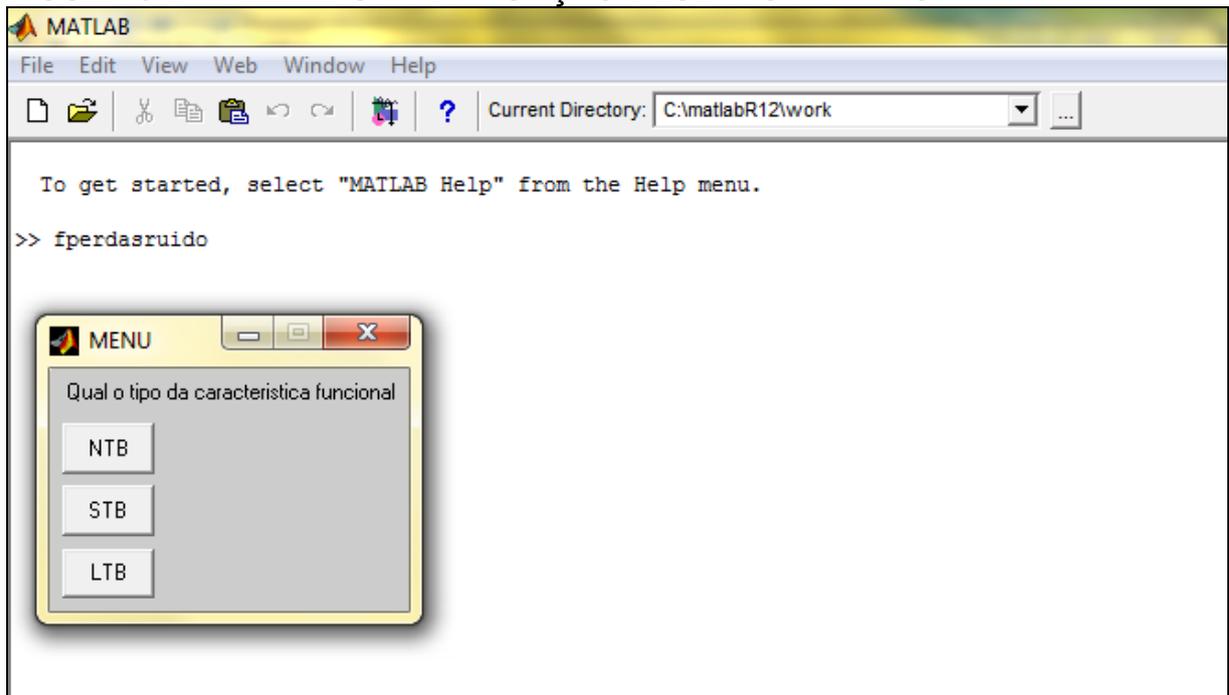


FONTE: O AUTOR

3.1.2 Telas de Entrada de Dados do *Software* Matlab

O nome do programa desenvolvido foi denominado de *fperdasruído* e tem como tela inicial a figura 3.2, onde se pode escolher o tipo de característica funcional do produto, denominada de: 1) Nominal-é-melhor (NTB); 2) Menor-é-melhor (STB); 3) Maior-é-melhor (LTB).

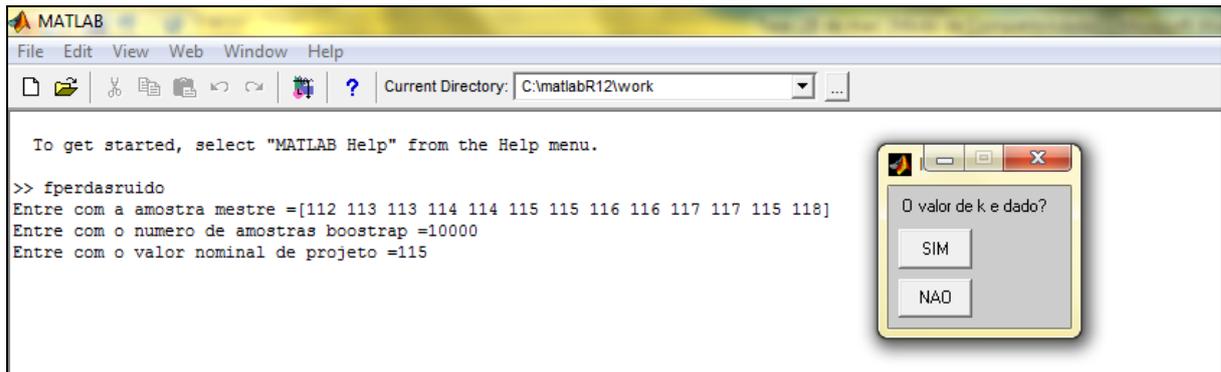
FIGURA 3.2 – TELA INICIAL DA FUNÇÃO DESENVOLVIDA NO MATLAB



FONTE: O AUTOR

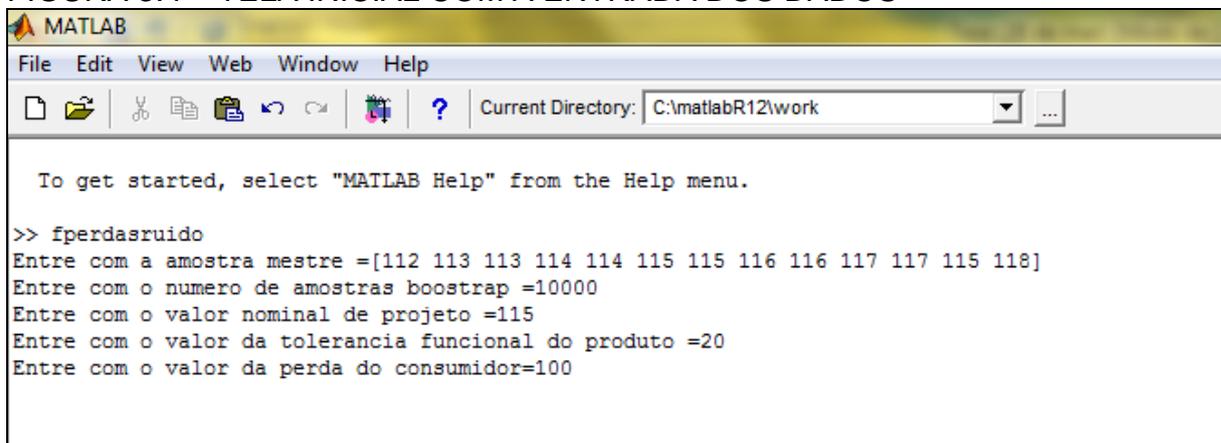
Após a escolha do tipo de característica funcional, deve-se entrar com a amostra mestre, número de amostras *bootstrap*, valor nominal de projeto (somente para o caso NTB) e definir se o valor do coeficiente de perda de qualidade k é dado ou não, conforme figura 3.3. Se sim, a entrada de dados está completa caso contrário deve-se definir o valor da tolerância funcional do produto e a perda para o consumidor conforme figura 3.4.

FIGURA 3.3 – TELA PARA ESCOLHA SE K É DADO OU NÃO



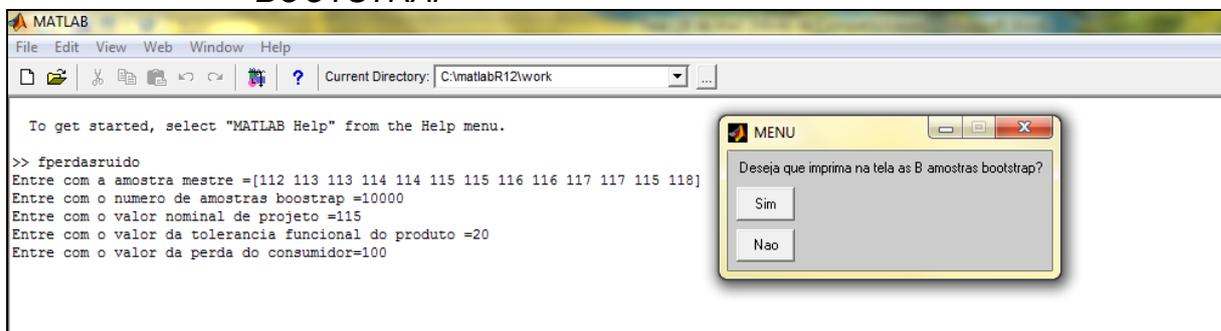
FONTE: O AUTOR

FIGURA 3.4 – TELA INICIAL COM A ENTRADA DOS DADOS



FONTE: O AUTOR

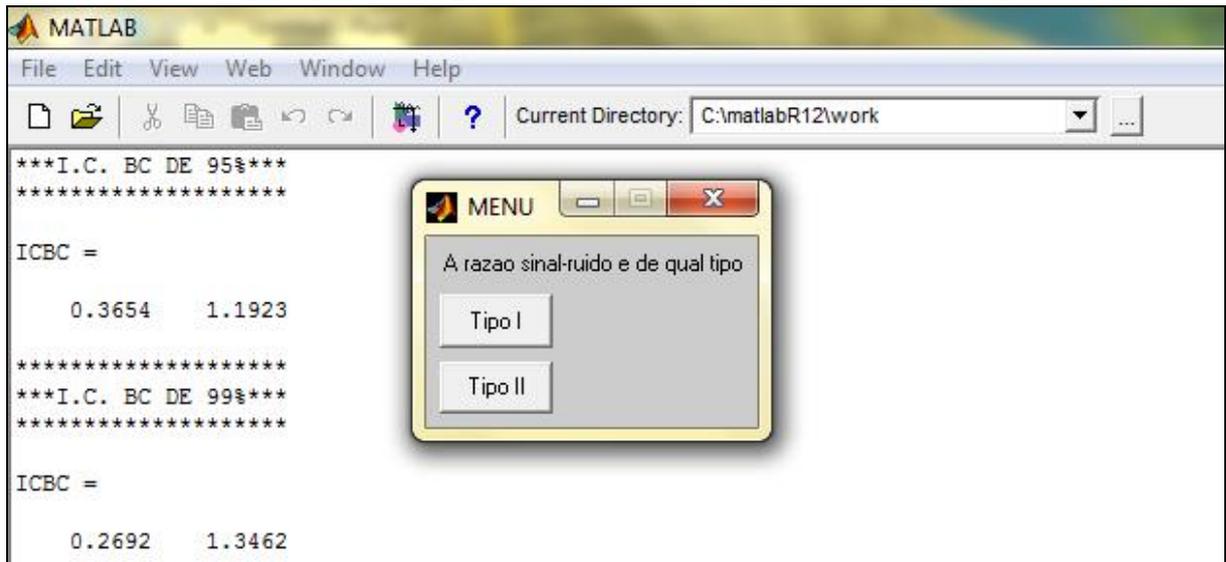
Após a entrada de dados, o programa dá a opção de se imprimir as B amostras *bootstrap*, conforme figura 3.5.

FIGURA 3.5 – TELA COM A OPÇÃO DE SE IMPRIMIR AS B AMOSTRAS *BOOTSTRAP*

FONTE: O AUTOR

Se a característica funcional escolhida for a nominal-é-melhor, pergunta-se se a razão sinal-ruído é do tipo I ou II, conforme figura 3.6.

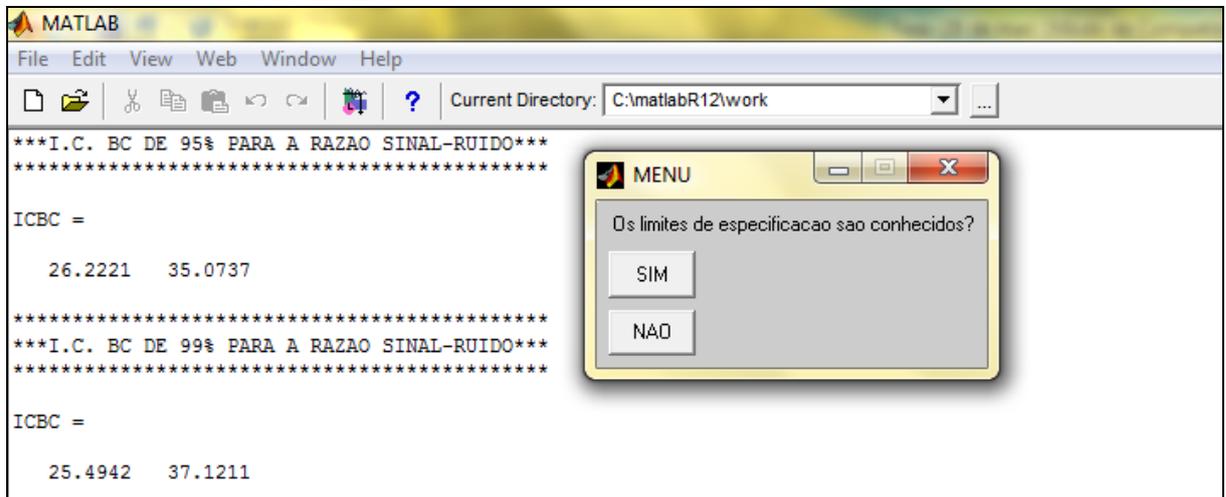
FIGURA 3.6 – TELA DE ESCOLHA DO TIPO DE RAZÃO SINAL-RUÍDO



FONTE: O AUTOR

E finalizando o programa pergunta se são conhecidos os limites de especificação do produto, conforme figura 3.7.

FIGURA 3.7 – TELA PARA A ESCOLHA SE OS LIMITES DE ESPECIFICAÇÃO SÃO DADOS



FONTE: O AUTOR

A amostra original inserida é denominada de amostra mestre. A mesma será utilizada para a reamostragem das B amostras *bootstrap*, respectivas estatísticas, distribuições *bootstrap* e intervalos de confiança de interesse.

Nesta tese se consideram as estatísticas: 1) Função perda de Taguchi; 2) Razão sinal-ruído; 3) Índices C_p , C_{pk} e C_{pkm} .

3.2 CARACTERIZAÇÃO E DESCRIÇÃO DAS AMOSTRAS MESTRES

Nesta seção se descreverá as amostras mestres para cada um dos três tipos de características funcionais.

3.2.1 Descrição da Amostra Mestre Para a Característica Nominal-é-Melhor

As amostras mestres referentes a característica nominal-é-melhor foram retiradas do livro *Quality by design :Taguchi Methods and U.S. Industry*, de autoria de Ealey (1988).

De acordo com Ealey (1988), a característica funcional da amostra mestre será a tensão de saída de uma fonte de alimentação de um aparelho de televisão, onde a tensão nominal será de 115 volts. Quando esta tensão variar mais de 20 volts da tensão nominal (tolerância funcional do produto) considera-se uma perda de \$100,00 para o consumidor. Desta forma define-se os limites de especificação do produto que são de 95 volts para o limite inferior e de 135 volts para o limite superior.

O cálculo de k (coeficiente de perda de qualidade) será efetuado de acordo com o tipo de característica funcional, seguindo a equação (2.5). Neste caso específico, onde a característica em questão é do tipo nominal-é-melhor, o valor de k será de 0,25.

A primeira amostra mestre é dada por

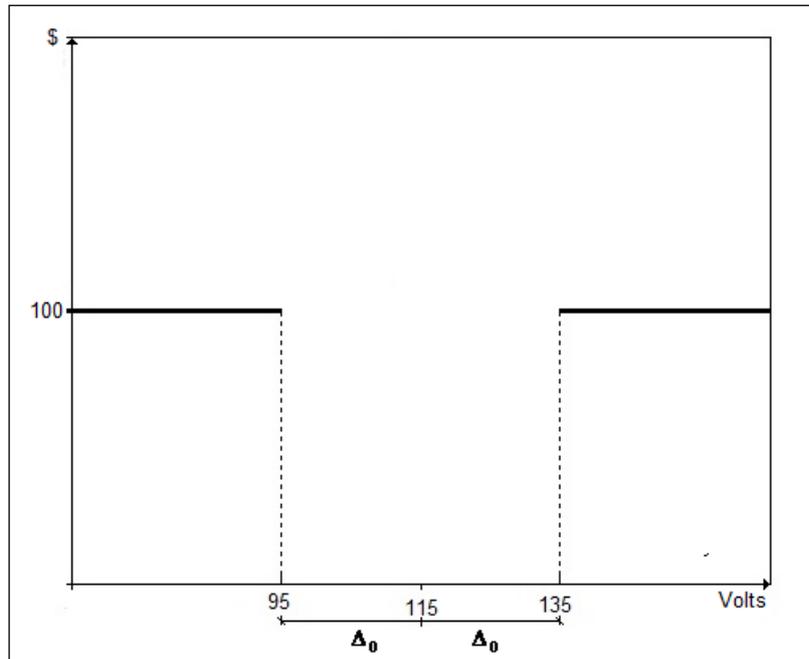
$$\underline{V1}' = [112 \ 113 \ 113 \ 114 \ 114 \ 115 \ 115 \ 116 \ 116 \ 117 \ 117 \ 115 \ 118]$$

e a segunda por

$$\underline{V2}' = [112 \ 113 \ 112 \ 113 \ 112 \ 113 \ 114 \ 115 \ 112 \ 113 \ 114 \ 112 \ 114]$$

A figura 3.8 descreve as características funcionais da fonte de alimentação.

FIGURA 3.8 – CARACTERÍSTICAS FUNCIONAIS DA FONTE



FONTE: O AUTOR

3.2.2 Descrição da Amostra Mestre Para a Característica Menor-é-Melhor

As amostras mestres referentes a característica menor-é-melhor foram retiradas do livro Engenharia da Qualidade em Sistemas de Produção, de autoria de Taguchi et al. (1990).

A característica funcional da amostra mestre será planeza de superfície de um bloco padrão. Quanto menor o desvio de planeza, melhor será o bloco. A tolerância funcional do produto é definida em $12 \mu m$ e quando o valor da planicidade passar desse valor tem-se uma perda para o consumidor de \$80,00. Os dados fornecidos são referentes aos dados de planicidade de blocos fabricados por duas máquinas M_1 e M_2 .

TABELA 3.1 –DADOS DE PLANICIDADE DAS MÁQUINAS 1 E 2

MÁQUINA	DADOS DE PLANICIDADE (μm)									
M_1	0	5	4	2	3	1	7	6	8	4
	6	0	3	10	4	5	3	2	0	7
M_2	5	4	0	4	2	1	0	2	5	3
	2	1	3	0	2	4	1	6	2	1

FONTES: TAGUCHI, G. et al.,1990, p. 46

O cálculo de k (coeficiente de perda de qualidade) será efetuado de acordo com o tipo de característica funcional, seguindo a equação (2.29). Neste caso específico, onde a característica em questão é do tipo menor-é-melhor, o valor de k

será de $\frac{80}{12^2}$.

3.2.3 Descrição da Amostra Mestre Para a Característica Maior-é-Melhor

As amostras mestres referentes a característica maior-é-melhor foram retiradas do livro Engenharia da Qualidade em Sistemas de Produção, de autoria de Taguchi et al. (1990).

A característica funcional em questão é a resistência de um adesivo, onde a mesma é determinada pela força necessária para separar os itens ligados pelo adesivo. O limite inferior de especificação (tolerância funcional) é de 5 kgf para a carga de ruptura, onde os itens fora da especificação são escapeados resultando em uma perda para o consumidor de \$70,00 por item.

As amostras são referentes à medição da força de ruptura em dois tipos de adesivos S_1 e S_2 .

TABELA 3.2 – DADOS DA FORÇA DE RUPTURA DOS ADESIVOS S_1 e S_2

TIPO DE ADESIVO	FORÇA DE RUPTURA (kgf)									
S_1	10,2	5,8	4,9	16,1	15,0	9,4	4,8	10,1		
	14,6	19,7	5,0	4,7	16,8	4,5	4,0	16,5		
S_2	7,6	13,7	7,0	12,8	11,8	13,7	14,8	10,4		
	7,0	10,1	6,8	10,0	8,6	11,2	8,3	10,6		

FONTES: TAGUCHI, G. et al.,1990, p. 48

O cálculo de k (coeficiente de perda de qualidade) será efetuado de acordo com o tipo de característica funcional, seguindo a equação (2.36). Neste caso específico, onde a característica em questão é do tipo maior-é-melhor, o valor de k será de 1750.

O objetivo de se utilizar duas amostras em cada um dos três casos possíveis de características funcionais existentes é a verificação e comparação dos cálculos propostos no objetivo desta tese.

3.3 REAMOSTRAGEM UTILIZANDO O MÉTODO BOOTSTRAP

As B amostras *bootstrap* são geradas efetuando-se o sorteio aleatório, com reposição, dos elementos que compõem a amostra mestre. As B amostras *bootstrap* são geradas no *software* Matlab por uma função já existente no mesmo.

O valor de B pode ser definido inicialmente pelo usuário, porém nesta presente tese serão considerados os valores de 10000, 20000 e 30000 amostras.

3.4 CÁLCULOS DA FUNÇÃO PERDA MÉDIA DE TAGUCHI

Para cada amostra *bootstrap* calcula-se a função perda média de Taguchi referente a característica funcional do produto analisado seguindo as equações (2.16), (2.31) e (2.38).

3.4.1 Função Perda Média Nominal-é-Melhor

A função perda média da amostra mestre descrita na seção 3.2.1 é dada por

$$\bar{L}(y) = 0,25[\sigma^2 + (\bar{y} - 115)^2] \quad (3.1)$$

e a mesma será calculada para cada amostra *bootstrap*. Assim, tem-se que

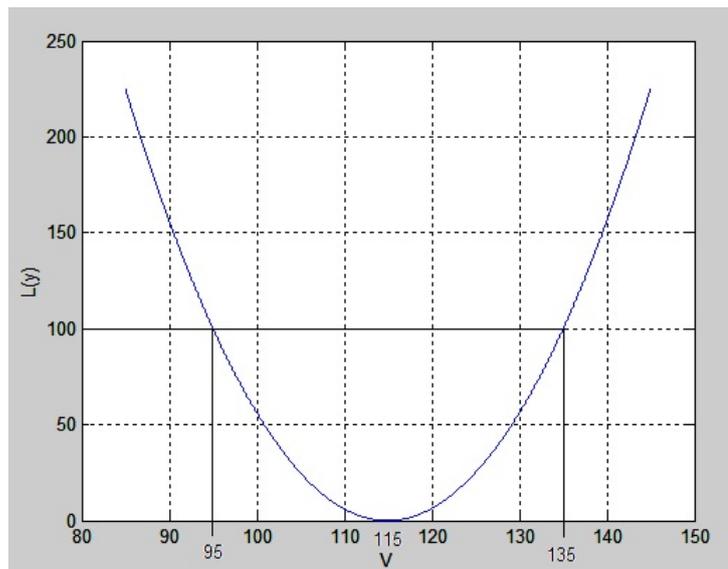
$$\hat{L}_i^*(y) = 0,25[\sigma_i^2 + (\bar{y}_i - 115)^2] \quad (3.2)$$

onde $i = 1, \dots, B$.

Desta maneira tem-se $\hat{L}_1^*(y), \hat{L}_2^*(y), \dots, \hat{L}_B^*(y)$, e a partir destas estimativas se calcula a variabilidade, os intervalos de confiança e a distribuição *bootstrap* da função perda média de Taguchi para a característica funcional nominal-é-melhor.

A figura 3.9 demonstra o comportamento da função de perda quadrática de Taguchi para as características funcionais da fonte de alimentação.

FIGURA 3.9 – FUNÇÃO PERDA DE TAGUCHI NOMINAL-É-MELHOR



FONTE: O AUTOR

3.4.2 Função Perda Média Menor-é-Melhor

A função perda média da amostra mestre descrita na seção 3.2.2 é dada por

$$\bar{L}(y) = \frac{80}{12^2} [\sigma^2 + \bar{y}^2] \quad (3.3)$$

e a mesma será calculada para cada amostra *bootstrap*. Assim, tem-se que

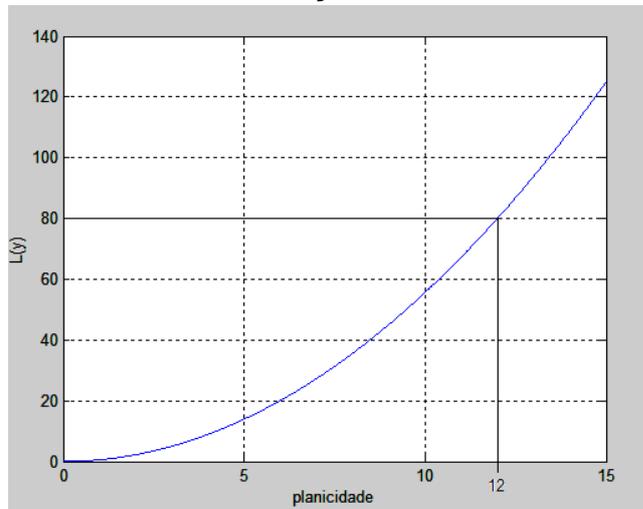
$$\hat{L}_i^*(y) = \frac{80}{12^2} [\sigma_i^2 + \bar{y}_i^2] \quad (3.4)$$

onde $i = 1, \dots, B$.

Desta maneira tem-se $\hat{L}_1^*(y), \hat{L}_2^*(y), \dots, \hat{L}_B^*(y)$, e a partir destas estimativas se calcula a variabilidade, os intervalos de confiança e a distribuição *bootstrap* da função perda média de Taguchi para a característica funcional menor-é-melhor.

A figura 3.10 demonstra o comportamento da função de perda quadrática de Taguchi para a característica funcional planicidade da superfície de um bloco padrão.

FIGURA 3.10 – FUNÇÃO PERDA DE TAGUCHI MENOR-É-MELHOR



FONTE: O AUTOR

3.4.3 Função Perda Média Maior-é-Melhor

A função perda média da amostra mestre descrita na seção 3.2.3 é dada por

$$\bar{L}(y) = 1750 \left[\frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \right] \quad (3.5)$$

e a mesma será calculada para cada amostra *bootstrap*. Assim, tem-se que

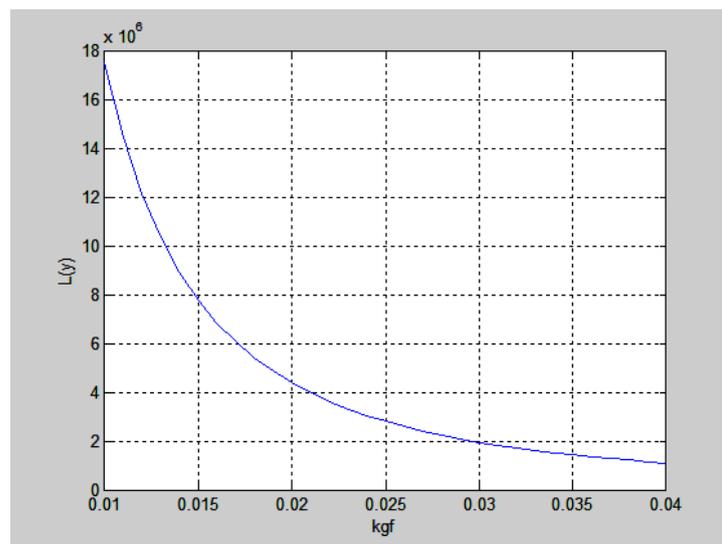
$$\bar{L}_i^*(y) = 1750 \left[\frac{1}{n} \sum_{j=1}^n \frac{1}{y_{ij}^2} \right] \quad (3.6)$$

onde $i = 1, \dots, B$.

Desta maneira tem-se $\hat{L}_1^*(y), \hat{L}_2^*(y), \dots, \hat{L}_B^*(y)$, e a partir destas estimativas se calcula a variabilidade, os intervalos de confiança e a distribuição *bootstrap* da função perda média de Taguchi para a característica funcional maior-é-melhor.

A figura 3.11 demonstra o comportamento da função de perda quadrática de Taguchi para a característica funcional força de ruptura.

FIGURA 3.11 - FUNÇÃO PERDA DE TAGUCHI MAIOR-É-MELHOR



FONTE: O AUTOR

3.5 CÁLCULOS DA RAZÃO SINAL-RUÍDO

Para cada amostra *bootstrap* calcula-se a razão sinal-ruído referente a característica funcional do produto analisado seguindo as equações (2.49), (2.53) e (2.54).

3.5.1 Razão Sinal-Ruído Nominal-é-Melhor

A razão sinal-ruído da amostra mestre descrita na seção 3.2.1 é dada por

$$S / N_{\text{tipo I-NTB}} = 10 \log \left[\frac{\bar{y}^2}{s^2} \right] \quad (3.7)$$

e a mesma será calculada para cada amostra *bootstrap*. Assim, tem-se

$$\text{de } S / N_{i \text{ tipo I-NTB}}^* = 10 \log \left[\frac{\bar{y}_i^2}{s_i^2} \right] \quad (3.8)$$

onde $i = 1, \dots, B$.

Desta maneira tem-se $S / N_1^*, S / N_2^*, \dots, S / N_B^*$, e a partir destas estimativas se calcula a variabilidade, os intervalos de confiança e a distribuição *bootstrap* da razão sinal-ruído para a característica funcional nominal-é-melhor.

3.5.2 Razão Sinal-Ruído Menor-é-Melhor

A razão sinal-ruído da amostra mestre descrita na seção 3.2.2 é dada por

$$S / N_{STB} = -10 \log \left[\frac{1}{n} \sum_{i=1}^n y_i^2 \right] \quad (3.9)$$

e a mesma será calculada para cada amostra *bootstrap*. Assim, tem-se que

$$S / N_{i STB}^* = -10 \log \left[\frac{1}{n} \sum_{j=1}^n y_{ij}^2 \right] \quad (3.10)$$

onde $i = 1, \dots, B$.

Desta maneira tem-se $S/N_1^*, S/N_2^*, \dots, S/N_B^*$, e a partir destas estimativas se calcula a variabilidade, os intervalos de confiança e a distribuição *bootstrap* da razão sinal-ruído para a característica funcional menor-é-melhor.

3.5.3 Razão Sinal-Ruído Maior-é-Melhor

A razão sinal-ruído da amostra mestre descrita na seção 3.2.3 é dada por

$$S/N_{LTB} = -10 \log \left[\frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \right] \quad (3.11)$$

e a mesma será calculada para cada amostra *bootstrap*. Assim, tem-se que

$$S/N_{iLTB}^* = -10 \log \left[\frac{1}{n} \sum_{j=1}^n \frac{1}{y_{ij}^2} \right] \quad (3.12)$$

onde $i = 1, \dots, B$.

Desta maneira tem-se $S/N_1^*, S/N_2^*, \dots, S/N_B^*$, e a partir destas estimativas se calcula a variabilidade, os intervalos de confiança e a distribuição *bootstrap* da razão sinal-ruído para a característica funcional maior-é-melhor.

3.6 CÁLCULOS DOS ÍNDICES C_p , C_{pk} e C_{pkm}

O cálculo dos três índices será efetuado somente para o caso nominal-é-melhor, pois neste caso se conhecem os limites de especificação do produto. Para os outros casos somente se calculará o índice C_{pkm} , visto que para o mesmo é necessário somente o conhecimento de unilateral dos limites de especificação, ou seja, o conhecimento do limite inferior ou superior de especificação.

Da mesma maneira, as distribuições *bootstrap* para os três índices de capacidade somente serão plotadas para o caso nominal-é-melhor, caso contrário, somente a distribuição *bootstrap* do índice será C_{pkm} plotado.

O cálculo de cada um dos índices será efetuado conforme as equações (2.59), (2.64) e (2.75), tanto para a amostra mestre quanto para as B amostras *bootstrap*. Serão considerados nesta tese somente o cálculo da variabilidade e dos intervalos de confiança do índice C_{pkm} , pois o mesmo pode ser calculado dada qualquer característica funcional de um produto.

4 RESULTADOS E ANÁLISES

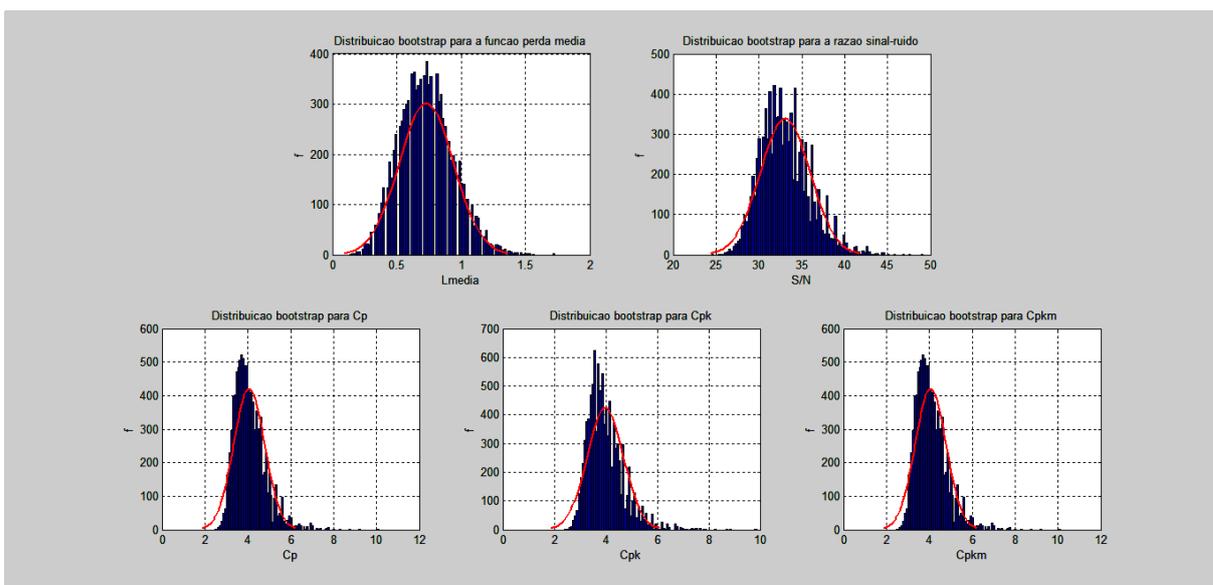
Os resultados demonstrados nesta presente tese são referentes às características funcionais nominal-é-melhor, menor-é-melhor e maior-é-melhor, sendo que as duas últimas características citadas terão somente as distribuições *bootstrap* da função perda de Taguchi, da razão sinal-ruído e do índice C_{pkm} pelo motivo explicado na seção 3.7.

4.1 DISTRIBUIÇÕES *BOOTSTRAP*

4.1.1 Distribuições *Bootstrap* Para o Caso Nominal-é-Melhor

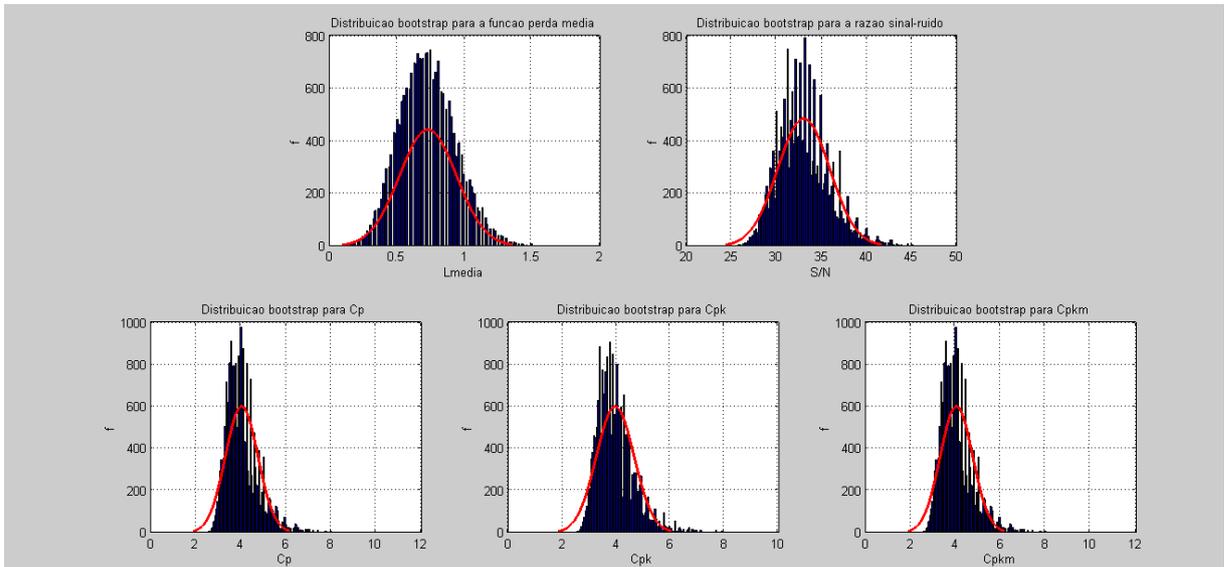
Dadas as amostras mestres $V1'$ e $V2'$, vistas na seção 3.2.1, se verifica, através dos gráficos (4.1), (4.2), (4.3), (4.4), (4.5) e (4.6) as distribuições *bootstrap* para o caso nominal-é-melhor da função perda média de Taguchi, da razão sinal-ruído tipo I e dos índices C_p , C_{pk} e C_{pkm} .

GRÁFICO 4.1 – DISTRIBUIÇÕES *BOOTSTRAP* DE $V1'$ PARA 10000 AMOSTRAS *BOOTSTRAP*



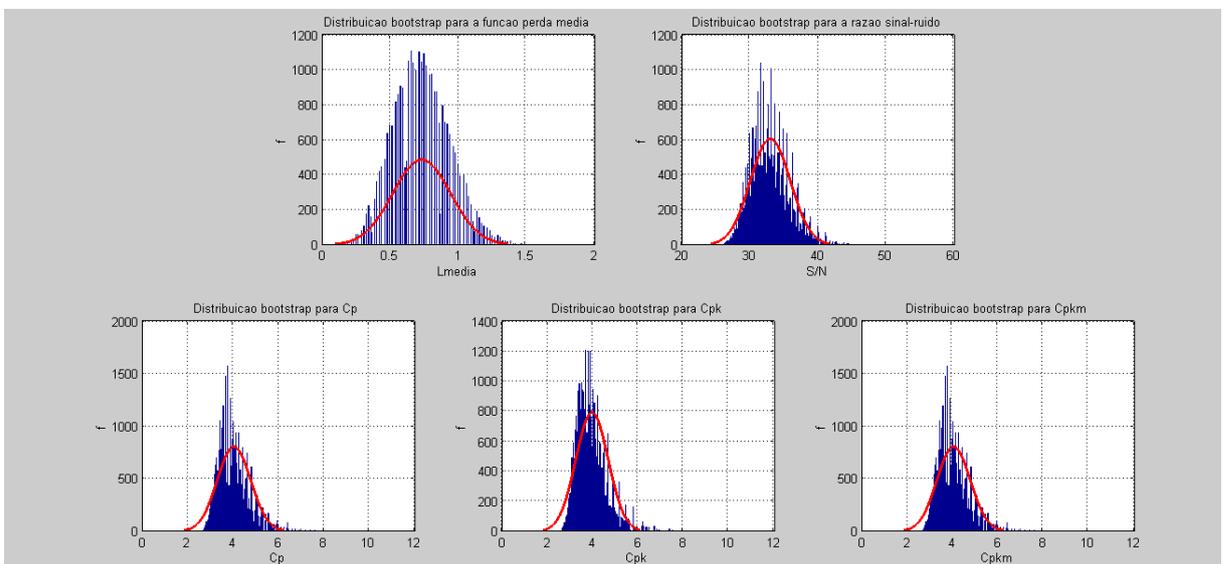
FONTE: O AUTOR

GRÁFICO 4.2 – DISTRIBUIÇÃO *BOOTSTRAP* DE $\underline{V1}$ ' PARA 20000 AMOSTRAS
BOOTSTRAP



FONTE: O AUTOR

GRÁFICO 4.3 – DISTRIBUIÇÃO *BOOTSTRAP* DE $\underline{V1}$ ' PARA 30000 AMOSTRAS
BOOTSTRAP

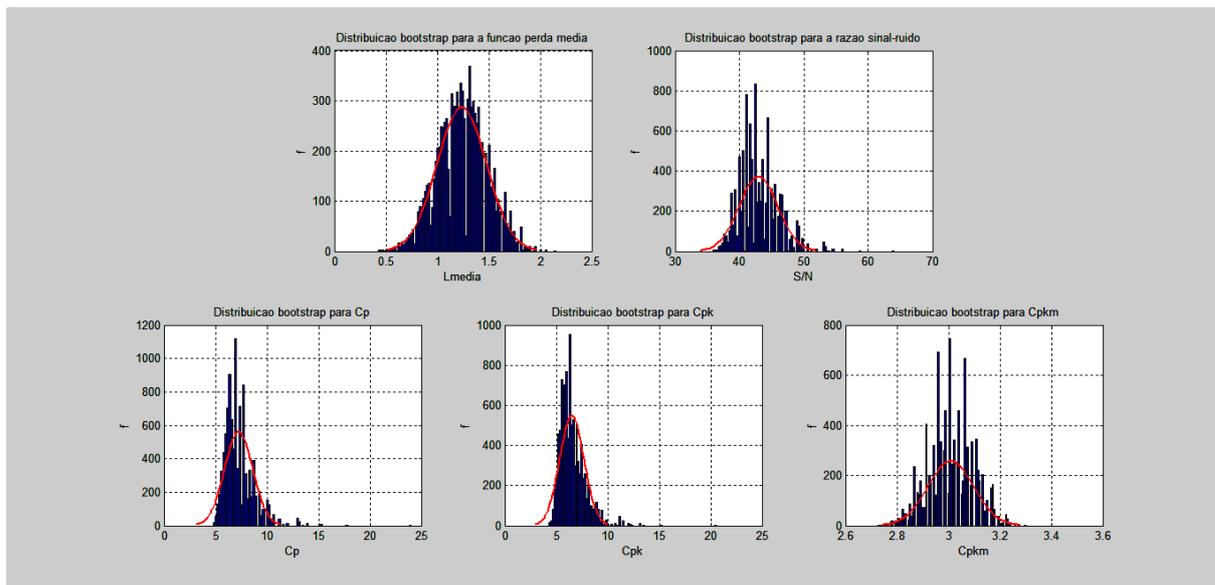


FONTE: O AUTOR

De acordo com os gráficos (4.1), (4.2) e (4.3) se observa que a distribuição *bootstrap* da função perda média de Taguchi visualmente apresenta uma distribuição próxima da distribuição normal, no entanto efetuou-se o teste de

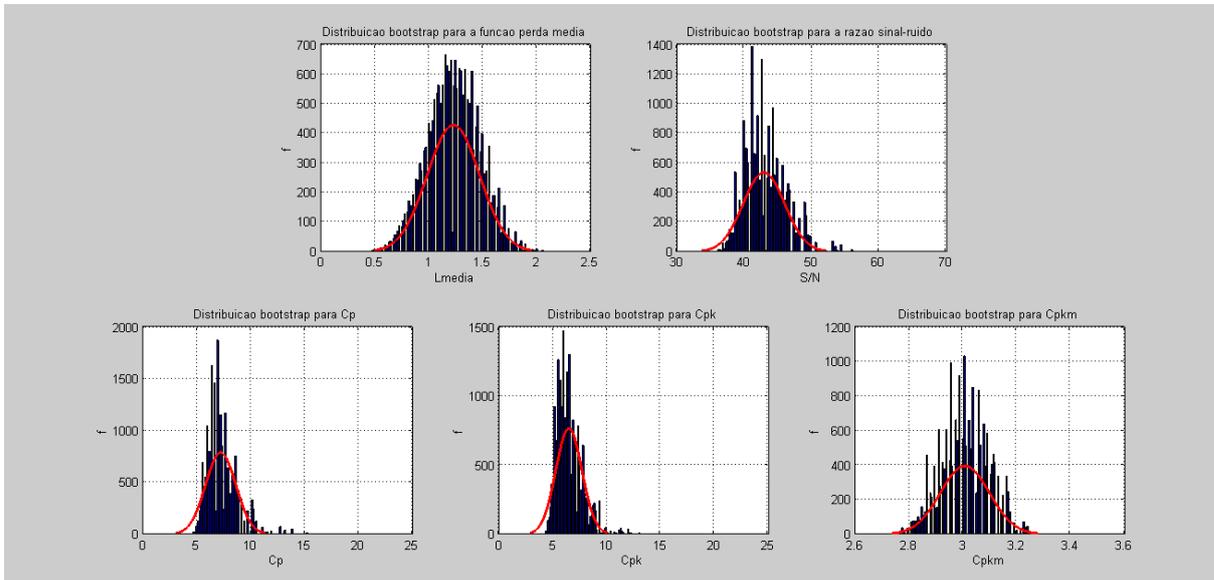
normalidade de Kolmogorov-Smirnov e Lilliefors para um nível de significância de 5% e não se verificou a normalidade, tanto para 10000, 20000 e 30000 amostras . Os gráficos referentes às distribuições *bootstrap* da razão sinal-ruído e dos índices Cp, Cpk e Cpkm apresentam uma certa assimetria e aparentemente não possuem uma forma parecida com alguma distribuição teórica de probabilidade conhecida.

GRÁFICO 4.4 – DISTRIBUIÇÕES *BOOTSTRAP* DE $\underline{V2}$ ' PARA 10000 AMOSTRAS
BOOTSTRAP



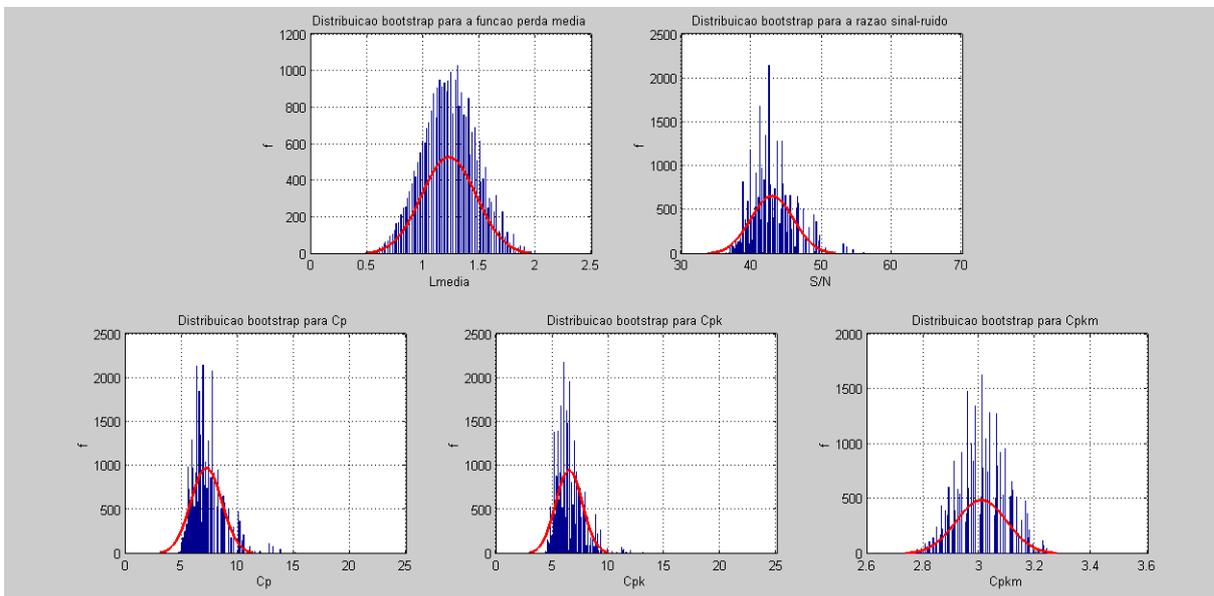
FONTE: O AUTOR

GRÁFICO 4.5 – DISTRIBUIÇÕES *BOOTSTRAP* DE $\underline{V_2}$ PARA 20000 AMOSTRAS *BOOTSTRAP*



FONTE: O AUTOR

GRÁFICO 4.6 – DISTRIBUIÇÕES *BOOTSTRAP* DE $\underline{V_2}$ PARA 30000 AMOSTRAS *BOOTSTRAP*



FONTE: O AUTOR

Analogamente a análise feita com os gráficos (4.1), (4.2) e (4.3), se observa que nos gráficos (4.4), (4.5) e (4.6) a distribuição *bootstrap* da função perda média de Taguchi apesar de visualmente aparentar uma distribuição normal, a sua

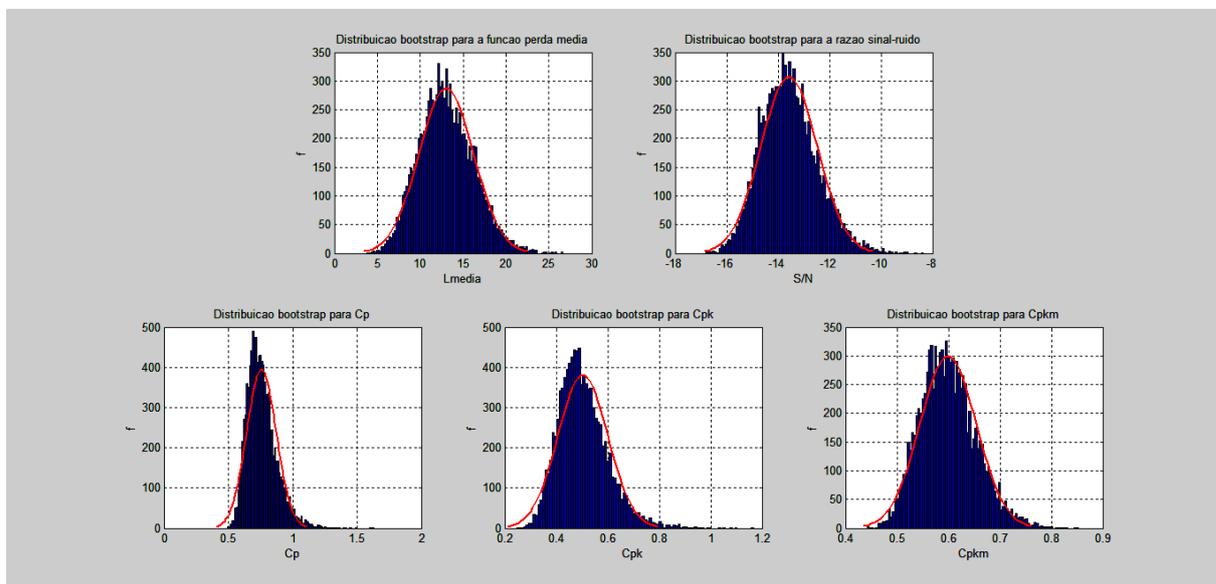
normalidade não é verificada, para um nível de significância de 5%, quando se realiza o teste de normalidade de Kolmogorov-Smirnov e Lilliefó

rs. Os gráficos referentes às distribuições *bootstrap* da razão sinal-ruído e dos índices C_p , C_{pk} e C_{pkm} não apresentam uma forma parecida com alguma distribuição teórica de conhecida.

4.1.2 Distribuições *Bootstrap* Para o Caso Menor-é-Melhor

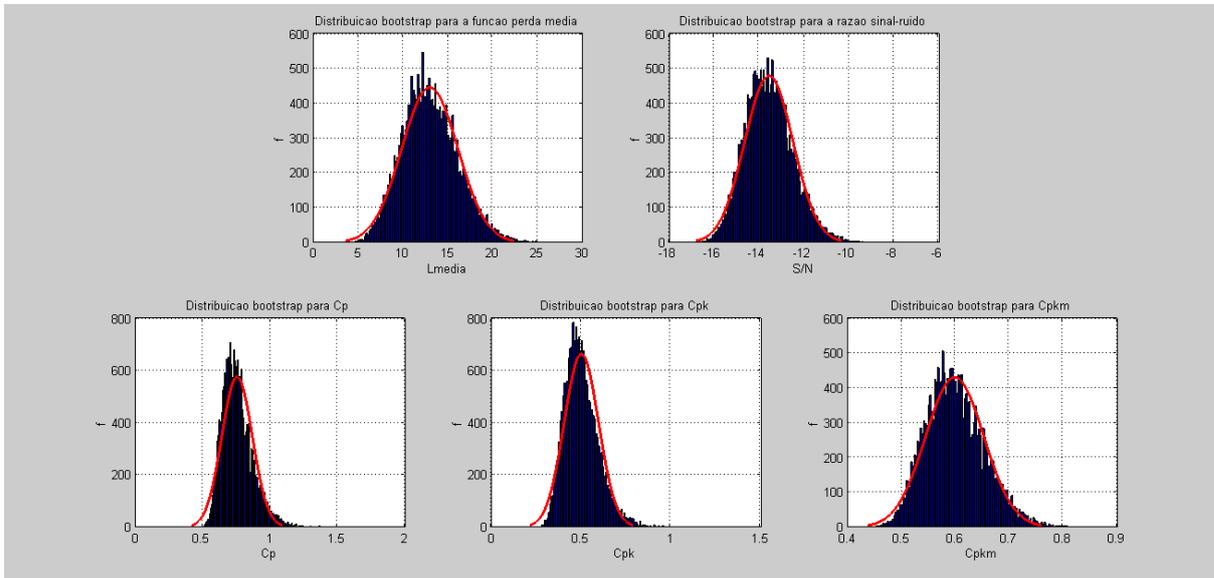
Dadas as amostras mestres M_1 e M_2 , vistas na seção 3.2.2, se verifica, através dos gráficos (4.7), (4.8), (4.9), (4.10), (4.11) e (4.12) as distribuições *bootstrap* para o caso menor-é-melhor da função perda média, da razão sinal-ruído e dos índices C_p , C_{pk} e C_{pkm} .

GRÁFICO 4.7 – DISTRIBUIÇÕES *BOOTSTRAP* DE M_1 PARA 10000 AMOSTRAS *BOOTSTRAP*



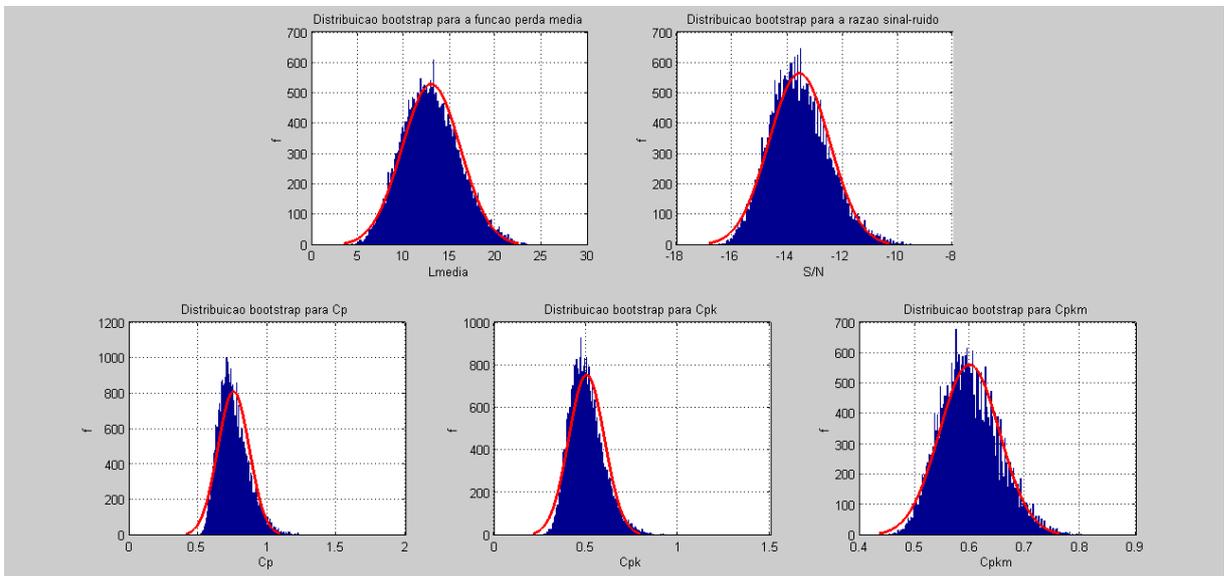
FONTE: O AUTOR

GRÁFICO 4.8 – DISTRIBUIÇÕES *BOOTSTRAP* DE M_1 PARA 20000 AMOSTRAS *BOOTSTRAP*



FONTE: O AUTOR

GRÁFICO 4.9 – DISTRIBUIÇÕES *BOOTSTRAP* DE M_1 PARA 30000 AMOSTRAS *BOOTSTRAP*

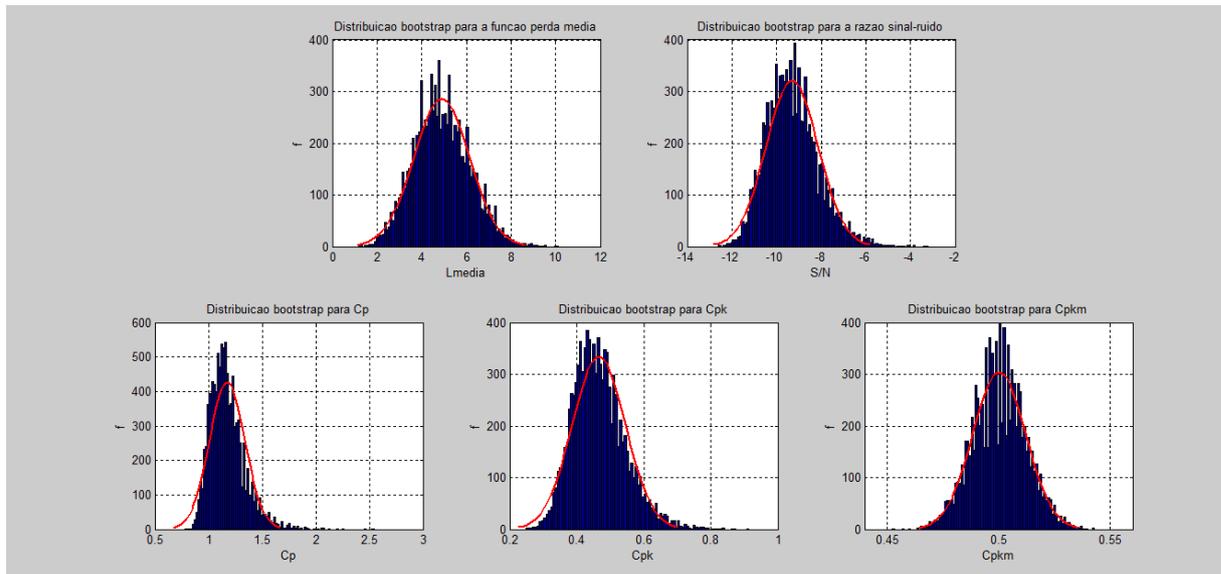


FONTE: O AUTOR

De acordo com os gráficos (4.7), (4.8) e (4.9) se observa que a distribuição *bootstrap* da função perda média de Taguchi e da razão-sinal ruído apresenta uma distribuição próxima da distribuição normal, no entanto efetuou-se o teste de

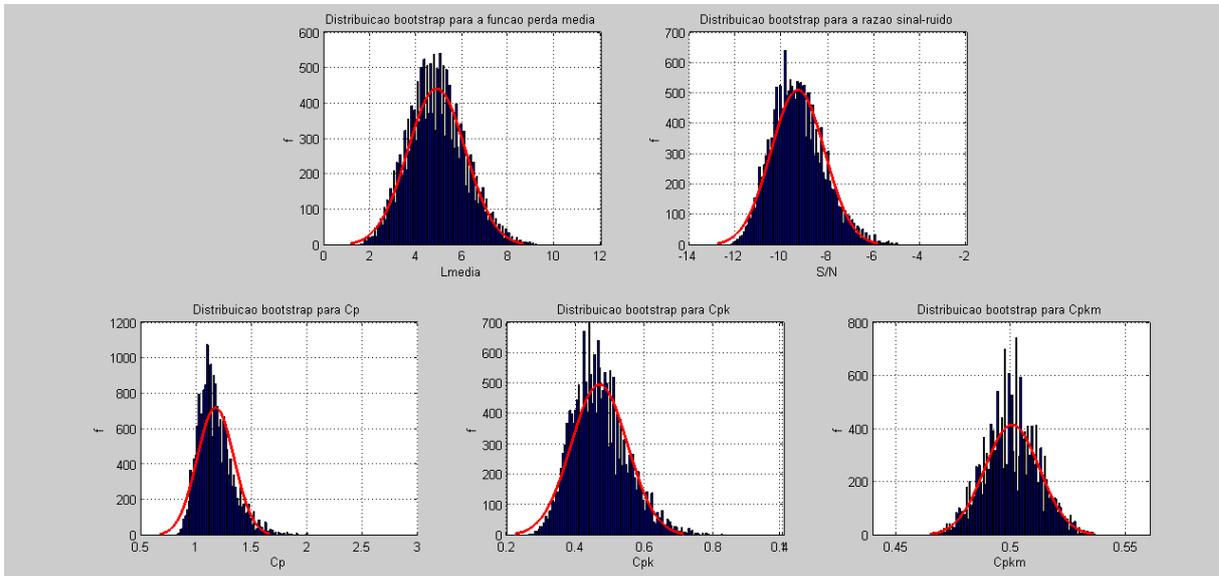
normalidade de Kolmogorov-Smirnov e Lilliefors para um nível de significância de 5% e não se verificou a normalidade. Os gráficos referentes às distribuições *bootstrap* dos índices C_p , C_{pk} e C_{pkm} , apresentam uma leve assimetria e não se aceita a hipótese de normalidade para os mesmos efetuando-se os testes de normalidade de Kolmogorov-Smirnov e Lilliefors.

GRÁFICO 4.10 – DISTRIBUIÇÕES *BOOTSTRAP* DE M_2 PARA 10000 AMOSTRAS *BOOTSTRAP*



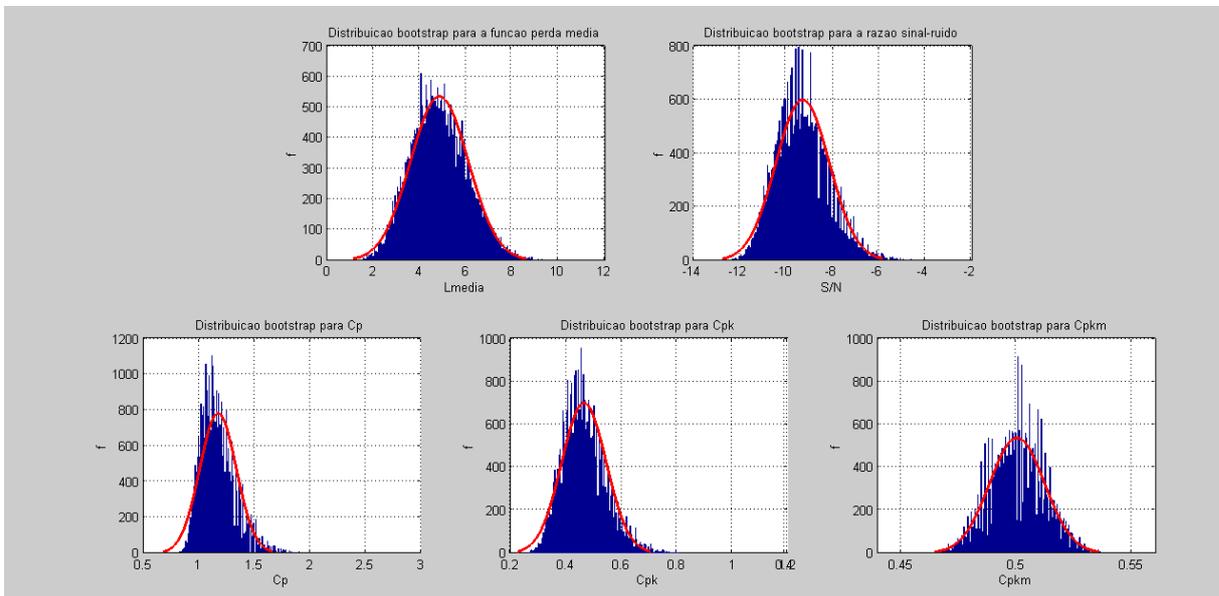
FONTE: O AUTOR

GRÁFICO 4.11 – DISTRIBUIÇÕES *BOOTSTRAP* DE M_2 PARA 20000 AMOSTRAS
BOOTSTRAP



FONTE: O AUTOR

GRÁFICO 4.12 – DISTRIBUIÇÕES *BOOTSTRAP* DE M_2 PARA 30000 AMOSTRAS
BOOTSTRAP



FONTE: O AUTOR

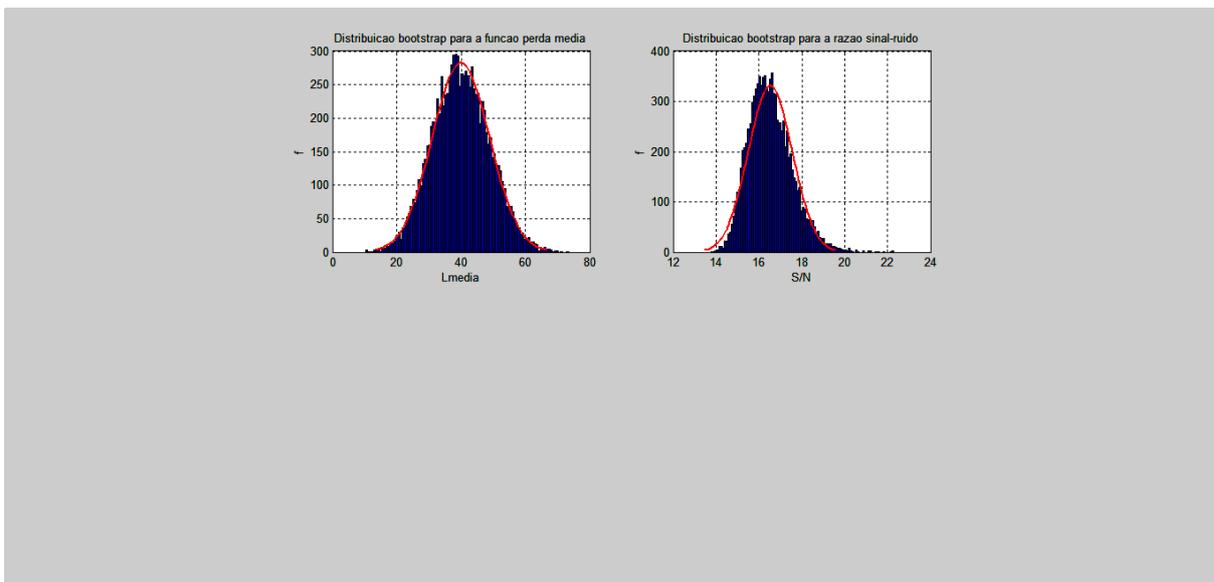
De acordo com os gráficos (4.10), (4.11) e (4.12) se observa que a distribuição *bootstrap* da função perda média de Taguchi visualmente apresenta uma distribuição próxima da distribuição normal, no entanto efetuou-se o teste de

normalidade de Kolmogorov-Smirnov e Lilliefors para um nível de significância de 5% e não se verificou a normalidade. Visualmente os gráficos referentes às distribuições *bootstrap* da razão sinal-ruído e dos índices C_p , C_{pk} e C_{pkm} não apresentam uma forma parecida com alguma distribuição teórica conhecida. Tais distribuições possuem também uma assimetria que pode ser verificada visualmente.

4.1.3 Distribuições *Bootstrap* Para o Caso Maior-é-Melhor

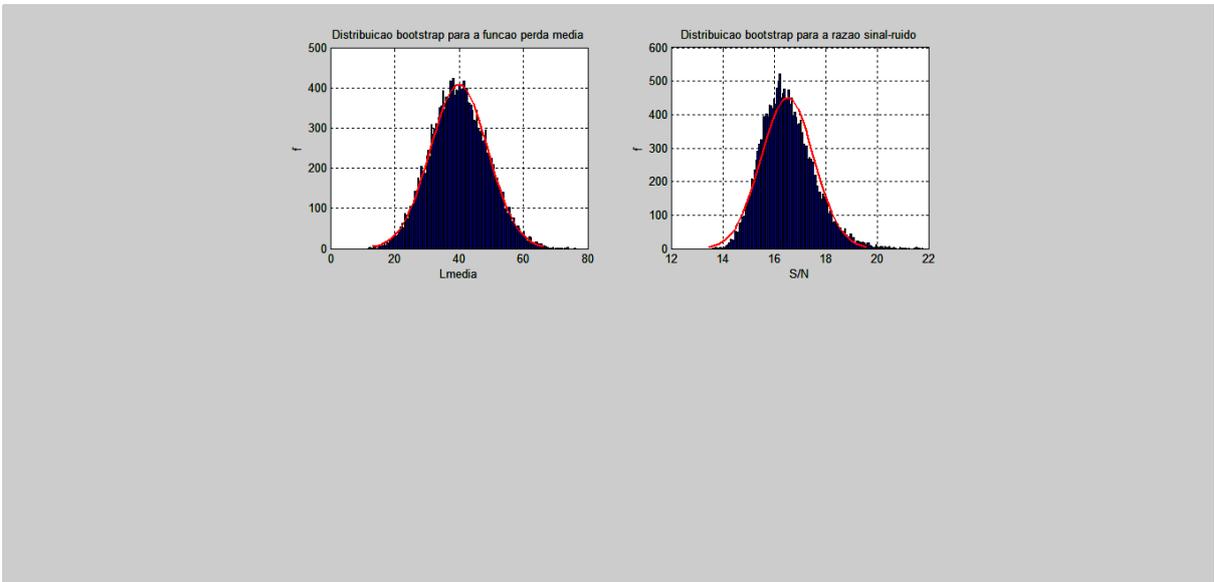
Dadas as amostras mestres S_1 e S_2 , vistas na seção 3.2.3, se verifica, através dos gráficos (4.13), (4.14), (4.15), (4.16), (4.17) e (4.18) as distribuições *bootstrap* para o caso maior-é-melhor da função perda média e da razão sinal-ruído. Não foi plotada a distribuição *bootstrap* para os índices C_p , C_{pk} e C_{pkm} pois não se conhece o limite de especificação superior do produto.

GRÁFICO 4.13 – DISTRIBUIÇÕES *BOOTSTRAP* DE S_1 PARA 10000 AMOSTRAS *BOOTSTRAP*



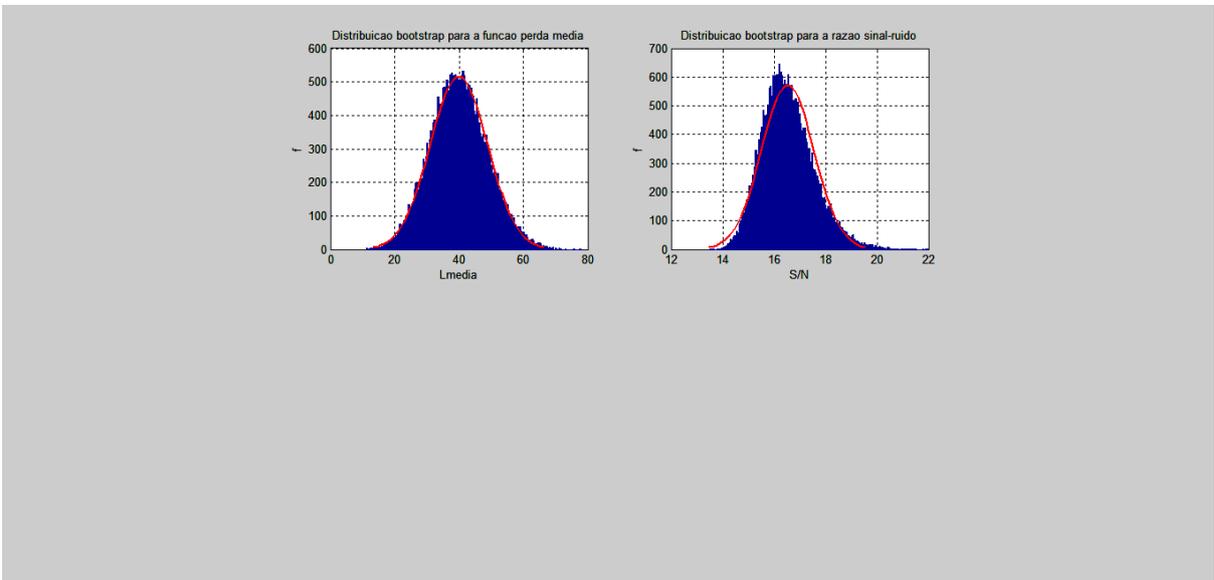
FONTE: O AUTOR

GRÁFICO 4.14 – DISTRIBUIÇÕES *BOOTSTRAP* DE S_1 PARA 20000 AMOSTRAS
BOOTSTRAP



FONTE: O AUTOR

GRÁFICO 4.15 – DISTRIBUIÇÕES *BOOTSTRAP* DE S_1 PARA 30000 AMOSTRAS
BOOTSTRAP

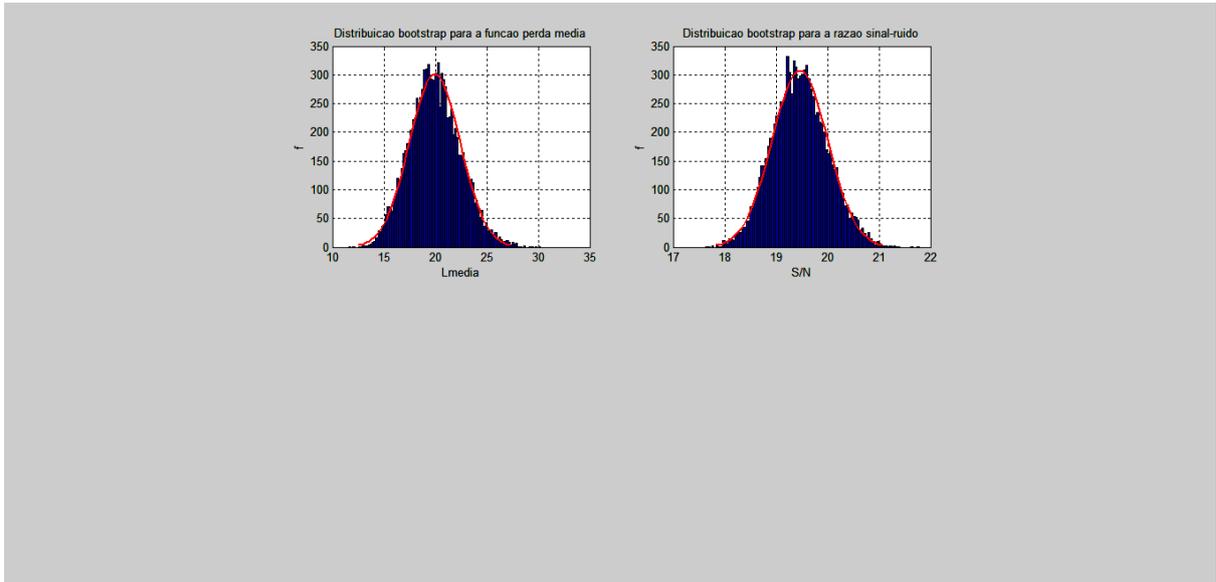


FONTE: O AUTOR

De acordo com os gráficos (4.13), (4.14) e (4.15) se observa que a distribuições *bootstrap* da função perda média de Taguchi e da razão sinal-ruído apresenta visualmente uma distribuição próxima da distribuição normal, no entanto efetuou-se o teste de normalidade de Kolmogorov-Smirnov e Lilliefors para um nível

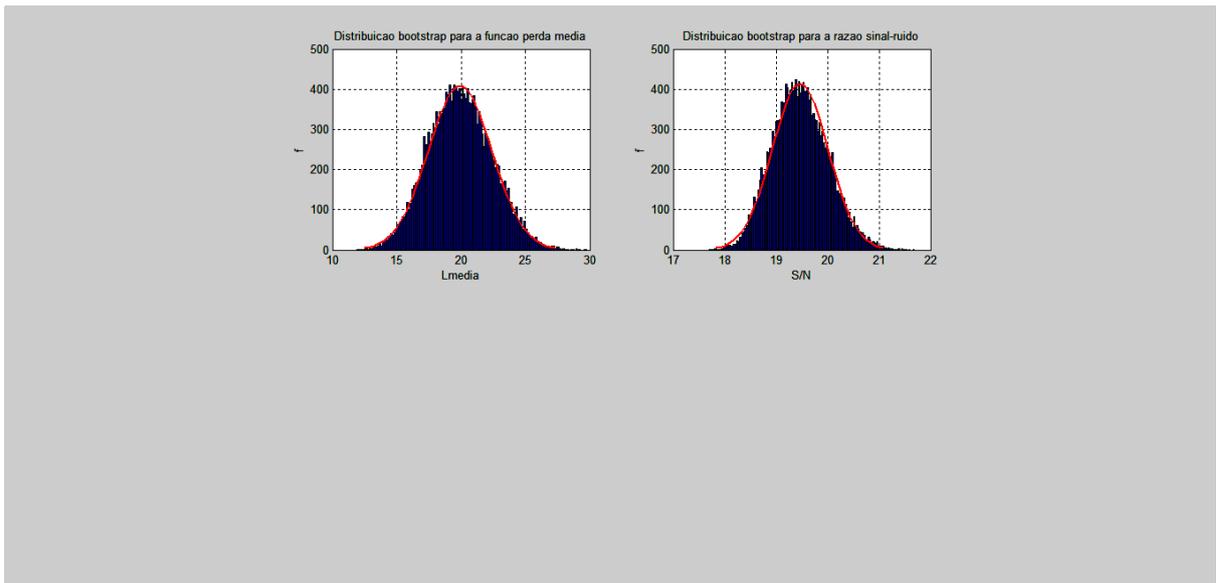
de significância de 5% e não se verificou a normalidade para ambos, tanto para 10000, 20000 e 30000 amostras *bootstrap*.

GRÁFICO 4.16 – DISTRIBUIÇÕES *BOOTSTRAP* DE s_2 PARA 10000 AMOSTRAS
BOOTSTRAP



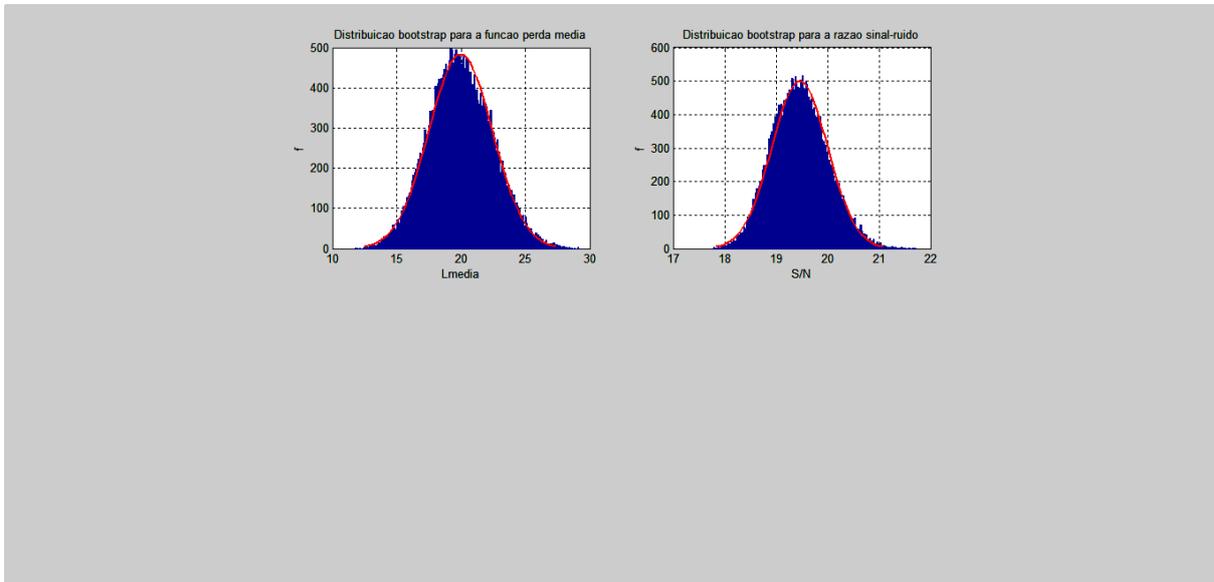
FONTE: O AUTOR

GRÁFICO 4.17 – DISTRIBUIÇÕES *BOOTSTRAP* DE s_2 PARA 20000 AMOSTRAS
BOOTSTRAP



FONTE: O AUTOR

GRÁFICO 4.18 – DISTRIBUIÇÕES *BOOTSTRAP* DE s_2 PARA 30000 AMOSTRAS *BOOTSTRAP*



FONTE: O AUTOR

De acordo com os gráficos (4.16), (4.17) e (4.18) se observa que a distribuições *bootstrap* da função perda média de Taguchi e da razão sinal-ruído apresenta visualmente uma distribuição próxima da distribuição normal, no entanto efetuou-se o teste de normalidade de Kolmogorov-Smirnov e Lilliefors para um nível de significância de 5% e não se verificou a normalidade para ambos, tanto para 10000, 20000 e 30000 amostras *bootstrap*.

4.2 VARIABILIDADE

Nas seções 4.2.1 e 4.2.2 demonstram-se os cálculos referentes às funções perda de Taguchi, razões sinal-ruído e índices C_p , C_{pk} e C_{pkm} para as suas respectivas amostras e características funcionais. Na seção 4.2.3 tem-se somente a demonstração dos cálculos referentes às funções perda de Taguchi e razão sinal-ruído para o caso maior-é-melhor pelo fato do não conhecimento do limite superior de especificação do produto.

4.2.1 Resultados da Variabilidade Para o Caso Nominal-é-Melhor

De acordo com a tabela 4.1 demonstra-se com os resultados referentes à função perda média de Taguchi, que a amostra $\underline{V1}'$ possui uma perda menor que a amostra $\underline{V2}'$, pois seus valores amostrais encontram-se mais próximos do valor nominal de projeto definido em 115 volts.

TABELA 4.1 – RESULTADOS PARA A FUNÇÃO PERDA MÉDIA PARA O CASO NTB

CÁLCULOS	$\underline{V1}'$			$\underline{V2}'$		
	B			B		
	10000	20000	30000	10000	20000	30000
$\bar{L}(y)$	0,7308	0,7308	0,7308	1,2308	1,2308	1,2308
SE_{boot}	0,2114	0,2098	0,2115	0,2408	0,2426	0,2424

FONTE: O AUTOR

Confrontando com os resultados obtidos na tabela 4.1, observa-se na tabela 4.2 que a amostra $\underline{V2}'$, apesar de ter uma perda média maior que amostra $\underline{V1}'$, possui uma resposta mais satisfatória com relação ao resultado referente à razão-sinal ruído e isto se dá pelo fato da mesma possuir uma menor variabilidade das observações que compõem a amostra.

TABELA 4.2 – RESULTADOS PARA A RAZÃO SINAL-RUÍDO PARA O CASO NTB

CÁLCULOS	$\underline{V1}'$			$\underline{V2}'$		
	B			B		
	10000	20000	30000	10000	20000	30000
$S/N_{tipo I-NTB}$ (dB)	31,2019	31,2019	31,2019	41,0616	41,0616	41,0616
SE_{boot} (dB)	2,9052	2,8816	2,9246	3,0177	3,0733	3,0499

FONTE: O AUTOR

Os resultados referentes às tabelas 4.3, 4.4 e 4.5 demonstram que ambos os processos possuem índices bem altos para a capacidade do processo, e isto se justifica pelo fato das observações, de ambas as amostras, estarem todas dentro dos limites de especificação e por possuírem uma baixa dispersão nos dados da

amostra mestre. Pelos resultados observa-se que a amostra $V1'$ possui o processo centrado e que a amostra $V2'$ não possui o processo centrado para as suas amostras mestre respectivas.

TABELA 4.3 – RESULTADOS PARA O ÍNDICE C_p SINAL-RUÍDO PARA O CASO NTB

CÁLCULOS	$V1'$			$V2'$		
	B			B		
	10000	20000	30000	10000	20000	30000
C_p	3,7463	3,7463	3,7463	6,6667	6,6667	6,6667
SE_{boot}	0,7238	0,7178	0,7326	1,3721	1,3925	1,3816

FONTE: O AUTOR

TABELA 4.4 – RESULTADOS PARA O ÍNDICE C_{pK} SINAL-RUÍDO PARA O CASO NTB

CÁLCULOS	$V1'$			$V2'$		
	B			B		
	10000	20000	30000	10000	20000	30000
C_{pK}	3,7463	3,7463	3,7463	6,0000	6,0000	6,0000
SE_{boot}	0,7014	0,6966	0,7106	1,1809	1,2059	1,1900

FONTE: O AUTOR

TABELA 4.5 – RESULTADOS PARA O ÍNDICE C_{pKM} SINAL-RUÍDO PARA O CASO NTB

CÁLCULOS	$V1'$			$V2'$		
	B			B		
	10000	20000	30000	10000	20000	30000
C_{pKM}	3,7463	3,7463	3,7463	2,9814	2,9814	2,9814
SE_{boot}	0,7238	0,7178	0,7326	0,0891	0,0908	0,0901

FONTE: O AUTOR

De acordo com os resultados, referentes às variabilidades calculadas pelo método *bootstrap*, observa-se que nas tabelas 4.1, 4.2, 4.3, 4.4 e 4.5 existem pequenas variabilidades entre os resultados de SE_{boot} para 10000, 20000 e 30000 amostras *bootstrap* para cada amostra mestre. Assim, conclui-se que 10000

amostras *bootstrap* são suficientes para a estimação dos intervalos de confiança das estatísticas propostas.

4.2.2 Resultados da Variabilidade Para o Caso Menor-é-Melhor

A tabela 4.6 demonstra os resultados referentes a perda média de Taguchi, assim se observa que a amostra mestre M_2 possui uma perda média menor que a amostra mestre M_1 , pois a maioria das suas observações encontram-se mais próximas do valor nominal que nesse caso é igual a zero.

TABELA 4.6 – RESULTADOS PARA A FUNÇÃO PERDA MÉDIA PARA O CASO STB

CÁLCULOS	M_1			M_2		
	B			B		
	10000	20000	30000	10000	20000	30000
$\bar{L}(y)$	13,0000	13,0000	13,0000	4,8889	4,8889	4,8889
SE_{boot}	3,1792	3,1197	3,1556	1,2485	1,2481	1,2425

FONTE: O AUTOR

De acordo com a tabela 4.7 se observa um resultado melhor com relação a razão sinal-ruído para a amostra mestre M_2 , pois a mesma apresenta menor dispersão das suas observações. Sendo assim, para essa característica funcional em questão a amostra M_2 é superior à M_1 .

TABELA 4.7 – RESULTADOS PARA A RAZÃO SINAL-RUÍDO PARA O CASO STB

CÁLCULOS	M_1			M_2		
	B			B		
	10000	20000	30000	10000	20000	30000
S/N (dB)	-13,6922	-13,6922	-13,6922	-9,4448	-9,4448	-9,4448
SE_{boot} (dB)	1,0956	1,0740	1,0918	1,1678	1,1619	1,1554

FONTE: O AUTOR

Pelos resultados obtidos e sintetizados nas tabelas 4.8, 4.9 e 4.10 observa-se, também, uma maior capacidade de processo para a amostra M_2 . Em ambas as amostras mestre o processo não encontra-se centrado nos limites de especificação.

TABELA 4.8 – RESULTADOS PARA O ÍNDICE C_p SINAL-RUÍDO PARA O CASO STB

CÁLCULOS	M_1			M_2		
	B			B		
	10000	20000	30000	10000	20000	30000
C_p	0,7166	0,7166	0,7166	1,1180	1,1180	1,1180
SE_{boot}	0,1152	0,1126	0,1134	0,1649	0,1659	0,1636

FONTE: O AUTOR

TABELA 4.9 – RESULTADOS PARA O ÍNDICE C_{pK} SINAL-RUÍDO PARA O CASO STB

CÁLCULOS	M_1			M_2		
	B			B		
	10000	20000	30000	10000	20000	30000
C_{pK}	0,4777	0,4777	0,4777	0,4472	0,4472	0,4472
SE_{boot}	0,0968	0,0953	0,0965	0,0795	0,0809	0,0798

FONTE: O AUTOR

TABELA 4.10 – RESULTADOS PARA O ÍNDICE C_{pKM} SINAL-RUÍDO PARA O CASO STB

CÁLCULOS	M_1			M_2		
	B			B		
	10000	20000	30000	10000	20000	30000
C_{pKM}	0,5825	0,5825	0,5825	0,4975	0,4975	0,4975
SE_{boot}	0,0547	0,0538	0,0542	0,0119	0,0119	0,0118

FONTE: O AUTOR

De acordo com os resultados, referentes às variabilidades calculadas pelo método *bootstrap*, observa-se que nas tabelas 4.6, 4.7, 4.8, 4.9 e 4.10 existem pequenas variabilidades entre os resultados de SE_{boot} para 10000, 20000 e 30000

amostras *bootstrap*. Assim, conclui-se que 10000 amostras *bootstrap* são suficientes para a estimação dos intervalos de confiança das estatísticas propostas.

4.2.3 Resultados da Variabilidade Para o Caso Maior-é-Melhor

Na tabela 4.11 observa-se que a amostra mestre S_2 possui uma perda média menor que a amostra mestre S_1 , pois observando a amostra, verifica-se que é necessário fazer mais força para separar os itens colados pela fita adesiva da amostra S_2 .

TABELA 4.11 – RESULTADOS PARA A FUNÇÃO PERDA MÉDIA PARA O CASO LTB

CÁLCULOS	S_1			S_2		
	B			B		
	10000	20000	30000	10000	20000	30000
$\bar{L}(y)$	39,9710	39,9710	39,9710	19,9302	19,9302	19,9302
SE_{boot}	8,8955	8,9158	8,8974	2,4688	2,4674	2,4723

FONTE: O AUTOR

Os resultados referentes a razão sinal-ruído, sintetizados na tabela 4.12, demonstra que existe uma menor variabilidade entre as observações da amostra S_1 em relação às observações da amostra S_2 , o que reflete em um menor valor para a razão sinal ruído da mesma em comparação a S_2 .

TABELA 4.12 – RESULTADOS PARA A RAZÃO SINAL-RUÍDO PARA O CASO LTB

CÁLCULOS	S_1			S_2		
	B			B		
	10000	20000	30000	10000	20000	30000
S/N (dB)	16,4129	16,4129	16,4129	19,4353	19,4353	19,4353
SE_{boot} (dB)	1,0241	1,0215	1,0174	0,5401	0,5432	0,5428

FONTE: O AUTOR

De acordo com os resultados, referentes às variabilidades calculadas pelo método *bootstrap*, observa-se que nas tabelas 4.11, e 4.12 existem pequenas variabilidades entre os resultados de SE_{boot} para 10000, 20000 e 30000 amostras *bootstrap* para cada amostra mestre. Assim, conclui-se que 10000 amostras *bootstrap* são suficientes para a estimação dos intervalos de confiança das estatísticas propostas.

4.3 INTERVALOS DE CONFIANÇA

4.3.1 Intervalos de Confiança Para o Caso Nominal-é-Melhor

TABELA 4.13 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA MÉDIA DE TAGUCHI PARA O CASO NTB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,3165	1,1450	0,7589	1,7026
<i>Bootstrap t</i>		0,2763	1,1913	0,7062	1,7553
<i>Bootstrap</i> Percentil		0,3462	1,1731	0,7692	1,7115
<i>Bootstrap</i> BC		0,3654	1,1923	0,7692	1,7115
<i>Bootstrap</i> Bca		0,3846	1,2500	0,7692	1,7115
<i>Bootstrap</i> Padrão	99%	0,1863	1,2762	0,6106	1,8509
<i>Bootstrap t</i>		0,0852	1,3764	0,4954	1,9662
<i>Bootstrap</i> Percentil		0,2500	1,3462	0,6154	1,8173
<i>Bootstrap</i> BC		0,2662	1,3654	0,6154	1,8337
<i>Bootstrap</i> Bca		0,3077	1,4603	0,6154	1,8462
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.14 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA MÉDIA DE TAGUCHI PARA O CASO NTB COM 20000 AMOSTRAS
BOOTSTRAP

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,3195	1,1421	0,7553	1,7063
<i>Bootstrap t</i>		0,2736	1,1880	0,7022	1,7594
<i>Bootstrap</i> Percentil		0,3462	1,1731	0,7500	1,7115
<i>Bootstrap</i> BC		0,3654	1,1923	0,7692	1,7115
<i>Bootstrap</i> Bca		0,3846	1,2308	0,7692	1,7115
<i>Bootstrap</i> Padrão	99%	0,1902	1,2713	0,6058	1,8557
<i>Bootstrap t</i>		0,0898	1,3718	0,4897	1,9718
<i>Bootstrap</i> Percentil		0,2500	1,3173	0,6154	1,8654
<i>Bootstrap</i> BC		0,2692	1,3462	0,6346	1,8654
<i>Bootstrap</i> Bca		0,3077	1,4231	0,6346	1,8654
Vício		Pequeno		Pequeno	

FONTES: O AUTOR

TABELA 4.15 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA MÉDIA DE TAGUCHI PARA O CASO NTB COM 30000 AMOSTRAS
BOOTSTRAP

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,3162	1,1453	0,7557	1,7058
<i>Bootstrap t</i>		0,2699	1,1916	0,7027	1,7589
<i>Bootstrap</i> Percentil		0,3462	1,1731	0,7692	1,7115
<i>Bootstrap</i> BC		0,3654	1,1923	0,7692	1,7115
<i>Bootstrap</i> Bca		0,3846	1,2308	0,7692	1,7115
<i>Bootstrap</i> Padrão	99%	0,1860	1,2756	0,6065	1,8551
<i>Bootstrap t</i>		0,0847	1,3768	0,4904	1,9711
<i>Bootstrap</i> Percentil		0,2500	1,3269	0,6154	1,8462
<i>Bootstrap</i> BC		0,2500	1,3462	0,6346	1,8654
<i>Bootstrap</i> Bca		0,3077	1,4038	0,6346	1,8654
Vício		Pequeno		Pequeno	

FONTES: O AUTOR

Pelos resultados sintetizados nas tabelas 4.13, 4.14 e 4.15, observa-se que se pode utilizar qualquer um dos tipos de intervalos, entre os cinco calculados, para representação do verdadeiro parâmetro da função perda média de Taguchi, pois se

tem o vício pequeno e pela distribuição *bootstrap* da mesma, representadas nos gráficos 4.1, 4.2, 4.3, 4.4, 4.5 e 4.6 verificam-se a proximidade da normalidade .

De acordo com os resultados demonstrados nas tabelas 4.16, 4.17 e 4.18 verifica-se que se podem utilizar os cinco tipos de intervalos de confiança para representação do verdadeiro parâmetro da razão sinal-ruído, pois se tem o vício pequeno e os resultados dos mesmos se encontram muito próximos para os níveis de significâncias propostos.

TABELA 4.16 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO NTB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	25,5077	36,8961	35,1469	46,9762
<i>Bootstrap t</i>		24,8719	37,5319	34,4865	47,6366
<i>Bootstrap</i> Percentil		28,2475	39,5032	38,1055	49,4898
<i>Bootstrap</i> BC		26,0027	35,1086	36,1883	44,5048
<i>Bootstrap</i> Bca		26,9757	36,9127	36,9219	46,5285
<i>Bootstrap</i> Padrão	99%	23,7185	38,6853	33,2884	48,8347
<i>Bootstrap t</i>		22,3277	40,0761	31,8438	50,2793
<i>Bootstrap</i> Percentil		27,0441	42,5774	37,0156	53,5307
<i>Bootstrap</i> BC		24,5200	37,1676	35,8782	46,7060
<i>Bootstrap</i> Bca		26,4432	41,9166	36,3891	52,0063
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.17 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO NTB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	25,5541	36,8497	35,0381	47,0851
<i>Bootstrap t</i>		24,9235	37,4803	34,3655	47,7577
<i>Bootstrap</i> Percentil		28,2243	39,5675	38,1055	49,4898
<i>Bootstrap</i> BC		26,3083	35,1086	36,1425	44,9331
<i>Bootstrap</i> Bca		27,0790	36,9701	36,8938	46,7060
<i>Bootstrap</i> Padrão	99%	23,7794	38,6244	33,1453	48,9778
<i>Bootstrap t</i>		22,4000	40,0038	31,6741	50,4490
<i>Bootstrap</i> Percentil		27,1019	42,6044	36,9338	53,5307
<i>Bootstrap</i> BC		25,6509	37,1676	35,3753	47,3253
<i>Bootstrap</i> Bca		26,5896	42,0707	36,3891	53,1128
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.18 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO NTB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	25,4698	36,9340	35,0937	47,0294
<i>Bootstrap t</i>		24,8298	37,5741	34,4273	47,6958
<i>Bootstrap</i> Percentil		28,2243	39,7976	38,1055	49,4898
<i>Bootstrap</i> BC		26,3462	35,1491	36,1238	44,9331
<i>Bootstrap</i> Bca		27,0790	36,9883	36,9157	46,5404
<i>Bootstrap</i> Padrão	99%	23,6687	38,7352	33,2185	48,9047
<i>Bootstrap t</i>		22,2686	40,1352	31,7609	50,3623
<i>Bootstrap</i> Percentil		27,1019	42,6442	36,9338	53,5307
<i>Bootstrap</i> BC		25,2949	37,3222	35,3674	46,7533
<i>Bootstrap</i> Bca		26,5909	42,1464	36,3891	53,1128
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

O resultado referente ao valor do índice C_p para as B amostras *bootstrap*, possui um vício grande, conforme sintetizado nos resultados das tabelas 4.19, 4.20 e 4.21, portanto, neste caso, recomenda-se utilizar os intervalos de confiança Bc e Bca para representação do verdadeiro parâmetro em questão.

TABELA 4.19 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO
NTB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap Padrão</i>	95%	2,3276	5,1651	3,9774	9,3559
<i>Bootstrap t</i>		2,1692	5,3235	3,6772	9,6562
<i>Bootstrap Percentil</i>		3,0405	5,8298	5,3974	10,4083
<i>Bootstrap BC</i>		2,8299	5,0488	5,1247	9,1953
<i>Bootstrap Bca</i>		2,9513	5,4904	5,2874	10,2494
<i>Bootstrap Padrão</i>	99%	1,8818	5,6108	3,1324	10,2009
<i>Bootstrap t</i>		1,5353	5,9574	2,4756	10,8577
<i>Bootstrap Percentil</i>		2,8312	6,9389	5,0674	13,1656
<i>Bootstrap BC</i>		2,6671	5,8298	4,8896	10,5749
<i>Bootstrap Bca</i>		2,8069	6,9876	5,0674	13,5076
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.20 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO
NTB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap Padrão</i>	95%	2,3394	5,1533	3,9238	9,4096
<i>Bootstrap t</i>		2,1823	5,3104	3,6175	9,7158
<i>Bootstrap Percentil</i>		3,0324	5,8298	5,3974	5,3974
<i>Bootstrap BC</i>		2,8493	5,0488	5,1247	9,4281
<i>Bootstrap Bca</i>		2,9550	5,4904	5,2874	10,2494
<i>Bootstrap Padrão</i>	99%	1,8973	5,5954	3,0619	10,2715
<i>Bootstrap t</i>		1,5537	5,9390	2,3919	10,9414
<i>Bootstrap Percentil</i>		2,8427	6,9389	5,0488	13,1656
<i>Bootstrap BC</i>		2,7057	5,9175	4,8398	10,5749
<i>Bootstrap Bca</i>		2,8361	7,0373	5,0674	13,8778
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.21 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO NTB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	2,3104	5,1822	3,9587	9,3746
<i>Bootstrap t</i>		2,1501	5,3426	3,6564	9,6769
<i>Bootstrap</i> Percentil		3,0324	5,9175	5,3974	10,4083
<i>Bootstrap</i> BC		2,8594	5,0674	5,1247	9,1953
<i>Bootstrap</i> Bca		2,9550	5,5635	5,2874	10,2494
<i>Bootstrap</i> Padrão	99%	1,8593	5,6334	3,1079	10,2255
<i>Bootstrap t</i>		1,5085	5,9841	2,4465	2,4465
<i>Bootstrap</i> Percentil		2,8427	6,9876	5,0488	13,1656
<i>Bootstrap</i> BC		2,7154	5,9476	4,8398	10,5749
<i>Bootstrap</i> Bca		2,8359	7,1931	5,0674	13,8778
Vício		Grande		Grande	

FONTE: O AUTOR

O resultado referente ao valor do índice C_{pk} para as B amostras *bootstrap*, possui um vício grande, conforme sintetizado nos resultado das tabelas 4.22, 4.23 e 4.24, portanto, neste caso, recomenda-se utilizar os intervalos de confiança Bc e Bca para representação do verdadeiro parâmetro em questão.

TABELA 4.22 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pk} PARA O CASO NTB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	2,3716	5,1211	3,6855	8,3145
<i>Bootstrap t</i>		2,2181	5,2746	3,4271	8,5729
<i>Bootstrap</i> Percentil		2,9895	5,6528	4,8990	9,3275
<i>Bootstrap</i> BC		2,8519	5,1641	4,6387	8,1252
<i>Bootstrap</i> Bca		3,0125	6,1778	4,8611	9,3275
<i>Bootstrap</i> Padrão	99%	1,9396	5,5530	2,9582	9,0418
<i>Bootstrap t</i>		1,6039	5,8888	2,3929	9,6071
<i>Bootstrap</i> Percentil		2,7824	6,7322	4,6437	11,4440
<i>Bootstrap</i> BC		2,6634	5,9552	4,4313	9,3275
<i>Bootstrap</i> Bca		2,9002	7,4077	4,6714	13,0974
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.23 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pk} PARA O CASO NTB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	2,3811	5,1116	3,6365	8,3635
<i>Bootstrap t</i>		2,2286	5,2641	3,3726	8,6274
<i>Bootstrap</i> Percentil		2,9823	5,6563	4,8990	9,3275
<i>Bootstrap</i> BC		2,8701	5,1711	4,6387	8,1696
<i>Bootstrap</i> Bca		3,0171	6,1931	4,8611	9,3547
<i>Bootstrap</i> Padrão	99%	1,9521	5,5406	2,8938	9,1062
<i>Bootstrap t</i>		1,6186	5,8741	2,3165	9,6835
<i>Bootstrap</i> Percentil		2,8033	6,7288	4,6265	11,4440
<i>Bootstrap</i> BC		2,7115	6,0461	4,4233	9,3275
<i>Bootstrap</i> Bca		2,9082	8,6328	4,6476	13,8575
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.24 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pk} PARA O CASO NTB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	2,3536	5,1390	3,6676	8,3324
<i>Bootstrap t</i>		2,1981	5,2946	3,4072	8,5928
<i>Bootstrap</i> Percentil		2,9823	5,7582	4,8990	9,3275
<i>Bootstrap</i> BC		2,8715	5,2486	4,6387	8,1696
<i>Bootstrap</i> Bca		3,0238	6,2634	4,8604	9,3275
<i>Bootstrap</i> Padrão	99%	1,9160	5,5767	2,9348	9,0652
<i>Bootstrap t</i>		1,5759	5,9168	2,3651	9,6349
<i>Bootstrap</i> Percentil		2,8033	6,7721	4,6387	11,4440
<i>Bootstrap</i> BC		2,7184	6,1898	4,4191	9,3275
<i>Bootstrap</i> Bca		2,9168	9,6154	4,6476	13,0974
Vício		Grande		Grande	

FONTE: O AUTOR

O resultado referente ao valor do índice C_{pkm} para as B amostras *bootstrap*, possui um vício grande, conforme sintetizado nos resultados das tabelas 4.25, 4.26 e 4.27, portanto, neste caso, recomenda-se utilizar os intervalos de confiança Bc e Bca para representação do verdadeiro parâmetro em questão.

TABELA 4.25 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO NTB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	2,3726	5,1651	2,8068	3,1561
<i>Bootstrap t</i>		2,1692	5,3225	2,8204	3,1658
<i>Bootstrap</i> Percentil		3,0405	5,8298	2,8361	3,1745
<i>Bootstrap</i> BC		2,8299	5,0488	2,7942	3,1791
<i>Bootstrap</i> Bca		2,9738	5,6138	2,8198	3,1653
<i>Bootstrap</i> Padrão	99%	1,8818	5,6108	2,7519	3,2109
<i>Bootstrap t</i>		1,5353	5,9574	2,6496	3,3210
<i>Bootstrap</i> Percentil		2,8312	6,9389	2,7849	3,2314
<i>Bootstrap</i> BC		2,6671	5,8298	2,7542	3,1791
<i>Bootstrap</i> Bca		2,8493	7,6420	2,7849	3,2314
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.26 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO NTB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	2,3394	5,1533	2,8034	3,1594
<i>Bootstrap t</i>		2,1823	5,3104	2,8018	3,1576
<i>Bootstrap</i> Percentil		3,0324	5,8298	2,8373	3,1724
<i>Bootstrap</i> BC		2,8493	5,0488	2,7942	3,1427
<i>Bootstrap</i> Bca		2,9814	5,6395	2,8198	3,1699
<i>Bootstrap</i> Padrão	99%	1,8973	5,5954	2,7475	3,2154
<i>Bootstrap t</i>		1,5537	5,9390	2,6445	3,3278
<i>Bootstrap</i> Percentil		2,8427	6,9389	2,7817	3,2314
<i>Bootstrap</i> BC		2,7057	5,9175	2,7452	3,1791
<i>Bootstrap</i> Bca		2,8628	7,6653	2,7817	3,2362
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.27 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO NTB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	V1		V2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	2,3104	5,1822	2,8049	3,1580
<i>Bootstrap t</i>		2,1501	5,3426	2,8049	3,1580
<i>Bootstrap</i> Percentil		3,0324	5,9175	2,8361	3,1745
<i>Bootstrap</i> BC		2,8594	5,0674	2,7942	3,1338
<i>Bootstrap</i> Bca		2,9738	5,7188	2,8165	3,1699
<i>Bootstrap</i> Padrão	99%	1,8593	5,6334	2,7494	3,2134
<i>Bootstrap t</i>		1,5085	5,9841	2,6496	3,3210
<i>Bootstrap</i> Percentil		2,8427	6,9876	2,7817	3,2314
<i>Bootstrap</i> BC		2,7154	5,9476	2,7452	3,1791
<i>Bootstrap</i> Bca		2,8628	7,7311	2,7817	3,2314
Vício		Grande		Grande	

FONTE: O AUTOR

4.3.2 Intervalos de Confiança Para o Caso Menor-é-Melhor

TABELA 4.28 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO STB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	6,7688	19,2312	2,4418	7,3359
<i>Bootstrap t</i>		6,3458	19,6542	2,2757	7,5021
<i>Bootstrap</i> Percentil		7,3750	19,6944	2,6111	7,4444
<i>Bootstrap</i> BC		7,6389	20,1389	2,6994	7,6111
<i>Bootstrap</i> Bca		8,0278	21,1289	2,8889	7,8889
<i>Bootstrap</i> Padrão	99%	4,8108	21,1892	1,6729	8,1048
<i>Bootstrap t</i>		3,9044	22,0956	1,3170	8,4608
<i>Bootstrap</i> Percentil		6,0000	22,3333	2,0556	8,3889
<i>Bootstrap</i> BC		6,2212	22,8282	2,1206	8,5565
<i>Bootstrap</i> Bca		6,8101	24,6674	2,3611	9,1030
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.29 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO STB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	6,8856	19,1144	2,4426	7,3352
<i>Bootstrap t</i>		6,4705	19,5295	2,2765	7,5012
<i>Bootstrap</i> Percentil		7,4444	19,5556	2,6389	7,5278
<i>Bootstrap</i> BC		7,7500	20,1389	2,7222	7,6389
<i>Bootstrap</i> Bca		8,1944	21,0556	2,8889	7,9167
<i>Bootstrap</i> Padrão	99%	4,9643	21,0357	1,6739	8,1038
<i>Bootstrap t</i>		4,0748	21,9252	1,3181	8,4597
<i>Bootstrap</i> Percentil		6,0833	22,0556	2,0556	8,3889
<i>Bootstrap</i> BC		6,3889	22,5278	2,1389	8,5000
<i>Bootstrap</i> Bca		7,0000	24,4787	2,3889	8,9444
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.30 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO STB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	6,8150	19,1850	2,4536	7,3242
<i>Bootstrap t</i>		6,3951	19,6049	2,2882	7,4895
<i>Bootstrap</i> Percentil		7,3333	19,6389	2,6389	2,6389
<i>Bootstrap</i> BC		7,6111	20,1111	2,7778	2,7778
<i>Bootstrap</i> Bca		8,0278	8,0278	2,9444	7,9722
<i>Bootstrap</i> Padrão	99%	4,8716	21,1284	1,6883	8,0894
<i>Bootstrap t</i>		3,9719	22,0281	1,3341	8,4437
<i>Bootstrap</i> Percentil		6,0000	21,8056	2,0556	8,3611
<i>Bootstrap</i> BC		6,2222	22,2778	2,1944	2,1944
<i>Bootstrap</i> Bca		6,8056	23,9783	2,4444	9,3325
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

Pelos resultados sintetizados nas tabelas 4.28, 4.29 e 4.30, observa-se que se pode utilizar qualquer um dos tipos de intervalos, entre os cinco calculados, para representação do verdadeiro parâmetro da função perda média de Taguchi, pois se

tem o vício pequeno e pela distribuição *bootstrap* da mesma, representadas nos gráficos 4.7, 4.8, 4.9, 4.10, 4.11 e 4.12 verificam-se a proximidade da normalidade .

De acordo com os resultados demonstrados nas tabelas 4.31, 4.32 e 4.33 se verifica a utilização dos cinco tipos de intervalos de confiança para representação do verdadeiro parâmetro da razão sinal-ruído, pois se tem o vício pequeno e pela distribuição *bootstrap* da mesma, representadas nos gráficos 4.7, 4.8, 4.9, 4.10, 4.11 e 4.12 verificam-se a proximidade da normalidade.

TABELA 4.31 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO STB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	-15,8395	-11,5448	-11,7336	-7,1560
<i>Bootstrap t</i>		-15,9852	-11,3991	-11,8890	-7,0006
<i>Bootstrap</i> Percentil		-15,4962	-11,2303	-11,2710	-6,7210
<i>Bootstrap</i> BC		-15,5751	-11,3513	-11,3327	-6,8124
<i>Bootstrap</i> Bca		-15,8320	-11,6286	-11,5076	-7,1181
<i>Bootstrap</i> Padrão	99%	-16,5142	-10,8701	-12,4528	-6,4368
<i>Bootstrap t</i>		-16,8266	-10,5578	-12,7858	-6,1039
<i>Bootstrap</i> Percentil		-16,0423	-10,3342	-11,7898	-5,6820
<i>Bootstrap</i> BC		-16,1172	-10,4336	-11,8611	-5,7978
<i>Bootstrap</i> Bca		-16,5114	-10,9661	-12,1447	-6,2325
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.32 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO STB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	-15,7972	-11,5871	-11,7221	-7,1675
<i>Bootstrap t</i>		-15,9401	-11,4442	-11,8767	-7,0129
<i>Bootstrap</i> Percentil		-15,4654	-11,2710	-11,3194	-6,7669
<i>Bootstrap</i> BC		-15,5811	-15,5811	-11,3513	-6,8574
<i>Bootstrap</i> Bca		-15,8149	-11,7026	-11,5229	-6,4520
<i>Bootstrap</i> Padrão	99%	-16,4586	-10,9257	-12,4377	-6,3247
<i>Bootstrap t</i>		-16,7648	-10,6195	-12,7690	-6,1207
<i>Bootstrap</i> Percentil		-15,9879	-10,3941	-11,7898	-5,6820
<i>Bootstrap</i> BC		-16,0746	-10,5936	-11,8184	-5,7978
<i>Bootstrap</i> Bca		-16,4947	-11,0551	-12,0674	-6,3347
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.33 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO STB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	-15,8320	-11,5523	-11,7093	-7,1803
<i>Bootstrap t</i>		-15,9773	-11,4070	-12,4209	-7,0266
<i>Bootstrap</i> Percentil		-15,4839	-11,2057	-11,2791	-6,7669
<i>Bootstrap</i> BC		-15,5691	-11,3354	-11,3672	-6,9461
<i>Bootstrap</i> Bca		-15,7749	-15,7749	-11,5534	-7,2016
<i>Bootstrap</i> Padrão	99%	-16,5044	-10,8799	-12,4209	-6,2016
<i>Bootstrap t</i>		-16,8157	-10,5686	-12,7503	-6,1394
<i>Bootstrap</i> Percentil		-15,9384	-10,3342	-11,7754	-5,8554
<i>Bootstrap</i> BC		-16,0105	-10,4727	-11,8752	-5,8546
<i>Bootstrap</i> Bca		-16,4139	-10,9342	-12,2389	-6,7746
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

O resultado referente ao valor do índice C_p para as B amostras *bootstrap*, possui um vício grande, conforme sintetizado nos resultado das tabelas 4.34, 4.35 e 4.36, portanto, neste caso, recomenda-se utilizar o intervalo de confiança Bca para

representação do verdadeiro parâmetro em questão, pois de acordo com distribuição *bootstrap* do mesmo, verifica-se uma certa assimetria, que pode ser visualizada nos gráficos 4.7, 4.8, 4.9, 4.10, 4.11 e 4.12.

O resultado referente ao valor do índice C_{pk} possui um vício grande para as B amostras referentes a M1 e um vício pequeno para as B amostras referentes a M2, conforme sintetizado nos resultado das tabelas 4.37, 4.38 e 4.39. Apesar das amostras *bootstrap* em M2 apresentarem um vício pequeno, neste caso, recomenda-se, ainda assim a utilização do intervalo de confiança Bca para representação do verdadeiro parâmetro em questão, pois de acordo com as distribuições *bootstrap* do mesmo, verifica-se uma assimetria, que pode ser visualizada nos gráficos 4.7, 4.8, 4.9, 4.10, 4.11 e 4.12.

TABELA 4.34 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO STB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,4907	0,9425	0,7948	1,4413
<i>Bootstrap t</i>		0,4754	0,9578	0,7728	1,4632
<i>Bootstrap</i> Percentil		0,5840	1,0350	0,9306	1,5670
<i>Bootstrap</i> BC		0,5548	0,9371	0,8966	1,4420
<i>Bootstrap</i> Bca		0,5796	1,0379	0,9251	1,5670
<i>Bootstrap</i> Padrão	99%	0,4197	1,0135	0,6932	1,5429
<i>Bootstrap t</i>		0,3869	1,0463	0,6462	1,5899
<i>Bootstrap</i> Percentil		0,5502	1,1803	0,8854	1,8099
<i>Bootstrap</i> BC		0,5261	1,0654	0,8582	1,6245
<i>Bootstrap</i> Bca		0,5552	1,3264	0,8947	2,0026
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.35 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO STB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,4958	0,9374	0,7928	1,4433
<i>Bootstrap t</i>		0,4809	0,9523	0,7707	1,4653
<i>Bootstrap</i> Percentil		0,5867	1,0217	0,9349	1,5708
<i>Bootstrap</i> BC		0,5584	0,9357	0,8947	1,4420
<i>Bootstrap</i> Bca		0,5818	1,0260	0,9246	1,5658
<i>Bootstrap</i> Padrão	99%	0,4265	1,0067	0,6906	0,6906
<i>Bootstrap t</i>		0,3944	1,0388	0,6433	0,6433
<i>Bootstrap</i> Percentil		0,5511	1,1552	0,8854	1,8198
<i>Bootstrap</i> BC		0,5264	1,051	0,8558	1,6245
<i>Bootstrap</i> Bca		0,5600	1,2889	0,8935	1,9617
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.36 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_p PARA O CASO STB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,4943	0,9389	0,7974	1,4387
<i>Bootstrap t</i>		0,4792	0,9540	0,7756	1,4604
<i>Bootstrap</i> Percentil		0,5839	1,0207	0,9349	1,5670
<i>Bootstrap</i> BC		0,5581	0,9371	0,9030	1,4420
<i>Bootstrap</i> Bca		0,5796	1,0235	0,9264	1,5658
<i>Bootstrap</i> Padrão	99%	0,4245	1,0087	0,6966	1,5394
<i>Bootstrap t</i>		0,3921	1,0411	0,6500	1,5861
<i>Bootstrap</i> Percentil		0,5503	1,1593	0,8872	1,7721
<i>Bootstrap</i> BC		0,5231	1,0480	0,8526	1,6203
<i>Bootstrap</i> Bca		0,5591	1,3009	0,8982	1,9786
Vício		Grande		Grande	

FONTE: O AUTOR

TABELA 4.37 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pK} PARA O CASO STB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,2880	0,6675	0,2915	0,6030
<i>Bootstrap t</i>		0,2751	0,6804	0,2809	0,6136
<i>Bootstrap</i> Percentil		0,3477	0,7250	0,3346	0,6470
<i>Bootstrap</i> BC		0,3301	0,6748	0,3188	0,6141
<i>Bootstrap</i> Bca		0,3125	0,6500	0,3057	0,5937
<i>Bootstrap</i> Padrão	99%	0,2283	0,7271	0,2425	0,6519
<i>Bootstrap t</i>		0,2007	0,7547	0,2198	0,6746
<i>Bootstrap</i> Percentil		0,3125	0,8543	0,2994	0,7252
<i>Bootstrap</i> BC		0,2953	0,7800	0,2872	0,6871
<i>Bootstrap</i> Bca		0,2610	0,7200	0,2658	0,6533
Vício		Grande		Pequeno	

FONTE: O AUTOR

TABELA 4.38 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pK} PARA O CASO STB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,2910	0,6645	0,2887	0,6058
<i>Bootstrap t</i>		0,2783	0,6772	0,2779	0,2779
<i>Bootstrap</i> Percentil		0,3505	0,7258	0,3343	0,6517
<i>Bootstrap</i> BC		0,3331	0,6767	0,3150	0,6095
<i>Bootstrap</i> Bca		0,3189	0,6498	0,3039	0,5932
<i>Bootstrap</i> Padrão	99%	0,2323	0,7232	0,2388	0,6556
<i>Bootstrap t</i>		0,2051	0,7504	0,2158	0,6787
<i>Bootstrap</i> Percentil		0,3175	0,8275	0,3009	0,7312
<i>Bootstrap</i> BC		0,2998	0,7749	0,2854	0,6857
<i>Bootstrap</i> Bca		0,2760	0,7232	0,2662	0,6521
Vício		Grande		Pequeno	

FONTE: O AUTOR

TABELA 4.39 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pk} PARA O CASO STB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,2887	0,6668	0,2907	0,6037
<i>Bootstrap t</i>		0,2758	0,2758	0,2801	0,6143
<i>Bootstrap</i> Percentil		0,3490	0,7234	0,3343	0,6498
<i>Bootstrap</i> BC		0,3292	0,6776	0,3189	0,6148
<i>Bootstrap</i> Bca		0,3128	0,6509	0,3072	0,5943
<i>Bootstrap</i> Padrão	99%	0,2293	0,7262	0,2416	0,6528
<i>Bootstrap t</i>		0,2018	0,7537	0,2188	0,6756
<i>Bootstrap</i> Percentil		0,3107	0,8280	0,3016	0,7265
<i>Bootstrap</i> BC		0,2937	0,7748	0,2881	0,6888
<i>Bootstrap</i> Bca		0,2692	0,2692	0,2708	0,6524
Vício		Grande		Pequeno	

FONTE: O AUTOR

O resultado referente ao valor do índice C_{pk} possui um vício grande para as B amostras referentes a M1 e um vício pequeno para as B amostras referentes a M2, conforme sintetizado nos resultado das tabelas 4.40, 4.41 e 4.42. Apesar das amostras *bootstrap* em M2 apresentar um vício pequeno, neste caso, recomenda-se, ainda assim a utilização do intervalo de confiança Bca para representação do verdadeiro parâmetro em questão, pois de acordo com as distribuições *bootstrap* do mesmo, verifica-se uma assimetria, que pode ser visualizada nos gráficos 4.7, 4.8, 4.9, 4.10, 4.11 e 4.12.

TABELA 4.40 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO STB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,4753	0,6896	0,4743	0,5208
<i>Bootstrap t</i>		0,3413	0,8237	0,4893	0,5309
<i>Bootstrap</i> Percentil		0,5043	0,7192	0,4770	0,5236
<i>Bootstrap</i> BC		0,4851	0,6838	0,4722	0,5184
<i>Bootstrap</i> Bca		0,5033	0,7251	0,4767	0,5243
<i>Bootstrap</i> Padrão	99%	0,4416	0,7233	0,4670	0,5281
<i>Bootstrap t</i>		0,2528	0,9122	0,4781	0,5488
<i>Bootstrap</i> Percentil		0,4820	0,7630	0,4706	0,5311
<i>Bootstrap</i> BC		0,4656	0,7291	0,4664	0,5257
<i>Bootstrap</i> Bca		0,4875	0,8142	0,4722	0,5365
Vício		Grande		Pequeno	

FONTE: O AUTOR

TABELA 4.41 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pKm} PARA O CASO STB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,4770	0,6880	0,4743	0,5208
<i>Bootstrap t</i>		0,4721	0,9565	0,4677	0,5341
<i>Bootstrap</i> Percentil		0,5060	0,7147	0,4776	0,5238
<i>Bootstrap</i> BC		0,4875	0,6832	0,4721	0,5187
<i>Bootstrap</i> Bca		0,5043	0,7213	0,4767	0,5240
<i>Bootstrap</i> Padrão	99%	0,4438	0,7212	0,4670	0,5281
<i>Bootstrap t</i>		0,3927	1,0418	0,4790	0,5485
<i>Bootstrap</i> Percentil		0,4826	0,7561	0,4706	0,5313
<i>Bootstrap</i> BC		0,4658	0,7245	0,4660	0,5257
<i>Bootstrap</i> Bca		0,4905	0,8017	0,4721	0,5353
Vício		Grande		Pequeno	

FONTE: O AUTOR

TABELA 4.42 – INTERVALOS DE CONFIANÇA PARA O ÍNDICE C_{pkm} PARA O CASO STB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	M1		M2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	0,4762	0,6888	0,4743	0,5207
<i>Bootstrap t</i>		0,3451	0,8199	0,4868	0,5321
<i>Bootstrap</i> Percentil		0,5042	0,5042	0,4776	0,5236
<i>Bootstrap</i> BC		0,4873	0,6838	0,4732	0,5184
<i>Bootstrap</i> Bca		0,5025	0,7192	0,4770	0,5240
<i>Bootstrap</i> Padrão	99%	0,4428	0,7222	0,4670	0,5280
<i>Bootstrap t</i>		0,2580	0,9070	0,4745	0,5414
<i>Bootstrap</i> Percentil		0,4821	0,7572	0,4709	0,4709
<i>Bootstrap</i> BC		0,4635	0,4635	0,4656	0,5255
<i>Bootstrap</i> Bca		0,4897	0,8007	0,4734	0,5355
Vício		Grande		Pequeno	

FONTE: O AUTOR

4.3.3 Intervalos de Confiança Para o Caso Maior-é-Melhor

TABELA 4.43 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO LTB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	S1		S2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	22,5361	57,4059	15,2658	24,6594
<i>Bootstrap t</i>		21,0107	58,9314	14,6250	25,4861
<i>Bootstrap</i> Percentil		23,1158	57,5103	15,2687	24,2547
<i>Bootstrap</i> BC		23,3820	57,8744	15,3268	24,2654
<i>Bootstrap</i> Bca		24,0609	58,6694	15,5248	25,2456
<i>Bootstrap</i> Padrão	99%	17,0577	62,8843	13,5147	26,2987
<i>Bootstrap t</i>		13,7585	66,1835	12,6598	27,2051
<i>Bootstrap</i> Percentil		18,2525	63,3114	14,0354	26,4698
<i>Bootstrap</i> BC		18,5561	63,7305	14,1258	26,4698
<i>Bootstrap</i> Bca		19,5717	65,5701	14,4258	27,1687
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.44 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO LTB COM 20000 AMOSTRAS BOOTSTRAP

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	S1		S2	
		LI	LS	LI	LS
<i>Bootstrap Padrão</i>	95%	22,4943	57,4477	15,0942	24,7663
<i>Bootstrap t</i>		20,9652	58,9768	14,6710	25,1895
<i>Bootstrap Percentil</i>		23,0760	57,9592	15,2711	24,8723
<i>Bootstrap BC</i>		23,3447	58,2451	15,3786	24,9742
<i>Bootstrap Bca</i>		23,8292	59,0334	15,5692	25,2157
<i>Bootstrap Padrão</i>	99%	17,0027	62,9393	13,5745	26,2859
<i>Bootstrap t</i>		13,6956	66,2464	12,6594	27,2011
<i>Bootstrap Percentil</i>		18,5677	63,5834	14,0306	26,4676
<i>Bootstrap BC</i>		18,7914	63,793	14,1268	26,6041
<i>Bootstrap Bca</i>		19,5526	64,8467	14,4169	27,1960
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.45 – INTERVALOS DE CONFIANÇA PARA A FUNÇÃO PERDA DE TAGUCHI PARA O CASO LTB COM 30000 AMOSTRAS BOOTSTRAP

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	S1		S2	
		LI	LS	LI	LS
<i>Bootstrap Padrão</i>	95%	22,5325	57,4095	15,0846	24,7759
<i>Bootstrap t</i>		21,0067	58,9353	14,6606	25,1999
<i>Bootstrap Percentil</i>		23,0908	23,0908	15,3311	24,9489
<i>Bootstrap BC</i>		23,4600	58,5232	15,4078	25,0304
<i>Bootstrap Bca</i>		24,0346	59,2425	15,5794	25,2806
<i>Bootstrap Padrão</i>	99%	17,0529	17,0529	13,5620	26,2985
<i>Bootstrap t</i>		13,7530	66,1890	12,6450	27,2154
<i>Bootstrap Percentil</i>		18,5681	63,9805	14,0577	26,5893
<i>Bootstrap BC</i>		18,8368	64,4216	14,1384	26,6575
<i>Bootstrap Bca</i>		19,7674	65,3512	14,4334	27,2046
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

Pelos resultados sintetizados nas tabelas 4.43, 4.44 e 4.45, observa-se que se pode utilizar qualquer um dos tipos de intervalos, entre os cinco calculados, para

representação do verdadeiro parâmetro da função perda média de Taguchi, pois se tem o vício pequeno e pelas distribuições *bootstrap* da mesma, representadas nos gráficos 4.13, 4.14, 4.15, 4.16, 4.17 e 4.18 verificam-se a proximidade da normalidade.

TABELA 4.46 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO LTB COM 10000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	S1		S2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	14,4057	18,4201	18,3268	20,5484
<i>Bootstrap t</i>		14,2301	18,5958	18,2758	20,5987
<i>Bootstrap</i> Percentil		14,8329	18,7913	18,4752	20,5487
<i>Bootstrap</i> BC		14,8055	18,7416	18,4587	20,5687
<i>Bootstrap</i> Bca		15,0249	19,5156	18,6148	20,9425
<i>Bootstrap</i> Padrão	99%	18,4201	19,0509	18,0365	20,8423
<i>Bootstrap t</i>		13,3952	19,4307	17,8654	21,0215
<i>Bootstrap</i> Percentil		14,4156	19,8172	18,2014	20,9587
<i>Bootstrap</i> BC		14,3869	19,7455	18,1827	20,9812
<i>Bootstrap</i> Bca		14,7585	22,0778	18,4504	21,5478
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.47 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO LTB COM 20000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	S1		S2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	14,4107	18,4151	18,3705	20,5000
<i>Bootstrap t</i>		14,2356	18,5903	18,2774	20,5931
<i>Bootstrap</i> Percentil		14,7992	18,7988	18,4732	20,5917
<i>Bootstrap</i> BC		14,7778	18,7485	18,4555	20,5612
<i>Bootstrap</i> Bca		15,0131	19,5206	18,6197	20,9236
<i>Bootstrap</i> Padrão	99%	13,7816	19,0443	18,0360	20,8345
<i>Bootstrap t</i>		13,4027	19,4231	17,8345	21,0360
<i>Bootstrap</i> Percentil		14,3969	19,7428	18,2032	20,9596
<i>Bootstrap</i> BC		14,3827	19,6908	18,1809	20,9299
<i>Bootstrap</i> Bca		14,7281	21,5035	18,4546	21,5318
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

TABELA 4.48 – INTERVALOS DE CONFIANÇA PARA A RAZÃO SINAL-RUÍDO PARA O CASO LTB COM 30000 AMOSTRAS *BOOTSTRAP*

TIPOS DE INTERVALOS DE CONFIANÇA	NÍVEL DE CONFIANÇA	S1		S2	
		LI	LS	LI	LS
<i>Bootstrap</i> Padrão	95%	14,4189	18,4070	18,3714	20,4991
<i>Bootstrap t</i>		14,2444	14,2444	18,2784	20,5921
<i>Bootstrap</i> Percentil		13,4149	18,7960	18,4599	20,5746
<i>Bootstrap</i> BC		14,7571	18,7271	18,4457	20,5530
<i>Bootstrap</i> Bca		15,0117	19,4729	18,6164	20,9171
<i>Bootstrap</i> Padrão	99%	13,7923	19,0336	18,0372	20,8333
<i>Bootstrap t</i>		13,4149	13,4149	17,8359	21,0346
<i>Bootstrap</i> Percentil		14,3699	19,7427	18,1833	20,9512
<i>Bootstrap</i> BC		14,3401	19,6803	18,1722	20,9264
<i>Bootstrap</i> Bca		14,7119	21,3781	18,4444	21,5791
Vício		Pequeno		Pequeno	

FONTE: O AUTOR

De acordo com os resultados demonstrados nas tabelas 4.46, 4.47 e 4.48 se verifica a utilização dos cinco tipos de intervalos de confiança para representação do verdadeiro parâmetro da razão sinal-ruído, pois se tem o vício pequeno e pelas distribuições *bootstrap* da mesma, representadas nos gráficos 4.13, 4.14, 4.15, 4.16, 4.17 e 4.18 verificam-se a proximidade da normalidade.

5 CONSIDERAÇÕES FINAIS

Os métodos empregados se mostraram eficientes para os cálculos propostos nos objetivos desta presente tese. Calculou-se a variabilidade existente entre as *B* amostras *bootstrap* para o resultado de cada um dos indicadores de qualidades, aqui denominados de função perda de Taguchi, razão sinal-ruído e índices C_p , C_{pk} e C_{pkm} .

Foi verificado que 10000 amostras *bootstrap* seriam suficientes para estimação dos intervalos de confiança, visto que o valor de SE_{boot} (erro padrão *bootstrap*) varia minimamente de 10000 para 20000 e para 30000 amostras *bootstrap*. Pelo algoritmo desenvolvido visualizou-se a distribuição de cada um dos indicadores, onde algumas das distribuições plotadas apresentaram, visualmente, uma forma muito próxima da distribuição Normal e outras apresentaram uma certa assimetria. Tais observações foram essenciais na decisão da utilização ou não de um determinado tipo de intervalo de confiança dentre os propostos.

Em seguida se calculou os intervalos de confiança, para os níveis de confiança de 95 e 99%, e confirmou-se a versatilidade e consistência do método de reamostragem *bootstrap* para estimação dos intervalos desses indicadores de qualidade, visto que não se emprega método analítico para o cálculo dos mesmos, mais especificamente ainda para a função perda média de Taguchi e para a razão sinal-ruído. O algoritmo desenvolvido no *software* Matlab se mostrou eficiente para os três tipos de características funcionais existentes e eficaz no cumprimento dos objetivos propostos, podendo ser utilizado como uma ferramenta de análise e comparação de propostas na área de engenharia da qualidade.

As amostras, para os três tipos de características funcionais conhecidas, foram retiradas de bibliografias conhecidas na área de engenharia de qualidade pela dificuldade encontrada em se estimar a perda para o cliente, visto que o mesmo é composto de custos diretos e indiretos, portanto subjetivos. Neste caso, entra em ação a experiência de dirigentes para estimação desses custos subjetivos, ficando como sugestão, a aplicação do algoritmo desenvolvido em um caso prático, onde se consiga estimar essa perda do cliente e conseqüente coeficiente de perda de qualidade utilizado nas funções perda de Taguchi.

REFERÊNCIAS

ALMEIDA, H. S. de; TOLEDO, J. C. de. **Método Taguchi: qualidade voltada para o projeto do produto e do processo**. Revista de administração. São Paulo, 1989.

ALVES, E. J.; LOIBEL, S. **Comparação entre intervalos de confiança calculados com métodos bootstrap e intervalos assintóticos**. CMAC Sudeste 2013. UNESP/SP, 2013. [Online; acesso em 20-janeiro-2015]. Disponível em: > <http://www.sbmac.org.br/cmacs/cmac-se/2013/trabalhos/PDF/4338.pdf>.

ANDREWS, D. W. K.; BUCHINSKY, M. **On the number of bootstrap repetitions for BCa confidence intervals**. Econometric Theory. v.18, n.4, 2002.

BABU, G. J. **Jackknife e Bootstrap**. Summer School in Statistics for Astronomers VII (2011): 109 [Online; acesso em 15-setembro-2014]. Disponível em: > http://www.iiap.res.in/astrostat/School10/LecFiles/JBabu_JackknifeBootstrap_notes.pdf.

BARRETO, M. C. M.; CESÁRIO, L. C. **Um estudo sobre o desempenho de intervalos de confiança *bootstrap* para a média de uma distribuição normal usando amostragem por conjuntos ordenados perfeitamente**. Rev. Mat. Estat. São Paulo, 2003. [Online; acesso em 15-fevereiro-2015]. Disponível em: > http://jaguar.fcav.unesp.br/RME/fasciculos/v21/v21_n3/A1_Luciana.pdf.

BENDELL, T. **Taguchi Methods: proceedings of the 1988 European conference**. London: Elsevier Science Publishers LTD, 1988.

BENNETT, P. J. **Introduction to the bootstrap and robust statistics**. 2009. [Online; acesso em 06-Junho-2014]. Disponível em: > <http://www.psychology.mcmaster.ca/bennett/boot09/rt2.pdf>.

BUCHE, D. D.; GLOVER, J. A. **Teaching Students to Review Research as an Aid for Problem-Solving.** *Handbook For Teaching Statistics and Research Methods*, Hillsdale, NJ: Lawrence Erlbaum Associates, 1988.

BUSSAB, W. DE O; MORETTIN, P. A. **Estatística básica.** 7ed. São Paulo: Saraiva, 2012.

BYRNE, M. D.; TAGUCHI, S. **The Taguchi parameter design.** Quality progress. Dezembro, 1987.

CATEN, C. S. **Método de otimização de produtos e processos medidos por múltiplas características de qualidade.** 1995. Dissertação (Mestrado em Engenharia da Qualidade) – Universidade Federal do Rio Grande do Sul – Programa de Pós-Graduação em Engenharia de Produção, Porto Alegre, 1995.

CHAVES, I. A. **Análise da confiabilidade estrutural em dutos sujeitos à corrosão através de um intervalo de confiança para o índice de confiabilidade e probabilidade de falha estimado pela técnica *bootstrap*.** Tese (Doutorado) – Universidade Federal do Paraná/PR - 2015

CHAVES NETO, A. **Bootstrap e regressão, uma opção aos mínimos quadrados generalizados.** Dissertação (Mestrado) – Unicamp/SP, 1985.

CHAVES NETO, A. **Técnicas estatísticas aplicadas à engenharia de qualidade.** Notas de aula, 2013.

CREVELING, C. M.; FOWLKES, W. Y. **Engineering methods for robust product design.** Massachusetts: Addison-Wesley Publishing Company, 1995.

CSILLAG, P. B. **Análise do valor: metodologia do valor.** 3.ed. São Paulo: Atlas, 1991.

CYMROT R.; RIZZO, A. L. T. Estudo e aplicações da técnica bootstrap. Universidade Presbiteriana Mackenzie: **II Jornada de Iniciação Científica**. 2006. [Online; acesso em 02-junho-2014]. Disponível em: > http://meusite.mackenzie.com.br/raquelc/ana_lucia.pdf.

DAVISON, A. C.; HINKLEY, D. V. **Bootstrap Methods and Their Application**. Cambridge: Univ. Press, 1997.

DUTANG, C. et al. **Bootstrap**. ISFA. 2008. [Online; acesso em 22-setembro-2014]. Disponível em: > <http://dutangc.free.fr/pub/stat/boot.pdf>.

EALEY, L. A. **Quality by design :Taguchi Methods ans U.S. Industry**. Dearborn, Michigan: ASI Press, 1988.

EFRON, B.; TIBSHIRANI, R. J. **An introduction to the bootstrap**. Washington: Chapman & Hall/CRC , 1993.

EFRON, B. **The Jackknife, the bootstrap and other resampling plans**. Technical report No. 63. Division of biostatistics. Stanford University. Stanford, California: 1980.

EFRON, B. **Bootstrap methods: Another look at the Jackknife**. The Annals of Statistics: 1-26. 1979.

EVERITT, B.S. **The Cambridge Dictionary of Statistics**. Cambridge: Cambridge University Press, 1998.

FERREIRA E. B.; SILVA C. T. **Desempenho de Testes de Normalidade Via Simulação de Monte Carlo**. 2008. [Online; acesso em 22-março-2015]. Disponível em : > <http://www.dex.ufla.br/53rbras/trabalhos/4.pdf>.

GONZALEZ, P. S. M. U. **Índices de capacidade do processo para distribuições não normais: uma aplicação na indústria metalúrgica**. Dissertação (Mestrado) – Universidade de São Paulo/Piracicaba, 2013.

HESTERBERG, T. **Bootstrapping student's understanding of statistical concepts**. In G. Burrill, & P. Elliot, *Thinking and reasoning with data and chance: NCTM Yearbook* (pp. 391–416). Reston, VA: National Council of Teachers of Mathematics. 2006. [Online; acesso em 16-Setembro-2014]. Disponível em: > <http://www.timhesterberg.net/articles>.

HESTERBERG, T. C. **Simulation and bootstrapping for teaching statistics**. Seattle, WA. 2011. [Online; acesso em 01-Junho-2014]. Disponível em: > <https://docs.google.com/viewer?a=v&pid=sites&srcid=dGltaGVzdGVyYmVvZyZy5uZXR8d3d3fGd4OjUxM2YxZTJiNDM0ZTI1N2U>.

HOROWITZ; J. L. **Handbook of econometric**. v. 5. USA: Elsevier Science, 2001.

JANSSEN, A.; PAULS, T. **How do bootstrap and permutation tests work?** *The Annals of Statistics*. Institute of Mathematical Statistics, 2003. Vol. 31, No. 3, 768–806.

JURAN, J. M.; GRZYNA, F. M. **Controle da qualidade handbook: conceitos, política e filosofia da qualidade**. v.1. São Paulo: Makron Books, 1991.

KACKAR, R. N. **Taguchi's quality philosophy: analysis and commentary**. Quality control, robust design, and the Taguchi method. Springer US, 1989. 3-21.

LUCIO, P.S.; LEANDRO, I. V.; PAULA, T. P. **Bootstrap aplicado à avaliação de incertezas estatísticas no prognóstico de quantis extremos de precipitação**. Instituto Nacional de Meteorologia (INMET) – Coordenação de Desenvolvimento e Pesquisa (CDP). Brasília, 2006.[Online; acesso em 06-Junho-2014]. Disponível em: > <http://www.cbmet.com/cbm-files/14-eee1d97e2f1534538b995b911f9082b6.pdf>.

MARQUES, J.; MARQUES, M. A. M. **Estatística básica para os cursos de engenharia**. 2 ed. Curitiba: Domínio do Saber, 2009.

MILLER, R. G. **The jackknife – A review.** *Biometrika*, Vol.61, No. 1, pp. 1-15, 1974.

MILLS, J. D. **Using computer simulation methods to teach statistics: a review of the literature.** *Journal of Statistics Education*. (2006). [Online; acesso em 14-Maio-2014]. Disponível em: > www.amstat.org/publications/jse/v10n1/mills.html.

MONTGOMERY, D.C.; RUNGER, G. C. **Applied statistics and probability for engineers.** John Wiley & Sons, 2003.

MORI, T. **Taguchi techniques for image and pattern developing technology.** New Jersey: Prentice-Hall, 1995.

NAKAGAWA, M. **Gestão estratégica de custos: conceito, sistemas e implementação.** São Paulo: Atlas, 1993.

OAKLAND, J. S. **Gerenciamento da qualidade total.** São Paulo: Nobel, 1994.

PALADINI, E. P. **Gestão de qualidade de um processo: A qualidade na produção de bens e serviços.** São Paulo: Atlas, 1995.

PEACE, G. S. **Taguchi methods: a hands-on approach.** Massachusetts: Addison-Wesley Publishing Company, 1993.

QUENOUILLE, M. H. **Aproximate tests of correlation time series.** *Jasa*, 1949.

QUENOUILLE, M. H. **Notes on Bias in Estimation.** *Biometrika*, n. 43, p. 353-360, 1956.

ROBLES JUNIOR, A. **Custos da qualidade: uma estratégia para a competição global.** São Paulo: Atlas, 1996.

ROSS, P. J. **Aplicações das técnicas de Taguchi na engenharia de qualidade.** São Paulo: Makron, McGraw-Hill, 1991.

SAMOHYL, R. W. **Controle estatístico de qualidade**. Rio de Janeiro: Elsevier, 2009.

SAWYER, S. **Resampling Data: Using a Statistical Jackknife**. Washington University: Washington, 2005.

SCHMIDHEINY, K. **The bootstrap**. *Short guides to microeconometrics*. Universität Basel.(2012) [Online; acesso em 18-SETEMBRO-2014]. Disponível em: > <http://kurt.schmidheiny.name/teaching/bootstrap2up.pdf>.

SILVA, C. T.; FERREIRA, E. B. **Testes de Normalidade Via Simulação Monte Carlo**. (2008)

SIMPSON, T. W. et al. **Manufacturing Processes: Integrated Product and Process Design**. McGraw Hill: New York, 2000.

TAGUCHI, G.; JUGULUM, R.; TAGUCHI, S. **Computer-Based robust engineering: essentials for DFSS**. Milwaukee: Quality Press, 2004.

TAGUCHI, G.; CHOWDHURY, S.; TAGUCHI, S. **Robust Engineering**. New York: McGraw-Hill, 2000.

TAGUCHI, G. et al. **Engenharia de qualidade em sistemas de produção**. Tradução Regina Cláudia Loverri; revisão técnica: José Carlos de Castro Waeny. São Paulo: Mcgraw-Hill, 1990.

TOLEDO, J. C. de. **Qualidade industrial: conceitos, sistemas e estratégias**. São Paulo : Atlas, 1987.

WOOD, M. **The role of simulation approaches in statistics**. *Journal of statistics Education*, 13(3), 1–11. 2005. [Online; acesso em 20-agosto-2014]. Disponível em: > www.amstat.org/publications/jse/v13n3/wood.html.

APÊNDICE

APÊNDICE 1 – FUNÇÃO MATLAB

```
function perdasruído(Amostra,B,mu,delta,cf,P)

%Amostra = amostra piloto com a característica funcional do produto analisado
%B = numero de amostras bootstrap
%mu = valor nominal de projeto (target)
%delta=valor da tolerancia funcional do produto
%cf = característica funcional do produto
%cf = 1 (Tipo nominal-e-melhor)
%cf = 2 (Tipo menor-e-melhor)
%cf = 3 (Tipo maior-e-melhor)
%P = perda do consumidor quando o produto esta fora do valor da tolerancia funcional

%tensaosaida;
%Amostra=V'
cf = menu('Qual o tipo da característica funcional','NTB','STB','LTB');
Amostra=input('Entre com a amostra mestre =');
B=input('Entre com o numero de amostras bootstrap =');
if cf==1
mu=input('Entre com o valor nominal de projeto =');
end
ck=menu('O valor de k e dado?','SIM','NAO');
if ck==2
delta=input('Entre com o valor da tolerancia funcional do produto =');
P=input('Entre com o valor da perda do consumidor=');
else
k=input('Entre com o valor de k (coeficiente de perda de qualidade):')
end

n=length(Amostra);

ab=menu('Deseja que imprima na tela as B amostras bootstrap?','Sim','Nao');

[Reamostras,bootsan]=BOOTSTRP(B,'mean', Amostra); %Efetua as B amostras bootstrap calculando a media amostral para cada uma delas
for i=1:n
for j=1:B
m=bootsan(i,j);
BAmostras(i,j)=Amostra(m);
end
end
BA=BAmostras';%imprime as B amostras bootstrap
if ab==1
disp('*****')
disp('*B AMOSTRAS BOOTSTRAP *')
disp('*****')
BA
end

%*****
%***Calculo da media de y e da variancia relativa a media de y da amostra mestre***
%*****

ymedia=mean(Amostra); %(Calculo da media de y no conjunto amostral)
for i=1:n
s(i)=(Amostra(i)-ymedia)^2;
```

```

end
sigma=sum(s)/n;%(Variancia referente a media amostral mestre)

%
%*****
%*****FUNCAO PEDA DE TAGUCHI*****
%*****
%
%*****
%*****
%***CARACTERISTICA FUNCIONAL NOMINAL-E-MELHOR***
%*****
%*****

if cf == 1
%*****
%***Calculo da funcao perda media de Taguchi para a amostra mestre***
%*****

disp('*****')
disp('*Funcao perda media nominal-e-melhor para a amostra mestre*')
disp('*****')
if ck==2
k=P/delta^2;
end
Lmedia=k*(sigma+(ymedia-mu)^2) %Calcula a perda media para o tipo nominal-e-melhor tipo I

%*****
%***Calculo de a para o intervalo de confianca BCA***
%*****
Ba=Amostra(:,2:n);
nB=length(Ba);
ymediaA=mean(Ba);
for i=1:nB
s(i)=(Ba(i)-ymediaA)^2;
end
sigmaA=sum(s)/nB;
k=P/delta^2;
LAmediaA(1)=k*(sigmaA+(ymediaA-mu)^2);
for i=1:n-1
Ba(:,i)=Amostra(i);
ymediaA=mean(Ba);
for j=1:nB
s(j)=(Ba(j)-ymediaA)^2;
end
sigmaA=sum(s)/n;
LAmediaA(i+1)=k*(sigmaA+(ymediaA-mu)^2);
end
LamediaAmean=mean(LAmediaA);
nLa=length(LAmediaA);
for l=1:nLa
num(l)=(LamediaAmean-LAmediaA(l))^3;
den(l)=(LamediaAmean-LAmediaA(l))^2;
end
a=sum(num)/(6*(sum(den))^(3/2));

%
%***Calculo da funcao perda media de Taguchi de cada amostra bootstrap***

```

```

%
%*****
%*Funcao perda media nominal-e-melhor para cada amostra bootstrap*
%*****
for i=1:B
    for j=1:n
        s(i,j)=(BA(i,j)-Reamostras(i))^2;
    end
    sigma(i)=sum(s(i,:))/n; %(Variancia referente a cada B amostra bootstrap)
    LmediaB(i)=k*(sigma(i)+(Reamostras(i)-mu)^2);%Calcula a perda media para o tipo nominal-e-melhor tipo I para cada B amostra bootstrap
end
LmediaB;
end

%*****
%*****
%***CARACTERISTICA FUNCIONAL MENOR-E-MELHOR***
%*****
%*****

if cf==2
    mu=0;
%*****
%***Calculo da funcao perda media de Taguchi para o caso menor-e-melhor para a amostra mestre***
%*****

disp('*****')
disp('*Funcao perda media menor-e-melhor para a amostra mestre*')
disp('*****')
if ck==2
    k=P/delta^2;
end
Lmedia=k*(sigma+(ymedia-mu)^2) %Calcula a perda media para o tipo menor-e-melhor

%*****
%***Calculo de a para o intervalo de confianca BCA***
%*****
Ba=Amostra(:,2:n);
nB=length(Ba);
ymediaA=mean(Ba);
for i=1:nB
    s(i)=(Ba(i)-ymediaA)^2;
end
sigmaA=sum(s)/nB;
k=P/delta^2;
LAmidiaA(1)=k*(sigmaA+(ymediaA-mu)^2);
for i=1:n-1
    Ba(:,i)=Amostra(i);
    ymediaA=mean(Ba);
    for j=1:nB
        s(j)=(Ba(j)-ymediaA)^2;
    end
    sigmaA=sum(s)/n;
    LAmidiaA(i+1)=k*(sigmaA+(ymediaA-mu)^2);
end
LAmidiaA;
LamediaAmean=mean(LAmidiaA);
nLa=length(LAmidiaA);
for l=1:nLa

```

```

    num(l)=(LamediaAmean-LamediaA(l))^3;
    den(l)=(LamediaAmean-LamediaA(l))^2;
end
a=sum(num)/(6*(sum(den))^(3/2));
%
%***Calculo da funcao perda media de Taguchi de cada amostra bootstrap***
%
%*****
%*Funcao perda media menor-e-melhor para cada amostra bootstrap*
%*****
for i=1:B
    for j=1:n
        s(i,j)=(BA(i,j)-Reamostras(i))^2;
    end
    sigma(i)=sum(s(i,:))/n; %(Variancia referente a cada B amostra bootstrap)
    LmediaB(i)=k*(sigma(i)+(Reamostras(i)-mu)^2);%Calcula a perda media para o tipo menor-e-melhor para cada B amostra bootstrap
end
LmediaB;
end

%*****
%*****
%***CARACTERISTICA FUNCIONAL MAIOR-E-MELHOR***
%*****
%*****

if cf == 3
%*****
%***Calculo da funcao perda media de Taguchi para a amostra mestre***
%*****

disp('*****')
disp('*Funcao perda media maior-e-melhor para a amostra mestre*')
disp('*****')
if ck==2
k=P*delta^2;
end

for i=1:n
    s(i)=(1/(Amostra(i))^2);
end
SOMA=sum(s);
Lmedia=k*(1/n)*SOMA;%Calcula a perda media para o tipo maior-e-melhor
Lmedia
%*****
%***Calculo de a para o intervalo de confianca BCA***
%*****
Ba=Amostra(:,2:n);
nB=length(Ba);
k=P*delta^2;
for s=1:nB
    Lmedia(s)=k*(1/n)*sum(1/(Ba(s))^2);%Calcula a perda media para o tipo maior-e-melhor
end
LamediaA(1)=sum(Lmedia);
for z=1:n-1
    Ba(:,z)=Amostra(z);
    for s=1:nB
        Lmedia(s)=k*(1/n)*sum(1/(Ba(s))^2);%Calcula a perda media para o tipo maior-e-melhor
    end
end

```

```

    LAmidiaA(z+1)=sum(Lmedia);
end
LAmidiaA;
LamediaAmean=mean(LAmidiaA);
nLa=length(LAmidiaA);

for l=1:nLa
    num(l)=(LamediaAmean-LAmidiaA(l))^3;
    den(l)=(LamediaAmean-LAmidiaA(l))^2;
end
a=sum(num)/(6*(sum(den))^(3/2))
%
%***Calculo da funcao perda media de Taguchi de cada amostra bootstrap***
%
%*****
%*Funcao perda media maior-e-melhor para cada amostra bootstrap*
%*****
for i=1:B
    INVERSOY=0;
    for j=1:n
        INVERSOYB(j)=1/BA(i,j)^2;
        %Calcula a perda media para o tipo maior-e-melhor para cada B amostra bootstrap
    end
    LmediaB(i)=k*(1/n)*sum(INVERSOYB);
end
LmediaB;
for i=1:n
    s(i)=(1/(Amostra(i))^2);
end
SOMA=sum(s);
Lmedia=k*(1/n)*SOMA;%Calcula a perda media para o tipo maior-e-melhor
Lmedia;
end

%*****
%*****
%*****BOOTSTRAP APLICADO A FUNCAO PERDA DE TAGUCHI*****
%*****
%*****

%Calculo do desvio padrao bootstrap (Erro padrao)
%-----
disp('*****')
disp('*Desvio padrao bootstrap*')
disp('*****')
MediaLmediaB=mean(LmediaB);
for i=1:B
    SEBOOT(i)=(LmediaB(i)-MediaLmediaB)^2;
end
SEBOOTFP=sqrt(sum(SEBOOT)/(B-1))

%*****
%***Teste de normalidade de Lilliefors***
%*****
h=lillietest(LmediaB)

%*****
%***Teste de normalidade de Kolmogorov-Smirnov***
%*****

```

```
ks=kstest(LmediaB)
```

```
%*****
%**CALCULO DA CURTOSE PARA A DISTRIBUICAO BOOTSTRAP DA FUNCAO PERDA**
%*****
```

```
CurtoseFperda=skewness(LmediaB)
```

```
%*****
%**CALCULO DO INTERVALOS DE CONFIANCA BOOTSTRAP**
%*****
```

```
disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 95% PARA A FUNCAO PERDA MEDIA*')
disp('*****')
z1=norminv(0.025);
z2=norminv(0.975);
LI=(Lmedia+z1*SEBOOTFP);
LS=(Lmedia+z2*SEBOOTFP);
if LI<0
    LI=0;
end
IC=[LI LS]
```

```
disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 99% PARA A FUNCAO PERDA MEDIA*')
disp('*****')
z1=norminv(0.005);
z2=norminv(0.995);
LI=(Lmedia+z1*SEBOOTFP);
LS=(Lmedia+z2*SEBOOTFP);
if LI<0
    LI=0;
end
IC=[LI LS]
```

```
disp('*****')
disp('*I.C. BOOSTRAT t DE 95% PARA A FUNCAO PERDA MEDIA*')
disp('*****')
t1=tinv(0.025,n-1);
t2=tinv(0.975,n-1);
LI=(Lmedia+t1*SEBOOTFP);
LS=(Lmedia+t2*SEBOOTFP);
if LI<0
    LI=0;
end
IC=[LI LS]
```

```
disp('*****')
disp('*I.C. BOOTSTRAP t DE 99% PARA A FUNCAO PERDA MEDIA*')
disp('*****')
t1=tinv(0.005,n-1);
t2=tinv(0.995,n-1);
LI=(Lmedia+t1*SEBOOTFP);
LS=(Lmedia+t2*SEBOOTFP);
if LI<0
    LI=0;
end
```

```

IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 95%*')
disp('*****')
P975=prctile(LmediaB,97.5);
P25=prctile(LmediaB,2.5);
LI=P25;
LS=P975;

if LI<0
    LI=0;
end
ICP=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 99%*')
disp('*****')
P995=prctile(LmediaB,99.5);
P005=prctile(LmediaB,0.5);
LI=P005;
LS=P995;

if LI<0
    LI=0;
end
ICP=[LI LS]

disp('*****')
disp('*I.C. BC DE 95%*')
disp('*****')

LmediaBOrd=sort(LmediaB);
Cont=0;
for i=1:B
    if LmediaBOrd(i)<=Lmedia
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
PI=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(LmediaB,PI*100);
LS=prctile(LmediaB,PS*100);

if LI<0
    LI=0;
end
ICBC=[LI LS]

disp('*****')
disp('*I.C. BC DE 99%*')
disp('*****')

LmediaBOrd=sort(LmediaB);

```

```

Cont=0;
for i=1:B
    if LmediaBOrd(i)<=Lmedia
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);
z2=norminv(0.995);
PI=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(LmediaB,PI*100);
LS=prctile(LmediaB,PS*100);

if LI<0
    LI=0;
end
ICBC=[LI LS]

disp('*****')
disp('***I.C. BCa DE 95%***')
disp('*****')

LmediaBOrd=sort(LmediaB);
Cont=0;
for i=1:B
    if LmediaBOrd(i)<=Lmedia
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
PI=normcdf(z0+((z0+z1)/(1-a*(z0+z1))));
PS=normcdf(z0+((z0+z2)/(1-a*(z0+z2))));;
LI=prctile(LmediaB,PI*100);
LS=prctile(LmediaB,PS*100);

if LI<0
    LI=0;
end
ICBCa=[LI LS]

disp('*****')
disp('***I.C. BCa DE 99%***')
disp('*****')

LmediaBOrd=sort(LmediaB);
Cont=0;
for i=1:B
    if LmediaBOrd(i)<=Lmedia
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);
z2=norminv(0.995);
PI=normcdf(z0+((z0+z1)/(1-a*(z0+z1))));

```

```

PS=normcdf(z0+((z0+z2)/(1-a*(z0+z2)))));
LI=prctile(LmediaB,P1*100);
LS=prctile(LmediaB,PS*100);

if LI<0
    LI=0;
end
ICBCa=[LI LS]

%*****
%***CALCULO DO VICIO***
%*****
disp('*****')
disp('*CALCULO DO VICIO*')
disp('*****')
MediaLmediaB=mean(LmediaB);
VICIO=abs(MediaLmediaB-Lmedia)
for i=1:B
    VBOOT(i)=(LmediaB(i)-Lmedia)^2;
end
DesvPadVICIO=sqrt(sum(VBOOT)/(B-1));
if VICIO<0.25*DesvPadVICIO
    disp('O vicio e pequeno')
else
    disp('O vicio e grande')
end
%*****
%***CALCULO DA DISTRIBUICAO BOOTSTRAP PARA A FUNCAO PERDA MEDIA***
%*****
subplot(2,3,1.5),histfit(LmediaB)
grid
title('Distribuicao bootstrap para a funcao perda media')
xlabel('Lmedia')
ylabel('f')

%*****
%*****
%*****RAZAO SINAL-RUIDO******
%*****
%*****

for i=1:n
    v(i)=(Amostra(i)-ymedia)^2;
end
ymedia;
sigmaSN=sum(v)/(n-1);

%*****
%*****
%***CARACTERISTICA FUNCIONAL NOMINAL-E-MELHOR***
%*****
%*****
if cf==1
    NTB=menu('A razao sinal-ruído e de qual tipo','Tipo I','Tipo II');
if NTB==1

%*****
%Calculo da razao sinal-ruído de para o caso nominal-e-melhor tipo I para a amostra mestre
%*****
disp('*****')

```

```

disp('*Razao sinal-ruído nominal-e-melhor tipo I para a amostra mestre*')
disp('*****')
SNNTBI=10*log10((ymedia)^2/sigmaSN^2)

%*****
%***Calculo de a para o intervalo de confianca BCA***
%*****

BaSN=Amostra(:,2:n);
nBSN=length(Ba);
ymediaASN=mean(Ba);
for iSN=1:nB
    sSN(iSN)=(Ba(iSN)-ymediaA)^2;
end
S=sum(sSN);
sigmaASN=sum(sSN)/nBSN;
SNNTBla(1)=10*log10((ymediaASN)^2/sigmaASN^2);
for i=1:n-1
    Ba(:,i)=Amostra(i);
    ymediaASN=mean(Ba);
    for j=1:nB
        sSN(j)=(Ba(j)-ymediaASN)^2;
    end
    sigmaASN=sum(sSN)/n;
    SNNTBla(i+1)=10*log10((ymediaASN)^2/sigmaASN^2);
end
SNNTBla;
SNNTBlamean=mean(SNNTBla);
nLaSN=length(SNNTBla);
for l=1:nLaSN
    numSN(l)=(SNNTBlamean-SNNTBla(l))^3;
    denSN(l)=(SNNTBlamean-SNNTBla(l))^2;
end
a=sum(numSN)/(6*(sum(denSN))^(3/2));
%*****

%Calculo da razao sinal-ruído nominal-e-melhor tipo I de cada amostra bootstrap
%*****

%*****
%*Razao sinal-ruído nominal-e-melhor tipo I para cada amostra bootstrap*
%*****

for i=1:B
    for j=1:n
        s(i,j)=(BA(i,j)-Reamostras(i))^2;
    end
    sigma1(i)=sum(s(i,:))/n; %(Variancia referente a cada B amostra bootstrap)
    SNNTBIB(i)=10*log10((Reamostras(i))^2/(sigma1(i))^2);%Calcula a perda media para o tipo nominal-e-melhor tipo I para cada B amostra bootstrap
end
SNNTBIB;
end

if NTB==2
%*****

%Calculo da razao sinal-ruído de para o caso nominal-e-melhor tipo II para a amostra mestre
%*****

disp('*****')
disp('*Razao sinal-ruído nominal-e-melhor tipo II para a amostra mestre*')
disp('*****')
SNNTBI=-10*log10(sigmaSN^2)

%*****
%***Calculo de a para o intervalo de confianca BCA***

```

```

%*****
BaSN=Amostra(:,2:n);
nBSN=length(Ba);
ymediaASN=mean(Ba)
for iSN=1:nB
    sSN(iSN)=(Ba(iSN)-ymediaA)^2;
end
S=sum(sSN)
sigmaASN=sum(sSN)/nBSN
SNNTBla(1)=10*log10(sigmaASN^2);
for i=1:n-1
    Ba(:,i)=Amostra(i);
    ymediaASN=mean(Ba);
    for j=1:nB
        sSN(j)=(Ba(j)-ymediaASN)^2;
    end
    sigmaASN=sum(sSN)/n;
    SNNTBla(i+1)=10*log10(sigmaASN^2);
end
SNNTBla;
SNNTBlamean=mean(SNNTBla);
nLaSN=length(SNNTBla);
for l=1:nLaSN
    numSN(l)=(SNNTBlamean-SNNTBla(l))^3;
    denSN(l)=(SNNTBlamean-SNNTBla(l))^2;
end
a=sum(numSN)/(6*(sum(denSN))^(3/2));

%*****
%Calculo da razao sinal-ruído nominal-e-melhor tipo II de cada amostra bootstrap
%*****

%*****
%*Razao sinal-ruído nominal-e-melhor tipo II para cada amostra bootstrap*
%*****

for i=1:B
    for j=1:n
        s(i,j)=(BA(i,j)-Reamostras(i))^2;
    end
    sigmaSN(i)=sum(s(i,:))/(n-1); % (Variancia referente a cada B amostra bootstrap)
    SNNTBIB(i)=10*log10((sigmaSN(i))^2); % Calcula a perda media para o tipo nominal-e-melhor tipo I para cada B amostra bootstrap
end
SNNTBIB;
end
end
%*****
%*****
%***CARACTERISTICA FUNCIONAL MENOR-E-MELHOR***
%*****
%*****
if cf==2
%*****
%Calculo da razao sinal-ruído para o caso menor-e-melhor para a amostra mestre
%*****
disp('*****')
disp('*Razao sinal-ruído menor-e-melhor para a amostra mestre*')
disp('*****')
for i=1:n
    y2(i)=Amostra(i)^2;
end
SNNTBI=-10*log10((1/n)*sum(y2))%Calcula a razao sinal-ruído menor-e-melhor para a amostra mestre

```

```

%*****
%***Calculo de a para o intervalo de confianca BCA***
%*****

BaSN=Amostra(:,2:n);
nBSN=length(Ba);
for iSN=1:nB
    y2SNSB(iSN)=BaSN(iSN)^2;
end
SSNSB=sum(y2SNSB);
SNNTBla(1)=-10*log10((1/nBSN)*SSNSB);
for i=1:n-1
    BaSN(:,i)=Amostra(i);
    for j=1:nB
        y2SNSB(j)= BaSN(j)^2;
    end
    SSNSBa=sum(y2SNSB);
    SNNTBla(i+1)=-10*log10((1/nBSN)*SSNSBa);
end
SNNTBla;
SNNTBlamean=mean(SNNTBla);
nLaSN=length(SNNTBla);
for l=1:nLaSN
    numSN(l)=(SNNTBlamean-SNNTBla(l))^3;
    denSN(l)=(SNNTBlamean-SNNTBla(l))^2;
end
a=sum(numSN)/(6*(sum(denSN))^(3/2));
%*****
%Calculo da razao sinal-ruído para o caso menor-e-melhor de cada amostra bootstrap
%*****

%*****')
%*Razao sinal-ruído menor-e-melhor para cada amostra bootstrap*')
%*****')

for i=1:B
    S=0;
    for j=1:n
        soma(i,j)=BA(i,j)^2;
    end
    S=sum(soma(i,:));
    SNNTBIB(i)=-10*log10((1/n)*S);%Calcula a perda media para o tipo menor-e-melhor para cada B amostra bootstrap
end
SNNTBIB;
end

if cf==3
%*****
%Calculo da razao sinal-ruído para o caso maior-e-melhor para a amostra mestre
%*****
disp('*****')
disp('*Razao sinal-ruído maior-e-melhor para a amostra mestre*')
disp('*****')

for i=1:n
    y2(i)=1/(Amostra(i)^2);
end
SNNTBI=-10*log10((1/n)*sum(y2))

%*****
%***Calculo de a para o intervalo de confianca BCA***
%*****

```

```

BaSN=Amostra(:,2:n);
nBSN=length(BaSN);
for iSN=1:nBSN
    y2SNSB(iSN)=1/(BaSN(iSN)^2);
end
SSNSB=sum(y2SNSB);
SNNTBla(1)=-10*log10((1/nBSN)*SSNSB);
for i=1:n-1
    BaSN(:,i)=Amostra(i);
    for j=1:nBSN
        y2SNSB(j)=1/(BaSN(iSN)^2);
    end
    SSNSBa=sum(y2SNSB);
    SNNTBla(i+1)=-10*log10((1/nBSN)*SSNSBa);
end
SNNTBla;
SNNTBlamean=mean(SNNTBla);
nLaSN=length(SNNTBla);
for l=1:nLaSN
    numSN(l)=(SNNTBlamean-SNNTBla(l))^3;
    denSN(l)=(SNNTBlamean-SNNTBla(l))^2;
end
a=sum(numSN)/(6*(sum(denSN))^(3/2));
%*****
%Calculo da razao sinal-ruído para o caso maior-e-melhor de cada amostra bootstrap
%*****

%*****')
%*Razao sinal-ruído maior-e-melhor para cada amostra bootstrap*')
%*****')

for i=1:B
    S=0;
    for j=1:n
        soma(i,j)=1/(BA(i,j)^2);
    end
    S=sum(soma(i,:));
SNNTBIB(i)=-10*log10((1/n)*S);%Calcula a perda media para o tipo menor-e-melhor para cada B amostra bootstrap
end
SNNTBIB;
end

%*****
%*****
%*****BOOTSTRAP APLICADO A RAZAO SINAL-RUIDO!*****
%*****
%*****

%*****
%***Teste de normalidade de Lilliefors***
%*****
hSN=lillietest(SNNTBIB)

%*****
%***Teste de normalidade de Kolmogorov-Smirnov***
%*****
ksSN=kstest(SNNTBIB)

%*****
%***CALCULO DA CURTOSE PARA A DISTRIBUICAO SINAL RUIDO!***

```

```

%*****

CurtoseSN=skewness(SNNTBIB)

%Calculo do desvio padrao bootstrap (Erro padrao)
%-----
disp('*****')
disp('*Desvio padrao bootstrap para S/N *')
disp('*****')
MediaSNNTBIB=mean(SNNTBIB);
for i=1:B
    SEBOOT(i)=(SNNTBIB(i)-MediaSNNTBIB)^2;
end
SEBOOTSR=sqrt(sum(SEBOOT)/(B-1))

%*****
%*****CALCULO DO INTERVALOS DE CONFIANCA BOOTSTRAP*****
%*****

disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 95% PARA A RAZAO SINAL-RUIDO*')
disp('*****')
z1=norminv(0.025);
z2=norminv(0.975);
LI=(SNNTBI+z1*SEBOOTSR);
LS=(SNNTBI+z2*SEBOOTSR);
IC=[LI LS]

disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 99% PARA A RAZAO SINAL-RUIDO*')
disp('*****')
z1=norminv(0.005);
z2=norminv(0.995);
LI=(SNNTBI+z1*SEBOOTSR);
LS=(SNNTBI+z2*SEBOOTSR);
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP t DE 95% PARA A RAZAO SINAL-RUIDO*')
disp('*****')
t1=tinv(0.025,n-1);
t2=tinv(0.975,n-1);
LI=(SNNTBI+t1*SEBOOTSR);
LS=(SNNTBI+t2*SEBOOTSR);
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP t DE 99% PARA A RAZAO SINAL-RUIDO*')
disp('*****')
t1=tinv(0.005,n-1);
t2=tinv(0.995,n-1);
LI=(SNNTBI+t1*SEBOOTSR);
LS=(SNNTBI+t2*SEBOOTSR);
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 95% PARA A RAZAO SINAL-RUIDO*')
disp('*****')

```

```

P975=prctile(SNNTBIB,97.5);
P25=prctile(SNNTBIB,2.5);
LI=P25;
LS=P975;
ICP=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 99% PARA A RAZAO SINAL-RUIDO*')
disp('*****')
P995=prctile(SNNTBIB,99.5);
P005=prctile(SNNTBIB,0.5);
LI=P005;
LS=P995;
ICP=[LI LS]

disp('*****')
disp('***I.C. BC DE 95% PARA A RAZAO SINAL-RUIDO***')
disp('*****')

SNNTBIBOrd=sort(SNNTBIB);
Cont=0;
for i=1:B
    if SNNTBIBOrd(i)<=SNNTBI
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
PI=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(SNNTBIB,PI*100);
LS=prctile(SNNTBIB,PS*100);
ICBC=[LI LS]

disp('*****')
disp('***I.C. BC DE 99% PARA A RAZAO SINAL-RUIDO***')
disp('*****')

SNNTBIBOrd=sort(SNNTBIB);
Cont=0;
for i=1:B
    if SNNTBIBOrd(i)<=SNNTBI
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);
z2=norminv(0.995);
PI=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(SNNTBIB,PI*100);
LS=prctile(SNNTBIB,PS*100);
ICBC=[LI LS]

```

```

disp('*****')
disp('***I.C. BCa DE 95%***')
disp('*****')

SNNTBIBOrd=sort(SNNTBIB);
Cont=0;
for i=1:B
    if SNNTBIBOrd(i)<=SNNTBI
        Cont=Cont+1;
    end
end
PO=Cont/B;
z0=norminv(PO);
z1=norminv(0.025);
z2=norminv(0.975);
PI=normcdf(z0+((z0+z1)/(1-a*(z0+z1))));
PS=normcdf(z0+((z0+z2)/(1-a*(z0+z2))));;
LI=prctile(SNNTBIB,PI*100);
LS=prctile(SNNTBIB,PS*100);
ICBCa=[LI LS]

disp('*****')
disp('***I.C. BCa DE 99%***')
disp('*****')

SNNTBIBOrd=sort(SNNTBIB);
Cont=0;
for i=1:B
    if SNNTBIBOrd(i)<=SNNTBI
        Cont=Cont+1;
    end
end
PO=Cont/B;
z0=norminv(PO);
z1=norminv(0.005);
z2=norminv(0.995);
PI=normcdf(z0+((z0+z1)/(1-a*(z0+z1))));
PS=normcdf(z0+((z0+z2)/(1-a*(z0+z2))));;
LI=prctile(SNNTBIB,PI*100);
LS=prctile(SNNTBIB,PS*100);
ICBCa=[LI LS]

%*****
%***CALCULO DO VICIO***
%*****
disp('*****')
disp('*CALCULO DO VICIO*')
disp('*****')
VICIOSN=abs(MediaSNNTBIB-SNNTBI)
for i=1:B
    VBOOT(i)=(SNNTBIB(i)-SNNTBI)^2;
end
DesvPadVICIO=sqrt(sum(VBOOT)/(B-1));
if VICIO<0.25*DesvPadVICIO
    disp('O vicio e pequeno')
else
    disp('O vicio e grande')
end

%*****

```

```

%*****CALCULO DA DISTRIBUICAO BOOTSTRAP PARA RELACAO S/N*****
%*****

subplot(2,3,2.5),histfit(SNNTBIB)
grid
title('Distribuicao bootstrap para a razao sinal-ruído')
xlabel('S/N')
ylabel('f')

%*****
%*****
%*****INDICES Cp, Cpk E Cpkm*****
%*****
%*****

LE=menu('Os limites de especificacao sao conhecidos?','SIM','NAO');
if LE==1
    if cf==1
        LIE=input('Entre com o valor do limite inferior de especificacao=');
        LSE=input('Entre com o valor do limite superior de especificacao=');
    elseif cf==2
        LSE=input('Entre com o valor do limite superior de especificacao=');
    else
        LIE=input('Entre com o valor do limite inferior de especificacao=');
    end

%*****
%**Teste de normalidade para Amostra mestre**
%*****

if n>=4
    h=lillietest(Amostra,0.01)
else
    AmostraUnica=Amostra
    Count=length(AmostraUnica)
    for i=2:B+1
        for j=1:n
            Count=Count+1;
            AmostraUnica(1,Count)=BA(i-1,j);
        end
    end
    h=lillietest(AmostraUnica);
end
end

if h==0
    disp('*****')
    disp('***Calculo do indice Cp,Cpk e Cpkm para a amostra mestre***')
    disp('*****')

    stddev=std(Amostra);
    ymedia=mean(Amostra); %(Calculo da media de y no conjunto amostral)
    if cf==1 %(Cp para o caso nominal-e-melhor)
        Cp=(LSE-LIE)/(6*stddev)
        Cps=(LSE-ymedia)/(3*std(Amostra));
        Cpi=(ymedia-LIE)/(3*std(Amostra));
        Cpk=min([Cpi Cps])
        T=(LSE+LIE)/2;
        V=(T-ymedia)/std(Amostra);
        Cpkm=Cp/(sqrt((1+V^2)))
    elseif cf==2 %(Cp para o caso menor-e-melhor)

```

```

mu=0;
LIE=0;
Cp=(LSE-LIE)/(6*stddev)
Cps=(LSE-ymedia)/(3*std(Amostra));
Cpi=(ymedia-LIE)/(3*std(Amostra));
Cpk=min([Cpi Cps])
T=(LSE+LIE)/2;
V=(T-ymedia)/std(Amostra);
Cpkm=Cp/(sqrt((1+V^2)))
else
disp('Nao se aplica o calculo de Cp, Cpk e Cpkm pois nao se conhece o LSE')
end

%*****
%***Calculo de a para o intervalo de confianca BCA***
%*****
if cf==1
%*****
%***Calculo de a para Cp***
%*****
BaCp=Amostra(:,2:n);
nCp=length(BaCp);
ymediaACp=mean(BaCp);
for i=1:nCp
sCp(i)=(BaCp(i)-ymediaACp)^2;
end
sigmaACp=sqrt(sum(sCp)/nCp);
Cpa(1)=(LSE-LIE)/6*sigmaACp;
for i=1:n-1
BaCp(:,i)=Amostra(i);
ymediaACp=mean(BaCp);
for j=1:nCp
sCp(j)=(BaCp(j)-ymediaACp)^2;
end
sigmaACp=sum(sCp)/nCp;
Cpa(i+1)=(LSE-LIE)/6*sigmaACp;
end
Cpa;
Cpamean=mean(Cpa);
nCpa=length(Cpa);
for l=1:nCpa
num(l)=(Cpamean-Cpa(l))^3;
den(l)=(Cpamean-Cpa(l))^2;
end
acp=sum(num)/(6*(sum(den))^(3/2));

%*****
%***Calculo de a para Cpk***
%*****
BaCpk=Amostra(:,2:n);
nCpk=length(BaCpk);
ymediaACpk=mean(BaCpk);
for i=1:nCpk
sCpk(i)=(BaCpk(i)-ymediaACpk)^2;
end
sigmaACpk=sqrt(sum(sCpk)/nCpk);
Cpsa=(LSE-ymediaACpk)/(3*sigmaACpk);
Cpia=(ymediaACpk-LIE)/(3*sigmaACpk);
Cpka(1)=min([Cpia Cpsa]);

```

```

for i=1:n-1
    BaCpk(:,i)=Amostra(i);
    ymediaACpk=mean(BaCpk);
    for j=1:nB
        sCpk(j)=(BaCpk(j)-ymediaACpk)^2;
    end
    sigmaACpk=sum(sCpk)/nCpk;
    Cpsa(i+1)=(LSE-ymediaACpk)/(3*sigmaACpk);
    Cpia(i+1)=(ymediaACpk-LIE)/(3*sigmaACpk);
    Cпка(i+1)=min([Cpia(i+1) Cpsa(i+1)]);
end
Cпка;
Cpkamean=mean(Cпка);
nCпка=length(Cпка);
for l=1:nLa
    num(l)=(Cpkamean-Cпка(l))^3;
    den(l)=(Cpkamean-Cпка(l))^2;
end
acpk=sum(num)/(6*(sum(den))^(3/2));

%*****
%***Calculo de a para Cpkm***
%*****
BaCpkm=Amostra(:,2:n);
nCpkm=length(BaCpkm);
ymediaACpkm=mean(BaCpkm);
for i=1:nCpkm
    sCpkm(i)=(BaCpkm(i)-ymediaACpkm)^2;
end
sigmaACpkm=sqrt(sum(sCpkm)/nCpkm);
Cp=(LSE-LIE)/(6*sigmaACpkm);
T=(LSE+LIE)/2;
V(1)=(T-ymediaACpkm)/sigmaACpkm;
Cpkma(1)=Cp/(sqrt((1+V(1)^2)));
for i=1:n-1
    BaCpkm(:,i)=Amostra(i);
    ymediaACpkm=mean(BaCpkm);
    for j=1:nCpkm
        sCpkm(j)=(BaCpkm(j)-ymediaACpkm)^2;
    end
    sigmaACpkm=sum(sCpkm)/nCpkm;
    Cp(i+1)=(LSE-LIE)/6*sigmaACpkm;
    T=(LSE+LIE)/2;
    V(i+1)=(T-ymediaACpkm)/sigmaACpkm;
    Cpkma(i+1)=Cp(i+1)/(sqrt((1+V(i+1).^2)));
end
Cpkma;
Cpkmamean=mean(Cpkma);
nCpkma=length(Cpkma);
for l=1:nCpkma
    num(l)=(Cpkmamean-Cpkma(l))^3;
    den(l)=(Cpkmamean-Cpkma(l))^2;
end
acpkm=sum(num)/(6*(sum(den))^(3/2));
end

if cf==2
%*****
%***Calculo de a para Cp***
%*****

```

```

BaCp=Amostra(:,2:n);
nCp=length(BaCp);
ymediaACp=mean(BaCp);
for i=1:nCp
    sCp(i)=(BaCp(i)-ymediaACp)^2;
end
sigmaACp=sqrt(sum(sCp)/nCp);
Cpa(1)=(LSE-LIE)/6*sigmaACp;
for i=1:n-1
    BaCp(:,i)=Amostra(i);
    ymediaACp=mean(BaCp);
    for j=1:nCp
        sCp(j)=(BaCp(j)-ymediaACp)^2;
    end
    sigmaACp=sum(sCp)/nCp;
Cpa(i+1)=(LSE-LIE)/6*sigmaACp;
end
Cpa;
Cpamean=mean(Cpa);
nCpa=length(Cpa);
for l=1:nCpa
    num(l)=(Cpamean-Cpa(l))^3;
    den(l)=(Cpamean-Cpa(l))^2;
end
acp=sum(num)/(6*(sum(den))^(3/2));

%*****
%***Calculo de a para Cpk***
%*****
BaCpk=Amostra(:,2:n);
nCpk=length(BaCpk);
ymediaACpk=mean(BaCpk);
for i=1:nCpk
    sCpk(i)=(BaCpk(i)-ymediaACpk)^2;
end
sigmaACpk=sqrt(sum(sCpk)/nCpk);
Cpsa=(LSE-ymediaACpk)/(3*sigmaACpk);
Cpia=(ymediaACpk-LIE)/(3*sigmaACpk);
Cpka(1)=min([Cpia Cpsa]);
for i=1:n-1
    BaCpk(:,i)=Amostra(i);
    ymediaACpk=mean(BaCpk);
    for j=1:nB
        sCpk(j)=(BaCpk(j)-ymediaACpk)^2;
    end
    sigmaACpk=sum(sCpk)/nCpk;
Cpsa(i+1)=(LSE-ymediaACpk)/(3*sigmaACpk);
Cpia(i+1)=(ymediaACpk-LIE)/(3*sigmaACpk);
Cpka(i+1)=min([Cpia(i+1) Cpsa(i+1)]);
end
Cpka;
Cpkamean=mean(Cpka);
nCpka=length(Cpka);
for l=1:nLa
    num(l)=(Cpkamean-Cpka(l))^3;
    den(l)=(Cpkamean-Cpka(l))^2;
end
acpk=sum(num)/(6*(sum(den))^(3/2));

```

```

%*****
%***Calculo de a para Cpkm***
%*****
BaCpkm=Amostra(:,2:n);
nCpkm=length(BaCpkm);
ymediaACpkm=mean(BaCpkm);
for i=1:nCpkm
    sCpkm(i)=(BaCpkm(i)-ymediaACpkm)^2;
end
sigmaACpkm=sqrt(sum(sCpkm)/nCpkm);
Cp=(LSE-LIE)/(6*sigmaACpkm);
T=(LSE+LIE)/2;
V(1)=(T-ymediaACpkm)/sigmaACpkm;
Cpkma(1)=Cp/(sqrt((1+V(1)^2)));
for i=1:n-1
    BaCpkm(:,i)=Amostra(i);
    ymediaACpkm=mean(BaCpkm);
    for j=1:nCpkm
        sCpkm(j)=(BaCpkm(j)-ymediaACpkm)^2;
    end
    sigmaACpkm=sum(sCpkm)/nCpkm;
    Cp(i+1)=(LSE-LIE)/6*sigmaACpkm;
    T=(LSE+LIE)/2;
    V(i+1)=(T-ymediaACpkm)/sigmaACpkm;
    Cpkma(i+1)=Cp(i+1)/(sqrt((1+V(i+1).^2)));
end
Cpkma;
Cpkmamean=mean(Cpkma);
nCpkma=length(Cpkma);
for l=1:nCpkma
    num(l)=(Cpkmamean-Cpkma(l))^3;
    den(l)=(Cpkmamean-Cpkma(l))^2;
end
acpkm=sum(num)/(6*(sum(den))^(3/2));
end

%*****
%*Calculo do indice Cp, Cpk e Cpkm para cada amostra bootstrap*1
%*****
for i=1:B
    media=mean(BA(i,:));
    if cf==1
        CpBOOT(i)=(LSE-LIE)/(6*std(BA(i,:)));
        Cpi(i)=(media-LIE)/(3*std(BA(i,:)));
        Cps(i)=(LSE-media)/(3*std(BA(i,:)));
        CpkBOOT(i)=min([Cpi(i) Cps(i)]);
        T=(LSE+LIE)/2;
        V=(T-ymedia)/std(BA(i,:));
        CpkmBOOT(i)=CpBOOT(i)/sqrt((1+V^2));
    elseif cf==2
        CpBOOT(i)=(LSE-LIE)/(6*std(BA(i,:)));
        Cpi(i)=(media-LIE)/(3*std(BA(i,:)));
        Cps(i)=(LSE-media)/(3*std(BA(i,:)));
        CpkBOOT(i)=min([Cpi(i) Cps(i)]);
        T=(LSE+LIE)/2;
        V=(T-ymedia)/std(BA(i,:));
        CpkmBOOT(i)=CpBOOT(i)/sqrt((1+V^2));
    end
end

```

```

end

%*****
%***CALCULO DO I.C. BOOTSTRAP PARA O INDICE Cp, Cpk e Cpkm***
%*****

%*****
%***Teste de normalidade de Lilliefors***
%*****
hCpk=lillietest(CpkBOOT)

%*****
%***Teste de normalidade de Kolmogorov-Smirnov***
%*****
ksSN=kstest(CpkBOOT)

%Calculo do desvio padrao bootstrap para os indices Cp, Cpk e Cpkm (Erro padrao)
%-----
Cp=(LSE-LIE)/(6*stddev);
disp('*****')
disp('*Desvio padrao bootstrap para Cp *')
disp('*****')
MediaCpBOOT=mean(CpBOOT);
for i=1:B
    SEBOOT1(i)=(CpBOOT(i)-MediaCpBOOT)^2;
end
SEBOOTCp=sqrt(sum(SEBOOT1)/(B-1))

disp('*****')
disp('*Desvio padrao bootstrap para Cpk *')
disp('*****')
MediaCpkBOOT=mean(CpkBOOT);
for i=1:B
    SEBOOT(i)=(CpkBOOT(i)-MediaCpkBOOT)^2;
end
SEBOOTCpk=sqrt(sum(SEBOOT)/(B-1))

disp('*****')
disp('*Desvio padrao bootstrap para Cpkm *')
disp('*****')
MediaCpkmBOOT=mean(CpkmBOOT);
for i=1:B
    SEBOOT2(i)=(CpkmBOOT(i)-MediaCpkmBOOT)^2;
end
SEBOOTCpkm=sqrt(sum(SEBOOT2)/(B-1))

%*****
%*****CALCULO DO INTERVALOS DE CONFIANCA BOOTSTRAP*****
%*****
disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 95% PARA O INDICE Cp*')
disp('*****')
z1=norminv(0.025);
z2=norminv(0.975);
LI=(Cp+z1*SEBOOTCp);
LS=(Cp+z2*SEBOOTCp);
if LI<0
    LI=0;

```

```

end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 99% PARA O INDICE Cp*')
disp('*****')
z1=norminv(0.005);
z2=norminv(0.995);
LI=(Cp+z1*SEBOOTCp);
LS=(Cp+z2*SEBOOTCp);
if LI<0
    LI=0;
end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP t DE 95% PARA O INDICE Cp*')
disp('*****')
t1=tinv(0.025,n-1);
t2=tinv(0.975,n-1);
LI=(Cp+t1*SEBOOTCp);
LS=(Cp+t2*SEBOOTCp);

if LI<0
    LI=0;
end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP t DE 99% PARA O INDICE Cp*')
disp('*****')
t1=tinv(0.005,n-1);
t2=tinv(0.995,n-1);
LI=(Cp+t1*SEBOOTCp);
LS=(Cp+t2*SEBOOTCp);

if LI<0
    LI=0;
end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 95% PARA O INDICE Cp*')
disp('*****')
P975=prctile(CpBOOT,97.5);
P25=prctile(CpBOOT,2.5);
LI=P25;
LS=P975;

if LI<0
    LI=0;
end
ICP=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 99% PARA O INDICE Cp*')
disp('*****')
P995=prctile(CpBOOT,99.5);
P005=prctile(CpBOOT,0.5);
LI=P005;

```

```

LS=P995;

if LI<0
    LI=0;
end
ICP=[LI LS]

disp('*****')
disp('***I.C. BC DE 95% PARA PARA O INDICE Cp*')
disp('*****')

CpBOOTBOrd=sort(CpBOOT);
Cont=0;
for i=1:B
    if CpBOOTBOrd(i)<=Cp
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
P1=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(CpBOOT,P1*100);
LS=prctile(CpBOOT,PS*100);

if LI<0
    LI=0;
end
ICBC=[LI LS]

disp('*****')
disp('***I.C. BC DE 99% PARA O INDICE Cp*')
disp('*****')

CpBOOTBOrd=sort(CpBOOT);
Cont=0;
for i=1:B
    if CpBOOTBOrd(i)<=Cp
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);
z2=norminv(0.995);
P1=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(CpBOOT,P1*100);
LS=prctile(CpBOOT,PS*100);

if LI<0
    LI=0;
end
ICBC=[LI LS]

disp('*****')
disp('***I.C. BCa DE 95% PARA O INDICE Cp****')

```

```

disp('*****')

CpBOOTBOrd=sort(CpBOOT);
Cont=0;
for i=1:B
    if CpBOOTBOrd(i)<=Cp
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
PI=normcdf(z0+((z0+z1)/(1-acp*(z0+z1))));
PS=normcdf(z0+((z0+z2)/(1-acp*(z0+z2))));
LI=prctile(CpBOOT,PI*100);
LS=prctile(CpBOOT,PS*100);
if LI<0
    LI=0;
end
ICBCa=[LI LS]

disp('*****')
disp('***I.C. BCa DE 99% PARA O INDICE Cp***')
disp('*****')

CpBOOTBOrd=sort(CpBOOT);
Cont=0;
for i=1:B
    if CpBOOTBOrd(i)<=Cp
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);
z2=norminv(0.995);
PI=normcdf(z0+((z0+z1)/(1-acp*(z0+z1))));
PS=normcdf(z0+((z0+z2)/(1-acp*(z0+z2))));
LI=prctile(CpBOOT,PI*100);
LS=prctile(CpBOOT,PS*100);
if LI<0
    LI=0;
end
ICBCa=[LI LS]

%*****
%***CALCULO DO VICIO***
%*****
disp('*****')
disp('*CALCULO DO VICIO*')
disp('*****')
Cp=(LSE-LIE)/(6*std(Amostra));
VICIOcp=abs(Mean(CpBOOT)-Cp)
for i=1:B
    VBOOT1(i)=(CpBOOT(i)-Cp).^2;
end
DesvPadVICIO1=sqrt(sum(VBOOT1)/(B-1));
if VICIOcp<0.25*DesvPadVICIO1
    disp('O vicio e pequeno')
else

```

```

disp('O vicio e grande')
end

%%%%%%%%%%
disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 95% PARA O INDICE Cpk*')
disp('*****')
z1=norminv(0.025);
z2=norminv(0.975);
LI=(Cpk+z1*SEBOOTCpk);
LS=(Cpk+z2*SEBOOTCpk);
if LI<0
    LI=0;
end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 99% PARA O INDICE Cpk*')
disp('*****')
z1=norminv(0.005);
z2=norminv(0.995);
LI=(Cpk+z1*SEBOOTCpk);
LS=(Cpk+z2*SEBOOTCpk);
if LI<0
    LI=0;
end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP t DE 95% PARA O INDICE Cpk*')
disp('*****')
t1=tinv(0.025,n-1);
t2=tinv(0.975,n-1);
LI=(Cpk+t1*SEBOOTCpk);
LS=(Cpk+t2*SEBOOTCpk);

if LI<0
    LI=0;
end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP t DE 99% PARA O INDICE Cpk*')
disp('*****')
t1=tinv(0.005,n-1);
t2=tinv(0.995,n-1);
LI=(Cpk+t1*SEBOOTCpk);
LS=(Cpk+t2*SEBOOTCpk);

if LI<0
    LI=0;
end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 95% PARA PARA O INDICE Cpk*')
disp('*****')
P975=prctile(CpkBOOT,97.5);
P25=prctile(CpkBOOT,2.5);
LI=P25;

```

```

LS=P975;

if LI<0
  LI=0;
end
ICP=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 99% PARA O INDICE Cpk*')
disp('*****')
P995=prctile(CpkBOOT,99.5);
P005=prctile(CpkBOOT,0.5);
LI=P005;
LS=P995;

if LI<0
  LI=0;
end
ICP=[LI LS]

disp('*****')
disp('*I.C. BC DE 95% PARA PARA O INDICE Cpk*')
disp('*****')

CpkBOOTBOrd=sort(CpkBOOT);
Cont=0;
for i=1:B
  if CpkBOOTBOrd(i)<=Cpk
    Cont=Cont+1;
  end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
P1=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(CpkBOOT,P1*100);
LS=prctile(CpkBOOT,PS*100);

if LI<0
  LI=0;
end
ICBC=[LI LS]

disp('*****')
disp('*I.C. BC DE 99% PARA O INDICE Cpk*')
disp('*****')

CpkBOOTBOrd=sort(CpkBOOT);
Cont=0;
for i=1:B
  if CpkBOOTBOrd(i)<=Cpk
    Cont=Cont+1;
  end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);

```

```

z2=norminv(0.995);
PI=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(CpkBOOT,PI*100);
LS=prctile(CpkBOOT,PS*100);

if LI<0
    LI=0;
end
ICBC=[LI LS]

disp('*****')
disp('***I.C. BCa DE 95% PARA O INDICE Cpk****')
disp('*****')

CpkBOOTBOrd=sort(CpkBOOT);
Cont=0;
for i=1:B
    if CpkBOOTBOrd(i)<=Cpk
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
PI=normcdf(z0+((z0+z1)/(1-a*(z0+z1))));
PS=normcdf(z0+((z0+z2)/(1-a*(z0+z2))));;
LI=prctile(CpkBOOT,PI*100);
LS=prctile(CpkBOOT,PS*100);
if LI<0
    LI=0;
end
ICBCa=[LI LS]

disp('*****')
disp('***I.C. BCa DE 99% PARA O INDICE Cpk****')
disp('*****')

CpkBOOTBOrd=sort(CpkBOOT);
Cont=0;
for i=1:B
    if CpkBOOTBOrd(i)<=Cpk
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);
z2=norminv(0.995);
PI=normcdf(z0+((z0+z1)/(1-a*(z0+z1))));
PS=normcdf(z0+((z0+z2)/(1-a*(z0+z2))));;
LI=prctile(CpkBOOT,PI*100);
LS=prctile(CpkBOOT,PS*100);
if LI<0
    LI=0;
end
ICBCa=[LI LS]

%*****
%***CALCULO DO VICIO***

```

```

%*****
disp('*****')
disp('*CALCULO DO VICIO*')
disp('*****')
VICIOCpk=abs(MediaCpkBOOT-Cpk)
for i=1:B
    VBOOT(i)=(CpkBOOT(i)-Cpk)^2;
end
DesvPadVICIOCpk=sqrt(sum(VBOOT)/(B-1));
if VICIOCpk<0.25*DesvPadVICIOCpk
    disp('O vicio e pequeno')
else
    disp('O vicio e grande')
end

```

```

%%
disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 95% PARA O INDICE Cpkm*')
disp('*****')
z1=norminv(0.025);
z2=norminv(0.975);
LI=(Cpkm+z1*SEBOOTCpkm);
LS=(Cpkm+z2*SEBOOTCpkm);
if LI<0
    LI=0;
end
IC=[LI LS]

```

```

disp('*****')
disp('*I.C. BOOSTRAT PADRAO DE 99% PARA O INDICE Cpkm*')
disp('*****')
z1=norminv(0.005);
z2=norminv(0.995);
LI=(Cpkm+z1*SEBOOTCpkm);
LS=(Cpkm+z2*SEBOOTCpkm);
if LI<0
    LI=0;
end
IC=[LI LS]

```

```

disp('*****')
disp('*I.C. BOOTSTRAP t DE 95% PARA O INDICE Cpkm*')
disp('*****')
t1=tinvt(0.025,n-1);
t2=tinvt(0.975,n-1);
LI=(Cpkm+t1*SEBOOTCpkm);
LS=(Cpkm+t2*SEBOOTCpkm);

if LI<0
    LI=0;
end
IC=[LI LS]

```

```

disp('*****')
disp('*I.C. BOOTSTRAP t DE 99% PARA O INDICE Cpkm*')
disp('*****')
t1=tinvt(0.005,n-1);
t2=tinvt(0.995,n-1);
LI=(Cpkm+t1*SEBOOTCpkm);
LS=(Cpkm+t2*SEBOOTCpkm);

```

```

if LI<0
    LI=0;
end
IC=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 95% PARA PARA O INDICE Cpkm*')
disp('*****')
P975=prctile(CpkmBOOT,97.5);
P25=prctile(CpkmBOOT,2.5);
LI=P25;
LS=P975;

if LI<0
    LI=0;
end
ICP=[LI LS]

disp('*****')
disp('*I.C. BOOTSTRAP PERCENTIL DE 99% PARA O INDICE Cpkm*')
disp('*****')
P995=prctile(CpkmBOOT,99.5);
P005=prctile(CpkmBOOT,0.5);
LI=P005;
LS=P995;

if LI<0
    LI=0;
end
ICP=[LI LS]

disp('*****')
disp('*I.C. BC DE 95% PARA PARA O INDICE Cpkm*')
disp('*****')

CpkmBOOTBOrd=sort(CpkmBOOT);
Cont=0;
for i=1:B
    if CpkmBOOTBOrd(i)<=Cpkm
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
PI=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(CpkmBOOT,PI*100);
LS=prctile(CpkmBOOT,PS*100);

if LI<0
    LI=0;
end
ICBC=[LI LS]

disp('*****')
disp('*I.C. BC DE 99% PARA O INDICE Cpkm*')

```

```

disp('*****')

CpkmBOOTBOrd=sort(CpkmBOOT);
Cont=0;
for i=1:B
    if CpkmBOOTBOrd(i)<=Cpkm
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);
z2=norminv(0.995);
PI=normcdf(2*z0+z1);
PS=normcdf(2*z0+z2);
LI=prctile(CpkmBOOT,PI*100);
LS=prctile(CpkmBOOT,PS*100);

if LI<0
    LI=0;
end
ICBC=[LI LS]

disp('*****')
disp('***I.C. BCa DE 95% PARA O INDICE Cpkm***')
disp('*****')

CpkmBOOTBOrd=sort(CpkmBOOT);
Cont=0;
for i=1:B
    if CpkmBOOTBOrd(i)<=Cpkm
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.025);
z2=norminv(0.975);
PI=normcdf(z0+((z0+z1)/(1-acpkm*(z0+z1))));
PS=normcdf(z0+((z0+z2)/(1-acpkm*(z0+z2))));
LI=prctile(CpkmBOOT,PI*100);
LS=prctile(CpkmBOOT,PS*100);
if LI<0
    LI=0;
end
ICBCa=[LI LS]

disp('*****')
disp('***I.C. BCa DE 99% PARA O INDICE Cpkm***')
disp('*****')

CpkmBOOTBOrd=sort(CpkmBOOT);
Cont=0;
for i=1:B
    if CpkmBOOTBOrd(i)<=Cpkm
        Cont=Cont+1;
    end
end
P0=Cont/B;
z0=norminv(P0);
z1=norminv(0.005);

```

```

z2=norminv(0.995);
PI=normcdf(z0+(z0+z1/(1-acpkm*(z0+z1))));
PS=normcdf(z0+(z0+z2/(1-acpkm*(z0+z2))));;
LI=prctile(CpkmBOOT,PI*100);
LS=prctile(CpkmBOOT,PS*100);
if LI<0
    LI=0;
end
ICBCa=[LI LS]

```

```

%*****
%***CALCULO DO VICIO***
%*****

```

```

disp('*****')
disp('*CALCULO DO VICIO*')
disp('*****')
VICIOcpkm=abs(MediaCpkmBOOT-Cpkm)
for i=1:B
    VBOOT2(i)=(CpkmBOOT(i)-Cpkm)^2;
end
DesvPadVICIO2=sqrt(sum(VBOOT2)/(B-1));
if VICIOcpkm<0.25*DesvPadVICIO2
    disp('O vicio e pequeno')
else
    disp('O vicio e grande')
end

```

```

%%%%%%%%%%
%*****

```

```

%CALCULO DA DISTRIBUICAO BOOTSTRAP PARA Cp, Cpk e Cpkm
%*****

```

```

if cf==1
subplot(2,3,4),histfit(CpBOOT)
grid
title('Distribuicao bootstrap para Cp')
xlabel('Cp')
ylabel('f')
subplot(2,3,5),histfit(CpkBOOT)
grid
title('Distribuicao bootstrap para Cpk')
xlabel('Cpk')
ylabel('f')
subplot(2,3,6),histfit(CpkmBOOT)
grid
title('Distribuicao bootstrap para Cpkm')
xlabel('Cpkm')
ylabel('f')
end
if cf==2
subplot(2,3,4),histfit(CpBOOT)
grid
title('Distribuicao bootstrap para Cp')
xlabel('Cp')
ylabel('f')
subplot(2,3,5),histfit(CpkBOOT)
grid
title('Distribuicao bootstrap para Cpk')
xlabel('Cpk')
ylabel('f')
subplot(2,3,6),histfit(CpkmBOOT)
grid

```

```
title('Distribuicao bootstrap para Cpkm')
xlabel('Cpkm')
ylabel('f')
end
else
    disp('Como a amostra nao e normal, nao se calculou Cp, Cpk e Cpkm')
end
else
    disp('Nao e possivel calcular os indices Cp, Cpk e Cpkm pois nao se conhece nenhum limite de especificacao')
end
end
```