



**UNIVERSIDADE FEDERAL DE MINAS GERAIS  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO**



**MODELAGEM E OTIMIZAÇÃO DE DESVIOS EM PEÇAS  
TERMOFORMADAS A VÁCUO UTILIZANDO  
MODELOS DE REGRESSÃO MÚLTIPLA E  
REDES NEURAS ARTIFICIAIS**

**WANDERSON DE OLIVEIRA LEITE**

**Belo Horizonte, 29 de maio de 2015**

**WANDERSON DE OLIVEIRA LEITE**

**MODELAGEM E OTIMIZAÇÃO DE DESVIOS EM PEÇAS  
TERMOFORMADAS A VÁCUO UTILIZANDO  
MODELOS DE REGRESSÃO MÚLTIPLA E  
REDES NEURAS ARTIFICIAIS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutor em Engenharia de Produção.

**Área de concentração:** Pesquisa Operacional e Engenharia de Manufatura.

**Orientador:** Prof. Dr. Juan Carlos Campos Rubio.

**Coorientador Sanduíche:** Dr. Francisco Mata Cabrera (UCLM - Espanha).

**Belo Horizonte  
Escola de Engenharia da UFMG  
2015**

L533m

Leite, Wanderson de Oliveira.

Modelagem e otimização de desvios em peças termoformadas a vácuo utilizando modelos de regressão múltipla e redes neurais artificiais [manuscrito] / Wanderson de Oliveira Leite. - 2015.

181 f., enc.: il.

Orientador: Juan Carlos Campos Rubio.

Coorientador: Francisco Mata Cabrera.

Tese (doutorado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Anexos e apêndices: f.170-181.

Bibliografia: f.163-169.

1. Engenharia de produção - Teses. 2. Redes neurais (Computação) - Teses. I. Campos Rubio, Juan Carlos. II. Mata Cabrera, Francisco. III. Universidade Federal de Minas Gerais. Escola de Engenharia. IV. Título.

CDU: 658.5(043)



## ATA DA DEFESA DE TESE DO ALUNO WANDERSON DE OLIVEIRA LEITE

Realizou-se, no dia 29 de maio de 2015, às 08:30 horas, Auditório da Escola de Engenharia da, sala 1010, da Universidade Federal de Minas Gerais, a 10ª defesa de tese, intitulada *MODELAGEM E OTIMIZAÇÃO DE DESVIOS EM PEÇAS TERMOFORMADAS A VÁCUO UTILIZANDO MODELOS DE REGRESSÃO MÚLTIPLA E REDES NEURAIS ARTIFICIAIS*, apresentada por WANDERSON DE OLIVEIRA LEITE, número de registro 2011712534, graduado no curso de DESENHO INDUSTRIAL, como requisito parcial para a obtenção do grau de Doutor em ENGENHARIA DE PRODUÇÃO, à seguinte Comissão Examinadora: Prof(a). Juan Carlos Campos Rubio - Orientador (Universidade Federal de Minas Gerais), Prof(a). Alexandre Mendes Abrao (Universidade Federal de Minas Gerais), Prof(a). Paulo Eustáquio de Faria (Universidade Federal de Minas Gerais), Prof(a). Tulio Hallak Panzera (Universidade Federal de São João del Rei), Prof(a). Rosemary Bom Conselho Sales (Universidade do Estado Minas Gerais - UEMG).

A Comissão considerou a tese:

Aprovada

Reprovada

Finalizados os trabalhos, lavrei a presente ata que, lida e aprovada, vai assinada por mim e pelos membros da Comissão.

Belo Horizonte, 29 de maio de 2015.

Prof(a). Juan Carlos Campos Rubio ( Doutor )

Prof(a). Alexandre Mendes Abrao ( Doutor )

Prof(a). Paulo Eustáquio de Faria ( Doutor )

Prof(a). Tulio Hallak Panzera ( Doutor )

Prof(a). Rosemary Bom Conselho Sales ( Doutora )



### FOLHA DE MODIFICAÇÕES

As modificações exigidas na tese de WANDERSON DE OLIVEIRA LEITE, número de registro 2011712534, de número 10, em 29 de maio de 2015, são relacionadas a seguir:

Area for listing modifications, currently blank and crossed out with a diagonal line.

O prazo para entrega da versão final do trabalho com as modificações exigidas acima é de:

- 7 (sete) dias                       30 (trinta) dias                       90 (noventa) dias  
 Outro (a critério da comissão): \_\_\_\_\_ dias

ficando responsável pela verificação destas o professor: \_\_\_\_\_

\_\_\_\_\_  
Assinatura do Aluno

\_\_\_\_\_  
Assinatura do Professor Responsável

Atesto que as modificações exigidas \_\_\_\_\_ integralmente cumpridas.

Belo Horizonte, \_\_\_\_ de \_\_\_\_ de \_\_\_\_.

\_\_\_\_\_  
Assinatura do Professor Responsável

À minha família,  
em especial aos meus pais,  
pelo apoio e compreensão  
de forma incondicional.

## AGRADECIMENTOS

Ao meu orientador, Juan Carlos Rubio, por toda a dedicação, esforço e paciência em orientar.

Ao meu coorientador de estágio no exterior (sanduíche) Dr. Francisco Mata Cabrera (*Universidad de Castilla-La Mancha* – UCLM, Espanha), pelas contribuições.

Ao Laboratório de Usinagem e Automação e ao Laboratório de Engenharia e Processos Avançados de Manufatura (LEPAM) da Universidade Federal de Minas Gerais (UFMG), pela cooperação na realização dos ensaios, testes e disponibilização dos equipamentos.

Ao campus de *Almadén e Ciudad Real* da *Universidad Castilla la Mancha*, por disponibilizar sua infraestrutura para desenvolvimento de estágio de doutorado.

Ao Professor Doutor Alexandre Mendes Abrão, do Departamento de Engenharia Mecânica da UFMG, por disponibilizar a utilização da infraestrutura do Laboratório de Usinagem e Automação para realização dos testes e medições e por ter aceitado fazer parte da banca examinadora desta tese de doutorado.

Ao Professor Doutor Paulo Eustáquio de Faria, do Departamento de Engenharia de Produção da UFMG, pelas contribuições ao longo destes anos e por ter aceitado fazer parte da banca examinadora.

À Professora Doutora Rosemary Bom Conselho Sales, da Universidade do Estado de Minas Gerais (UEMG), pelas inúmeras contribuições ao longo destes anos e por ter aceitado fazer parte da banca examinadora.

Ao Professor Doutor Túlio Hallak Panzera, do Departamento de Engenharia Mecânica da Universidade Federal de São João Del-Rei, por ter aceitado fazer parte da banca examinadora.

Aos pesquisadores e alunos do Laboratório de Usinagem e Automação e do LEPAM, pelas contribuições na realização dos experimentos, em especial ao Professor Doutor Alexandre Mendes Abrao e ao Professor Doutor Paulo Eustáquio de Faria e os discentes Caio Henrique A. Maciel, Eduardo Martins, Gleydson Albano, Ingrid Nascimento e Rodrigo Menezes.

Aos secretários de Pós-Graduação, Marcos Leão e Inês de Cássia F. Couto, pelos auxílios prestados ao longo destes anos.

À Professora e revisora Magda Barbosa Roquette de Pinho Taranto, pela disponibilidade e proatividade na resolução das inúmeras perguntas, dúvidas e questionamentos e, ainda, pelos serviços técnicos prestados ao longo destes anos.

Aos colegas do curso de Pós-Graduação em Engenharia de Produção, pelos momentos difíceis.

À Coordenadoria de Aperfeiçoamento de Pessoal de Ensino Superior (CAPES), pela concessão de bolsas.

Ao meu pai (*in memoriam*) e a minha mãe, pelo apoio e compreensão de forma incondicional.

A Rosalva Campos Luciano, Maria Leite, Dária, Nádia Helena, Jane Corrêa, Fábio Martins, Vera Martins, Renata Filippeto, Angeles Bello, Virginia Pinho, Carolina Santos, Elizangela Martins, Silvana Rodrigues, Rosângela Alves, Deise Cristina, Maria Ângela, Sônia Alves, Dária de Fátima, Luiz Junior, Elbert Mullher, Leandro Silva, Maria Cristina, Fabiana Lopes, Isabel Leite e demais amigos que estiveram ao meu lado, apoiando e entendendo os momentos difíceis.



A todos que porventura possam ter sido esquecidos neste momento.

Por fim, mas fundamental, agradeço a toda a minha família, em especial a Maria R. N. Oliveira, Mimorina Germano, Maria Celeste, Marli Magela, Carmen Muñoz, Luis Quintana e as Sagrário Davila, pela compreensão da minha ausência e por sempre apoiarem e acreditarem.

Meus sinceros agradecimentos.

*“O que sabemos é uma gota, o que ignoramos é um oceano”.*  
Isaac Newton *in Philosophiae Naturalis Principia Mathematica* (1676).

# SUMÁRIO<sup>1</sup>

LISTA DE FIGURAS

LISTA DE GRÁFICOS

LISTA DE QUADROS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

NOMENCLATURA

RESUMO

1 INTRODUÇÃO.....	28
1.1 Objetivos.....	31
1.2 Organização da tese.....	32
2 REVISÃO BIBLIOGRÁFICA.....	34
2.1 O processo de termoformagem a vácuo.....	34
2.1.1 A termoformagem.....	34
2.1.2 A técnica de termoformagem a vácuo.....	36
2.1.3 Principais propriedades dos materiais e parâmetros de fabricação que afetam a qualidade de peças termoformadas a vácuo.....	40
2.1.3.1 A retração térmica em polímeros no processo de termoformagem a vácuo.....	40
2.1.3.2 Condutividades e difusividade térmica em polímeros no processo de termoformagem a vácuo.....	43
2.1.3.3 O aquecimento de polímeros no processo de termoformagem a vácuo.....	44
2.1.3.4 Característica do aquecimento por radiação no processo de termoformagem.....	47
2.1.3.5 O resfriamento e arrefecimento no processo de termoformagem a vácuo.....	50

---

<sup>1</sup> Este trabalho foi revisado de acordo com as novas regras ortográficas aprovadas pelo Acordo Ortográfico assinado entre os países que integram a Comunidade de Países de Língua Portuguesa (CPLP), em vigor no Brasil desde 2009. E foi formatado de acordo com "Manual de editoração para dissertações e teses" do Programa de Pós-Graduação em Engenharia Mecânica da UFMG de 18/10/2004 e Norma ABNT de 2003.

2.1.3.6 Característica do projeto do molde para termoformagem a vácuo..	52
2.1.3.7 Aspectos gerais da qualidade dimensional e geométrica do produto termoformado.....	57
2.2 Inteligência computacional em processo de manufatura.....	62
2.2.1 Sistemas baseados em conhecimento.....	64
2.2.2 Lógica nebulosa.....	66
2.2.3 Algoritmos genéticos.....	68
2.2.4 Redes neurais artificiais em processo de manufatura.....	71
2.2.4.1 Modelagem matemática de uma RNA.....	73
2.2.4.2 RNA aplicada a processos de manufatura.....	82
3 MATERIAL E MÉTODOS.....	88
3.1 Materiais, equipamentos e ferramentas computacionais.....	90
3.1.1 Materiais.....	90
3.1.2 Equipamentos.....	91
3.1.3 Ferramentas computacionais.....	93
3.2 Montagem do sistema de testes.....	93
3.3 Definição dos desvios dimensionais, geométricos e métodos de mensuração .....	96
3.4 Métodos e procedimentos de análise de dados utilizados.....	103
4 TESTES EXPLORATÓRIOS.....	107
4.1 Realização dos testes exploratórios.....	107
4.2 Análises dos resultados do teste exploratório.....	110
4.3 Considerações preliminares.....	115
5 TESTES DEFINITIVOS.....	117
5.1 Realização dos testes.....	117
5.2 Análise dos resultados do teste definitivo.....	119
5.3 Considerações preliminares.....	128

6 DESENVOLVIMENTO DOS MODELOS DE PREVISÃO E OTIMIZAÇÃO.....	131
6.1 Desenvolvimento dos modelos da estimativa e otimização dos desvios utilizando modelos de regressão múltipla.....	132
6.1.1 Primeira etapa: modelagem da estimativa dos desvios da peça utilizando modelo de otimização de múltiplas respostas.....	132
6.1.2 Segunda etapa: estimativa do melhor conjunto de parâmetros que otimiza os desvios da peça utilizando modelo de otimização de múltiplas respostas.....	134
6.1.3 Considerações finais.....	138
6.2 Desenvolvimento do modelo da estimativa e otimização dos desvios utilizando RNA.....	138
6.2.1 Primeira etapa: modelagem da estimativa dos desvios da peça utilizando modelo de RNA.....	138
6.2.2 Segunda etapa: estimativa do melhor conjunto de parâmetros que otimiza os desvios da peça utilizando modelos de RNA.....	145
6.2.3 Considerações preliminares.....	150
7 TESTES DE VALIDAÇÃO DOS MODELOS DE ESTIMATIVA E OTIMIZAÇÃO DE DESVIOS.....	151
7.1 Realização dos testes de validação dos modelos de estimativa e otimização de desvios.....	151
7.2 Considerações finais.....	155
8 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS.....	158
ABSTRACT.....	162
REFERÊNCIAS.....	163
ANEXO E APÊNDICES.....	170

## LISTA DE FIGURAS

FIGURA 2.1 - Chocalhos de bebê produzidos pela técnica de termoformagem por sopro.....	34
FIGURA 2.2 - Principais etapas do processo de termoformagem.....	35
FIGURA 2.3 - Principais componentes do processo de termoformagem a vácuo.....	37
FIGURA 2.4 - Desenho básico do equipamento de termoformagem a vácuo e seus componentes.....	39
FIGURA 2.5 - Exemplos de aplicação industrial de produtos termoformados.	39
FIGURA 2.6 - Gráfico de temperatura vs volume específico para diversos polímeros.....	41
FIGURA 2.7 - Exemplificação da retenção do sentido de retração.....	42
FIGURA 2.8 - Exemplo prático do efeito da laminação sobre o sentido de retração.....	43
FIGURA 2.9 - Valores de condutividade térmica e difusão térmica de alguns materiais.....	44
FIGURA 2.10 - Temperaturas locais na placa em função do tempo no caso hipotético de existir um tempo ótimo.....	45
FIGURA 2.11 - a) Curva dos valores entalpia para diversos polímeros; b) Curva dos valores de calor específico de diversos polímeros.....	46
FIGURA 2.12 - Exemplo de elementos térmicos utilizados nos sistemas de aquecimento de equipamento de termoformagem a vácuo.....	47
FIGURA 2.13 - a) Distribuição de temperatura na placa do polímero (efeito <i>energy uptake</i> ); b) Distribuição de temperatura ideal por um sistema de aquecimento.....	48
FIGURA 2.14 - Gráfico conjunto do tempo de aquecimento e arrefecimento vs temperatura e espessura de uma placa de PET 1,5 mm.....	49
FIGURA 2.15 - Tempo vs temperaturas ao longo da espessura de uma placa de PS 2,1 mm.....	49
FIGURA 2.16 - Interação entre a folha quente e o molde frio e suas respectivas mudanças de temperatura.....	51

FIGURA 2.17 - a) Peça fabricada com molde negativo com suas espessuras locais; b) peça fabricada com molde positivo com suas espessuras pontuais.	52
FIGURA 2.18 - Exemplos de aplicação de moldes para termoformagem: a) Molde em madeira do protetor de roda de um veículo; b) Molde para copos descartáveis.....	53
FIGURA 2.19 - Exemplos de materiais aplicados a moldes para termoformagem a) Molde em resina epóxi fundido BC7136 ; b) Molde em uretano fundido BC8010 e;.c) Molde em compósito METAPOR HD 210 AL.....	54
FIGURA 2.20 - Exemplo de orifícios para sucção de ar entre molde e folha; a) Canal; b) Furo.....	54
FIGURA 2.21 - Recomendações quanto à localização e à disposição dos furos de sucções.....	55
FIGURA 2.22 - a) Moldes positivos; b) Moldes negativos.....	55
FIGURA 2.23 - a) Exemplo de termoformagem com molde positivo; b) Exemplo de termoformagem com molde negativo.....	56
FIGURA 2.24 - Efeito da temperatura sobre o módulo de elasticidade de polipropileno homopolímero, policloreto de vinila e copolímero de olefin cíclico.....	57
FIGURA 2.25 - Variação de 10% espessura ao longo do contorno para placas grossas e variabilidade de 5% entre dias mensurados.....	59
FIGURA 2.26 - Exemplo de variação de espessura pontual em produtos fabricados com folhas finas.....	59
FIGURA 2.27 - Simulação de espessura ao longo do contorno de sua geometria.....	60
FIGURA 2.28 - Possíveis defeitos relacionados ao projeto da geometria da peça.....	61
FIGURA 2.29 - Valores de tolerâncias gerais para produtos termoformados	62
FIGURA 2.30 - Método de aproximação utilizando um RNA.....	63
FIGURA 2.31 - Síntese dos sistemas convencionais e os sistemas baseados em conhecimento.....	64
FIGURA 2.32 - Estrutura de um sistema baseado em conhecimento.....	65
FIGURA 2.33 - Estrutura básica de um sistema <i>fuzzy</i> .....	66
FIGURA 2.34 - Exemplo hipotético do processo <i>fuzzy</i> .....	67

FIGURA 2.35 - Fluxograma de um algoritmo genético básico.....	69
FIGURA 2.36 - Visão geral: o fluxo de atividade de um algoritmo genético.	71
FIGURA 2.37 - Visão esquemática de um neurônio.....	72
FIGURA 2.38 - Visão esquemática de uma rede neural <i>feed-forward</i> .....	73
FIGURA 2.39 - Comparação das funções de transferência: (a) <i>Hardlime</i> ; (b) <i>Purlin</i> .....	75
FIGURA 2.40 - Arquitetura da genética de MLP.....	76
FIGURA 2.41 - Comparação dos processos de propagação do erro $\delta$ : (a) BP e; (b) LM.....	79
FIGURA 2.42 - Comparação das funções de transferência: (a) <i>Logsig e</i> ; (b) <i>Tansig</i> .....	82
FIGURA 3.1 - Diagrama de fluxo da metodologia de pesquisa adotada.....	89
FIGURA 3.2 - a) Chapa de PS; b) Folha cortada no dimensional de trabalho e limpa; c) pacote de folhas.....	90
FIGURA 3.3 - a) Bloco de MDF utilizado para fabricação do molde; b) Bloco de alumínio utilizado para fabricação do molde.....	91
FIGURA 3.4 - a) Centro de usinagem CNC ROMI <i>Discovery 560</i> ; b) MMC TESA Micro-Hite 3D.....	92
FIGURA 3.5 – Máquina de termoformagem modelo VFBPD 3036, Branel Máquinas.....	92
FIGURA 3.6 - Fluxo de atividades do desenvolvimento do projeto do produto.....	94
FIGURA 3.7 - Fluxo de atividades do desenvolvimento molde/matriz.....	95
FIGURA 3.8 - Montagem final da bancada de testes para desenvolvimento do trabalho experimental.....	96
FIGURA 3.9 - Definição de desvio dimensional da altura total do produto: componentes.....	97
FIGURA 3.10 - Coleta de pontos para determinação dos planos de medição com sistema de controle dimensional MMC 3D.....	98
FIGURA 3.11 - Definição do desvio geométrico de planeza do fundo da peça: componentes.....	99
FIGURA 3.12 - Definição do desvio geométrico do ângulo lateral da peça: componentes.....	100



FIGURA 3.13 - Definição do desvio dimensional do comprimento diagonal superior: componentes.....	101
FIGURA 3.14 - Procedimento de medição do desvio dimensional da diagonal.....	102
FIGURA 4.1 - Esquematização do processo de produção das peças.....	109
FIGURA 6.1 - Representação esquemática do algoritmo de cálculo do modelo otimização de múltiplas respostas utilizado na pesquisa.....	134
FIGURA 6.2 - Estrutura genérica da RNA proposta para o desenvolvimento da pesquisa.....	140
FIGURA 6.3 - Gráficos de superfície do tempo de aquecimento vs potência de aquecimento vs desvio médio da altura total do produto: a) modelo "V" e; b) modelo "Z".....	143

## LISTA DE GRÁFICOS

GRÁFICO 4.1 - Distribuição gráfica dos valores de desvios das amostras: testes exploratórios.....	111
GRÁFICO 4.2 - Probabilidade da estimativa dos efeitos vs desvio dimensional da altura total da peça ( $\alpha=0,05$ ).....	112
GRÁFICO 4.3 - Probabilidade normal da estimativa dos efeitos vs desvio geométrico de planeza do fundo da peça ( $\alpha=0,05$ ).....	113
GRÁFICO 4.4 - Probabilidade da estimativa dos efeitos vs desvio geométrico médio dos ângulos laterais da peça ( $\alpha=0,05$ ).....	114
GRÁFICO 4.5 - Probabilidade da estimativa dos efeitos vs desvio dimensional do comprimento da diagonal da peça ( $\alpha=0,05$ ).....	114
GRÁFICO 5.1 - Distribuição gráfica dos valores de desvios das amostras: testes experimentais.....	120
GRÁFICO 5.2 - Probabilidade da estimativa dos efeitos vs desvio dimensional da altura total da peça ( $\alpha=0,05$ ).....	121
GRÁFICO 5.3 - Probabilidade normal da estimativa dos efeitos vs desvio geométrico de planeza do fundo da peça ( $\alpha=0,05$ ).....	122
GRÁFICO 5.4 - Probabilidade da estimativa dos efeitos desvio geométrico médio dos ângulos laterais da peça ( $\alpha=0,05$ ).....	122
GRÁFICO 5.5 - Probabilidade da estimativa dos efeitos vs desvio dimensional do comprimento da diagonal da peça ( $\alpha=0,05$ ).....	123
GRÁFICO 5.6 - Interações dos fatores vs desvio dimensional da altura total da peça.....	125
GRÁFICO 5.7 - Interações dos fatores vs desvio geométrico de planeza do fundo da peça.....	126
GRÁFICO 5.8 - Interações dos fatores vs desvio geométrico médio dos ângulos laterais da peça.....	127
GRÁFICO 5.9 - Interações dos fatores vs desvio dimensional do comprimento da diagonal da peça.....	128
GRÁFICO 5.10 - Solução conjunta da otimização das respostas para o desvio dimensional e geométrico da peça.....	130

GRÁFICO 6.1 - Modelos desenvolvidos vs desvio dimensional da altura total.....	144
GRÁFICO 6.2 - Modelos desenvolvidos vs desvio geométrico de planeza do fundo.....	144
GRÁFICO 6.3 - Modelos desenvolvidos vs desvio geométrico médio dos ângulos laterais.....	145
GRÁFICO 6.4 - Modelos desenvolvidos vs desvio dimensional do comprimento da diagonal.....	145
GRÁFICO 6.5 - Solução conjunta da estimativa dos efeitos principais vs desvios dimensionais e geométricos analisados: testes experimentais.....	149
GRÁFICO 7.1 - Valores das médias dos desvios dimensionais e geométricos das peças por tipo de modelo de otimização testado.....	156
GRÁFICO 7.2 - Erro das estimativas sobre as amostras por tipo de modelo de otimização desenvolvido.....	157

## LISTA DE QUADROS

QUADRO 4.1 – Fatores e seus níveis de variação: testes exploratórios.....	108
QUADRO 5.1 – Fatores e seus níveis de variação: testes experimentais...	117

## LISTA DE TABELAS

TABELA 4.1 - Desvios mensurados nas amostras: testes exploratórios.....	110
TABELA 4.2 - Resumo da ANOVA para os efeitos das fontes de variação sobre os desvios dimensionais e geométricos nas amostras: testes exploratórios.....	115
TABELA 5.1 - Desvios mensurados nas amostras: testes experimentais....	119
TABELA 5.2 - Resumo da ANOVA para os efeitos das fontes de variação sobre os desvios dimensionais e geométricos nas amostras: testes experimentais.....	124
TABELA 6.1 - Resumo das análises dos desempenhos dos modelos de regressão múltipla para os desvios dimensionais e geométricos da peça...	133
TABELA 6.2 - Espaço de busca e discretização utilizados no primeiro processo de busca.....	136
TABELA 6.3 - Resumo das melhores classificações da primeira etapa de estimativa de parâmetros ótimos para a otimização dos desvios dimensionais e geométricos da peça utilizando MOMR.....	136
TABELA 6.4 - Espaço de busca e discretização utilizados no segundo processo de busca.....	137
TABELA 6.5 - Resumo das melhores classificações da segunda etapa de estimativa de parâmetros ótimos para a otimização dos desvios dimensionais e geométricos da peça utilizando MOMR.....	137
TABELA 6.6 - Exemplo da codificação realizada para treinamento da rede.	139
TABELA 6.7 - Resumo das principais características e valores de desempenho dos modelos de RNA desenvolvidos e testados.....	142
TABELA 6.8 - Resumo das melhores classificações da primeira etapa de estimativa de parâmetros ótimos para a otimização dos desvios dimensionais e geométricos da peça utilizando RNA.....	146
TABELA 6.9 - Resumo das melhores classificações da segunda etapa de estimativa de parâmetros ótimos para a otimização dos desvios dimensionais e geométricos da peça utilizando RNA.....	147
TABELA 7.1 - Fatores e níveis desenvolvidos para testes de validação dos modelos de estimativa e otimização de desvios.....	152

TABELA 7.2 - Resumo dos resultados nas peças do teste com o MOMR 01.....	153
TABELA 7.3 - Resumo dos resultados nas peças do teste com o MOMR 02.....	154
TABELA 7.4 - Resumo dos resultados nas peças do teste com o MORNA 01.....	154
TABELA 7.5 - Resumo dos resultados nas peças do teste com o MORNA 02.....	155

## LISTA DE ABREVIATURAS E SIGLAS

ABS	Acrilonitrilo butadieno estireno
ADALINE	<i>Adaptive Linear Neuron Networks</i>
AG	Algoritmo genético
AI	Inteligência artificial
AL	Alumínio
ALMP	Ângulo lateral mensurado na peça
ALPP	Ângulo lateral previsto no projeto da peça
ANOVA	Análise de variância
ATI	<i>Associated Thermoforming, Inc</i>
ATP	Altura total da peça
ATPP	Altura total do projeto da peça
BP	<i>Back-propagation</i>
CAD	<i>Computer-aided design</i>
CAI	<i>Computer-Aided Inspection</i>
CAM	<i>Computer-Aided Manufacturing</i>
CAPES	Coordenadoria de Aperfeiçoamento de Pessoal de Ensino Superior
CDMP	Comprimento mensurado na peça
CDPP	Comprimento da diagonal superior previsto no projeto da peça
CE	Computação evolutiva
CIM	Manufatura Integrada por Computador
cm	Centímetro
cm/s	Centímetro por segundo
CNC	<i>Computer Numeric Control</i>
CSTR	<i>Continuous stirred-tank reactor model</i>
DDATP	Desvio dimensional da altura total da peça
DDCDP	Desvio dimensional do comprimento da diagonal superior da peça
DDGP	Dimensionais e geométricos da peça
DGALP	Desvio geométrico de um dos ângulos laterais da peça
DGMALP	Desvio geométrico médio dos ângulos laterais da peça
DGPFP	Desvio geométrico de planeza do fundo da peça
DPFM	Desvio de planeza do fundo do molde

EQ.	Equação
EUA	Estados Unidos da América
FEA	<i>Finite Element Analysis</i>
FMS	Sistemas flexíveis de manufatura
FSW	<i>Friction Stir Welding</i>
GL	Grau de liberdade
<i>hardlim</i>	Função de transferência neural com limites determinados
HDPE	Polietileno de Alta Densidade
HIPS	Poliestireno de alto impacto
IC	Inteligência computacional
KBS	<i>Knowledge Based Systems</i>
Kcal	Quilocaloria
kg	Quilograma
km	Quilômetro
kW	Kilo Watt
LEPAM	Laboratório de Engenharia e Processos Avançados de Manufatura
LI	Limite inferior
LM	<i>Levenberg-Marquardt</i>
LMS	<i>Least Mean Squared</i>
LS	Limite superior
m	Metro
MAE	<i>Mean Absolute Error</i>
Máx	Maximização
mbar	Millibar
MDF	<i>Medium density fiberboard</i>
ME	<i>Mean error</i>
MEF	Método dos Elementos Finitos
Mín	Minimização
MLP	<i>Multi-layer perceptron</i>
mm	Milímetro
MMC	Máquinas de medir por coordenadas
MOMR	Modelos de otimização de múltiplas respostas
MPC	<i>Model Predictive Control</i>
MQ	Médias Quadráticas



MQ <sub>E</sub>	Média Quadrática do Erro
MQ <sub>i</sub>	MQ ajustada
MRM	Modelo de Regressão Múltipla
MSE	<i>Mean Squared Error</i>
<i>Mu</i>	<i>Momentum constant</i>
n <sup>o</sup>	Número
PC	Policarbonato
PE	Polietileno
PET	Politereftalato de etileno
PFF	Planejamento fatorial fracionado
pH	Potencial hidrogeniônico
pol.	Polegada
PP	Polipropileno
PS	Poliestireno
purelin	Função de transferência Neural linear
PVC	Policloreto de vinila
RLM	Regressão linear múltipla
RMR	Regressão multirresposta
RNA	Redes neurais artificiais
RP	Engenharia reversa
s	Segundo
SQ	Somas dos quadrados
SQ <sub>E</sub>	Soma dos Quadrados do Erro
SQ <sub>i</sub>	Soma dos quadrados de um fator <i>i</i>
SQ <sub>T</sub>	Soma dos Quadrados Totais
SSE	<i>Squared Error</i>
T	Total
TG	<i>Glass transition</i>
UCLM	<i>Universidad de Castilla-La Mancha</i>
UEMG	Universidade do Estado de Minas Gerais
UFMG	Unniversidade Federal de Minas Gerais
vs	<i>Versus</i>
W	Watt

## NOMENCLATURA

### Símbolos

%	Por cento
>	Para
±	Mais ou menos
≈	Aproximadamente
≤	Menor ou igual
3D	Tridimensional
$D_i$	Valor da <i>i</i> -ésima saída desejada para o neurônio <i>j</i>
E	Elevado à potência de
$e_j$	Erro calculado para o neurônio <i>j</i>
F	Grau Fahrenheit
$f(.)$	Função de ativação
G	Solução do algoritmo decrescente do gradiente ( <i>Descent Algorithm</i> )
H	Aproximação da matriz <i>Hessiana</i>
<i>i</i>	<i>Index ou índice</i>
I	Matriz identidade
<i>j</i>	Índice do <i>j</i> -ésimo item
J	Matriz jacobiana
<i>k</i>	Índice do regressor
K	Número de saídas da rede da RNA
l	<i>Layer</i> ou camada de uma RNA
<i>n</i>	Número de padrões apresentados à rede
n	Número de amostras do fator
<i>net</i>	Função de ativação de entrada da RNA
<i>p</i>	Índice de interação da RNA
<i>t</i>	distância entre os dois planos ideais projetados
$R^2$	Coeficiente de determinação
S	Desvio-padrão da amostra
<i>u</i>	<i>Momentum constant</i>
<i>u</i>	Saída linear de um neurônio artificial
V1	Grau de liberdade do fator

$V_2$	Grau de liberdade do erro total
$x$	Variável independente ou regresso
$x_i$	Valor <i>i-ésima</i> entrada de um neurônio
$X$	Vetor ou matriz de valores de entrada da rede neural artificial
$\bar{X}$	Média da amostra
$W$	Vetor de pesos de um neurônio artificial ou RNA
$w_i$	Peso da <i>i-ésima</i> entrada de um neurônio artificial
$w_{ji}$	Peso da <i>i-ésima</i> entrada de um do <i>j-ésimo</i> neurônio
$y^j$	Valor <i>i-ésima</i> de saída do neurônio artificial
$y_{ik}$	<i>k-ésima</i> observação sujeita ao <i>i-ésimo</i> tratamento
$Y$	Variável dependente ou de resposta
$^{\circ}\text{C}$	Grau Celsius
$\theta$	Bias
$\varphi$	Função de ativação
$\lambda$	Fator escalar da funções de ativação
$\alpha$	Taxa de aprendizagem da RNA
$\alpha$	Nível de significância
$\beta$	Coeficientes de regressão
$\delta$	Termo de propagação de erro
$\mu$	Coeficiente de combinação
$\varepsilon$	Termo de erro aleatório

## RESUMO

No processo de termoformagem a vácuo, a qualidade final da peça depende de diversas variantes do sistema, que tornam a sua modelagem matemática computacional um processo complexo multivariável e de objetivos conflitantes. Por conseguinte, as expectativas quanto aos desvios do produto são, por vezes, subjetivas e dependentes do conhecimento prévio do executor. Neste sentido, este trabalho desenvolveu modelos utilizando Redes Neurais Artificiais (RNA) visando à correta previsão e minimização dos valores dos desvios das peças termoformadas a vácuo em limites admissíveis de tolerância. Para tal, foram produzidas amostras em testes exploratórios, experimentais e de validação de uma peça típica em Poliestireno (PS), por meio do planejamento fatorial fracionado ( $2^{k-p}$ ). Este estudo inicial permitiu identificar que todos os fatores principais são significativos em pelo menos um dos desvios dimensionais ou geométricos da peça. Posteriormente, foram programadas e testadas RNA com diversas estruturas e configurações e comparativamente Modelos de Otimização de Múltiplas Respostas (MOMR). Os resultados mostraram que os modelos de RNA e MOMR foram capazes de convergir para configurações de parâmetros de fabricação que otimizam os desvios da peça, entretanto, só os modelos com RNA conseguiram obter erros de estimativa dentro dos limites dos valores encontrados nos testes de validação. Assim, demonstrou-se que os modelos com RNA são propostas promissoras para o desenvolvimento de modelos e algoritmos que estimem e minimizem desvios de peças termoformadas a vácuo.

**Palavras-chave:** Termoformagem a vácuo. Redes Neurais Artificiais. Desvios dimensionais e geométricos. Planejamento e Análise de Experimentos.

# 1 INTRODUÇÃO

A fabricação de produtos utilizando plásticos teve grande impulso nos anos 60, sendo uma das tecnologias responsáveis em grande parte pelo desenvolvimento industrial e redução do custo final de produtos, e ainda é um dos processos de manufatura que mais evoluíram nas últimas décadas (THRONE, 2008). Nesse segmento, o setor de produção de produtos plásticos termoformados sustenta, há quase meio século, crescimento anual constante de 5-6% na indústria norte-americana (MURALISRINIVASAN, 2009). Segundo Throne (2011), estima-se que em 2007 a indústria sul-americana tenha manufaturado 540 milhões de quilogramas (kg) de produtos termoformados, com faturamento estimado em 26 milhões de dólares por ano.

Nesse contexto, a termoformagem a vácuo, ou *vacuum forming*, é o método que envolve a conformação de uma folha de termoplástico pré-aquecido por meio da pressão de vácuo produzido no espaço da cavidade do molde, sendo capaz de produzir peças plásticas em alto volume para várias aplicações industriais e comumente usadas em embalagens de alimentos e produtos. Segundo Yang e Hung (2004a), embora esse processo tenha sido desenvolvido há mais de três décadas, ainda existem problemas não resolvidos que dificultam o sucesso global do uso dessa tecnologia, como, por exemplo, a não uniformidade da espessura local de peça causada, algumas vezes, pelo conflito de objetivos existente entre os aspectos de qualidade e os ajustes das variáveis de controle do processo.

O que se vê, na prática, é que a capacidade real do processo é de difícil previsibilidade e depende do conhecimento prévio ou aprendizagem do executor. A avaliação do desempenho do sistema normalmente é subjetiva, devido à natureza dos subprocessos e da ação de fatores como matéria-prima do molde, ambiente de fabricação, características do equipamento, tipo e matéria-prima da folha e parâmetros de fabricação, que exercem papel predominante no resultado final. Isso, por vezes, torna a modelagem matemática computacional do sistema um processo complexo multivariável, com características não lineares e de objetivos

conflitantes (ENGELMANN; SALMANG, 2012; KLEIN, 2009; THRONE, 2008; YANG, HUNG, 2004a).

Em sistemas como este, Meziane *et al.* (2000), Tadeusiewicz (2011) e Pham e Pham (2001) acreditam que as abordagens tradicionais para o controle do processo de manufatura não conseguem atender na totalidade ou são incapazes, muitas vezes, de resolver os problemas ou, ainda, não conseguem incluir aspectos "humanos" de controle de processo, como a imprecisão e indefinição, que são inerentes ao modelo mental do decisor.

Assim, tem-se desenvolvido nas últimas décadas o campo da inteligência computacional (IC) aplicada à manufatura, que se refere às pesquisas realizadas a partir de uma série de ferramentas computacionais para a resolução de problemas que requerem habilidades da inteligência humana para sua resolução ou modelagem (MEZIANE *et al.*, 2000; TADEUSIEWIC, 2011). O controle ou a previsão de parâmetros de produção vem sendo pesquisado mais intensivamente por meio da aplicação de redes neurais artificiais (RNA) desde os anos 80 (EFE, 2011; HUANG; ZHANG, 1994).

Essa área de investigação centra-se, principalmente, em técnicas que abordam o processo de aprendizagem e treinamento do cérebro humano como ferramenta para modelar e emular sistemas. Nesse caso, as RNAs surgem como um dos principais métodos utilizados na engenharia para modelagem computacional de problemas complexos que normalmente requerem a capacidade de aprendizagem para sua resolução e/ou tomada de decisões perante novas situações (MEZIANE *et al.*, 2000; TADEUSIEWIC, 2011). Entretanto, para o processo de termoformagem a vácuo o que se encontra na literatura são investigações pontuais na tentativa de obter um modelo matemático para problemas específicos.

Assim, alguns autores têm desenvolvido modelos com algoritmos baseados em técnicas de inteligência artificial ou otimização estatística para apenas uma característica de qualidade da peça, frequentemente a sua espessura, como as apresentadas por Yang e Hung (2004a; 2004b), Engelmann e Salmang (2012), Karjust, Küttner e Pohlak (2007), Velsker *et al.* (2011), e também a aplicação de

RNA para definição de parâmetros de processamento na obtenção de espessuras locais predefinidas, de Chang, Wen e Liu (2005). Essas pesquisas deixam aberta a análise dos demais desvios do produto e validação do método. Outras investigações encontradas na literatura concentram-se em estudos da modelagem ou controle do sistema de aquecimento, da temperatura da folha e da espessura da parede por diferentes métodos e técnicas.

Além disso, os trabalhos de Throne (1996, 2009 e 2011), Muralisrinivasan (2009), Klein, (2009) e Eneglmann (2012) limitam-se a apresentar cada peculiaridade do processo de forma separada e a descrever os problemas de fabricação (normalmente o processo de aquecimento ou espessura final) como eventos isolados de soluções pontuais, não abordando a modelagem do sistema e as relações conflitantes dos parâmetros de produção.

Então, fez-se necessária uma investigação que aborde de forma conjunta a fabricação e qualidade da peça e, posteriormente, a sua modelagem computacional, visando contribuir cientificamente para a compreensão e melhoria da previsibilidade do processo e, conseqüentemente, para a qualidade global do produto.

Diante do exposto, esta pesquisa pretendeu estudar três principais lacunas indicadas pela revisão da literatura sobre termoformagem a vácuo, para as quais se poderia contribuir, sendo:

- a) O estudo dos parâmetros de fabricação para determinar suas influências na qualidade global da peça;
- b) a análise conjunta das influências dos parâmetros de fabricação *versus* (vs) os desvios dimensionais e geométricos do produto e;
- c) o estudo e validação da aplicabilidade do uso das RNAs para modelar os parâmetros de fabricação significativos e otimizar (minimizar) os desvios do produto por meio da programação de modelos computacionais.

Esses resultados experimentais permitiram o desenvolvimento de modelos computacionais de multivariáveis com o objetivo de obter correta previsão dos

parâmetros de fabricação e dos desvios em diversas situações, as quais permitam a produção de peças dentro de limites ótimos de qualidade para a geometria da peça estudada. O conjunto de parâmetros de fabricação estudados são: tempo de aquecimento, potência de aquecimento, parâmetros de atuação do molde, tempo de vácuo e pressão de vácuo.

## 1.1 Objetivos

O objetivo principal deste trabalho é desenvolver modelos computacionais utilizando algoritmos baseados em Redes Neurais Artificiais que corretamente estimem e minimizem valores dos desvios dimensionais e geométricos em peças termoformadas a vácuo.

Os principais objetivos específicos são:

- a) Desenvolver uma bancada de testes que propicie o desenvolvimento dos testes experimentais.
- b) Identificar e descrever as variáveis que influenciam no processo de fabricação de peças em PS termoformadas a vácuo.
- c) Testar e utilizar métodos de controle de qualidade para produtos de PS termoformados a vácuo.
- d) Analisar o desvio dimensional da altura total da peça, o desvio geométrico de planeza do fundo da peça, o desvio geométrico médio dos ângulos laterais da peça e o desvio dimensional do comprimento da diagonal superior da peça, associando-os aos parâmetros de fabricação matéria-prima do molde, espessura da folha, tempo de aquecimento, potência de aquecimento, parâmetros de atuação do molde (pressão e velocidade), tempo de vácuo e pressão de vácuo.
- e) Modelar e simular computacionalmente fatores que interferem no controle do processo de termoformagem a vácuo conjuntamente com os desvios da peça.



- f) Desenvolver e testar modelos computacionais de otimização que utilizam algoritmos de RNAs (MORNA) para estimar e otimizar desvios de peças termoformadas a vácuo de PS.
- g) Desenvolver modelo de otimização de múltiplas respostas dos valores dos desvios da peça e comparar seus desempenhos com os MORNAS.
- h) Comparar resultados experimentais e previsões de modelos computacionais de otimização dos desvios de peças termoformadas a vácuo de PS.
- i) Verificar a eficiência dos modelos computacionais desenvolvidos por meio de testes de validação.

## **1.2 Organização da tese**

Este trabalho é dividido em oito capítulos, sendo: capítulo 1 - Introdução; capítulo 2 - Revisão Bibliográfica; capítulo 3 - Material e Métodos; capítulo 4 - Testes Exploratórios; capítulo 5 - Testes Experimentais; capítulo 6 - Desenvolvimento dos modelos de previsão e otimização; capítulo 7 - Testes de validação dos modelos desenvolvidos; capítulo 8 - Conclusões e sugestões para trabalhos futuros.

O capítulo 2 apresenta ao leitor uma revisão geral e básica dos princípios e teorias da manufatura de peças termoformadas a vácuo e tópicos correlacionados. Nele são descritos primeiramente o processo de termoformagem a vácuo e teorias relacionadas, depois teorias e técnicas de inteligência computacional em processo de manufatura e, por fim, de forma sucinta, equaciona testes estatísticos para dados amostrais juntamente com técnicas de regressão.

O capítulo 3 descreve a metodologia de desenvolvimento, os materiais, os equipamentos e as ferramentas computacionais utilizadas e também, de forma breve, a montagem do sistema de testes. Por fim, são descritos e equacionados os desvios e análises abordadas, bem como os métodos de medição utilizados.

No capítulo 4 discorre-se sobre o procedimento experimental realizado para o desenvolvimento dos testes iniciais exploratórios, iniciando-se pelo planejamento experimental, posteriormente pela realização dos testes, medições e análises das

peças. Em seguida, nas considerações iniciais são discutidos os fatores significativos e as relações entre parâmetros de fabricação e desvios, juntamente com algumas conclusões iniciais.

Já o capítulo 5 relata o desenvolvimento dos testes experimentais que seguem as mesmas etapas dos testes exploratórios. Entretanto, nesse capítulo é aprofundada a análise dos parâmetros de fabricação vs os desvios do produto e, ainda, são discutidos e apresentados os dados que serão utilizados para o desenvolvimento dos modelos de previsão e otimização dos desvios.

No capítulo 6 são abordados procedimentos e metodologias utilizados para o desenvolvimento dos modelos computacionais de regressão multirresposta (RMR) e RNA, desenvolvidos para prever as configurações dos parâmetros ótimos de fabricação e estimar os desvios do produto. E ainda serão feitas análises e discussões sobre a seleção dos melhores modelos a serem adotados juntamente com os valores de previsão para cada modelo.

O capítulo 7 trata do desenvolvimento dos testes de validação dos modelos computacionais desenvolvidos e também de seus resultados, as análises das aproximações e a comparação da eficiência de aproximação entre os modelos. Por fim, tabelas e gráficos são utilizados para comparativos dos resultados dos quatro modelos e conclusões preliminares.

Por último, o capítulo 8 faz a síntese das principais conclusões a respeito da metodologia experimental utilizada, dos resultados relativos às etapas de testes experimentais e testes de validação, da eficiência de aproximação dos modelos computacionais, bem como dos modelos computacionais desenvolvidos. São feitas, ainda, algumas sugestões para trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 O processo de termoformagem a vácuo

#### 2.1.1 A termoformagem

Os primórdios das técnicas de termoformagem são datados da pré-história quando no Egito e Micronésia folhas de Tortoise (queratina) eram aquecidas em óleo quente dentro de fôrmas (moldes) para produzir embalagens de alimentos. Já na época moderna, em 1870 nos Estados Unidos da América (EUA), John Wesley Hyatt e Charles Burroughs desenvolveram técnicas para moldar folhas de nitrato de celuloide (celulose) submetidas a vapor e pressão em moldes de aço. Produtos típicos desse processo e época são pequenas garrafas, molduras e chocalhos de bebê como o apresentando na FIG. 2.1, produzidos em 1890 por Hyatt em celulose pela técnica de termoformagem por sopro (THRONE, 2008).



FIGURA 2.1 - Chocalhos de bebê produzidos pela técnica de termoformagem por sopro.

Fonte: Throne (2008).

Atualmente, a termoformagem é um termo genérico para um grupo de processos de manufatura de termoplásticos tais como a termoformagem a vácuo (*vacuum forming*), termoformagem a vácuo pela técnica de dobras (*drape forming*),

termoformagem a vácuo com uso de pressão de ar positiva (*air-slip forming*) e outras técnicas pouco usadas, como a *billow or free bubble forming*, *mechanical bending*, *matched-mold forming* e *twin-sheet forming* (THRONE, 2008).

Segundo Klein (2009) e Muralisrinivasan (2009), independentemente do processo adotado, hoje a termoformagem engloba basicamente quatro técnicas de processamento que utilizam algum tipo de "força" para moldar uma folha de termoplástico aquecida durante o processo de fabricação, sendo estas: 1ª) a pressão mecânica aplicada diretamente sobre a folha; 2ª) a pressão de vácuo produzida entre a folha e o molde; 3ª) a pressão de ar aplicada na folha do lado oposto ao molde e; 4ª) combinações dessas forças.

De forma geral, as etapas típicas desse processo são mostradas na FIG. 2.2, sendo: a) preparação de folha; b) fixação da folha no equipamento; c) aquecimento da folha até a sua temperatura de conformação e/ou estiramento; d) travamento da folha e/ou retirada do sistema de aquecimento; e) opcionalmente, pré-estiramento; f) moldagem da folha utilizando algum tipo de principal força e, opcionalmente, uma secundária; g) resfriamento da peça até a temperatura em que a nova forma seja permanente; h) desmontagem da peça e retirada do sobrematerial e/ou rebarbas (MURALISRINIVASAN, 2009). A FIG. 2.2 apresenta as principais etapas do processo de termoformagem.




FIGURA 2.2 - Principais etapas do processo de termoformagem.

Fonte: adaptado de: Muralisrinivasan (2009).

### 2.1.2 A técnica de termoformagem a vácuo

Diversos autores apresentam variadas definições para a termoformagem a vácuo, também conhecida por *vacuum forming*. Throne (1996) define a técnica como o processo no qual a pressão negativa (vácuo) é usada para modelar uma folha pré-aquecida sobre a cavidade do molde. De forma similar, Klein (2009) define como o processo em que a força de vácuo obtida pela pressão atmosférica negativa é usada para forçar uma folha aquecida contra a superfície "fria" do molde, a qual adquire o seu formato. Já Muralisrinivasan (2009) reconhece que é umas das técnicas mais antigas de moldar a vácuo, na qual uma folha no início do seu ciclo de aquecimento é forçada contra a parte interior de um molde negativo. Macarrão (2004) complementa que é o processo no qual apenas "meio" molde é suficiente para moldar folhas de termoplásticos.

Mediante essas definições, pode-se afirmar que a termoformagem a vácuo pode ser descrita como a técnica de conformação e/ou estiramento de peças em material termoplástico pré-aquecido por meio da utilização da força obtida por intermédio da pressão de vácuo negativa produzida no espaço da cavidade do molde, sendo capaz de produzir peças plásticas em alto volume para várias aplicações industriais e comumente usadas em embalagens de alimentos e produtos. De forma similar, a FIG. 2.2 supra-apresentada exemplifica de forma geral a sequência básica das subetapas desse processo de fabricação. Segundo Yang e Hung (2004a), embora esse processo tenha sido desenvolvido há mais de três décadas, ainda existem problemas não resolvidos que dificultam o sucesso global do uso dessa tecnologia, como, por exemplo, a não uniformidade da espessura local de peça, causada algumas vezes pelo conflito de objetivos existente entre os aspectos de qualidade e os ajustes das variáveis de controle do processo.

O que se vê, na prática, é que a capacidade real do processo é de difícil previsibilidade e depende do conhecimento prévio ou aprendizagem do executor. A avaliação do desempenho do sistema normalmente é subjetiva, devido à natureza dos subprocessos e da ação de fatores como matéria-prima do molde, ambiente de fabricação, características do equipamento, tipo e matéria-prima da folha e parâmetros de fabricação, que exercem papel predominante no resultado final.

Isso, por vezes, torna a modelagem matemática computacional do sistema um processo complexo multivariável, com características não lineares e de objetivos conflitantes (ENGELMANN; SALMANG, 2012; KLEIN, 2009; THRONE, 2008; YANG, HUNG, 2004a).

De forma específica, o que acontece nesse processo de termoformagem é que, após a folha do polímero ser aquecida por um sistema de aquecimento, ela é forçada contra o molde (positivo ou negativo), que possui orifícios de sucção em torno das regiões mais profundas e de áreas que exigem detalhes nítidos. Então, por meio de um sistema de bomba de vácuo, o ar é "sugado" no espaço entre a folha aquecida (cavidade) e o molde, fazendo com que a placa aquecida entre em contato com o molde e assuma a sua forma (MURALISRINIVASAN, 2009; THRONE, 1996). Na FIG. 2.3 encontram-se os principais componentes desse processo.

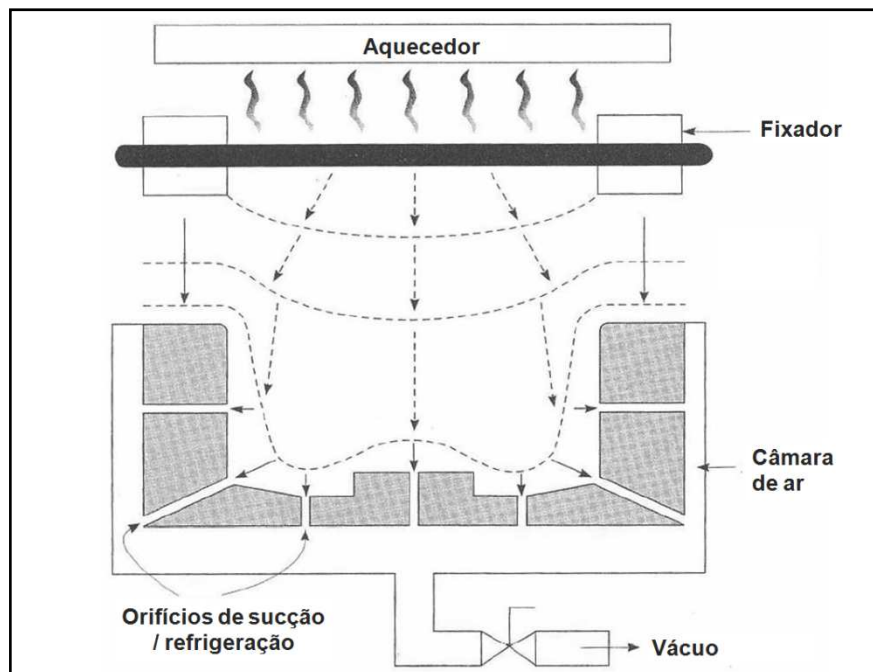


FIGURA 2.3 - Principais componentes do processo de termoformagem a vácuo.

Fonte: adaptado de: Karjust, Küttner e Pohlak (2007).

Como descrito, o processamento começa pelo aumento da temperatura da folha por um sistema de aquecimento para os polímeros amorfos, o que representa cerca de 80% de todos os polímeros que são termoformados. Esse aquecimento se

estende até uma "faixa" um pouco acima de sua temperatura de transição vítrea (TG - *Glass Transition*), como, por exemplo, o poliestireno (PS), o policloreto de vinila (PVC), o policarbonato (PC), o poliestireno de alto impacto (HIPS), o acrilonitrilo-butadieno-estireno (ABS) e outros. Já para materiais cristalinos ou semicristalinos utilizados na termoformagem, citam-se o polietileno (PE) e o polipropileno (PP) pelo aquecimento da folha um pouco abaixo do ponto de fusão. Os valores utilizados na prática são normalmente tabelados por fabricantes de matéria-prima, pela literatura específica, ou definidos em testes práticos (MURALISRINIVASAN, 2009; THRONE, 2008).

Ainda quanto ao tipo de matéria-prima, ela pode ser apresentada na forma de chapas ou bobinas com até 1.000 m de comprimento e sua espessura pode variar de 0,05 a 8 mm. Normalmente, nesse processo o material pode ser classificado de acordo com a espessura da chapa ou calibre, sendo: as películas, os filmes, as lâminas ou as bobinas com espessuras menores que 0,25 mm geralmente usadas para embalar produtos, nomeada como *blisters*; as chapas finas, as de calibre fino ou *light-gauge* são as chapas ou bobinas de 0,25 a 1,5 mm, usadas principalmente para embalagens rígidas ou descartáveis; e as chapas de calibre grosso, chapas espessas ou *heavy gauge* são as que possuem espessuras maiores que 3 mm, utilizadas em peças de automóveis, cabines de jipes e equipamentos eletrônicos, etc. (MURALISRINIVASAN, 2009; THRONE, 1996).

Quanto aos equipamentos utilizados nesse processo, inicialmente os mesmos eram de acionamento manual, dotados de um sistema de aquecimento, um sistema de vácuo e uma estrutura de suporte. Na atualidade, as máquinas de termoformagem a vácuo oferecem múltiplas possibilidades para produção de peças, assim, dependendo das necessidades de volume, de precisão, do acabamento, da dimensão da peça e outras características desejadas, podem ser propostos determinados equipamentos mecanizados, automatizados ou sistemas flexíveis de manufatura (FMS) (ENGELMANN; SALMANG, 2012). Mas, sinteticamente, pode-se considerar que os equipamentos comerciais para baixa/média produção (12 a 60 peças/hora) são compostos das seguintes partes: a) sistema de aquecimento; b) sistema de movimentação; c) estrutura de suporte; d) mesa de trabalho; e) sistema de vácuo; f) painel de controle; g) estrutura de

base (THRONE, 1996). A FIG. 2.4 apresenta o desenho básico do equipamento de termoformagem a vácuo e seus principais componentes.




FIGURA 2.4 - Desenho básico do equipamento de termoformagem e seus componentes.

Fonte: adaptado de Throne (1996).

Por meio deste processo é possível produzir peças de alta complexidade geométrica em larga escala industrial para diversas aplicações industriais, tais como: indústria alimentícia, cosméticos, equipamentos médicos, eletrônica, indústria automotiva, indústria aeronáutica, materiais de escritório, brinquedos e outros. A FIG. 2.5 mostra alguns exemplos de aplicações industriais de produtos termoformados que foram objeto de trabalhos de investigação na última década, sendo o copo descartável por Klein (2009) (FIG. 2.5a); a embalagem genérica para alimentos por Leite (2011) (FIG. 2.5b); e o gabinete interno de geladeira por Engelmann e Salmang (2012) (FIG.2.5c).




FIGURA 2.5 - Exemplos de aplicação industrial de produtos termoformados.

Fonte: Klein (2009); Leite (2011); Engelmann e Salmang (2012)



### 2.1.3 Principais propriedades dos materiais e parâmetros de fabricação que afetam a qualidade de peças termoformadas a vácuo

A qualidade final do produto termoformado a vácuo depende primeiramente da sequência completa do processo, ou seja, aquecimento, conformação e/ou estiramento por meio de vácuo, resfriamento e extração da peça. E esta, por sua vez, depende da matéria-prima utilizada, do ambiente de fabricação, do equipamento, dos moldes, etc., bem como dos parâmetros do processo como o tempo de aquecimento, a pressão de vácuo, a velocidade do molde, a espessura da folha, entre outros, que possuem características não lineares e de objetivos conflitantes (MURALISRINIVASAN, 2009; THRONE, 2008; YANG; HUNG 2004a).

Assim, embora os projetistas devam ter algumas expectativas quanto às tolerâncias dimensionais e a qualidade para peças termoformadas, infelizmente o número de variáveis envolvidas nesse processo torna-a uma atividade difícil. Segundo Klein (2009), no desenvolvimento de uma peça, até que seu molde seja fabricado de um determinado material, testado usando o equipamento e matéria-prima definidos pelo método e parâmetros escolhidos, a capacidade real do processo é de difícil previsibilidade e depende do conhecimento prévio ou aprendizagem do executor. Ao mesmo tempo, a avaliação do desempenho do sistema é, por vezes, subjetiva, devido à natureza dos subprocessos, sendo muito difícil a avaliação isolada do efeito principal de cada variável em cada passo do processo (ENGELMANN; SALMANG, 2012).

Assim, nessa gama de variáveis, interações e subprocessos possíveis, serão apresentadas a seguir algumas propriedades dos materiais e parâmetros de fabricação que afetam a qualidade de peças termoformadas a vácuo, conseqüentemente, o produto final.

#### 2.1.3.1 A retração térmica em polímeros no processo de termoformagem a vácuo

A retração térmica (*thermal shrinkage*) é uma das principais propriedades de um material polimérico termoformado. Quando o polímero é aquecido até sua

temperatura de conformação, o espaçamento entre suas moléculas aumenta e à medida que a temperatura do polímero é reduzida durante o seu processo de resfriamento com ou sem contato com o molde, há a gradativa redução de seu volume e o aumento da sua densidade, ou seja, sofre retração (THRONE, 2008). A FIG. 2.6 exibe graficamente esse processo.




FIGURA 2.6 - Gráfico de temperatura vs volume específico para diversos polímeros.

Legenda: 30% DOP FPVC = 30% Di Octil Ftalato e 70 % Policloreto de Vinila Flexível;

PC = Policarbonato; PMMA = Polimetil Metacrilato; PS = Poliestireno e;

RPVC = Policloreto de Vinila Reforçado com Fibra de Vidro.

Fonte: adaptado de Throne (2008).

Então, o mais importante princípio do processo de termoformagem é manter contra o molde a geometria formada pela folha aquecida por determinado tempo, ou seja, reter a sua retração utilizando a pressão negativa de vácuo durante o processo de resfriamento. Sob essas condições, o polímero não necessariamente se contrai uniformemente em todas as direções e sentido. Assim, à medida que o polímero esfria, será menos provável que moléculas regressem ao seu estado inicial e sua geometria será tanto quanto possível similar ao molde (GRUENWALD, 1998; THRONE, 2008).

Ao mesmo tempo, outro conceito relacionado é a retenção do sentido de retração (*orientation shrinkage*), que acontece simultaneamente à contração da volumétrica

do polímero. Segundo Throne (2008) e Gruenwald (1998), durante o processo de fabricação, ao "esticar" gradativamente a folha aquecida sobre o molde, ela é esfriada pela superfície do mesmo. Assim, o polímero em contato com regiões mais quentes do molde retrai mais do que aquelas em contato com superfícies de temperatura mais baixas. Ou então, neste último, o polímero simplesmente não retrai, gerando problemas de qualidade, como empenamento, moldagem incompleta, bolhas na superfície e distorções de forma, conforme já apresentado por Leite (2011).

A FIG. 2.7 exemplifica esse conceito, apresentando o gráfico de temperatura e tensão do interior da folha no caso em que o molde e placa possuem a mesma temperatura (2.7a) e o caso em que o molde possui temperatura muito diferente da folha e/ou existe baixa taxa de condutividade térmica entre eles (2.7b).

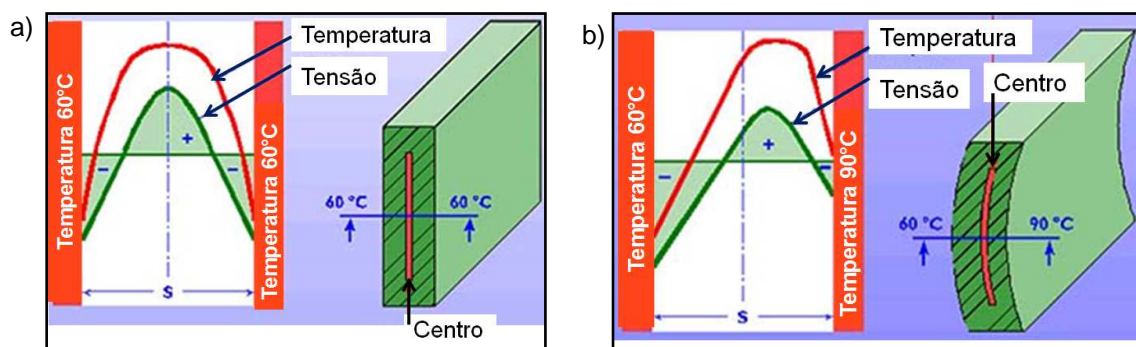


FIGURA 2.7 - Exemplicação da retenção do sentido de retração.

Fonte: adaptado de Lanxess (2014).

Por fim, uma característica que pode afetar a uniformidade da retração é a orientação de corte da folha. A folha normalmente é produzida em uma extrusora e calandrada na espessura solicitada. Esse processo tende a tornar as moléculas alinhadas ou orientadas na direção de laminação. Como resultado, durante o processo de termoformagem tem-se uma taxa adicional de retração, que varia de 0 a 5% nesse sentido (THRONE, 2008). A FIG. 2.8 apresenta um teste realizado por Klein (2009), em que se percebe claramente essa tendência à retração no sentido da laminação após o aquecimento, teste este realizado com tiras de uma chapa de PS que foram recortadas em diferentes sentidos de sua laminação.




FIGURA 2.8 - Exemplo prático do efeito da orientação da laminação sobre o sentido de retração - a) Amostras cortadas e frias; b) Amostras pós-aquecimento.

Fonte: Klein (2009).

### 2.1.3.2 Condutividades e difusividade térmica em polímeros no processo de termoformagem a vácuo

A transferência de calor por condução da superfície externa mais quente até o interior da folha do polímero é um fator de controle do processo de aquecimento e resfriamento dentro do ciclo da termoformagem. Por sua vez, difusividade térmica é a variável dos polímeros que melhor expressa quanto tempo é necessário para a condução de calor da superfície da folha propagar até seu núcleo (KLEIN, 2009; THRONE, 2008). Na FIG. 2.9 apresenta-se a comparação dos valores de condutividade térmica e difusividade térmica de alguns polímeros e matéria-prima de moldes para termoformagem.

Como pode ser visto na FIG. 2.9, o valor da difusividade térmica do polietileno de alta densidade (HDPE) é quase duas vezes a do Poliestireno, ou seja, com a mesma taxa de entrada de energia e tempo a diferença de temperatura do HDPE da superfície ao núcleo será sempre menor do que para o PS. Conclui-se, assim, que, mantendo-se as mesmas condições de fabricação, o PS terá um ciclo de aquecimento maior que o HDPE. Ao mesmo tempo, ao comparar valores para matérias-primas de molde como o alumínio (AL) e a madeira, constata-se que o alumínio possui valores muito superiores.

Material	Condutividade térmica Btu/ft °F (x 10 <sup>-3</sup> kW/m °C)	Difusão térmica X 10 <sup>-4</sup> ft <sup>2</sup> /h (x 10 <sup>-4</sup> cm <sup>2</sup> /s)	Condutividade térmica Relativo ao PS
Poliestireno	0,105 (0,180)	29,7 (7,66)	1
Acrilonitrilo Butadieno Estireno	0,121 (0,207)	25,0 (6,45)	0,67
Polycarbonato	0,070 (0,120)	33,0 (8,51)	1,15
PVC Rígido	0,100 (0,207)	32,5 (8,39)	0,95
Polietileno de Baixa Densidade	0,230 (0,390)	46,0 (11,9)	2,2
Polietileno de Alta Densidade	0,290 (0,500)	55,0 (14,2)	2,75
Homopolímero Polipropileno	0,110 (0,190)	25,0 (6,45)	0,67
Politereftalato de Etileno	0,138 (0,236)	36,8 (9,48)	1,3
Polipropileno + 40% talco	0,308 (0,527)	73,0 (19,0)	2,5
Polipropileno + 40% Fibra de vidro	0,144 (0,246)	36,0 (9,30)	1,2
Nylon 6	0,167 (0,268)	62,0 (16,0)	2,1
Nylon 6 + 30% Fibra de vidro	0,133 (0,278)	27,0 (7,00)	0,9
Copolímero Polioximetileno (POM)	0,633 (1,083)	203 (52)	6,8
POM + 30% Fibra de Vidro	0,867(1,483)	252 (65)	8,5
Espuma de PS de Baixa Densidade	0,016 (0,027)	80,0 (20,6)	0,15
Alumínio	72,5 (124)	18,850 (4860)	690
Aço	21,3 (36,4)	3,930 (1010)	200
Madeira	0,073 (0,125)	104 (26,8)	0,7
Gesso	0,174 (0,298)	120 (31,0)	1,66
Espuma sintética	0,07 (0,12)	40 (10,3)	0,67

FIGURA 2.9 - Valores de condutividade térmica e difusão térmica de alguns materiais.

Fonte: adaptado: Throne (2008).

### 2.1.3.3 O aquecimento de polímeros no processo de termoformagem a vácuo

Diversos fatores influenciam o tempo necessário para aquecer um polímero em sua faixa de temperatura de conformação no termoformagem a vácuo, como a natureza de absorção de energia, as características do polímero, o *lay out* e a geometria do sistema de aquecimento, se a folha é aquecida em um lado ou dois, pré-aquecimento, entre outros (GRUENWALD, 1998; THRONE, 2011).

Assim, o primeiro passo do aquecimento da folha de um polímero para seu processamento é determinar a faixa de temperatura ótima ou janela de conformação e então aquecer a folha até esse patamar. A FIG. 2.10 mostra, para um caso hipotético, a sobreposição das temperaturas locais (folha) em relação ao tempo para o caso ideal em que a temperatura da superfície atinge a temperatura de máxima de conformação, ao mesmo tempo, em que a temperatura central atinge a temperatura de mínima e o tempo ótimo, sendo a área destacada descrita como "janela de conformação" (THRONE, 1996).




FIGURA 2.10 - Temperaturas locais na placa em função do tempo no caso hipotético de existir um tempo ótimo.

Fonte: adaptado de Throne (1996).

Para polímeros amorfos, a janela de conformação está entre uma faixa de  $\pm 19^{\circ}\text{C}$  da temperatura recomendada, existindo, assim, limites superiores e inferiores bem definidos. Já os polímeros cristalinos possuem uma janela em pequenas gamas de temperatura, normalmente próximas da temperatura de fusão do material (KLEIN, 2009). De forma geral, no ANEXO A encontram-se as temperaturas recomendadas por Throne (1996) para o processamento de termoplásticos pelo processo de termoformagem.

No mesmo contexto, segundo Gruenwald (1998) e Throne (2008), duas variáveis expressam como um polímero específico aquece a partir da temperatura ambiente até a sua temperatura de conformação. Primeiramente, a entalpia, que é a quantidade total de energia necessária para aquecer um polímero a partir da temperatura ambiente até a sua temperatura de conformação, sendo uma função da temperatura em unidades de Kcal/kg. Já a segunda, o calor específico de um material, é a quantidade de calor necessária para elevar  $1^{\circ}\text{C}$  uma unidade de massa desse material, também em Kcal/kg. A FIG. 2.11 apresenta de forma geral valores de entalpia e calor específico para diversos polímeros.

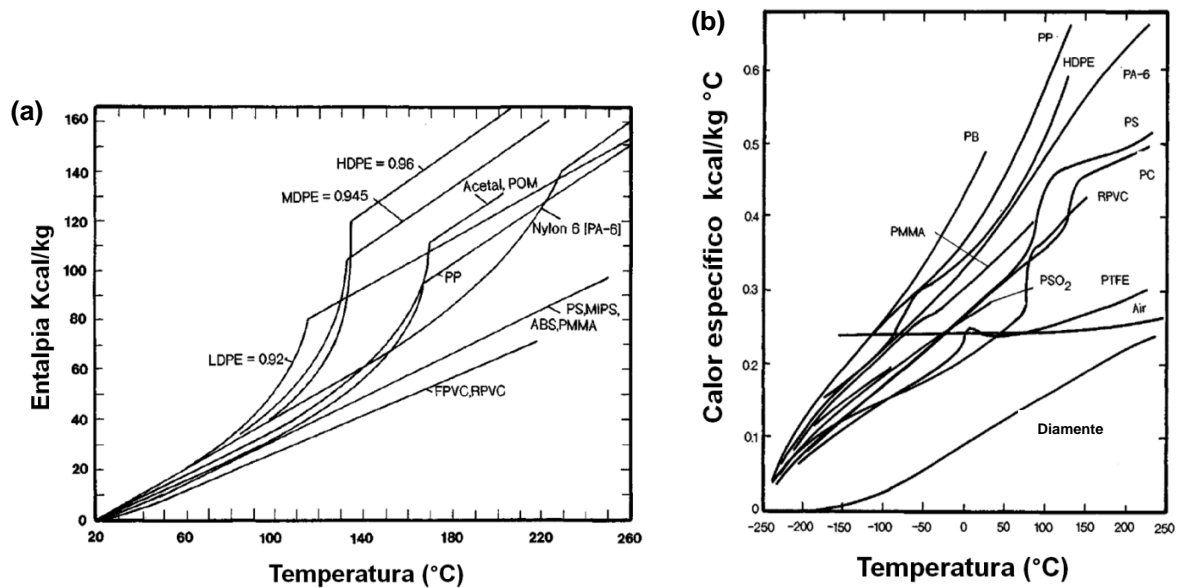


FIGURA 2.11 – a) Curva dos valores entalpia para diversos polímeros; b) Curva dos valores de calor específico de diversos polímeros.

Legenda: ABS = Acrilonitrilo Butadieno Estireno; Acetal POM = Copolímero Polioximetileno; FPVC = Policloreto de Vinila Flexível; HDPE = Polietileno de Alta Densidade; MDPE = Polietileno de Média Densidade; MIPS = Polímeros de Impressão Molecular; PA-6 = Poliamida 6; PB = Polibutileno; PC = Policarbonato; PMMA = Polimetilmetacrilato; PP = Polipropileno; PS = Poliestireno; PSO = *Polymeric Sulphonyl Radicals*; PTFE = Politetrafluoretileno e; RPVC: Policloreto de Vinila Reforçado com Fibra de Vidro;

Fonte: adaptado de Throne (1996).

Assim, observando a FIG. 2.11, conclui-se que é necessária mais energia para aquecer um polímero cristalino, como HDPE, até uma determinada temperatura de conformação do que para aquecer um polímero amorfo, como poliestireno. Ou seja, se a taxa de entrada de energia para ambos é constante, leva, em média, 2,3 vezes mais tempo para aquecer o HDPE de que o PS.

Por fim, em relação aos métodos de aquecimento da folha, três são os mais utilizados: aquecimento em estufa, aquecimento por radiação e aquecimento por contato com placas aquecidas. Esses métodos utilizam os mais diversos elementos térmicos, como lâmpadas infravermelho, painéis cerâmicos de aquecimento, aquecedores a gás butano, entre outros. A FIG. 2.12 ilustra exemplos de componentes de sistemas de aquecimento utilizados nesse tipo de processo. A FIG.2.12a apresenta um conjunto de lâmpadas infravermelho de uma estrutura do

sistema de aquecimento e a FIG. 2.12b um elemento de aquecimento infravermelho de cerâmica utilizado em painéis de aquecimento.




FIGURA 2.12 – Exemplo de elementos térmicos utilizados nos sistemas de aquecimento de equipamento de termoformagem a vácuo.

Fonte: a) O autor; b) adaptado de Rosen (2002).

Por sua vez, a transferência de energia térmica pode acontecer isoladamente ou de forma combinada por condução, convecção ou radiação. Então, para filmes e películas são recomendados métodos por condução, para folhas finas por radiação ou condução e chapas espessas técnicas por condução ou convecção (ROSEN, 2002; THRONE, 2011).

#### 2.1.3.4 Característica do aquecimento por radiação no processo de termoformagem

Primeiramente, a eficiência de transferência de energia pelo sistema de aquecimento por radiação no processo de termoformagem depende de características do projeto do forno e da disposição de elementos mecânicos e radiantes, tais como quadros de fixação, trilhos, paredes laterais do forno, lâmpadas ou resistências, refletores, entre outros (ROSEN, 2002; THRONE, 2008). Muralisrinivasan (2009) complementa que as máquinas semiautomatizadas de termoformagem geralmente utilizadas fornecem somente aquecimento radiante superior para a folha e assim podem gerar problemas como formação de bolhas na superfície, degradação, mudança de coloração ou indução de tensões a partir do aquecimento irregular ou inadequado.



Ainda, segundo Rosen (2002) e Throne (2008), o intercâmbio de energia não é uniforme em toda a folha, devido às características técnicas do tipo de aquecedor e ambiente. Teoricamente, os aquecedores na região central da folha cobrem mais área do que os aquecedores das bordas ou cantos. Como resultado, as extremidades de uma folha são normalmente mais frias do que o centro da folha; e os cantos mais frios do que as extremidades, como apresentado na FIG. 2.13a. Isso é conhecido como "efeito da absorção de energia de aquecimento (*energy uptake*)", sendo o sistema de aquecimento ideal aquele que propicie a temperatura uniforme em toda a folha, como exemplificado na FIG. 2.13b.

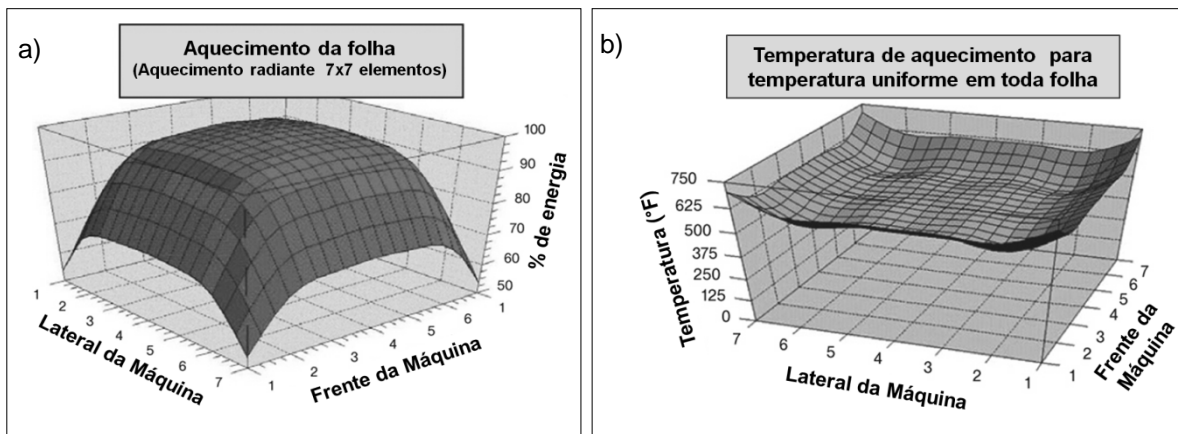


FIGURA 2.13 - a) Distribuição de temperatura na placa do polímero (efeito *energy uptake*); b) Distribuição de temperatura ideal por um sistema de aquecimento.

Fonte: adaptado de Throne (2008).

Além disso, o que se observa, segundo Muralisrinivasan (2009), para esse tipo de aquecimento é a distribuição de aquecimento irregular ou inadequado na espessura da folha. A FIG. 2.14 elaborada por ele mostra a distribuição da temperatura nas faces e centro de uma folha politereftalato de etileno (PET) de 1,5 mm de espessura aquecida apenas na face superior e suas diferenças de temperatura em toda a espessura, evidenciando, assim, a relação do tipo de aquecimento com o tempo de aquecimento e a distribuição irregular de temperatura na face.

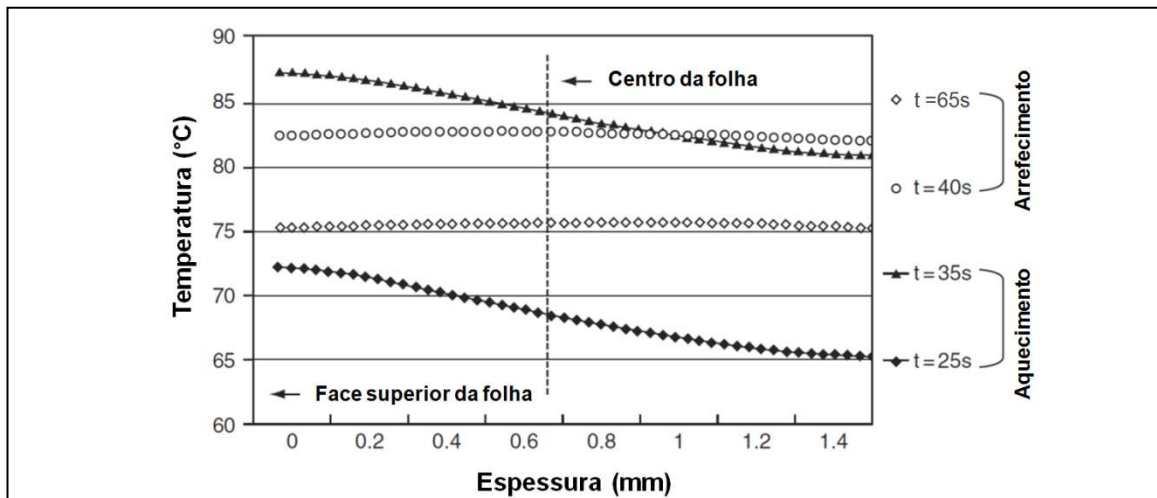


FIGURA 2.14 - Gráfico conjunto do tempo de aquecimento e arrefecimento vs temperatura e espessura de uma placa de PET 1,5 mm.

Fonte: adaptado de Muralisrinivasan (2009).

Complementar ao exposto, Throne (1996) apresenta ao longo do tempo as temperaturas em diferentes regiões e profundidades para uma folha de PS de 2,1 mm de espessura aquecida apenas na face superior, juntamente com o respectivo mapa das regiões térmicas pós-aquecimento (FIG. 2.15).

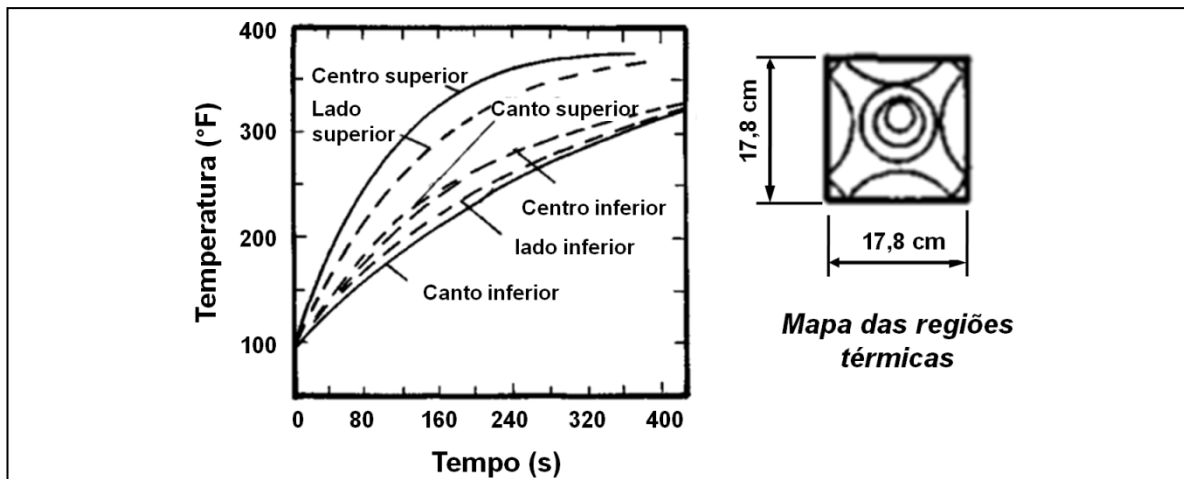


FIGURA 2.15 - Tempo vs temperaturas ao longo da espessura de uma placa de PS 2,1 mm.

Fonte: adaptado de Throne, (1996).

Dessa forma, para Muralisrinivasan (2009), a condição ideal é que a temperatura da folha seja tão uniforme quanto possível a partir da sua espessura no momento da conformação. Segundo ele, isso pode acontecer naturalmente para películas e filmes, porém, para espessuras acima de 1,5 mm e polímeros com baixo valor de

difusividade térmica, deve ser encontrada uma relação tecnicamente satisfatória para o processo. Entretanto, devido à quantidade de variáveis envolvidas, esse processo pode ser de difícil equacionamento.

Por fim, Throne (2008) afirma que, para produzir uma folha com temperatura uniforme, desde que possível tecnicamente, a saída de energia de aquecimento na região central deve ser reduzida em relação às laterais e estas em relação aos cantos, visando minimizar os efeitos do sistema de aquecimento sobre a placa, conforme ilustrado na FIG. 2.13a.

#### 2.1.3.5 O resfriamento e arrefecimento no processo de termoformagem a vácuo

Segundo Throne (1996) e Klein (2009), existem diversas variáveis no processo de "troca de calor" que afetam o tempo e o ciclo total de resfriamento no processo de termoformagem. Estas incluem a matéria-prima, o sistema de resfriamento, a espessura do material depois da conformação ou estiramento, a temperatura do material, a temperatura do equipamento, a temperatura do molde, o material do molde, entre outros, que tornam seu controle e previsão uma atividade complexa.

Já para a relação folha e molde, o que se observa é que o arrefecimento começa imediatamente quando a folha entra em contato com a superfície do molde. Assim, usando o conceito de aquecimento por condução, o material termoplástico quente aquece o molde frio e o molde esfria a folha (KLEIN, 2009; THRONE, 2008). Exemplificando, a FIG. 2.16 exibe os perfis da temperatura em função do tempo, para a relação de interação entre a folha quente e o molde frio e suas respectivas mudanças de temperatura.

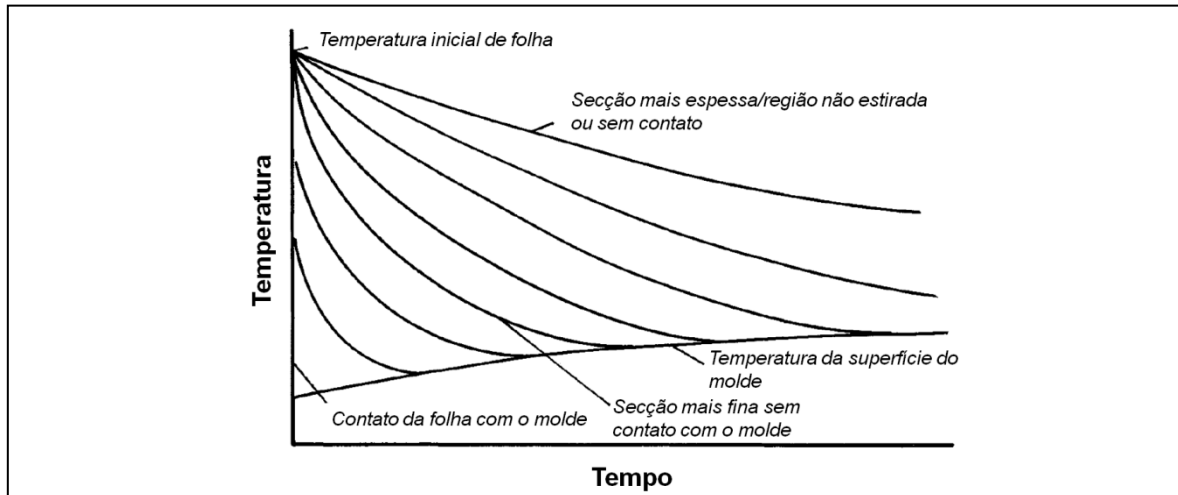


FIGURA 2.16 - Curvas das interação entre a folha quente e o molde frio e suas respectivas mudanças de temperatura.

Fonte: adaptado de Throne (1996).

Complementarmente, para Throne (2008), um conceito técnico importante sobre o resfriamento da folha é que, uma vez que o material toca a superfície do molde frio, o alongamento nessa área cessa ou é "contido" (vide seção 2.1.3.1). Assim, a primeira área da folha a ter contato com o molde será a mais espessa e a última esticará mais e, portanto, será mais fina. Isso explica o fato de cantos raiados tridimensionais (3D) profundos terem espessuras mais finas que o restante do produto.

A FIG. 2.17 ilustra um teste desenvolvido por Klein (2009) para esse efeito em um molde positivo e outro negativo e o impacto da espessura local devido ao resfriamento "instantâneo" da folha. Nela vê-se uma folha de 0,15 polegada de espessura conformada em um molde negativo e a comparação das diversas espessuras ao longo da superfície. Já na FIG. 2.17b vê-se a mesma folha estirada em um molde positivo e a descrição de suas diversas espessuras pontuais ao longo do seu contorno.

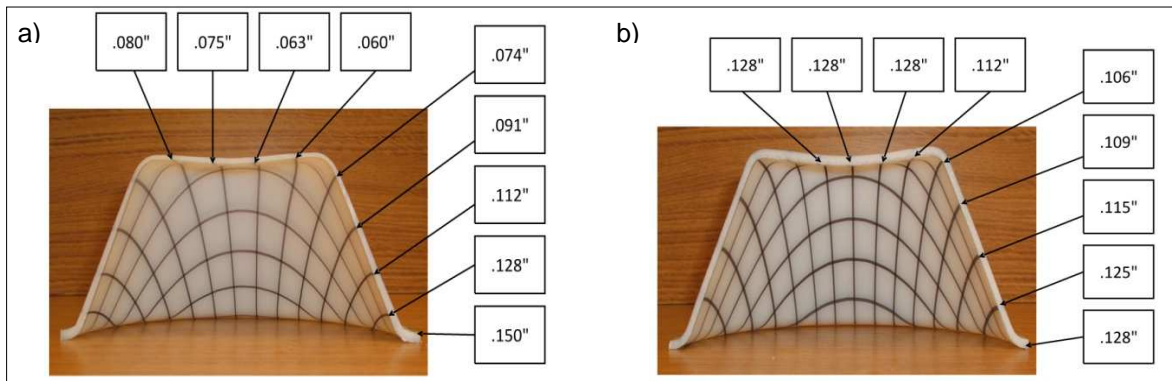


FIGURA 2.17 - a) Peça fabricada com molde negativo com suas espessuras locais; b) peça fabricada com molde positivo com suas espessuras pontuais.

Fonte: adaptado de Klein (2009).

#### 2.1.3.6 Característica do projeto do molde para termoformagem a vácuo

Alguns autores, como Klein (2009), Muralisrinivasan (2009) e Throne (2008), asseguram que diversos aspectos devem ser observados no desenvolvimento dos moldes para termoformagem a vácuo, sendo os principais a geometria da peça, a matéria-prima do molde, o material a ser conformado e a sua espessura, a temperatura recomendada para a folha e molde, bem como o volume de ar que necessita ser evacuado de tempo em tempo.

Assim, quanto aos aspectos térmicos, segundo Muralisrinivasan (2009), o aconselhável é que a temperatura do molde deve ser abaixo da temperatura de transição vítrea da folha no momento da conformação. Entretanto, entre os autores não há consenso sobre qual seria a temperatura ideal, sendo normalmente tabelados valores de 20-99°C (ANEXO A). Klein (2009) sugere que o molde deve atuar como um permutador de temperatura para extrair o calor da folha e acomodar as contrações do produto, devendo-se observar as características térmicas do material do molde.

Quanto à matéria-prima para fabricação dos moldes, são utilizados diversos materiais, cada qual com suas particularidades. Os moldes de madeiras, principalmente pinheiros (FIG. 2.18a) e compósitos particulados com resíduo de madeira, como o *medium density fiberboard* (MDF), possuem custo baixa e

significativa facilidade de fabricação e correção, sendo recomendados apenas para protótipos ou produção em baixa escala, menos de 1.000 peças (THRONE, 2008). Já o alumínio é o material recomendado para moldes permanentes e deve ser mantido a 25-99°C por meio de sistema de refrigeração (FIG. 18b).



FIGURA 2.18 - Exemplos de aplicação de moldes para termoformagem: a) Molde em madeira do protetor de roda de um veículo; b) Molde para copos descartáveis.

Fonte: Klein (2009).

Por outro lado, os moldes de epóxi e poliéster duram mais do que os moldes de madeira, entretanto, a condutividade e difusão térmica destes últimos são mais pobres do que do alumínio, requerendo longos ciclos de resfriamento para evitar altas temperaturas na superfície (MURALISRINIVASAN, 2009). E, ainda, os moldes podem ser fabricados em resina epóxi fundido (FIG. 2.19a), uretano ou poliuretano fundido (FIG. 2.19b) e materiais compósitos porosos como METAPOR<sup>®</sup> (FIG. 2.19c), que permite ao sistema de vácuo puxar "diretamente" a folha junto ao molde (MACARRÃO, 2004).



FIGURA 2.19 - Exemplos de materiais aplicados a moldes para termoformagem: a) Molde em resina epóxi fundido BC7136 ; b) Molde em uretano fundido BC8010 e; c) Molde em compósito METAPOR HD 210 AL.

Fonte: BCC Products (2015); BCC Products (2015) e; Tooling Technology (2015).

Acrescenta-se que os moldes devem possuir orifícios de vácuo e/ou furos na proporção suficiente, que permitam que o fluxo de ar evacue durante o processo de conformação (THRONE, 2008). O termo orifício é utilizado para especificar ranhuras, canais ou qualquer outra abertura que permita que o ar flua. A FIG. 2.20 dá exemplo de canal e furos de sucção.



FIGURA 2.20 - Exemplo de orifícios para sucção de ar entre molde e folha; a) Canal; b) Furo.

Ainda segundo Throne (2008), devem ser seguidas algumas orientações quanto à localização e à disposição dos furos em superfícies horizontais planas e ao longo de cantos tridimensionais, em moldes machos ou nas quinas dos moldes fêmeas. Esses furos normalmente são fabricados entre 0,04 e 0,08 mm de diâmetro para filmes, 0,08-1,0 mm para chapas finas e 0,5-2,0 mm para chapas grossas (MURALISRINIVASAN, 2009). A FIG. 2.21 ilustra algumas recomendações quanto à localização e à disposição dos furos de sucções de Throne (2008).






FIGURA 2.21 - Recomendações quanto à localização e à disposição dos furos de sucções.

Fonte: adaptado de Throne (1996).

Quando ao formato, os moldes podem ser de dois tipos, a saber: molde positivo, que é o mais usado no mercado, em vista de seu baixo custo de produção e da possibilidade de obtenção de peças com superfícies mais rígidas (FIG. 22a) e; negativo que é o mais usado na produção em alta escala, pois permite considerável economia de matéria-prima (FIG. 22b) (KLEIN, 2009; THRONE, 2008).




FIGURA 2.22 - a) Moldes positivos; b) Moldes negativos.

Fonte: adaptado de: Klein (2009).

Nesse contexto, ressalta-se que a superfície em contato com o molde será mais lisa e sem defeitos para moldes negativos (FIG. 2.22b) de metal ou em resina epóxi fundido, o que é um fator crítico em peças transparentes. Já em moldes de madeira, gesso e materiais porosos, é aconselhável o uso de moldes positivos (FIG. 2.22a), pois o molde poderá gravar na peça sua textura ou fissuras. Sala, Landro e Casago (2002) opinam que a escolha entre fazer o molde com a superfície positiva ou negativa da peça dependerá de qual será a superfície da peça que precisará ser controlada.



Na prática, o tipo de molde afeta diretamente a espessura local do produto. A FIG. 2.23 mostra o estudo, estiramento e conformação utilizando folhas com marcação quadriculada, ficando evidente que a escolha do formato do molde afeta diretamente a espessura local e distribuição do material pós-processamento (vide seções 2.1.3.1 e 2.1.3.5).




FIGURA 2.23 - a) Exemplo de termoformagem com molde positivo; b) Exemplo de termoformagem com molde negativo.

Fonte: adaptado de: Klein (2009).

Por fim, o módulo de elasticidade de cada polímero é modificado com a temperatura de maneira independente, dada a sua temperatura de moldagem. Em consequência, aplicada determinada tensão ou força (sistema de vácuo) o material flui de forma particular sobre o molde, tornando-se, assim, o projeto único de um molde para diversos polímeros, uma atividade complexa ou proibitiva (ROSEN 2002; THRONE, 1996). A FIG. 2.24 mostra o efeito da temperatura sobre o módulo de elasticidade de alguns polímeros utilizados na termoformagem.

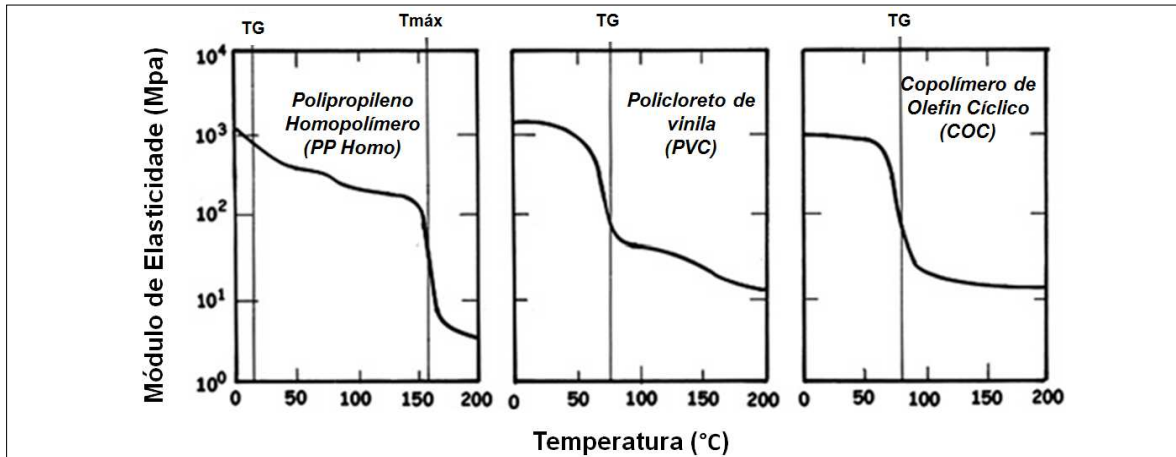


FIGURA 2.24 - Efeito da temperatura sobre o módulo de elasticidade de polipropileno homopolímero, policloreto de vinila e copolímero de olefin cíclico.

Fonte: adaptado de Throne (1996).

Percebe-se que a quantidade de força necessária para "esticar" a folha a uma determinada medida é mais elevada em temperaturas mais baixas. Isso significa que a profundidade da área de conformação é proporcional à temperatura de conformação e espessura da folha (ROSEN, 2002; THRONE, 1996).

#### 2.1.3.7 Aspectos gerais da qualidade dimensional e geométrica do produto termoformado

Para Klein (2009), Muralisrinivasan (2009), Rosen (2002) e Throne (1996), diversos são os aspectos do processo de manufatura que interferem na qualidade dimensional e geométrica do produto. Assim, a definição dos desvios a serem controlados deve basear-se principalmente na aplicabilidade e funcionalidade do produto. Isso posto, para Muralisrinivasan (2009) e Throne, (2011) os aspectos gerais que interferem na qualidade do produto podem ser agrupados em quatro categorias:

- Processo de fabricação, incluindo a alimentação, pré-aquecimento, a força usada para formar, a pressão aplicada e a taxa de resfriamento;
- as variáveis de manufatura utilizadas na entrada e saída;
- material e projeto de molde, incluindo o tamanho do molde e contra molde, tipo de molde, o projeto em si, proporção e tipo de material e;

- d) processo de controle do sistema, tais como aquecimento, vácuo, resfriamento, etc.

Dessa forma, a qualidade final do produto depende dos parâmetros do processo, de matéria-prima, ambiente de fabricação, equipamento, moldes, entre outros, o que torna sua previsão um processo complexo multivariável com características não lineares e de objetivos conflitantes (THRONE, 2008; YANG, HUNG 2004a).

No desenvolvimento de processos de baixa e média produção, apura-se que, até que seu molde seja fabricado de um determinado material, testado usando o equipamento e matéria-prima definidos pelo método e parâmetros escolhidos, a capacidade real do processo é de difícil previsibilidade e depende do conhecimento prévio ou aprendizagem do executor. Ao mesmo tempo, em processos industriais de larga escala de produção o foco da garantia da qualidade está no controle da matéria-prima e do processo, baseada em dados históricos de problemas de produção, ou seja, no pré-conhecimento (KLEIN, 2009; ROSEN, 2002).

Quanto ao controle dimensional do produto, diversos autores enfatizam o controle da espessura da parede da peça como sendo o fator crítico na qualidade do produto termoformado. Porém, a própria natureza do processo, já descrita, torna complexa a previsão da espessura local do produto, o que tem sido objeto de estudo nos últimos anos, por exemplo, por Yang e Hung (2004a; 2004b), Chang, Wen e Liu (2005), Karjust, Küttner, e Pohlak (2007) e Engelmann e Salmamg (2012).

Nesse cenário, em um produto fabricado com placas de espessuras grossas, a espessura varia, em média, 10%, FIG. 2.25; e para os produzidos com filmes e espessuras finas essa variação chega, em média, a 20%, independentemente do tipo de termoplástico e processamento, FIG. 2.26 (THRONE, 2011).

Assim, conforme apresentado na FIG. 2.25, para o mesmo produto, processo, parâmetros, etc., pode existir uma variabilidade em torno de 5% do valor da espessura média entre dias mensurados, o que evidencia a complexidade da previsibilidade do processo.

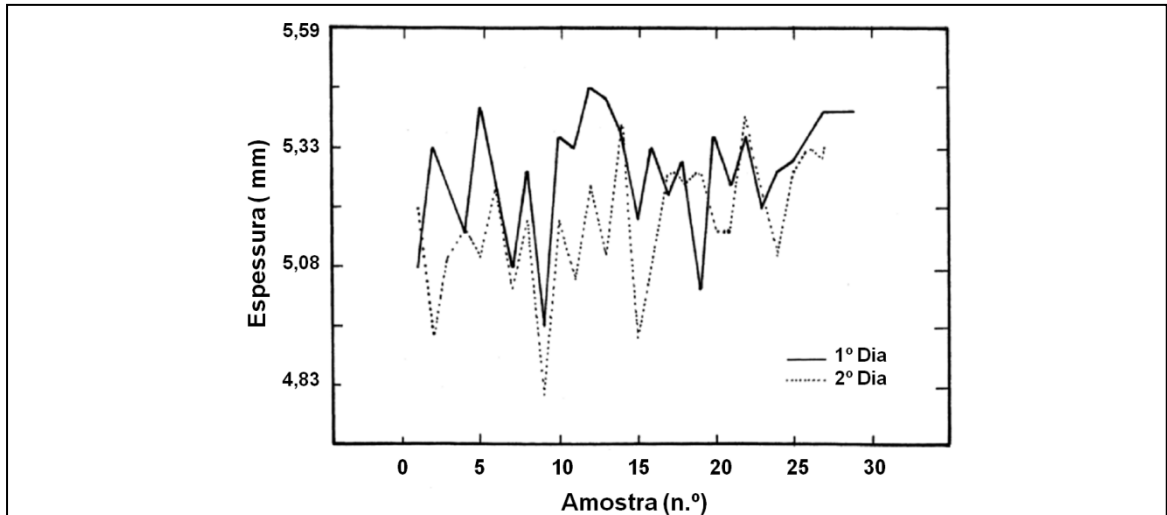


FIGURA 2.25 - Variação de 10% espessura ao longo do contorno para placas grossas e variabilidade de 5% entre dias mensurados.

Fonte: adaptado de: Throne (2008).

Ao mesmo tempo, a FIG. 2.26 exemplifica a típica variação na espessura pontual de copos descartáveis (folha fina) em uma amostragem de 20 produtos, em que existe uma variação típica média de 20% da espessura pontual.

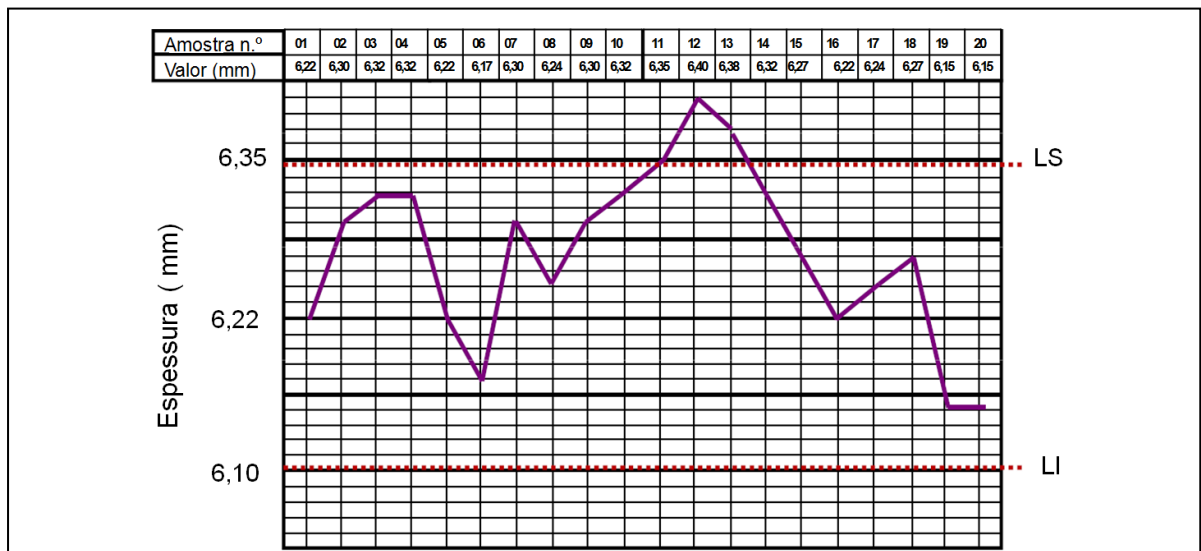


FIGURA 2.26 - Exemplo da variação de espessura pontual em produtos fabricados com folhas finas. Fonte: adaptado de Klein, (2009).

A esse respeito, não foram encontradas na literatura pesquisada descrições das relações ou inter-relações entre desvios dimensionais e geométricos do produto, porém são citados três principais aspectos que afetam ambos os desvios, a saber: geometria da peça, o projeto do molde e a forma como o material flui sobre o molde

durante o processamento (ROSEN, 2002; SALA; LANDRO; CASAGO, 2002; THRONE, 2008;).

A FIG. 2.27 apresenta, por meio de cálculo computacional (*Finite Element Analysis* - FEA), uma simulação na qual é analisada a forma geométrica da peça vs espessura local da parede e, desta forma, evidencia-se a variação de espessura ao longo do contorno da geometria.

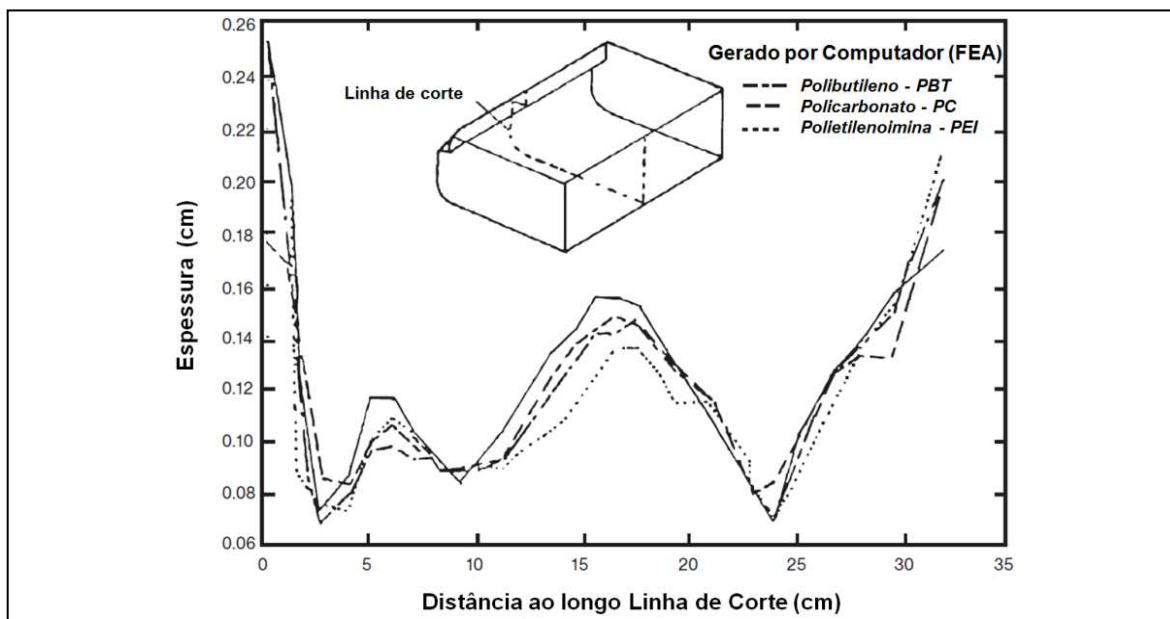


FIGURA 2.27 - Simulação da espessura da peça ao longo do contorno de sua geometria.

Fonte: adaptado de Throne (2008).

Na FIG. 2.27, observa-se que a variação da espessura da parede depende da forma geométrica do produto e independe do material da folha. Ao mesmo tempo, vê-se que, mesmo em regiões planas, a espessura da parede não é constante, o que, por sua vez, gera tensões durante o processo de resfriamento da folha, as quais podem produzir desvios geométricos na peça, como erro de planeza e paralelismo.

Quanto aos desvios dimensionais e geométricos, conforme já descrito (2.1.3.1, 2.1.3.5 e 2.1.3.6), a temperatura da placa no momento do estiramento ou conformação associado ao formato do molde interfere na forma como a folha flui sobre o molde. Teoricamente, a primeira parte da folha a tocar no molde se esfria, contendo a fluidez do material sobre o molde e terá maior espessura.

A combinação desses eventos com os demais processos pode produzir desvios no produto, como erro de forma, de inclinação e dimensional (ROSEN, 2002; THRONE, 1996).

Por último, o projeto da geometria da peça contribui para a uniformidade da espessura da parede, a fluidez do material, o posicionamento de elementos, o acúmulo de material em cantos ou regiões, a rigidez estrutural, a estabilidade dimensional, o processo de resfriamento, entre outros, sendo considerado uma fonte potencial de defeitos da peça (ROSEN, 2002). A FIG. 2.28 apresentada por Rosen (2002) mostra possíveis defeitos relacionados ao projeto da geometria da peças.




FIGURA 2.28 - Possíveis defeitos relacionados ao projeto da geometria da peça.

Fonte: adaptado de Rose (2002).

Por fim, para Klein (2009) e Throne (1996; 2008), devem-se ter algumas expectativas quanto a tolerâncias dimensionais de peças termoformadas. Diversos autores e fabricantes, mesmo sem consenso entre eles, sugerem alguns valores de referência quanto às tolerâncias dimensionais de peças termoformadas, porém não propõem algum equipamento de medição específico a ser utilizado. Klein (2009) e Karjust, Küttner e Pohlak (2007) propõem a fabricação de peças testes com moldes

protótipos para verificação da real capacidade do cenário de produção, o que foi validado por Chang, Wen e Liu (2005) em uma máquina de termoformagem a vácuo em escala laboratorial.

Como referência, podem-se adotar para embalagens e materiais descartáveis feitos com materiais de espessura fina tolerância de  $\pm 0,254$  mm até 152 mm de comprimento e  $\pm 0,25$  mm adicionais para cada 25,4 mm adicional e para espessuras grossas e produtos não de embalagem,  $\pm 0,76$  mm até 305 mm de comprimento e  $\pm 0,0508$  mm adicionais por cada 10 mm de estriamento (KLEIN, 2009).

A FIG. 2.29 transcreve os valores de referências sugeridos pela *Associated Thermoforming, Inc.* (ATI, 2013) para dimensões gerais de produtos termoformados.

Característica/Relações	Termoformagem por pressão	Termoformagem à vácuo
Abaixo de 152,4 mm	0,254 mm	0,381 mm
152,4 - 304,8 mm	0,508 mm	0,635 mm
152,4 - 457,2 mm	0,635 mm	0,762 mm
Acima de 457,2 mm	0,051 por 25,4mm	0,051 por 25,4mm

FIGURA 2.29 – Valores de tolerâncias gerais para produtos termoformados.

Fonte: adaptado de ATI (2003).

## 2.2 Inteligência computacional em processo de manufatura

Diversos autores acreditam que as abordagens tradicionais para o controle do processo de manufatura não conseguem atender na totalidade ou são incapazes, muitas vezes, de resolver os problemas ou, ainda, não conseguem incluir aspectos "humanos" de controle de processo, como a imprecisão e indefinição, que são inerentes ao modelo mental do decisor.

Nesse contexto, desde o seu surgimento, na década de 50, como uma subárea da ciência da computação, a inteligência artificial (AI) tem evoluído em várias técnicas, com aplicações em sistemas de manufatura (MEZIANE *et al.*, 2000).

Por sua vez, inteligência computacional (IC) aplicada à manufatura refere-se às pesquisas dentro da AI, que se concentram na modelagem de sistemas naturais ou reais que podem ser considerados sistemas inteligentes (PHAM; PHAM, 2001). Assim, a IC tem desenvolvido, nas últimas décadas, uma série de ferramentas, as quais são utilizadas na Engenharia para resolver problemas complexos que normalmente requerem habilidades da inteligência humana, como o conhecimento prévio ou a capacidade de aprendizagem para resolução e tomada de decisões perante novas situações (MEZIANE *et al.*, 2000; TADEUSIEWIC, 2011).

Nesse campo de pesquisa, o funcionamento do cérebro humano é a fonte de inspiração, por isso essa área de investigação centra-se, principalmente, nas técnicas que abordam o processo de treinamento como ferramenta para emular a tomada de decisão (TADEUSIEWIC, 2011). Nesse caso, o emprego da IC no controle ou previsão de parâmetros de produção vem sendo pesquisado mais intensivamente, por meio da aplicação de redes neurais artificiais, desde os anos 1980 (EFE, 2011; HUANG; ZHANG, 1994).

De forma simplificada, a previsão de um processo por uma RNA pode ser interpretada como a aproximação de uma função desconhecida a qual se deseja encontrar. Então, o objetivo é ajustar os parâmetros da rede/modelo de tal modo que ela irá produzir uma resposta aproximada da função desconhecida, dada uma entrada qualquer em um processo de aprendizagem e adaptação contínuas, conforme apresentado na FIG. 2.30 de Meziane *et al.* (2000).

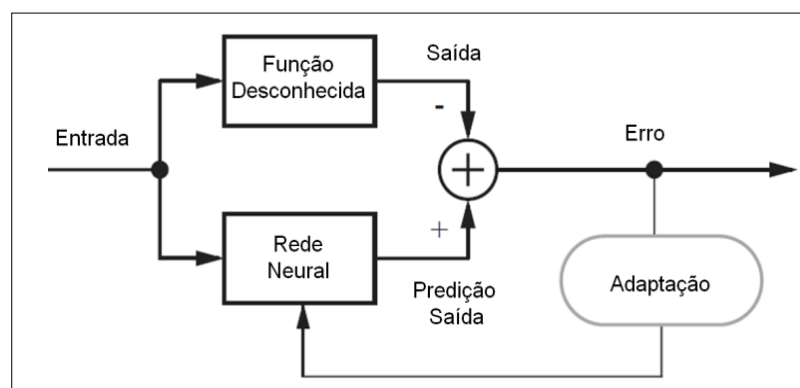


FIGURA 2.30 - Método de aproximação utilizando um RNA.

Fonte: Meziane *et al.* (2000).



Nessa área há também outros processos naturais que podem e são utilizados como fonte de ideias para o desenvolvimento de sistemas inteligentes, como, por exemplo, os sistemas baseados em conhecimento, a lógica *fuzzy* e a computação evolutiva (PHAM; PHAM, 2001).

### 2.2.1 Sistemas baseados em conhecimento

Os sistemas baseados em conhecimento (*Knowledge Based Systems* - KBS) ou sistemas especialistas desenvolvidos por pesquisadores na década de 70 e aplicados comercialmente durante os anos 1980 foram a primeira tentativa da utilização de equipamentos de manufatura com algum grau de inteligência na tomada de decisão (MEZIANE *et al.*, 2000).

São programas de computador que incorporam o conhecimento sobre um domínio estreito/específico para a solução de problemas relacionados a esse domínio, incorporando o conhecimento de especialistas em aplicações que objetivavam replicar o raciocínio. Esse raciocínio levava o gestor treinado a tomar a melhor decisão no controle da planta (melhor prática) (PHAM; PHAM, 2001).

Em resumo, esses sistemas baseados em conhecimento diferem dos sistemas convencionais em: como são organizados, como incorporam conhecimento, como executam e a forma que interagem com os usuários (RESENDE; PUGLIESI; VAREJÃO, 2003). A FIG. 2.31 apresenta as principais diferenças entre os sistemas convencionais e aqueles baseados em conhecimento.

<b>Sistemas Convencionais</b>	<b>Sistemas Baseados em Conhecimento</b>
Estrutura de dados	Representação do conhecimento
Dados relações entre dados	Conceito, relações entre conceitos e regras.
Tipicamente usa algoritmo determinístico	Busca Heurística
Conhecimento embutido no código do programa	Conhecimento representado explicitamente e separado do programa que manipula e interpreta
Explicação do raciocínio é difícil	Podem e devem explicar seu raciocínio

FIGURA 2.31 - Síntese dos sistemas convencionais e os sistemas baseados em conhecimento.

Fonte: adaptado de: Resende, Pugliesi e Varejão (2003).

Esses sistemas possuem uma estrutura geral que consiste em: a) núcleo do sistema baseado em conhecimento, que desempenha as principais funções com seu sistema de regras, por exemplo, "if" e "then". E o mecanismo de inferência ou base de conhecimento, onde está representado todo o conhecimento; b) memória de trabalho, onde são armazenadas as respostas associadas à situação contida na base (conclusões); c) base de dados, onde podem estar armazenados os dados e informações; e) interface com o usuário, responsável pela interação junto a este, conforme ilustrado sinteticamente na FIG. 2.32, (MEZIANE *et al.*, 2000; RESENDE; PUGLIESI; VAREJÃO, 2003)

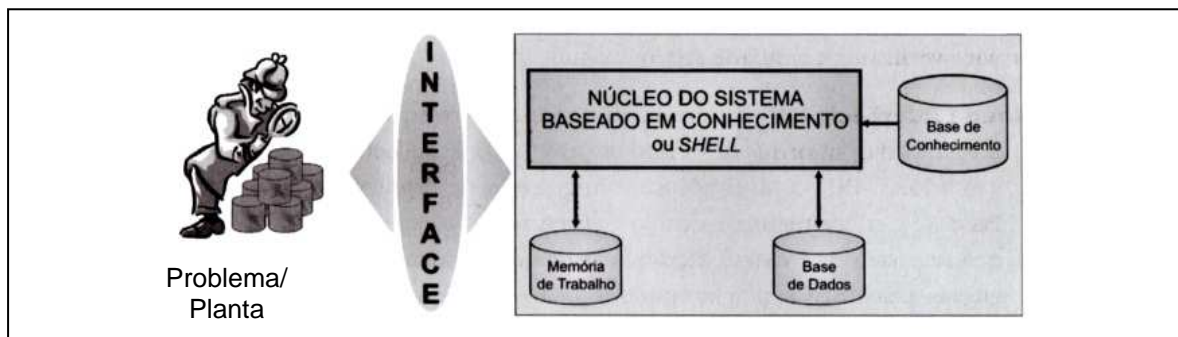


FIGURA 2.32 - Estrutura de um sistema baseado em conhecimento.

Fonte: adaptado de Resende, Pugliesi e Varejão (2003).

Uma das desvantagens desses sistemas computacionais convencionais que utilizam regras, sentenças factuais (afirmações), tabelas (sim ou não), etc. é que sua base computacional deve lidar com informações precisas, como os números, símbolos, palavras, etc. - em cada caso deve ser um número exato. Eles não podem lidar com novas situações não previstas explicitamente em suas bases de conhecimento ou ambíguas e ainda são completamente incapazes de produzir conclusões assertivas quando tais situações são apresentadas. Então, em algumas situações é preciso implementar em um sistema inteligente uma parte do bom senso humano e a dualidade, existentes nas contradições entre o pensamento ambíguo, confuso (nebuloso - *fuzzy*) e inexato humano (PHAM; PHAM, 2001; TADEUSIEWIC, 2011).

### 2.2.2 Lógica nebulosa

No início dos anos 60, pesquisadores investigavam os conceitos de incertezas e ambiguidades associados ao raciocínio humano e como utilizar essa lógica para a compreensão de sistemas reais. Baseado nesses princípios, Zadeh (1965) introduziu no campo da IC o termo "lógica *fuzzy*", "teoria *fuzzy*" ou "lógica nebulosa" por meio de sua teoria dos conjuntos *fuzzy*. Em seu artigo "*Fuzzy sets*", ele descreve essa nova ferramenta matemática que utiliza conhecimento e incertezas para replicar/modelar o mecanismo do pensamento humano, com valores linguísticos em lugar de números, levando esses valores para a teoria de sistemas computacionais e desenvolvendo um novo conjunto, o conjunto *fuzzy* (CARDIM, 2009; KOWALSKA; SZABAT, 2011; PRECUP; HELLENDORRN, 2011).

Na literatura podem ser encontrados diferentes modelos de lógica nebulosa, variando as funções de pertinência, métodos de inferência, os caminhos dos sinais de saída, etc. A princípio, podem parecer totalmente diferentes, quando se comparam os diversos modelos nebulosos. No entanto, todos eles possuem basicamente uma estrutura comum, FIG. 2.33.

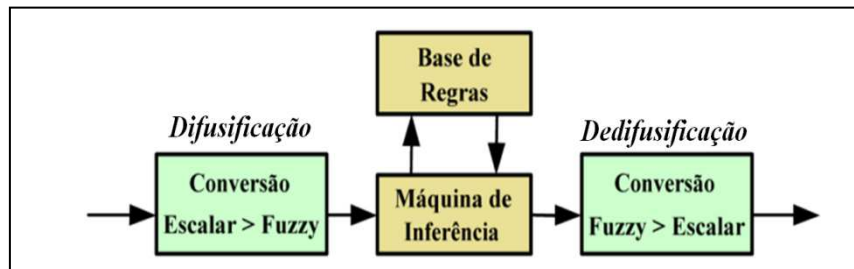


FIGURA 2.33 - Estrutura básica de um sistema *fuzzy*.

Fonte: adaptado de Almeida e Evsukopff (2003).

Essa estrutura é composta de quatro blocos básicos: difusificação ou conversão escalar de entradas, base/banco de regras, máquina de inferência nebulosa/*fuzzy* e de difusificação ou conversão escalar de saída. No primeiro bloco, o módulo de interface de entrada recebe valores numéricos ou descritivos. Eles então são convertidos por uma escala *fuzzy* por meio da intersecção *fuzzy* com os graus de pertinência de disparo para cada regra de entradas. Esse processamento transforma informações quantitativas em qualitativas e é comumente chamado de defuzzificação (ALMEIDA; EVSUKOPFF, 2003; KOWALSKA; SZABAT, 2011).

Assim, a máquina de inferência recebe valores difusificados, processa as regras existentes no banco de conhecimento e gera um conjunto *fuzzy* a partir da composição de todas as regras disparadas (ALMEIDA; EVSUKOPFF, 2003).

Finalmente, o módulo de interface de saída recebe um conjunto *fuzzy* para cada variável de saída e o converte em um valor escalar correspondente, gerando saídas compatíveis com os sistemas externos. As técnicas mais utilizadas para conversão *fuzzy*>escalar são o método do centro de massa e o método da média dos máximos (ALMEIDA; EVSUKOPFF, 2003; KOWALSKA; SZABAT, 2011).

Na FIG. 2.34 encontra-se um exemplo hipotético de processamento *fuzzy*, onde são usadas duas funções de pertinência [máx(A,B)], dois termos (x e y). E, como saída, são apresentados dois processos de defuzzificação, o método do centro de massa e o método da média dos máximos.

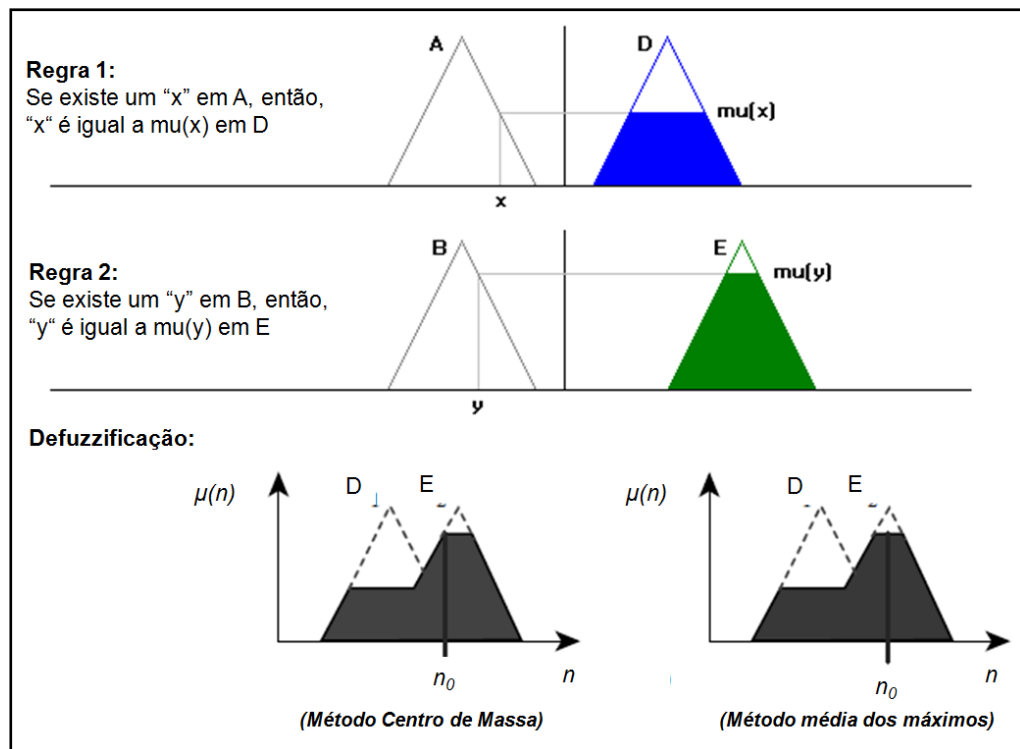


FIGURA 2.34 - Exemplo hipotético do processo *fuzzy*.

Fonte: adaptado de Almeida e Evsukopff (2003).

Entretanto, modelos *fuzzy* podem atender com certa precisão às classificações e resolução de sistemas com três dimensões. Para problemas com mais dimensões,

as redes neurais e as técnicas de computação evolutiva têm uma vantagem significativa, porque podem se auto-organizar, generalizar e otimizar funções não lineares ou multimodais (PHAM; PHAM, 2001; TADEUSIEWICZ, 2011).

### 2.2.3 Algoritmos genéticos

Dentro da IC, outra técnica utilizada na modelagem da biologia humana de ideias para a tecnologia computacional é a computação evolutiva (CE) (KOZA, 1992). Os métodos com base em cálculos evolutivos combinam buscas aleatórias (por causa do uso de cruzamentos e mutação) com pesquisas orientadas para objetivos de maximização e minimização, destacando-se, nesses métodos, os algoritmos genéticos (AGs) (TADEUSIEWICZ, 2011).

De forma geral, os AGs são modelos de IC desenvolvidos com base nas teorias de seleção natural e na hereditariedade dos indivíduos (DARWIN, 1859), tendo seus operadores inspirados nos processos de evolução natural. De forma específica, um AG é um método de pesquisa que utiliza técnicas de busca aleatória direcionada, desenvolvido por Holland (1975) para encontrar uma solução ideal global (mínimo global) em espaços de busca complexos, normalmente multidimensionais, ou seja, um algoritmo de otimização global. Os indivíduos nesse processo são comparados aos cromossomos e geralmente representados por sequências de números binários (zero e um) (CARVALHO; BRAGA; LUDEMIR, 2003; PHAM; PHAM, 2001).

Nesse processo, os operadores genéticos, conhecidos como mecanismo de reprodução, manipulam os indivíduos (cromossomos) de uma população ao longo de várias gerações (cruzamentos e/ou mutações) para melhorar a sua aptidão gradualmente. Na resolução de problemas, cada indivíduo normalmente corresponde a uma possível solução para o problema e um mecanismo de reprodução opera sobre a população atual de forma paralela ao objetivo de buscar pontos nos quais a função a ser maximizada ou minimizada tem valores globais ótimos. Assim, ele busca, em várias regiões distintas do espaço, solução em áreas mais promissoras, por meio dos indivíduos mais aptos. Além disso, a pesquisa é realizada simultaneamente em muitos caminhos paralelos e aleatórios, devido ao

fato de que vários cromossomos podem pertencer a diversas gerações simuladas, em diferentes etapas de evolução da população (épocas) (CARVALHO; BRAGA; LUDEMIR, 2003; PHAM; PHAM, 2001).

Os AGs não usam muitos conhecimentos sobre o problema e não lidam diretamente com os parâmetros do problema, eles codificam os parâmetros de estudo. Dessa maneira, o primeiro aspecto a ser considerado antes da utilização é a representação (codificação) desse problema, de maneira que os AGs possam trabalhar adequadamente. O segundo passo é a criação de um conjunto de soluções possíveis para o início do processo de otimização, dada uma população inicial. A terceira etapa é selecionar ou desenvolver um conjunto adequado de operadores genéticos e proceder à evolução da população. Por fim, os AGs devem comparar a nova solução com as anteriores para tentar melhorá-la, buscando o ótimo (PHAM; PHAM, 2001). O processo interno dos AGs se desenvolve de forma genérica, conforme o fluxograma da FIG. 2.35.



FIGURA 2.35 - Fluxograma de um algoritmo genético básico.

Fonte: adaptado de Pham e Pham (2001).

Basicamente, o processo, conforme já descrito, inicia-se com a representação do problema, em geral. O cromossomo representa o conjunto de parâmetros da função-objetivo. Se o cromossomo representa  $n$  parâmetros, então o espaço de busca tem  $n$  dimensões. O indivíduo normalmente é representado utilizando-se um vetor de tamanho finito e um alfabeto também de tamanho finito, em que cada elemento do vetor denota a presença (1) ou a ausência (0) de determinada característica (CARVALHO; BRAGA; LUDEMIR, 2003).

A inicialização trata-se do desenvolvimento do conjunto de indivíduos que representa a população e um grupo de soluções iniciais para o problema. Existem tradicionalmente duas maneiras de formar essas respostas iniciais. A primeira consiste na utilização de soluções geradas aleatoriamente, produzidas por um gerador de números aleatórios, por exemplo. Já a segunda utiliza-se do conhecimento *a priori* de especialista sobre o dado problema de otimização, para desenvolver o conjunto de soluções iniciais. Então, o AG submete o modelo ao processo de evolução (PHAM; PHAM, 2001).

Na avaliação, o AG avalia quais as soluções e os indivíduos da população que são mais adequados (aptos) para o problema proposto, ou seja, que melhor respondem à função objetivo.

O objetivo do processo de seleção é reproduzir novos indivíduos cujos valores de ótimos são mais elevados. Assim, os cromossomos são selecionados para a reprodução em função de sua aptidão para resolver o problema, sendo os principais métodos: de roleta, de torneio e o de amostragem universal estocástica (CARVALHO; BRAGA; LUDEMIR, 2003).

O cruzamento é considerado a etapa que faz com que os AGs se diferenciem dos demais métodos já descritos, tal como programação dinâmica. São criados dois novos indivíduos (filhos) utilizando-se dois indivíduos (pais) colhidos a partir da população atual. Assim, as características das soluções escolhidas são recombinadas. Existem várias maneiras de fazer isso, as mais conhecidas são de um ponto de cruzamento, de dois pontos de cruzamento, ciclo de cruzamento e o cruzamento uniforme (PHAM; PHAM, 2001).

Na mutação, as características dos indivíduos resultantes do processo anterior são alteradas, invertendo-se *bits* (zero e um) aleatoriamente, de acordo com alguma característica específica. Acrescenta-se, assim, uma variabilidade na espécie, forçando o algoritmo para procurar novas áreas (PHAM; PHAM, 2001).

Já a atualização processa a remontagem da nova população, considerando os novos indivíduos que foram gerados, ou seja,  $n+x_1+\dots+x_n$  indivíduos. Findada a atualização, o AG retorna à etapa de avaliação da população ou finaliza a otimização se as condições de encerramento da evolução ou critérios de parada forem atingidos. A FIG. 2.36 dá um exemplo hipotético desse fluxo geral de atividade de um AG.

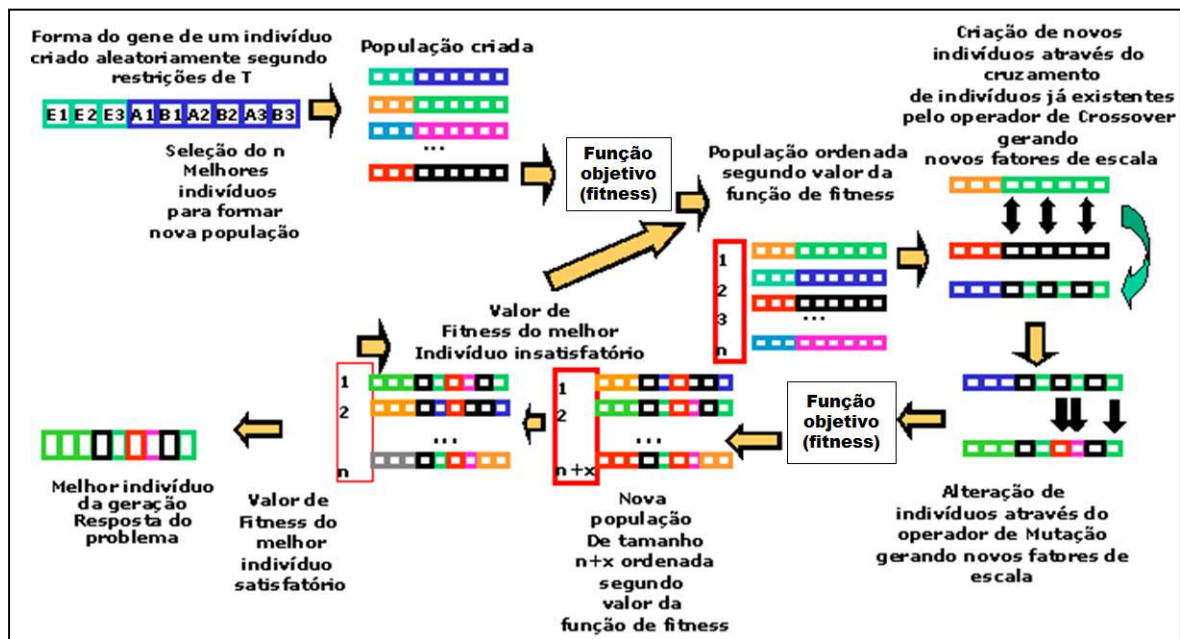


FIGURA 2.36 - Visão geral: o fluxo de atividade de um algoritmo genético.

Fonte: adaptado de Kumazawa (2003).

#### 2.2.4 Redes neurais artificiais em processo de manufatura

Os sistemas de controle de processos baseado em redes neurais artificiais (RNA) historicamente inicia-se com as pesquisas que relatam o desenvolvimento do algoritmo *backpropagation*, em 1982 (HAO; WILAMOWSKI, 2011). Werbos (2011) descreve os primeiros usos com resultados interessantes de RNA com



*backpropagation* em controle de sistemas dinâmicos. Efe (2011) cita os trabalhos de Kawato, Furukawa e Suzuki (1987) e o livro de Antsakli, Passino e Wang (1991) como sendo as obras iniciais sobre o controle de processos por RNA e o trabalho pioneiro de Narendra e Parthasarathy (1990) como a base de muitos pesquisadores que estudam o controle de processos baseado em RNA ou *neurocontrol*.

De forma geral, as RNAs são modelos matemáticos que se assemelham às estruturas neurais biológicas e possuem sua capacidade computacional para resolver problemas, conseguido por meio do aprendizado adquirido. Esses modelos são constituídos de uma série de "elementos" interligados, conhecidos como neurônios artificiais ou *perceptron* (BRAGA; CARVALHO; LUDERMIR, 2003; ESTEBAN *et al.*, 2009). A FIG. 2.37 disponibiliza a visão esquemática de um neurônio artificial.




FIGURA 2.37 - Visão esquemática de um neurônio.

Fonte: adaptado de Braga, Carvalho e Ludermir (2003).

Para aproximar pontualmente o problema, cada neurônio recebe uma série de valores de entrada em vetor  $x = [x_1, x_2, \dots, x_n]$ . Para cada entrada  $x_i$  há um peso correspondente  $w_{ji}$ . A soma das *i-ésimas* entradas  $x_i$  ponderadas pelos pesos  $w_i$  gera valor somatório que é chamado de saída linear  $u$ . Por fim, a saída  $y$  do neurônio é obtida pela aplicação de uma função de ativação  $f(\cdot)$  (que pode assumir várias formas, normalmente não lineares) a saída linear  $u$ , ou seja, a função  $y=f(u)$  (BRAGA; CARVALHO; LUDERMIR, 2003; ESTEBAN *et al.*, 2009).

Por conseguinte, uma rede neural ou rede *feed-forward*. (FIG. 2.38) é formada por  $n$  desses neurônios artificiais simples (FIG. 2.37), cada qual executando uma função específica, entretanto, a RNA como um todo tem a capacidade

computacional de resolver problemas complexos em espaços n-dimensionais (BRAGA; CARVALHO; LUDERMIR, 2003). Então, por conseguir traduzir parte do conhecimento biológico em aplicações tecnológicas, elas podem aprender a se auto-organizar, generalizar, prever valores, realizar uma análise holística, etc. (TADEUSIEWICZ, 2011).

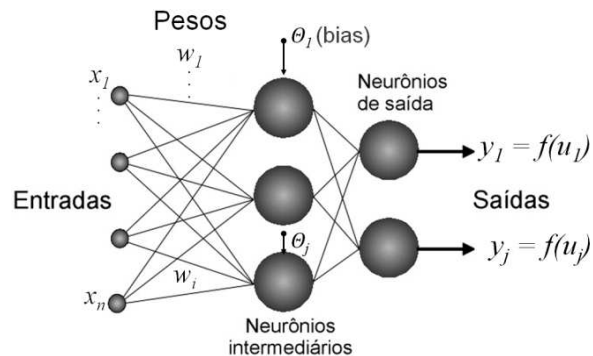


FIGURA 2.38 - Visão esquemática de uma rede neural *feed-forward*.

Fonte: adaptado de Braga, Carvalho e Ludermir (2003).

No caso de redes tipo *feedforward* ou redes diretas (FIG. 2.38), as entradas de um neurônio são os valores de entrada e seus pesos ou elementos de saída de outro neurônio interligado ( $y=f(u)$ ), portanto, a rede normalmente é organizada em  $l$  camadas (*layers*). O resultado computado na camada da saída é a resposta da rede a uma determinada entrada processada pelos seus  $n$  neurônios em suas  $l$  camadas (ESTEBAN *et al.*, 2009; PRIORE *et al.*, 2002). Logo, as sequências de interligações entre os neurônios, os seus respectivos pesos  $w_{ij}$  e a(s) função(ões) de ativação são responsáveis pelo armazenamento do conhecimento da RNA (PRIORE *et al.*, 2002).

#### 2.2.4.1 Modelagem matemática de uma RNA

As redes de camada simples ou *perceptron* são especialmente adequadas para problemas simples e classificação de padrões, sendo rápidas e confiáveis para os problemas aplicáveis (ROSENBLATT, 1961). O modelo é constituído de quatro elementos, sendo um conjunto de pesos " $W$ " que ponderam as " $X$ " entradas,

representando as sinapses do neurônio, um combinador que pode ser linear ou não linear, uma função de ativação usada para limitar a amplitude da saída do neurônio e em alguns casos se inclui um *bias*  $\theta_j$  para cada neurônio  $j$ , aplicado externamente.

Assim, matematicamente, conforme desenvolvido por Rosenblatt (1958), tem-se que a ativação de entrada "*net*" para os  $j$  neurônios na camada " $l$ " é:

$$net_j^l = \sum_{i=1}^n \{W_{j,i}^{l(p)} * X_i + \theta_j\} \quad (2.1)$$

Sendo  $W$  o vetor de peso das ligações do neurônio  $j$ ,  $X$  o vetor ou matriz de entrada e  $n$  o número de padrões apresentados à rede (entradas desse neurônio). O processamento das entradas  $X_i$  e saída  $Y_j$  do neurônio  $j$  na interação " $p$ " é dado pela EQ. 2.2:

$$Y_{j(p)}^l = \varphi_j^l\{net_j^l\} \quad (2.2)$$

sendo  $Y_{j(p)}^l$  o sinal ou valor de saída do neurônio  $j$  e  $\varphi_j^l$  a função de ativação desse neurônio.

Conseqüentemente, o erro na  $p$ -ésima interação para o  $i$ -ésimo padrão apresentado à rede é definido por:

$$e_{j,i(p)}^l = (D_i - Y_{j,i(p)}^l) \quad (2.3)$$

Sendo  $D_i$  o valor da  $i$ -ésima saída desejada para o neurônio  $j$ .

E as EQUAÇÕES 2.4, 2.5 e 2.6 descrevem os cálculos do erro da rede e as atualizações dos pesos e *bias*, respectivamente:

$$ME_{(p)} = \frac{1}{K} \sum_{j=1}^K \frac{1}{n} \sum_{i=1}^{n(l)} (e_{j,i(p)}^l) \quad (2.4)$$

$$W_{j,i(p+1)}^1 = W_{j,i(p)}^1 + \alpha * (e_{j,i(p)}^1 * X_i) \quad (2.5)$$

$$\theta_{j(p+1)} = \theta_{j(p)} + (e_{j,i(p)}^1) \quad (2.6)$$

Sendo  $ME_{(p)}$  o erro médio (*Mean Error* - ME),  $W_{j,i(p)}^l$  o peso para as  $i$ -ésimas entrada,  $\theta_{j(p)}$  o valor da *bias* do neurônio  $j$  e  $\alpha$  a taxa de aprendizagem. E, ainda, o índice " $K$ " representa o número de saídas da rede e  $n$  é o número de padrões apresentados à rede.

Concomitantemente, o modelo de redes lineares adaptativas de neurônio único ou *Adaptive Linear Neuron Networks* (ADALINE) é semelhante ao *perceptron*, mas a sua função de transferência é linear (*purelin*), em vez de com limites determinados, (*hardlim*) utilizada no *perceptron* "padrão". Isso permite que as suas saídas possam assumir qualquer valor, enquanto que a saída *perceptron* "padrão" está limitada a zero ou um. Na FIG. 2.39 comparam-se os dois métodos de transferências citados.



FIGURA 2.39 - Comparação das funções de transferência:

(a) *Hardlime*; (b) *Purlin*

Essa rede utiliza como regra de aprendizagem o algoritmo *Least Mean Squared* (LMS) de *Widrow-Hoff*, que minimiza a média do erro quadrático (*Mean Squared Error* - MSE), EQ. 2.7, que atualiza a cada interação os pesos e *bias*, buscando-se minimizar a MSE (WIDROW; STERNS, 1985).

$$MSE_{(p)} = \frac{1}{K} \sum_{j=1}^K \frac{1}{n} \sum_{i=1}^{n(l)} (e_{j,i(p)}^1)^2 \quad (2.7)$$

As EQUAÇÕES 2.8 e 2.9 descrevem as atualizações dos pesos e *bias* desse modelo, respectivamente:

$$W_{j,i}^{l(p+1)} = W_{j,i}^{l(p)} + 2 * \alpha * e_{j,i}^{l(p)} * X_i \quad (2.8)$$

$$\theta_{j(p+1)} = \theta_{j(p)} + 2 * \alpha * (e_{j,i}^{l(p)}) \quad (2.9)$$

Já as redes neurais artificiais de multicamada comumente designadas de *Multi-Layer Perceptron* (MLP) (FIG. 2.40), basicamente, consistem em neurônios divididos em níveis ou camada, sendo uma camada de entrada, uma camada de saída e uma ou mais camadas escondidas ou ocultas.




FIGURA 2.40 - Arquitetura da genética de MLP.

Percebe-se que os neurônios entre as camadas são unidos por ligações com sináptica (pesos), que armazena o conhecimento entre a entrada e saída relacionada. São normalmente implementadas com os algoritmos de treinamento *backpropagation* (BP) e *Levenberg-Marquardt* (LM).

O algoritmo de treinamento BP é um método de aprendizado supervisionado, baseado na generalização da regra *Delta*, que requer um conjunto de entradas e saídas desejadas, conhecidas como padrões (*pattern*) de treinamento (KOSKO, 1994; SCHALKOFF, 1997). O aprendizado por *batch* do algoritmo procura minimizar uma função de erro global ou soma do erro quadrático (*Sum Squared Error* - SSE).

Na MLP a ativação de entrada "net" para os  $j$  neurônios na camada principal, escondida e de saída é dada pela EQ. 1, sendo "W" o vetor de peso das ligações do neurônio  $j$  e "X" o vetor ou matriz de entrada e "n" o número de padrões apresentados à rede (entradas desse neurônio).

Entre as funções de ativação possíveis, se assumir-se a unipolar *sigmóid* a saída desse neurônio é dada pela EQ. 2.10:

$$Y_{j(p)}^l = \frac{1}{1+e^{-\lambda net_j}} \quad (2.10)$$

sendo  $\lambda$  o fator escalar.

Como já descrito, o treinamento da RNA determina os pesos da ligação que são necessários para se obter o resultado desejado. Assim, esse algoritmo é baseado na atualização dos pesos da rede, procurando minimizar a SSE para os  $j$ -ésimos neurônios da camada em cada época. O cálculo desse erro é apresentado na EQ. 2.11:

$$SSE_{j(p)} = \frac{1}{2} \sum_{i=1}^{n(l)} (e_{j,i(p)}^l)^2 \quad (2.11)$$

A minimização da função para cada  $n$ -ésimo padrão levará à minimização da  $SSE_{(p)}$ . Assim, a rede é treinada para todos os padrões (*pattern*) de treinamento e a Média do Erro Quadrático (MSE) é calculada para todos os padrões. O processo de treinamento é encerrado quando a MSE atinge erro igual ou inferior ao especificado ou quando o número de épocas atinge o seu valor máximo determinado. O MSE é definido conforme a EQ. 2.7.

Em todas as interações do algoritmo a atualização dos pesos das ligações é determinada para os  $j$ -ésimos neurônios, conforme a EQ. 2.12:

$$W_{j,i(p+1)}^l = W_{j,i(p)}^l + (\mu) * (\delta_{j,j(p)}) * (Y_{j,i(p)}^l) + \alpha * (SSE_{j(p)} * Y_{j,i(p)}^l) \quad (2.12)$$

Sendo  $p$  a interação de treinamento,  $\alpha$  a taxa de aprendizagem e  $mu$  o *momentum constant*.

E, ainda, o termo de propagação de erro ( $\delta_{j,i(p)}$ ) ou gradiente do erro é definido, conforme a EQ. 2.13, para a camada de saída, e pela EQ. 2.14, para as camadas ocultas (KARNIK *et al.*, 2008).

$$\delta_{j,k(p)} = (D_i - Y_{j,i(p)}^l) * (1 - Y_{j,i(p)}^l); j = 1, \dots, K \quad (2.13)$$

$$\delta_{j,i(p)} = Y_{j,i(p)}^l * (1 - Y_{j,i(p)}^l) * (\delta_{j,k(p)}) * (W_{j,i(p)}^l); \quad i = 1, \dots, \quad (2.14)$$

Complementar ao exposto, o algoritmo LM adotado para treinamento de redes neurais por Hagan e Menhaj (1994) e depois implementado por Demuth e Beale (2004) para o software *MATLAB*® fornece uma solução numérica para o problema de minimizar uma função não linear, por meio do cálculo de matrizes *jacobianas*, baseada no método de *Gauss-Newton* e no algoritmo do gradiente decrescente (*Gradient Descent Algorithm*). Nas RNAs, esse algoritmo é adequado para a resolução de problemas de pequeno e médio porte (HAO; WILAMOWSKI, 2011).

Nesse algoritmo, o processo de cálculo para as matrizes *jacobianas* pode ser pensado como o cálculo inverso (*back*) do algoritmo BP. Porém, para cada padrão de entrada de  $X_{i,j}$  no algoritmo de BP, apenas um processo de retropropagação é necessária, enquanto que no algoritmo LM o processo de retropropagação tem de ser repetido para cada saída separadamente, a fim de se obterem linhas consecutivas da matriz *jacobiana*. E, ainda, os gradientes de erros  $\delta$  são calculados para os neurônios  $j$  de cada saída  $K$  separadamente (HAO; WILAMOWSKI, 2011). A FIG. 2.41 ilustra a comparação dos métodos de propagação do gradiente do erro utilizados pelos algoritmos BP e LM.




FIGURA 2.41 - Comparação dos processos de propagação do erro  $\delta$ : (a) BP e; (b) LM.

Além disso, no processo de retropropagação, o erro é substituído por um valor de unidade (HAGAN; MENHAJ, 1994).

Matematicamente, tem-se que a ativação de entrada "net" para o  $j$  neurônio na primeira camada é:

$$net_j^1 = \sum_{i=1}^n \{ W_{ji}^1 * X_i + \theta_{j0}^1 \} \quad (2.15)$$

Sendo  $X_i$   $i$ -ésima entrada do neurônio  $j$  da primeira camada ponderada pelo respectivo peso  $W_{ji}^1$ , em que há  $n$ , de 1- $n$ , padrões de entradas e pesos. O índice  $j$  refere-se a qual neurônio da camada se está trabalhando e  $\theta_{j0}^1$  a *bias* do neurônio  $j$  da 1ª camada.

Analogamente, o processamento das entradas  $X_i$  e saída  $Y_j$  do neurônio  $j$  na interação " $p$ " é dado pela EQ. 2.2, sendo  $Y_{j(p)}$  o sinal ou valor de saída do neurônio  $j$  e  $\varphi_j$  a função de ativação desse neurônio.

O cálculo das derivadas da função de ativação na interação  $p$  para os  $j$  neurônios da 1ª camada é definido como:

$$S_{j(p)}^1 = \frac{\partial \varphi_j^1}{\partial net_j^1} \quad (2.16)$$



Admitindo-se as saídas do neurônio da camada atual (1ª) como entradas para as  $l$ -ésimas camadas subsequentes da rede, são assumidas as EQ. 2.2, 2.15 e 2.16 para cálculo de  $net_j^l, Y_{jp}^l$  e  $S_{jp}^l$  de todas  $l$  camadas da rede. Assim, têm-se todos os pontos das matrizes de "Y" e "S" para os  $j$  neurônios da rede (nós) necessários para os cálculos em sentido contrário (*back*) à rede do erro, gradiente e pesos.

Para os neurônios da última camada, têm-se:

$$e_{j(p)} = (D_{i,j(p)} - Y_{j(p)}) \quad (2.17)$$

Sendo  $e_{j(p)}$  o erro calculado para o neurônio  $j$ , da época  $p$ , pelo respectivo  $i$ -ésimo item desejado do vetor objetivo  $D_{ji(p)}$ , por meio do valor de saída  $Y_{j(p)}$  do neurônio. E, ainda, o termo de autopropagação de erro ( $\delta_{j(p)}^l$ ) é definido conforme a EQ. 2.18, somente para a camada de saída.

$$\delta_{j(p)}^l = S_{j(p)}^l \quad (2.18)$$

Para as camadas internas ou ócultas até a camada de entrada, tem-se que:

$$\delta_{j(p)}^{l-1} = \sum_{i=1}^{n(l)} w_{j,i(p)}^l * \delta_{j,i(p)}^l \quad (2.19)$$

$$\delta_{j(p)}^l = \delta_{j(p)}^{l-1} * S_{j(p)}^l \quad (2.20)$$

Sendo  $\delta_{j(p)}^{l-1}$  o gradiente do erro das entradas da camada atual  $l$  para as saídas da camada anterior ( $l-1$ ) e  $\delta_{j(p)}^l$  é o termo de propagação de erro das saídas da camada atual para as entradas (autopropagação).

Em todas as épocas a atualização dos pesos das ligações é determinado para o  $j$ -ésimo neurônio de cada camada, conforme EQ. 21.

$$W_{j(p+1)}^l = W_{j(p)}^l - (H_{(p)} + \mu * I)^{-1} * G_{(p)} \quad (2.21)$$

Sendo:

$$H_{(p)} = J_{(p)}^T * J_{(p)} \quad (2.22)$$

$$G_p = J_{(p)}^T * SSE_{(p)} \quad (2.23)$$

Sendo  $H_{(p)}$  a aproximação da matriz *Hessiana* e  $G_p$  a solução do algoritmo decrescente do gradiente (*Descent Algorithm*) na época  $p$ , para os  $n$  padrões de entradas da rede. Sendo  $H_{(p)}$  uma matriz  $n \times n$ ,  $G_p$  é um vetor coluna de  $n$  elementos e o termo  $I$  é a matriz identidade  $n \times n$ .

A aproximação da matriz *Hessina* e o gradiente do erro são calculados por meio das soluções numéricas do sistema formado pela matriz *jacobiana*  $J$  de tamanho  $m \times n$ , sendo  $m$  a quantidade de dados para um padrão  $X_n$  da matriz  $X$  e  $J^T$  a sua transposta. Definindo-se pela EQ.2.24,  $J_{(p)}$  é:

$$J_{(p)} = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_1} & \dots & \frac{\partial e_{1,1}}{\partial w_n} \\ \dots & \dots & \dots \\ \frac{\partial e_{1,m}}{\partial w_{1(p)}} & \dots & \frac{\partial e_{1,m(p)}}{\partial w_{n(p)}} \end{bmatrix} \quad (2.24)$$

Concomitantemente, na EQUAÇÃO 2.21,  $\mu$  é o coeficiente de combinação que é atualizado a cada interação  $p$ . Assim, se a época resultou em aumento do erro, então normalmente o coeficiente é multiplicado por um fator escalar 10. Se o inverso ocorreu, ele é dividido pelo mesmo fator (HAO; WILAMOWSKI, 2011).

Nesse modelo, duas funções de transferência são usadas frequentemente para problemas de reconhecimento de padrões, a *logsig* e a *tansig*. Similar ao descrito

anteriormente para a função *hardlim*, a função *logsig* gera saídas entre zero e um, enquanto a função unipolar *sigmóid Tan-Sigmoid* (*tansig*) não possui limites determinados (KAUR, 2012). A FIG. 2.42 mostra a comparação dos dois métodos de transferências citados, *logsig* e *tansig*.



FIGURA 2.42 - Comparação das funções de transferência: (a) *Logsig* e; (b) *Tansig*.

Por fim, adotou-se nesta pesquisa a Média Absoluta dos Erros (*Mean Absolute Error* - MAE), com parâmetro de performance das redes estudadas, por melhor representar os desvios reais (absolutos) entre os dados coletados e treinados, ou seja, o quão próximo a simulação está dos dados amostrados (magnitude). A EQUAÇÃO 2.25 descreve os cálculos da MAE.

$$MAE_{(p)} = \frac{1}{K} \sum_{j=1}^K \frac{1}{n} \sum_{i=1}^{n(l)} |e_{j,i}^l| \quad (2.25)$$

#### 2.2.4.2 RNA aplicada a processos de manufatura

Os diversos modelos de RNA, na última década, estão sendo implantados em variados campos industriais e engenharias (SUZUKI, 2011). Diversos autores têm publicado revisões de literatura a respeito, para apresentar o atual estado da arte, contribuições, perspectivas e sumarizar os diversos modelos e variadas estruturas de redes que estão sendo utilizados para predição e/ou controle de processos.

Assim, de forma geral, os trabalhos de Pham e Pham (2001), Ahmad, Mat Noor e Zhang (2009) e Lalithamma e Puttaswamy (2014) apresentam revisões de literatura da aplicação de RNA em sistemas de controle, abordando redes simples e de

múltiplas camadas, comparações entre estruturas de rede e algumas discussões sobre vantagens, limitações do uso e perspectivas.

De forma específica, Hui, Fun e Connie (2011) ressaltam os principais avanços, técnicas e limitações da aplicação de RNAs na indústria têxtil e de vestuário. Manjunath, Patel e Krishna (2013) salientam os principais problemas abordados na injeção e fundição de metais e sumarizam os principais métodos, estruturas e observações quanto ao uso de RNAs nesse processo. Mat Noor *et al.* (2010) abordam o estado da arte da produção de polímeros com ênfase nos "plásticos de engenharia" e os principais avanços na modelagem e controle do processo, utilizando técnicas de redes neurais.

No campo do controle de bioprocessos, a revisão elaborada por Zulkeflee e Aziz (2007) pode ser considerado uma referência quanto ao uso de técnicas de IC, entre elas as RNAs em diversos processos. E para o controle, análise e produção de cereais diversos, o trabalho de Goyal (2013) realça o estado da arte das principais contribuições das técnicas de RNA nos processos.

Já as pesquisas de Hakimpour *et al.* (2011) e Soroush, Nakhai e Bahreininejad (2009) registram apanhados de trabalhos relacionados à gestão da produção e da cadeia de suprimentos. E o estudo comparativo realizado por Paliwal e Kumar (2009) procede a uma relevante análise de técnicas de RNA e métodos estatísticos e suas aplicações em diferentes tipos de processos com ferramenta de controle de produção.

Em concordância, Kumar e Thakur (2012) realizaram revisão de algumas perspectivas para uso de RNA em aplicações avançadas que futuramente podem ser incorporadas aos atuais processos produtivos.

Além dessas pesquisas, na última década, em diversos segmentos fabris é crescente o número de trabalhos aplicados relacionados ao controle de processos por RNAs, com diferentes perspectivas e contribuições, vários deles sumarizados por Meziane *et al.* (2000), Efe (2011) e Suzuki (2011).

Nesse cenário, Slomp e Klingenberg (2004) estudaram o controle do processo informatizado de fabricação de produtos em chapas metálicas (*Computer-Aided Design - CAD - e Computer-Aided Manufacturing - CAM*) pelo processo de punçionamento ou recorte e como o uso de RNA poderia ajudar a desenvolver um controlador virtual para a troca de ferramenta em um processo autônomo.

Govindhasam *et al.* (2005) avaliaram o controle e otimização da fabricação de disco de alumínio, utilizando um modelo de rede neural baseada em NARX (*autoregressive with external input model*) para determinar os parâmetros ótimos de fabricação. Concluíram que redes dinâmicas e não lineares são eficazes para controle de processo com múltiplas variáveis e espaço solução.

Spina (2006) e Hao, Hai e Zhu (2010) investigaram os parâmetros do processo de moldagem por injeção de polímeros por meio da associação de RNA com Método dos Elementos Finitos (MEF) e ferramentas estatísticas, objetivando o uso conjunto dessa ferramenta e posteriormente a otimização dos parâmetros via programação e simulação. Eles concluíram que a utilização das redes neurais associada a outras técnicas possibilitou a identificação de parâmetros ótimos para o processo de injeção de polímeros e que a RNA foi um método eficiente para lidar com parâmetros multivariados. Complementarmente, Chen, Tsai e Lai (2010), para o mesmo processo, propõem uma metodologia que combina Taguchi, RNA, algoritmos genéticos e a ANOVA para a predição do controle do processo. Concluiu-se, pelos resultados experimentais, que a metodologia proposta pode melhorar a qualidade do produto e reduzir custo de produção.

E, ainda, o uso de RNA com redes recorrentes foi analisado por Lu *et al.* (2007) no processo de moldagem por injeção de termoplásticos para previsão e controle de seus parâmetros não lineares. O objetivo principal foi modelar um algoritmo neural para o controle em tempo real da temperatura da máquina injetora. Ao mesmo tempo, Lu e Tsai (2010) pesquisaram a mesma metodologia e processo, mas com redes de entradas e saídas múltiplas, o que designaram de Modelo de Controle Preditivo (*Model Predictive Control - MPC*). Em ambos, o método proposto foi aprovado e as redes desenvolvidas foram eficientes no ajuste dos parâmetros do processo, mesmo com pequenas perturbações externas. Em adição, Chen e Lai

(2011) desenvolveram um *software* de controle do equipamento de injeção por meio dos dados fornecidos por uma RNA previamente desenvolvida para controlar a temperatura e o fluxo de material.

Yousif, Daws e Kazem (2008) trabalharam no desenvolvimento de uma rede neural para análise e simulação da correlação dos parâmetros do processo de soldadura *Friction Stir (Friction Stir Welding - FSW)* com as propriedades mecânicas (resistência à tração, limite de escoamento e alongamento) das juntas soldadas em chapas de alumínio. A comparação entre os dados medidos e simulados mostrou que as redes modeladas podem ser utilizadas como alternativa para controle indireto do processo e, conseqüentemente, das características mecânicas do produto, com boa precisão.

O uso de dois modelos de RNA foi avaliado por Esteban *et al.* (2009) associando-os a dois gráficos de controle de processo para modelagem e controle da fabricação de placas de aglomerado de madeira. Eles apuraram que as redes desenvolvidas baseadas em dados históricos do processo foram capazes de prever os valores dos parâmetros de fabricação com baixo desvio, quando analisadas por ferramentas estatísticas, e ainda atendem à acurácia exigida por normas europeias de controle de processo de fabricação de aglomerados.

Shaban *et al.* (2010) pesquisaram o desenvolvimento de RNA para criação automatizada de gráfico ou cartas de controle por meio de sistema automático de aquisição de dados em um processo de Manufatura Integrada por Computador (CIM). A rede desenvolvida foi avaliada por meio de teste e concluiu-se que ela apresenta melhor previsão dos resultados do que outras técnicas pesquisadas em trabalho anteriores.

Já ZareNezhad e Aminian (2011) desenvolveram estudo para analisar a capacidade de RNA na estimação de controle de sistemas não lineares. Para tal, utilizaram um modelo de reator tanque de agitação contínuo (*continuous stirred-tank reactor model - CSTR*). Com base nesse estudo e simulação do sistema, concluíram que a rede neural forneceu dados confiáveis mesmo em caso de distúrbios de reações exotérmicas no sistema.

Mekras e Artemakis (2012) empregaram um modelo de RNA para estudar o processo de extrusão de microtubos poliméricos em diversos materiais. Os autores constataram que para processos não convencionais de fabricação, como o estudado, as redes neurais de forma satisfatória (erro  $\leq 1\%$ ) conseguem modelar e simular o processo e estimar os parâmetros de fabricação.

Uma metodologia que utiliza modelo de RNA para prever os indicadores de desempenho de qualidade foi elaborada por Abdelwahed, El-Baz e El-Midany (2012) na fabricação de um compressor alternativo de refrigeração, após seus diversos processos de fabricação e montagem. O modelo proposto consegue prever com certa precisão a capacidade de refrigeração e os parâmetros de desempenho. Anteriormente, Priore *et al.* (2002) propuseram metodologia similar para resolver um problema de sequenciamento de produção em um FMS. E detectaram que, comparado ao processo convencional de sequenciamento, a metodologia que utiliza as RNAs proporciona o menor valor médio de atrasos, ou seja, melhor indicador.

Já a análise da utilização de RNA na melhoria do processo de fabricação de aço foi desenvolvida por Grešovnik *et al.* (2012). O estudo dos autores consistiu no desenvolvimento de um aplicativo que utilizava as redes neurais para, primeiramente, aproximar os parâmetros de matéria-prima do processo e, posteriormente, em testes para otimizar o processo de danos materiais de carbono. Por fim, foi usado para simular toda a cadeia do processo de lingotamento contínuo. Inicialmente, os resultados foram promissores em teste de parametrização da cadeia produtiva e continuam melhorando o modelo para usá-lo no apoio à tomada de decisão.

Florjanič, Govekar e Kuzman (2013) procederam a estudos e comparações de métodos de estimativa da quantidade de horas para fabricação de moldes cujo processo requer métodos intuitivos e analógicos que foram modelados por RNA e comparados com outras técnicas normalmente utilizadas. O método desenvolvido permitiu melhorar a estimativa do tempo de projeto e fabricação em um processo multivariável.

Por fim, para o processo de termoformagem a vácuo, de forma geral, os que se encontram nas literaturas são pontuais contribuições sumarizadas por Chang, Wen e Liu (2005). As pesquisas desenvolvidas por Yang e Hung (2004a) que testam a modelagem e otimização por RNA dos parâmetros de fabricação vs a espessura pontual do produto foram feitas por Karjust, Küttner Pohlak (2007) e Velsker *et al.* (2011) sobre o desenvolvimento de uma metodologia que utiliza RNA para otimização das tecnologias de produção junto com o projeto do produto. Por fim, tem-se a investigação publicada por Chang, Wen e Liu (2005), que testaram em uma máquina de termoformagem a vácuo em escala laboratorial a aplicação de uma metodologia baseada em RNA em um modelo inverso de RNA, que usa as espessuras locais desejadas como entradas e os parâmetros de processamento como saídas.



### 3 MATERIAL E MÉTODOS

Neste capítulo é descrita a metodologia utilizada, em uma primeira fase, para o estudo experimental dos efeitos dos parâmetros de fabricação (variáveis de entrada), de controle (variáveis de saída) e de suas interações, nos desvios dimensionais e geométricos de peças de poliestireno produzidas com o processo de termoformagem a vácuo. Esses resultados experimentais permitiram o desenvolvimento de modelos computacionais de multivariáveis com o objetivo de obter correta previsão dos parâmetros de fabricação e dos desvios em diversas situações, as quais permitam a produção de peças dentro de limites ótimos de qualidade para a geometria da peça estudada.

Complementando a descrição do procedimento experimental, são apresentados os materiais, equipamentos e ferramentas computacionais utilizadas, bem como as respectivas montagens. Relatam-se os desvios dimensionais e geométricos admissíveis e seus métodos de medição. E, por fim, é feita breve descrição dos métodos e procedimentos de análises estatísticas utilizados na metodologia proposta.

Assim, para o desenvolvimento prático deste trabalho, primeiramente foram propostos: o monitoramento e a automação da banca de testes; o desenvolvimento do projeto da peça e do molde; o planejamento dos experimentos e a fabricação de peças para análises quantitativas por meio de técnicas e ferramentas estatísticas. Em uma segunda etapa, modelagem computacional dos fatores mais significativos do processo e dos desvios do produto, por meio de modelos computacionais de otimização que utilizam RNA e modelos de regressão múltipla (MRM). E, por fim, testes comparativos e de validação dos modelos computacionais desenvolvidos. Ressalta-se que os códigos *scripts* de programação dos modelos foram desenvolvidos no período de "estágio de doutorado sanduíche" na *Escuela de Ingeniería Minera e Industrial de Almadén*. O diagrama de fluxo de atividades idealizado para desenvolvimento desta pesquisa é apresentado na FIG. 3.1.

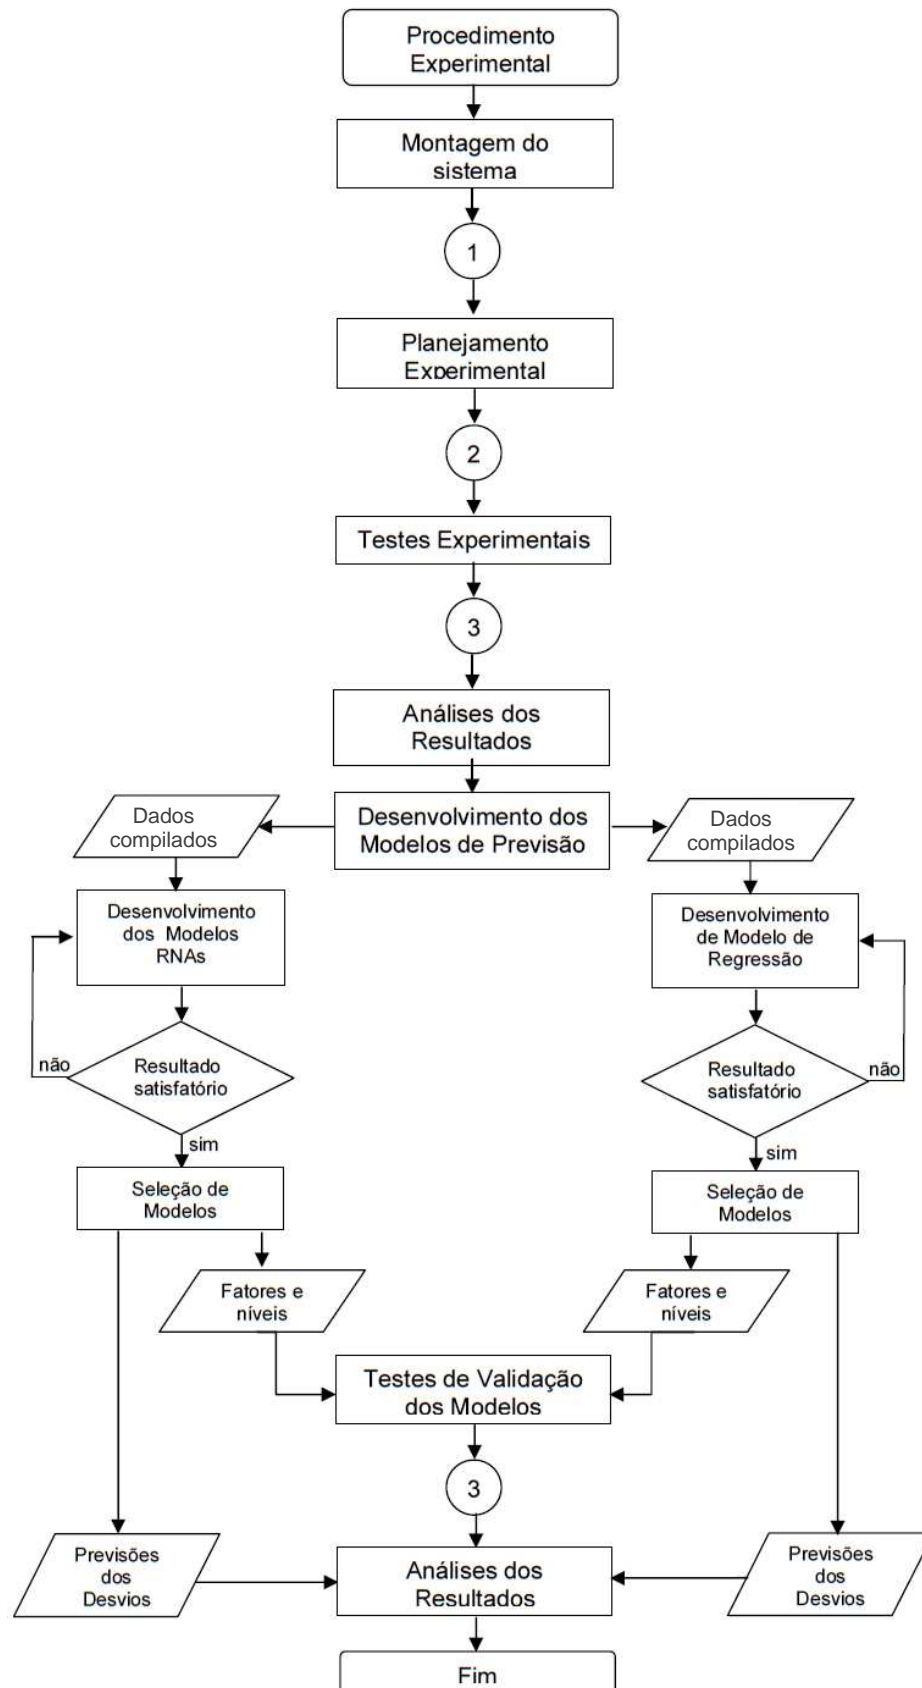


Figura 3.1 - Diagrama de fluxo da metodologia de pesquisa adotada.

\*Para subetapas 01, 02 e 03 (APÊNDICE A).

### 3.1 Materiais, equipamentos e ferramentas computacionais

#### 3.1.1 Materiais

Na fabricação das peças foram utilizadas chapas laminadas de poliestireno (PS) na cor branca, com espessura de 1,0 e 1,5 mm adquiridas no período de 2012 à 2014 da *One1 Plastic* (EUA) que é representada no Brasil pela *SID SIGNS International Distributor*, com sede na cidade de Barueri, no estado de São Paulo. As chapas foram cortadas em placas com 300 x 360 mm (dimensão da máquina), limpas com panos descartáveis de limpeza *Life Clean*, sabão líquido de Potencial hidrogeniônico (pH) neutro e água e posteriormente acondicionadas em pacotes envolvidos por plástico-filme (FIG. 3.2).




FIGURA 3.2 - a) Chapa de PS; b) Folha cortada no dimensional de trabalho e limpa; c) pacote de folhas.

Já para fabricação dos moldes, dois tipos de materiais foram utilizados nesta pesquisa, placas de MDF e chapas de alumínio liga 5052 (AL 5052) (FIG. 3.3).




FIGURA 3.3 - a) Bloco de MDF utilizado para fabricação do molde; b) Bloco de alumínio utilizado para fabricação do molde.

### 3.1.2 Equipamentos

No desenvolvimento deste trabalho foram utilizados diversos equipamentos. A seguir é apresentada a relação dos principais utilizados para desenvolvimento da pesquisa, sendo:

- a) Para usinagem dos moldes utilizados no equipamento de termoformagem a vácuo, foi utilizado o centro de usinagem da marca ROMI, modelo *Discovery* 560, com potência do motor de 9 kW (FIG. 3.4a);
- b) a máquina de medir por coordenadas tridimensional (MMC 3D) utilizada para controle geométrico das peças produzidas foi uma TESA Micro-Hite fabricada pelo grupo Hexagon Metrology 3D, que funciona com sensores optoeletrônicos, sonda de ponta esférica de rubi, tem precisão de 0,003 mm e apresenta os resultados na escala de milésimo de milímetro (0,001 mm) (FIG. 3.4b);




FIGURA 3.4 - a) Centro de usinagem CNC ROMI *Discovery 560*; b) MMC TESA Micro-Hite 3D.

- c) Na fabricação das peças foi utilizada uma máquina de termoformagem a vácuo de pequeno porte, do tipo manual, modelo VFBPD 3036 fabricada pela Branel Máquinas, que possui capacidade de trabalhar com placas de espessura de 0,1 a 3,0 mm e área 300 x 360 x 150 mm. Possui, ainda bomba de vácuo de 160 mbar e sistema de aquecimento por resistência infravermelho composto de duas resistências de 750 W e duas de 1.000 W (FIG. 3.5).



FIGURA 3.5 - Máquina de termoformagem modelo VFBPD 3036, Branel Máquinas.

### 3.1.3 Ferramentas computacionais

Os principais *softwares* utilizados no trabalho experimental e suas respectivas utilizações são:

- a) *SolidWorks® 2010*, *software* CAD modelador de sólidos, montagem e detalhamento técnico, utilizado para os projetos;
- b) *EdgeCAM® 2010 by SolidWorks®*, *software* CAM utilizado para programação dos equipamentos de usinagem por comando numérico computadorizado (CNC);
- c) *Volcomp*, programa de inspeção auxiliada por computador *Computer-Aided Inspection* (CAI) da MMC 3D utilizado para cálculo das medições das peças e transferência de dados para posterior análise;
- d) *Arduino versão 1.05 R2*, *software* utilizado para programação, compilação e *upload* da placa de microcontrolador *Arduino Uno*;
- e) *MATLAB® 7.12.0635*, *software* utilizado para programação e processamento dos modelos computacionais, gráficos 3D e processamento de dados;
- f) *Minitab® 16*, *software* utilizado para análises estatísticas diversas e processamento de gráficos;

## 3.2 Montagem do sistema de testes

A montagem do sistema de testes consistiu no desenvolvimento do projeto da peça, fabricação e inspeção dos moldes, montagem dos periféricos no maquinário e moldes, montagem e configuração dos equipamentos auxiliares, configuração e montagem do microcontrolador (*Arduino*) e, por fim, na integração do microcontrolador com os sensores, atuadores e o sistema computacional (*softwares* e computador). A seguir, as principais intervenções desenvolvidas na montagem do cenário proposto:

- a) Projeto da peça a ser fabricada: a partir de um produto base, foi desenvolvido um produto genérico com características dimensionais, geométricas e especificações técnicas similares, adotando-se metodologia

específica de engenharia reversa (*Reverse Engineering* - RP), proposta por Leite (2011). A FIG. 3.6 apresenta etapas do fluxo de atividades do desenvolvimento do projeto do produto: a) produto referencial; b) produto desenvolvido e; c) curvas de conversão em raios de curvatura.




FIGURA 3.6 - Fluxo de atividades do desenvolvimento do projeto do produto.

- b) Desenvolvimento e fabricação dos moldes: os moldes foram desenvolvidos com o auxílio do *software* CAD/CAM, com base no projeto da peça, considerando-se as características inerentes ao processo de manufatura e contração volumétrica do produto (0,5%). Posteriormente, foram usinados no centro de usinagem CNC e em ambos foram implantados termopares tipo "K" para monitoramento de dados de temperatura. Por fim, realizou-se o controle tridimensional dos moldes, por meio da MMC 3D, determinando, assim, os desvios dimensionais e geométricos presentes no molde. A FIG. 3.7, apresenta o fluxo de atividade acima descrito, sendo: a) projeto do molde no *software* CAD/CAM; b) programação no *software* CAM da usinagem do molde; c) usinagem CNC da base; d) furação para sucção do ar/vácuo do molde; e) controle tridimensional e; f) conjunto montado.






FIGURA 3.7 - Fluxo de atividades do desenvolvimento molde/matriz.

c) Automação da máquina termoformagem a vácuo: diversas intervenções foram necessárias para possibilitar o correto controle de parâmetros e aquisição de dados no desenvolvimento do trabalho experimental, como: instalação de cilindros pneumáticos, válvulas solenoides, reguladores de vazão, reprojeto do sistema de aquecimento, montagem do painel auxiliar de controle e de placa de microcontrolador (*Arduino*).

A FIG. 3.8 apresenta a montagem final dos equipamentos, molde e computador, na bancada de testes proposta para o desenvolvimento desta pesquisa. Sendo: a) conjunto de máquina de termoformagem e periféricos; b) cilindro de movimentação da gaveta/sistema de aquecimento; c) *software* de controle de temperatura; d) válvulas de controle dos sistemas pneumático; e) cilindro de movimentação da mesa/molde; f) microcontrolador arduíno e conectores e; g) painel principal e auxiliar de controle.






FIGURA 3.8 - Montagem final da bancada de testes para desenvolvimento do trabalho experimental.

### 3.3 Definição dos desvios dimensionais, geométricos e métodos de mensuração

De acordo com Muralisrinivasan (2009), Karjust, Küttner e Pohlak (2007), Chang, Wen e Liu (2005) e Yang e Hung (2004) no processo de termoformagem a vácuo, diversos parâmetros de controle e qualidade podem ser utilizados, dependendo do tipo de equipamento, molde, geometria do produto, entre outros.

Ao mesmo tempo, Klein (2009), Throne (1996; 2008), Karjust, Küttner e Pohlak (2007) e Chang, Wen e Liu (2005) sugerem alguns valores ou parâmetros de referência quanto às tolerâncias dimensionais de peças termoformadas, não havendo consenso entre eles. E, ainda, esses autores não propõem qualquer método ou equipamento de medição específico a ser utilizado.

Diante do exposto, definiu-se controlar os seguintes desvios utilizando os respectivos equipamentos, escalas, métodos de medição e tolerâncias, descritos nos tópicos subsequentes, sendo eles:

a) Desvio dimensional da altura total da peça

Primeiramente, a dimensão da altura total da peça (ATP) foi determinada a partir do cálculo da distância modular, entre dois planos paralelos formados pela parte superior e pela parte inferior no produto (FIG. 3.9).




FIGURA 3.9 - Definição de desvio dimensional da altura total do produto: componentes.

Para medição desses planos foi utilizada a MMC 3D, portando um sonda sólida de rubi com 4 mm de diâmetro e calibrada com erro de forma  $\pm 0,004$  mm (FIG. 3.10).




FIGURA 3.10 - Coleta de pontos para determinação dos planos de medição com sistema de controle dimensional MMC 3D. a) coleta de pontos na parte superior da peça e, b) coleta de pontos na superfície do fundo da peça.

O procedimento utilizado para determinar a posição espacial de cada um dos planos foi: a) coletar dois pontos em cada lateral da superfície superior da peça (FIG. 3.10a); b) coletar nove pontos na superfície do fundo da peça (FIG. 3.10b); c) via *software* CAI, projetá-los espacialmente; d) via *software*, calcular o módulo distância perpendicular entre os planos, ou seja, a ATP (FIG. 3.9).

Por último, foi definido o desvio dimensional da altura total da peça (DDATP), que foi calculado por meio da diferença entre o valor de altura total do projeto da peça (ATPP) e o valor da ATP, ou seja:

$$DDATP = (ATPP - ATP) == (ATPP - |Z_{Plano Superior} - Z_{Plano Inferior}|) \quad (3.1)$$

Sendo ATPP = 57,92 mm.

Complementarmente ao exposto, como critério de aceitação ou rejeição do produto, conforme Throne (1996), foi adotado erro de  $\pm 1\%$  da dimensão do projeto do produto, neste caso,  $\pm 0,6$  mm.

b) Desvio geométrico de planeza do fundo da peça

Neste estudo, o desvio geométrico de planeza do fundo da peça (DGPF) foi definido como a distância " $t$ " entre os dois planos ideais projetados (FIG. 3.11), onde a superfície real do fundo da peça (FIG. 3.9) deve estar situada, corrigida pelo desvio de planeza do fundo do molde.




FIGURA 3.11 - Definição do desvio geométrico de planeza do fundo da peça: componentes.

Analogamente ao tópico anterior, para medição desses planos e distância " $t$ " foi utilizada MMC 3D (FIG. 3.4b).

O procedimento que foi utilizado para cálculo da distância  $t$  é: a) coletar nove (09) pontos na superfície do fundo da peça (FIG 3.10b) e; b) via software CAI, projetar espacialmente os dois planos limítrofes ideais da superfície real e calcular a distância " $t$ " entre os planos.

Por último, o DGPF foi calculado por meio da diferença entre a distância  $t$  e o valor do desvio de planeza do fundo do molde (DPFM), ou seja:

$$DPIP = (t - DPFM) == (|Z_{Plano Superior} - Z_{Plano Inferior}| - DPFM) \quad (3.2)$$

Sendo DPFM = 0,11 mm.

Como critério de aprovação do produto, foi admitido o erro de  $\pm 50\%$  da dimensão do projeto da peça, neste caso,  $\pm 1$ mm.

c) Desvio geométrico médio dos ângulos laterais da peça

Primeiramente, sendo  $s$  o índice de uma das laterais da peça, o desvio geométrico de um dos ângulos laterais da peça ( $DGALP_s$ ) é a diferença existente entre o ângulo lateral previsto no projeto da peça ( $ALPP_s$ ) e o ângulo lateral mensurado na peça ( $ALMP_s$ ), medido em graus ( $^\circ$ ) (FIG 3.12a).

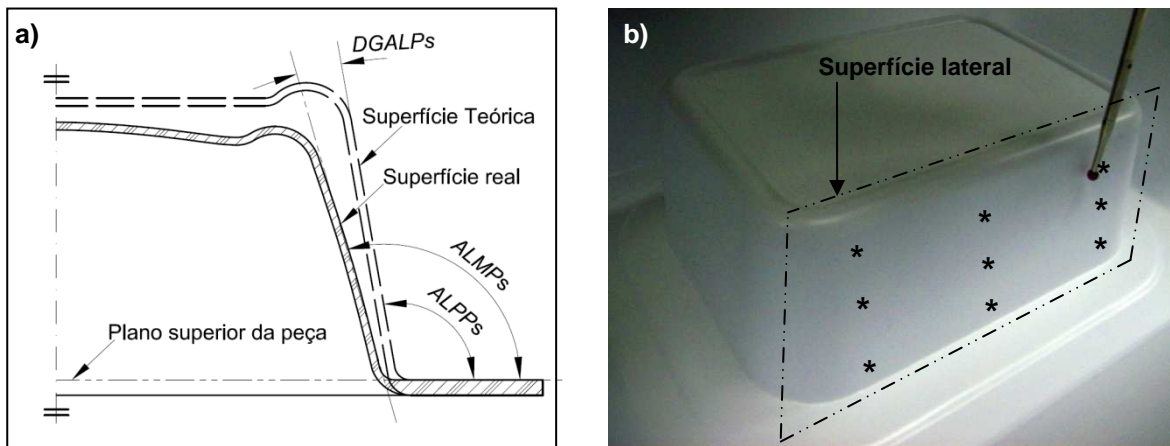


FIGURA 3.12 - Definição do desvio geométrico do ângulo lateral da peça: componentes.

Assim, o procedimento adotado para mensurar os ângulos laterais foi: a) projetar espacialmente o plano superior da peça (vide tópico a e FIG. 3.10a); b) coletar nove pontos na superfície lateral avaliada (FIG. 3.12b); c) via *software* CAI, projetar espacialmente o plano em análise (FIG 3.12a); ainda, via *software*, calcular o ângulo entre os dois planos analisados, (FIG. 3.12a); d) repetir esse processo para demais laterais da peça.

Então, o desvio geométrico médio dos ângulos laterais da peça ( $DGMALP_i$ ) pode ser calculado pela média dos  $DGALP_s$ , ou seja:

$$DGMALP_i = \frac{1}{z} \sum_{j=1}^z DGALP_s == \frac{1}{4} \sum_{j=1}^4 (ALMP_s - ALPP_s) \quad (3.3)$$

Sendo  $i$  o índice do produto analisado,  $z$  o número de lados e  $s$  o índice do lado avaliado, logo:

Ângulo frontal do projeto da peça ( $ALPP_1$ ) =  $95,93^\circ$ ;  
 Ângulo posterior do projeto da peça ( $ALPP_2$ ) =  $95,93^\circ$ ;  
 Ângulo esquerdo do projeto da peça ( $ALPP_3$ ) =  $96,02^\circ$  e;  
 Ângulo direito do projeto da peça ( $ALPP_4$ ) =  $96,06^\circ$ .

Analogamente, para medição desse desvio foi utilizada MMC 3D e as configurações supramencionadas. Como critério de aprovação da peça foi adotado o erro de  $\pm 1\%$  da dimensão média do projeto da peça (THRONE, 1996), convertido em grau decimal, neste caso,  $\pm 0,72^\circ$ .

d) Desvio dimensional do comprimento da diagonal superior da peça

Neste estudo, o desvio dimensional do comprimento da diagonal superior da peça (DDCDP) foi considerado a redução ou aumento das dimensões da extremidade superior do produto (comprimento e largura), avaliadas por meio da relação quadrática de suas dimensões, ou seja, a dimensão da diagonal relativa (FIG. 3.13).




FIGURA 3.13 - Definição do desvio dimensional do comprimento diagonal superior: componentes.

Para quantificar esse desvio dimensional foi calculado o erro existente entre o comprimento da diagonal superior previsto no projeto da peça (CDPP) e o comprimento mensurado na peça (CDMP) (FIG. 3.13).

O procedimento utilizado foi: a) fixar uma posição do eixo "Z" (FIG. 3.14a); b) coletar cinco pontos ao longo da superfície lateral avaliada (FIG. 3.14a); c) repetir esse processo para as demais laterais; b) via *software* CAI, projetar espacialmente as retas contidas entre os pontos analisados (FIG 3.14b); d) por fim, calcular as distâncias laterais das retas em *X* e *Y* via *software* CAI (FIG. 3.14b).

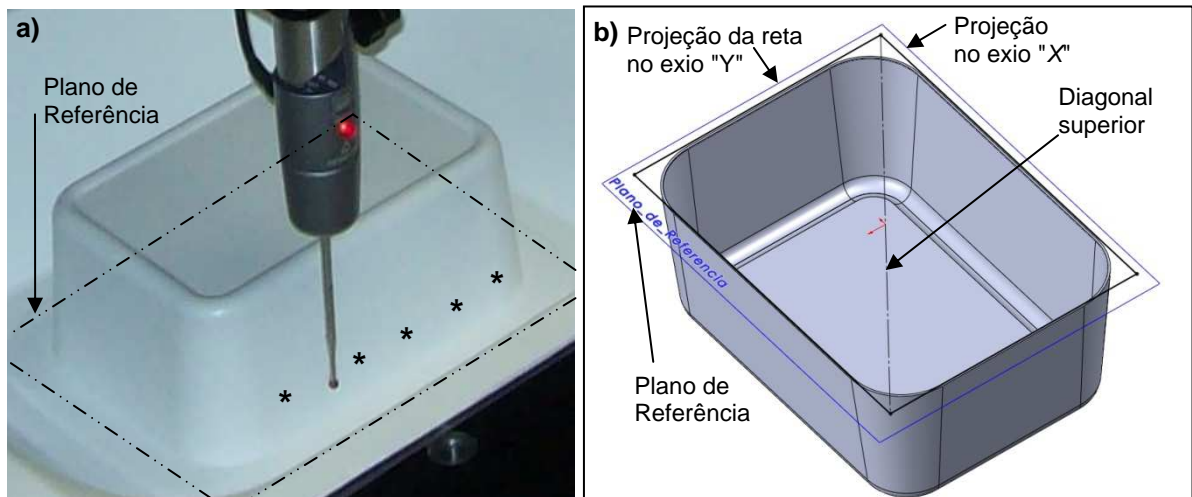


FIGURA 3.14 - Procedimento de medição do desvio dimensional da diagonal. a) fixação do eixo "Z" e coleta dos pontos; b) parte superior da peça em corte: projeção das retas laterais no eixo X e Y e da diagonal.

Então, o DD<sub>CDP</sub> é calculado por meio da diferença entre o valor do CDMP e o valor do CDPP, ou seja:

$$DDCD_i = (CDPP - CDMP_i) = (CDPP) - \sqrt{(compimento_i)^2 + (largura_i)^2} \quad (3.4)$$

Sendo *i* o índice do produto analisado e CDPP = 208,0 mm.

Serão utilizadas MMCs e configurações já descritas e como critério de aprovação da peça foi adotado erro de ±1% da dimensão média do projeto do produto, ou seja, ±2,1 mm (THRONE, 1996).

### 3.4 Métodos e procedimentos de análise de dados utilizados

Após a realização dos experimentos foi feito o teste estatístico dos dados analisados. As estatísticas de teste propostas na pesquisa são os testes  $T$  ( $t$ -test) e  $F$  ( $F$ -test) para a ANOVA (MONTGOMERY, 2013). A ANOVA é um conjunto de modelos estatísticos utilizados para analisar as diferenças entre as médias de dados agrupados (fatores) e suas interações. Em sua forma mais simples, fornece teste estatístico para a comparação de média de fatores em diferentes grupos e, por consequência, generaliza o teste  $T$  para dois ou mais fatores.

Assim, após a coleta e classificação dos dados, foi verificada a existência de *outlier*, ou seja, fatores discrepantes em cada grupo. De posse desses dados, foram elaborados os respectivos gráficos de probabilidade normal por meio das estimativas do teste  $T$  para o grupo de fatores vs o tipo de desvio. A estatística  $t_i$  do teste  $T$  ANOVA descreve a suposição de que as " $n$ " amostras aleatórias são provenientes da distribuição de população aproximadamente normal dentro de seu grupo de índice  $i$ , sendo calculada por:

$$t_i = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \quad (3.5)$$

Sendo  $t_i$  a estimativa calculada,  $\bar{X}$  a média da amostra,  $\mu_0$  a média da população,  $S$  o desvio-padrão da amostra e  $n$  o número de amostras do fator.

Assim sendo,  $t_i$  é o valor calculado de teste  $T$  e  $\pm T_{\alpha/2, v_2}$  o valor limite da região crítica e o critério de rejeição é  $t_i > T_{\alpha/2, v_2}$  e  $t_i < -T_{\alpha/2, v_2}$ . Ou seja, pode-se supor que um  $t_i$  calculado encontra-se fora da distribuição da população se não estiver contido nos extremos da distribuição  $T$  definidos por  $T_{\alpha/2, v_2}$ , com intervalo de confiança de 95% ( $\alpha=0,05$ ). Por consequência, para definição dos efeitos principais ou mais significativos, serão calculadas as estatísticas dos fatores e suas interações por meio da EQ. 3.5. Para o valor da linha limite, tem-se nesta pesquisa, inicialmente,  $T_{0,25,16} > t_i > T_{0,25,16}$ , onde  $T_{0,25,16} = 2,120$  (MONTGOMERY; RUNGER, 2009).



De forma análoga, a estatística do teste  $F$  ANOVA foi realizada para validar quais os principais fatores e interações estatisticamente significativos no mesmo intervalo de confiança de 95% ( $\alpha=0,05$ ).

Neste trabalho, para testar a evidência de que o efeito do fator não é significativo ( $H_0=0$ ), também, foi adotado o cálculo do valor ou índice  $F_0$ , que tem distribuição  $F$  com  $V1$  e  $V2$  graus de liberdade. Assim, se  $F_0$  é o valor calculado do teste  $F$  e  $F_{\alpha, V1, V2}$  o valor limite da região crítica com nível de significância  $\alpha$ , tem-se que o critério de rejeição é  $F_0 > F_{\alpha, V1, V2}$ , ou seja, pode-se aceitar a hipótese de que o efeito do fator é significativo se o valor encontrado for maior que o valor limite da região crítica.

Essa análise foi calculada e apresentada por meio da tabela de teste  $F$ , que consiste nos cálculos das somas dos quadrados (SQ) ou *Sum of Squares*, dos graus de liberdade (GLs) ou *Degrees of Freedom*, das médias quadráticas (MQ) ou *Mean Square*, do valor  $F_0$  e do valor  $P$  ou *p-value*.

Assim, o valor  $F_0$  foi calculado dividindo-se MQ ajustada ( $MQ_i$ ) de cada fator  $i$  ou tratamento pela Média Quadrática do Erro ( $MQ_E$ ) dos respectivos fatores ou tratamentos (MONTGOMERY; RUNGER, 2009). Ou seja:

$$F_0 = \frac{MQ_i}{MQ_E} \quad (3.6)$$

Sendo:

$$MQ_i = \frac{SQ_i}{a_i - 1} \quad (3.7)$$

e

$$MQ_E = \frac{SQ_E}{a_i \cdot (n-1)} \quad (3.8)$$

Sendo  $a_{i..}$  a quantidade das  $i$ -ésimas variações dadas a um fator (níveis), ou seja,  $i = 1, 2, \dots, a_{i..}$ , e  $n$  as  $j$ -ésimas observações de um fator ou tratamento.

Nas EQUAÇÕES 3.7 e 3.8 tem-se que a soma dos quadrados de um fator de índice  $i$  ( $SQ_i$ ) e a soma dos quadrados do erro ( $SQ_E$ ) dos fatores são calculados, respectivamente, pelas EQ. 3.9 e 3.10, como se segue.

$$SQ_i = \sum_{k=1}^{a_i} \frac{y_{ik..}^2}{b_i} - \dots - \frac{y^2 \dots}{a_i b_{i..n}} \quad (3.9)$$

$$SQ_E = SQ_T - SQ_{AB..} - \dots - SQ_i \quad (3.10)$$

Sendo  $y_{ik}$  a  $k$ -ésima observação sujeita ao  $i$ -ésimo tratamento. E a  $SQ_T$  é matematicamente definida como:

$$SQ_T = \sum_{k=1}^{a_i} \dots \sum_{z=1}^n y_{ik}^2 - y_{ik..}^2 \quad (3.11)$$

Portanto, tem-se nesta pesquisa, inicialmente, que,  $F_{0,05;1;16} = 4,49$  para  $\alpha = 0,05$ ,  $V1 = 1$  e  $V2 = 16$ . E, ainda, para inspeção complementar do nível de probabilidade de  $F_{0,05;1;16} > F_0 \geq \alpha$  ou  $p$ -valor, foi considerado  $p$ -valor  $\leq 0,05$ , para ser uma fonte de variação significativa do efeito do fator no processo (MONTGOMERY; RUNGER, 2009).

Concomitantemente a esses testes estatísticos dos dados experimentais, serão calculados os coeficientes de regressão dos modelos de regressão múltipla (MRM), descritos por Montgomery e Runger (2009) e Montgomery (2013).

O MRM é o modelo de regressão que contém mais de uma variável independente ou regresso,  $x$ , ou seja, uma variável dependente ou de resposta,  $Y$ , esta relacionadas a  $k$  regressores ou variáveis de entrada. Tem-se, então, que:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_j x_k + \dots + \beta_j x_1 x_2 + \dots + \beta_j x_k x_{k+1} + \varepsilon \quad (3.12)$$

Sendo  $\beta_0$  a interseção da superfície de resposta ou plano, os  $x_k$  são as  $k$  variáveis regressoras, os  $\beta_j$  são os  $j$  coeficientes de regressão e  $\varepsilon$  é o termo de erro aleatório. O termo de produto cruzado  $\beta_j x_k x_{k+1}$  do modelo é a inclusão do efeito de interação das variáveis de entrada tomadas duas a duas.

Para estimar os  $j$  coeficientes de regressão dos modelos de regressão múltipla, neste trabalho foi utilizado o método dos mínimos quadrados. Supondo-se que existem  $n > k$  amostras e seja  $x_{ij}$  a  $i$ -ésima observação ou nível da variável  $x_j$ , a função dos mínimos quadrados é dada por:

$$L = \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij} \right)^2, \quad i = 1, 2, \dots, n \text{ e } n > k \quad (3.13)$$

Sendo  $L$  o valor a ser minimizado em relação a  $\beta_0, \beta_1, \dots, \beta_{0k}$ , nas  $p=k+1$  equações normais de cada um dos coeficientes de regressão desconhecidos.

Tem-se, daí, que a solução dessas  $p$ -ésimas equações normais serão os estimadores dos coeficientes de regressão,  $\beta_0, \beta_1, \dots, \beta_{0k}$ . Essas equações podem ser resolvidas por diversos métodos matemáticos de resolução de sistemas de equações lineares ou *softwares*, nesta pesquisa, por meio do *software* de cálculo estatístico *Minitab*®.

Por fim, neste trabalho, esses coeficientes serão utilizados para modelagem computacional dos MRMs para cada tipo de variável de resposta ou desvios da peça, os quais, na etapa de desenvolvimento dos modelos de previsão e otimização, serão usados para o desenvolvimento dos modelos de otimização de múltiplas respostas (MOMR), descrito por Montgomery (2013).

Entretanto, ressalta-se que, embora o MRM em sua concepção seja um modelo de regressão linear, neste estudo a forma da superfície de resposta gerada não deverá ser linear. Dependendo do valor dos  $\beta_j$  dos modelos (segunda ordem com interações), eles deverão teoricamente gerar diversos formatos de superfícies não lineares (MONTGOMERY, 2013).

## 4 TESTES EXPLORATÓRIOS

Inicialmente, para o estudo experimental dos parâmetros de fabricação (variáveis de entrada) e de controle (variáveis de saída) e de suas interações, de forma a gerar subsídios para os testes experimentais, fez-se necessário um estudo exploratório para analisar, nesse problema multivárivel, quais variáveis e faixas de valores são significativas quanto à modelagem e otimização do processo em estudo. Assim, a seguir são apresentados esses testes exploratórios, juntamente com a análise dos resultados.

### 4.1 Realização dos testes exploratórios

No processo de termoformagem a vácuo, diversos parâmetros de controle e qualidade podem ser utilizados, dependendo do tipo de equipamento, molde, geometria do produto, entre outros. Assim, nesta pesquisa optou-se por controlar os principais parâmetros de fabricação (fatores) descritos por Throne (1996) e compatíveis com o equipamento, sendo eles:

- a) Matéria-prima do molde = A;
- b) Espessura da folha = B;
- c) Parâmetros de aquecimento (tempo e potência) = C;
- d) Parâmetros de atuação do molde (pressão e velocidade) = D;
- e) Tempo de vácuo = E;
- f) Pressão de vácuo = F.

Assim, com base nas características do equipamento e ensaio preliminares, foram definidos dois níveis ou faixa de variação dos fatores para a etapa de testes exploratórios, conforme QUADRO 4.1.

QUADRO 4.1  
Fatores e seus níveis de variação: testes exploratórios

NÍVEL	FATOR							
	A	B (mm)	C		D		E (s)	F (mbar)
			(s)	(%)	(bar)	(cm/s)		
Baixo (-1)	MDF	1 mm	79	80	3,0	17,3	5,5	10
Alto (+1)	Alumínio	1,5 mm	89	85	3,5	21,5	7	12,5

Ao mesmo tempo, nesta etapa de testes foi adotado o planejamento fatorial fracionado (PFF) " $2^{6-2}_{IV}$ ". Por definição, ele possui seis fatores com dois níveis cada e uma fração de 1/4 dos experimentos a serem realizados. Além disto, duas réplicas foram realizadas, portanto, o número total de experimentos foi de 32 e a sequência foi realizada aleatoriamente. O APÊNDICE B mostra o PFF  $2^{6-2}_{IV}$  para esta etapa de experimentação e a sequência de execução. Assim sendo, foram fabricadas 32 peças, sendo 16 amostras e mais uma réplica por amostra, utilizando como matéria-prima placas de PS que foram previamente secas a 50°C na posição vertical por duas horas em uma "estufa".

Após a conformação a vácuo das peças, estas foram acondicionadas até seu completo resfriamento em uma sala climatizada a  $\approx 22^{\circ}\text{C}$  com  $\approx 60\%$  de umidade. Posteriormente, foram inspecionadas as peças e os respectivos cálculos dos desvios dimensionais e geométricos. Para quantificar os desvios da peça em relação ao seu projeto, foram aplicadas as metodologias de avaliação previstas na seção 3.3.

A FIG. 4.1 esquematiza o processo de produção das peças desde a preparação do equipamento até os cálculos dos desvios, sendo: a) programação do microcontrolador; b) preparação do molde; c) preparação e montagem da placa; d) fixação da placa; e) aquecimento da placa; f) conformação/ estiramento; g) remoção da peça; h) armazenamento/resfriamento; i) controle dimensional; j) obtenção no *software* CAI de variáveis de controle ou exportação e; k) tabulação das variáveis de controle e cálculo de desvios.

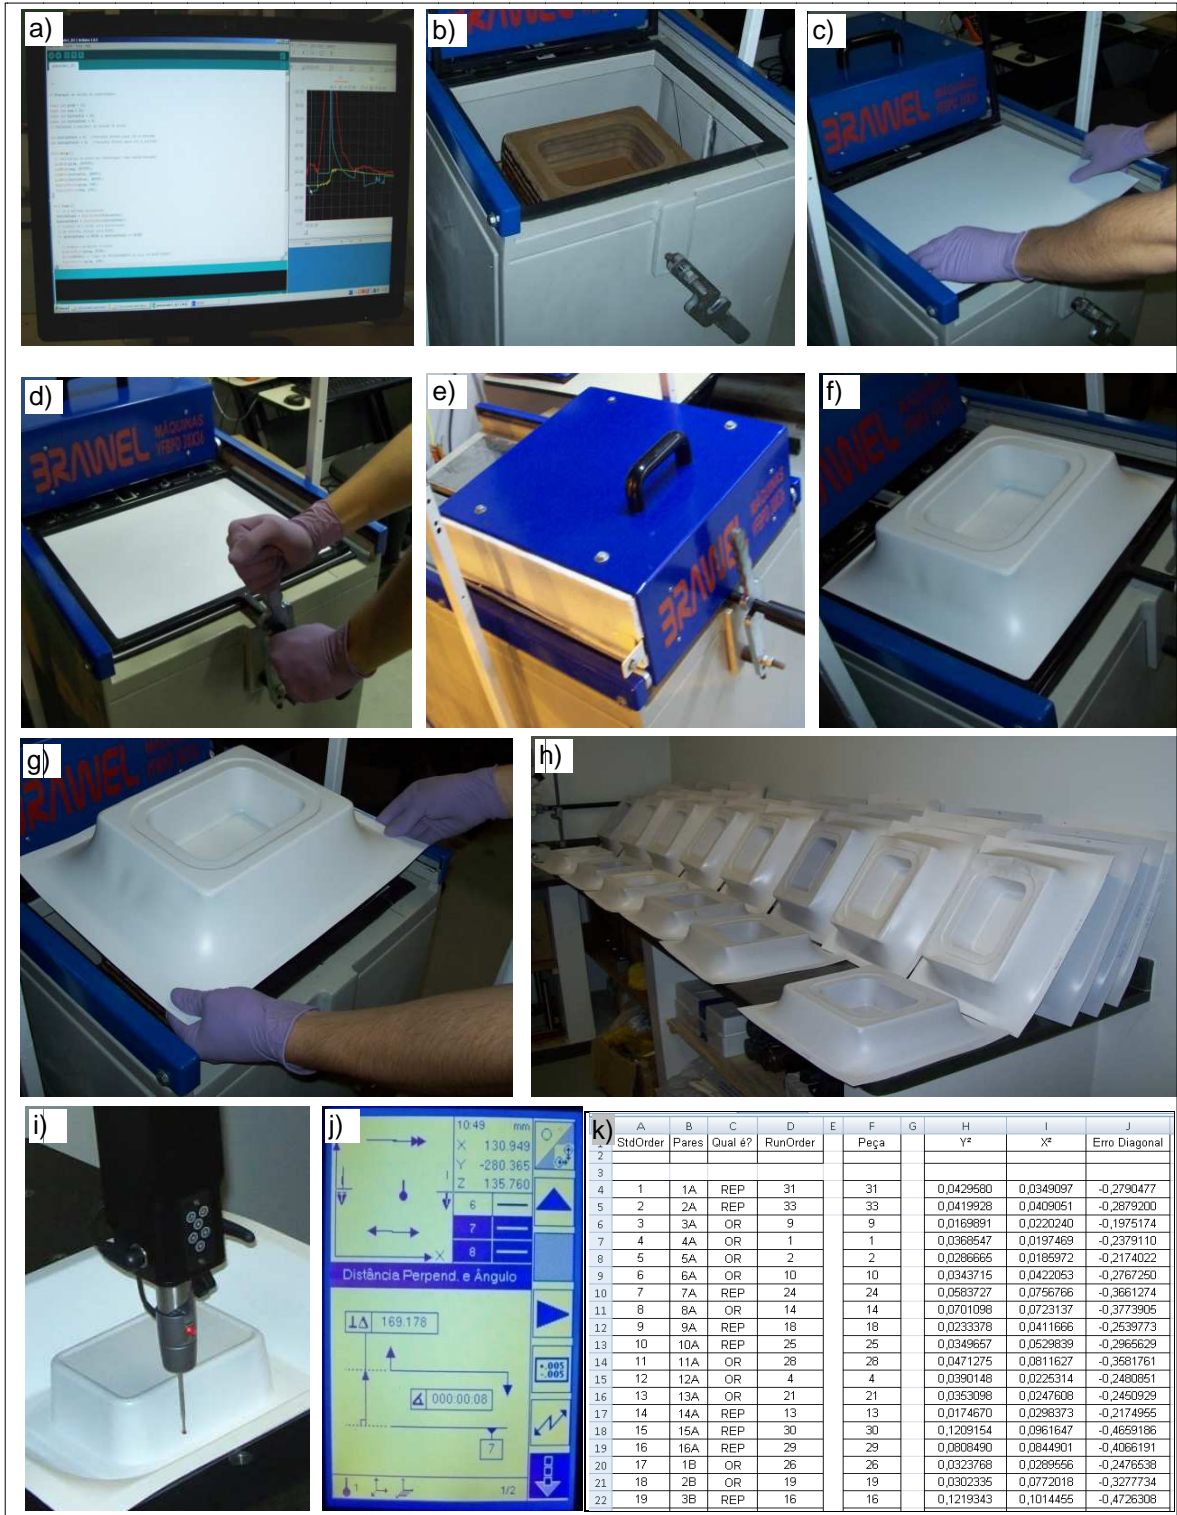


FIGURA 4.1 - Esquemática do processo de produção das peças

	A	B	C	D	E	F	G	H	I	J
	StdOrder	Pares	Qual 4?	RunOrder		Peça		Y²	X²	Erro Diagonal
2										
3										
4	1	1A	REP	31		31		0,0429580	0,0349097	-0,2790477
5	2	2A	REP	33		33		0,0419928	0,0409051	-0,2879200
6	3	3A	OR	9		9		0,0169891	0,0220240	-0,1975174
7	4	4A	OR	1		1		0,0368547	0,0197469	-0,2379110
8	5	5A	OR	2		2		0,0286665	0,0185972	-0,2174022
9	6	6A	OR	10		10		0,0343715	0,0422053	-0,2767250
10	7	7A	REP	24		24		0,0563727	0,0756766	-0,3661274
11	8	8A	OR	14		14		0,0701096	0,0723137	-0,3773905
12	9	9A	REP	18		18		0,0233378	0,0411666	-0,2539773
13	10	10A	REP	25		25		0,0349657	0,0529839	-0,2965629
14	11	11A	OR	26		26		0,0471275	0,0811627	-0,3581761
15	12	12A	OR	4		4		0,0390148	0,0225314	-0,2480851
16	13	13A	OR	21		21		0,0353098	0,0247608	-0,2450929
17	14	14A	REP	13		13		0,0174670	0,0298373	-0,2174955
18	15	15A	REP	30		30		0,1209154	0,0961647	-0,4659186
19	16	16A	REP	29		29		0,0808490	0,0844501	-0,4066191
20	17	17B	OR	26		26		0,0323768	0,0289566	-0,2476538
21	18	2B	OR	19		19		0,0302395	0,0772019	-0,3277734
22	19	3B	REP	16		16		0,1219343	0,1014455	-0,4726308

A TAB. 4.1 apresenta, na sequência do PFF ou "ordem padrão", os desvios mensurados nas peças, respectivamente, DDATP, DGFPF, DGMALP e DDCDP.

TABELA 4.1  
Desvios mensurados nas amostras: testes exploratórios

CORRIDA		DESVIO / RESULTADO			
Ordem padrão	Ordem de execução	DDATP (mm)	DGFPF (mm)	DGMALP (°)	DDCDP (mm)
1	1	-0,402	0,300	0,297	-0,064
2	18	-0,730	2,091	1,036	-0,813
3	7	-0,207	0,095	0,133	-0,156
4	27	-0,410	2,608	0,274	0,004
5	11	-0,460	0,333	0,298	-0,084
6	21	-0,596	2,217	0,745	-0,044
7	14	-0,617	0,197	0,275	-0,165
8	26	0,783	1,975	0,609	-0,090
9	12	-0,507	0,295	0,303	-0,037
10	28	0,278	2,045	0,950	-0,014
11	5	-1,876	0,941	0,691	0,307
12	30	-1,077	2,535	0,505	-0,418
13	10	-0,296	0,234	0,223	-0,151
14	25	0,330	1,980	0,597	0,093
15	4	-0,225	0,284	0,175	-0,169
16	29	-0,364	2,822	0,536	0,299
17	3	-0,216	0,248	0,113	-0,091
18	32	-0,186	1,991	0,945	-0,704
19	9	-0,359	0,085	0,079	-0,149
20	31	-0,815	2,751	0,813	0,168
21	6	-0,663	0,338	0,208	0,026
22	19	-0,206	1,346	0,626	-0,081
23	8	-0,454	0,163	0,144	-0,163
24	20	0,481	2,061	0,457	-0,211
25	16	-0,459	0,232	0,244	-0,141
26	22	0,423	2,221	0,919	0,284
27	2	-2,613	1,322	0,861	0,483
28	17	-0,787	2,159	0,756	-0,497
29	13	-0,423	0,242	0,255	-0,118
30	23	0,220	1,991	0,580	-0,236
31	15	-0,550	0,301	0,148	-0,178
32	24	0,657	2,210	0,638	-0,240

Dimensões em milímetros. Calibração: erro de forma 0,003 mm, esfera de rubi Ø4,0mm.

#### 4.2 Análises dos resultados do teste exploratório

É apresentada a seguir a análise dos valores e faixas de desvios, da normalidade dos dados coletados, dos efeitos mais significativos sobre os desvios das peças.

Assim, primeiramente, com base na TAB. 4.1, os dados formam agrupados em blocos e representados por meio de um gráfico do tipo *boxplots* (GRA. 4.1). Nesse gráfico é possível identificar que os dados em cada bloco se encontram bem agrupados, mas com alguns pontos distantes da média do grupo ou *outlier*.




GRÁFICO 4.1 - Distribuição gráfica dos valores de desvios das amostras: testes exploratórios.

Analisando este gráfico, tem-se que, em relação ao desvio da altura, os dois pontos mais baixos representam as peças em molde de MDF (11 e 27), com espessura de 1,5 mm e parâmetro de aquecimento e pressão de vácuo nos níveis baixos (-1); e os mais altos (8 e 32) são amostras em molde de AL 5052, espessura de 1,5 mm e parâmetros de aquecimento alto. Ainda, os maiores valores do desvio diagonal (2, 18 e 28) representam a amostra em molde de AL 5052 com parâmetros de aquecimento baixo; e os menores, peças em molde de MDF com espessura de 1,5 e parâmetros de aquecimento baixo.

Os gráficos de probabilidade normal para as estimativas do teste  $t$ , ou seja, os fatores ( $t_i$ ) vs os tipos de desvios são apresentados nos GRA. 4.2 a 4.5. Neles são destacados os efeitos mais significativos e representada sua magnitude para o valor da estimativa de  $-t_{0.25,16} > t_i > t_{0.25,16}$  onde,  $t_{0.25,16} = 2,120$ . Ou seja, para sua análise, qualquer fator que obtenha pelo cálculo do teste  $t$  valor inferior a -2,120 ou



superior a 2,210 é um fator significativo para o desvio em análise, sendo este intervalo de teste representado graficamente por uma linha negra no gráfico.

O GRÁF. 4.2 mostra os resultados do teste *t* para o erro na altura total do produto. Lê-se que os fatores matéria-prima do molde, espessura da folha e parâmetros de aquecimento, isoladamente, interferem significativamente na dimensão total do produto.




GRÁFICO 4.2 - Probabilidade da estimativa dos efeitos vs desvio dimensional da altura total da peça ( $\alpha=0,05$ ).

O GRA. 4.3 apresenta que o efeito mais significativo é a materia-prima do molde, ou seja, sua variação possui grandes reflexos na planicidade inferior do produto.

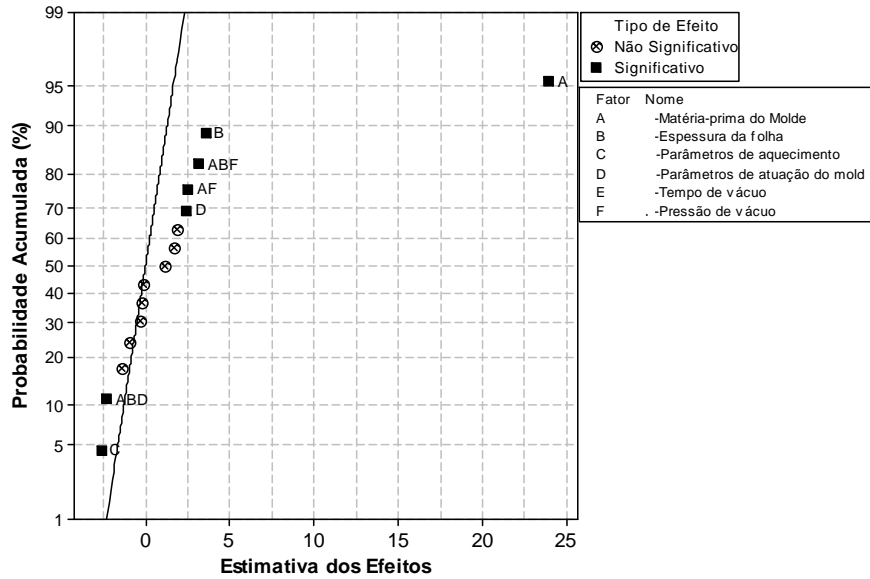


GRÁFICO 4.3 - Probabilidade normal da estimativa dos efeitos vs desvio geométrico de planeza do fundo da peça ( $\alpha=0,05$ ).

Por sua vez, no GRÁF. 4.4, observa-se que, para os desvios dos ângulos laterais, os fatores de primeira ordem, matéria-prima do molde, parâmetros de aquecimento e tempo de vácuo afetam esse tipo de desvio durante o processo.




GRÁFICO 4.4 - Probabilidade da estimativa dos efeitos vs desvio geométrico médio dos ângulos laterais da peça ( $\alpha=0,05$ ).

Já para o desvio do comprimento da diagonal superior do produto (GRÁF. 4.5), a pressão de vácuo e os parâmetros de atuação do molde são os que têm mais influência. Na região limite encontra-se o fator matéria-prima do molde.




GRÁFICO 4.5 - Probabilidade da estimativa dos efeitos vs desvio dimensional do comprimento da diagonal da peça ( $\alpha=0,05$ ).

Para corroborar as análises do teste *t* apresentadas na forma de gráfico, foi aplicado o procedimento de ANOVA para o teste *F* por meio do *software* de cálculo estatístico *Minitab*®, para confirmar quais fatores influenciam o processo e evidenciar suas respectivas magnitudes.

A TAB. 4.2 representa o resumo dos cálculos da ANOVA para fontes de variação vs os desvios estudados, com nível de confiança de 95% ( $\alpha=0,05$ ). Nela é possível observar, pelos valores apresentados, que os termos ressaltados nos GRÁF. 4.2 a 4.5 são realmente os mais significativos para cada tipo de desvio, sendo os mesmos sinalizados por "\*" nas colunas  $F_{(0)}$  da tabela para o teste *F* e destacados por meio de sublinhado no caso do *p-valor*  $\leq 0,05$ , para uma fonte de variação significativa.

TABELA 4.2

Resumo da ANOVA para os efeitos das fontes de variação sobre os desvios dimensionais e geométricos nas amostras: testes exploratórios

Fonte de Variação		Respostas / Tipos de Desvio							
Fator / Termo	Descrição	Desvio dimensional da altura total da peça		Desvio geométrico de planeza do fundo da peça		Desvio geométrico médio dos ângulos laterais da peça		Desvio dimensional do comprimento da diagonal da peça	
		$F_{(0)}$	p-valor	$F_{(0)}$	p-valor	$F_{(0)}$	p-valor	$F_{(0)}$	p-valor
A	Matéria-prima do Molde	100,8*	<u>0,000</u>	84,36*	<u>0,000</u>	26,12*	<u>0,000</u>	4,49*	<u>0,050</u>
B	Espessura da folha	12,97*	<u>0,002</u>	3,06	0,100	7,76*	<u>0,013</u>	1,65	0,217
C	Parâmetros de aquecimento	6,95*	<u>0,018</u>	11,41*	<u>0,004</u>	21,52*	<u>0,000</u>	0,17	0,681
D	Parâmetros de atuação do molde	6,07*	<u>0,025</u>	3,47	0,081	1,84	0,193	5,87*	<u>0,028</u>
E	Tempo de vácuo	1,31	0,269	9,92*	<u>0,006</u>	0,56	0,466	0,78	0,390
F	Pressão de vácuo	0,04	0,841	3,11	0,097	4,35	0,053	8,94*	<u>0,009</u>
A*B	-	2,88	0,109	11,14*	<u>0,004</u>	2,18	0,159	0,01	0,938
A*C	-	0,09	0,764	0,34	0,570	1,03	0,325	11,48*	<u>0,004</u>
A*D	-	0,91	0,353	3,72	0,072	9,15	0,008	0,07	0,800
A*E	-	2,02	0,175	0,04	0,839	25,02*	<u>0,000</u>	4,46	0,051
A*F	-	6,51*	<u>0,021</u>	3,27	0,090	4,71	0,045	28,82*	<u>0,000</u>
B*D	-	3,43	0,083	5,84*	<u>0,028</u>	25,71*	<u>0,000</u>	2,32	0,147
B*F	-	0,01	0,906	6,04	0,026	7,21	0,016	4,54*	<u>0,049</u>
A*B*D	-	5,19*	<u>0,037</u>	0,59	0,455	0,30	0,591	23,92*	<u>0,000</u>
A*B*F	-	10,25*	<u>0,006</u>	4,16	0,058	11,69*	<u>0,004</u>	1,48	0,242

$S = 0,13755$ ;  $R^2 = 86,09\%$  e;  $R^2_{(adj)} = 73,04\%$

Legenda: \* = Significativo pelo teste F, respectivamente,  $\alpha = 0,05$  e  $f_{0,05;1;16} = 4,49$ ; ANOVA: Análise de Variância;  $S = \sqrt{MQ_E}$ ;  $R^2$  = Coeficiente de determinação e;  $R^2_{(adj)}$  = Coeficiente de determinação ajustado.

### 4.3 Considerações preliminares

De forma geral, os resultados dos testes exploratórios comprovam que todos os fatores analisados são significativos para os estudos dos desvios dimensionais e geométricos.

De maneira pontual, a análise da TAB. 4.1, permite concluir que os desvios discrepantes do conjunto de dados, ou seja, tecnicamente fora de controle, encontram-se nas peças fabricadas em molde de MDF com espessura de 1,5 mm

e parâmetros de aquecimento baixo (-1) e também em amostras de molde de AL ora com parâmetros de aquecimento baixo, ora, alto. Isso evidencia o caráter multivariável e não linear dos parâmetros de fabricação do processo. Ao mesmo tempo, inferiu-se pelos GRA. 4.2 a 4.5 e TAB. 4.2 que o fator A (matéria-prima do molde) possui grande influência quanto a todos os resultados dos desvios dimensionais e geométricos estudados, interferindo, assim, diretamente na qualidade do produto.

Ainda com base na TAB. 4.2 e nos critérios de aceitação dos produtos definidos na seção 3.3, é evidenciado que apenas algumas amostras produzidas em moldes de MDF encontram-se dentro da faixa de tolerância aceitável, ou seja, esse tipo de molde encontra-se mais adequado ao maquinário utilizado.

Diante do exposto, foi realizada uma nova etapa de testes aprofundados que contemplem as conclusões das análises iniciais, ou seja, testes mais específicos. Assim, primeiramente para evitar que a maior predominância do fator "matéria-prima do molde" venha a contaminar a influência dos fatores combinados dentro do intervalo de confiança adotado nas análises, serão fabricadas amostras apenas em molde de MDF. O mesmo procedimento foi adotado para o fator "espessura da folha" que foi fixada no nível alto, ou seja, 1,5 mm.

Para observar detalhadamente a influência dos "parâmetros de aquecimento", que é o segundo de maior influência nos desvios avaliados, ele foi desmembrado em dois novos fatores, a serem controlados em novas faixas superiores, devido à fixação do termo B no nível alto. Por fim, os demais fatores serão ajustados baseados na faixa máxima dos parâmetros de aquecimento.

## 5 TESTES DEFINITIVOS

O objetivo desses novos testes experimentais é aprofundar na análise dos parâmetros de fabricação e de inter-relações de modo a permitir o desenvolvimento de um modelo generalista multivariável que consiga prever o comportamento dos desvios do processo em diversas situações. Assim como, *a posteriori*, no cenário de manufatura idealizado obter um conjunto de parâmetros otimizados para fabricação de peças que propicie alcançar o menor conjunto de desvios e, conseqüentemente, o melhor desempenho do sistema.

### 5.1 Realização dos testes

Para desenvolvimento da segunda sequência de testes experimentais, diferentemente do cenário anterior, onde existiam duas matérias-primas do molde e espessuras da folha, nesta etapa foi utilizada apenas uma matéria-prima para o molde, o MDF, e uma espessura da folha, 1,5 mm. O fator "parâmetro de aquecimento" foi desmembrado em dois, "tempo de aquecimento" e "potência de aquecimento". Por fim, foram estabelecidos novos níveis para os parâmetros, baseados na faixa dos fatores de aquecimento.

O QUADRO 5.1 apresenta os fatores e níveis utilizados na segunda etapa de testes, os testes experimentais.

QUADRO 5.1  
Fatores e seus níveis de variação - Testes Experimentais

Níveis	Fatores					
	A	B	C		D	E
	Tempo de aquecimento (s)	Potência de aquecimento (%)	Parâmetros de atuação do molde		Tempo de vácuo (s)	Pressão de vácuo (mbar)
Pressão (bar)			Velocidade (cm/s)			
Baixo (-1)	80	90	3,4	18,4	7,2	10
Alto (+1)	90	100	4,0	21,6	9,0	15

Para execução da segunda sequência de testes foi utilizado o planejamento fatorial fracionado com cinco fatores de dois níveis cada, contemplando uma fração de 1/2 dos experimentos totais, descrito como “ $2^{5-1}_V$ ”. Para cada teste desenvolvido foi realizada uma réplica e foram acrescentados ao planejamento dois testes no ponto central (*center point*). O APÊNDICE C apresenta o PFF  $2^{5-1}_V$  para essa etapa de experimentação e a sequência de execução.

Para a realização dos testes foram utilizados os mesmos equipamentos, *softwares*, sistemas de aquisição de dados e matéria-prima da primeira etapa de testes experimentais. Ao mesmo tempo, para garantir a confiabilidade dos dados e comparação com os demais testes, foram usados os mesmos procedimentos para inspeção das peças, equipamentos e *softwares*, bem como a metodologia descrita anteriormente.

A sequência de testes foi realizada conforme o APÊNDICE C e os parâmetros de fabricação foram novamente programados no microcontrolador. Desta forma, e seguindo as mesmas etapas dos testes anteriores (FIG. 4.1), foram fabricadas 34 peças e após o resfriamento das amostras foi feita a inspeção das peças, sendo os dados dos desvios calculados e tabulados. A TAB. 5.1 apresenta os desvios dimensionais e geométricos mensurados nas amostras.

TABELA 5.1

Desvios mensurados nas amostras: testes experimentais

CORRIDA		<i>Desvio dimensional da altura total da peça (mm)</i>	<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	<i>Desvio geométrico médio dos ângulos laterais da peça (°)</i>	<i>Desvio dimensional do comprimento da diagonal da peça (mm)</i>
<i>Ordem padrão</i>	<i>Ordem de execução</i>				
1	31	-1,294	1,532	0,642	-0,279
2	33	-1,096	0,320	0,477	-0,288
3	9	-0,323	0,418	0,410	-0,198
4	1	-0,122	0,358	0,269	-0,238
5	2	-0,628	1,050	0,476	-0,217
6	10	-0,943	0,281	0,398	-0,277
7	24	-0,639	0,531	0,242	-0,366
8	14	-0,328	0,265	0,239	-0,377
9	18	-1,431	0,955	0,462	-0,254
10	25	-0,757	0,230	0,043	-0,297
11	28	-0,419	0,265	0,223	-0,358
12	4	-0,463	0,213	0,204	-0,248
13	21	-1,234	0,805	0,442	-0,245
14	13	-0,989	0,301	0,128	-0,217
15	30	-0,792	0,213	0,164	-0,466
16	29	-0,692	0,238	0,181	-0,407
17	26	-1,306	1,551	0,628	-0,248
18	19	-0,645	0,502	0,433	-0,328
19	16	-0,492	0,279	0,292	-0,473
20	11	-0,463	0,288	0,107	-0,383
21	17	-0,563	1,150	0,476	-0,227
22	12	-1,000	0,451	0,416	-0,241
23	15	-0,597	0,110	0,235	-0,423
24	32	-0,824	0,062	0,221	-0,455
25	6	-1,565	0,910	0,539	-0,160
26	3	-0,464	0,238	0,113	-0,305
27	34	-0,832	0,736	0,231	-0,430
28	8	-0,490	0,204	0,302	-0,288
29	23	-1,022	1,106	0,442	-0,310
30	5	-0,467	0,294	0,082	-0,231
31	20	-0,576	0,213	0,232	-0,460
32	7	-0,229	0,270	0,218	-0,294
33	27	-0,785	0,505	0,285	-0,317
34	22	-0,794	0,457	0,322	-0,301

Dimensões em milímetros. Calibração: erro de forma 0,003 mm, esfera de rubi Ø4,0mm.

## 5.2 Análises dos resultados do teste definitivo

É apresentada a seguir a análise dos valores e faixas de desvios, da normalidade dos dados coletados, dos efeitos mais significativos, das tendências de comportamento das variáveis estudadas e das interações dos parâmetros de fabricação sobre os desvios das peças.



Assim, primeiramente, o GRA. 5.1 mostra a distribuição tipo *BoxPlots* dos dados da TAB. 5.1. Nele se constata que os dados em cada bloco se encontram bem agrupados, com exceção apenas de dois pontos (amostra 01 e sua réplica, amostra 17) para o desvio de planeza na parte inferior.

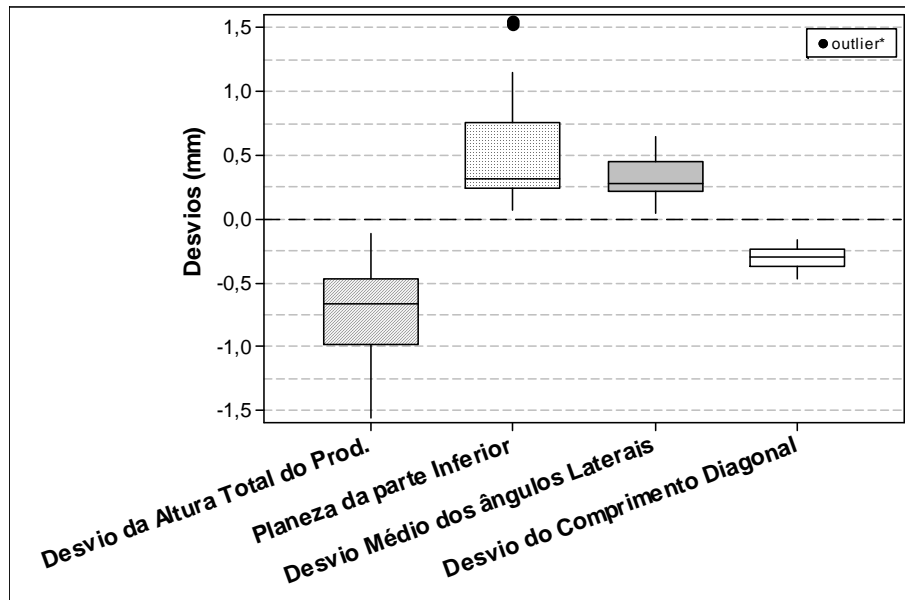


GRÁFICO 5.1 - Distribuição gráfica dos valores de desvios das amostras: testes experimentais.

Ao mesmo tempo, quando confrontados os GRA. 4.1 e 5.1, evidencia-se que essas amostras encontram-se dentro da faixa de valores dos dados do primeiro experimento. Conseqüentemente, conclui-se que esses novos dados representam satisfatoriamente uma parte amostral dos testes anteriores.

Os GRÁF. 5.2 a 5.5 mostram, respectivamente, a probabilidade normal para as estimativas dos fatores ( $t_i$ ) vs os desvios dimensionais e geométricos da peça, com base no teste  $t$ , sendo que  $-t_{025,17} > t_i > t_{025,17}$ , onde,  $t_{025,17} = 2,110$ .

Assim, primeiramente, no GRÁF. 5.2 nota-se que os efeitos principais "tempo de aquecimento" e "potência de aquecimento" são os mais significativos na análise do desvio da dimensão total do produto, e em uma escala de menor importância, mas significativa, as interações AC, AD e BC. Ainda, comparando esse resultado com os dos experimentos anteriores (cap. 4), inferiu-se que, independentemente do tipo

de material do molde, os "parâmetros de aquecimento" interferem no desvio total de altura do produto.




GRÁFICO 5.2 - Probabilidade da estimativa dos efeitos vs desvio dimensional da altura total da peça ( $\alpha=0,05$ ).

Já no GRÁF. 5.3 é possível observar que todos os fatores são significativos; e em alto grau de importância, a interação de segunda ordem "tempo de aquecimento" e "potência de aquecimento" (A\*B). Relacionando esse resultado com os anteriores, concluiu-se que para amostras produzidas em molde em MDF esse tipo de desvio é mais sensível à modificação dos fatores, tornando, assim, seu controle mais crítico.

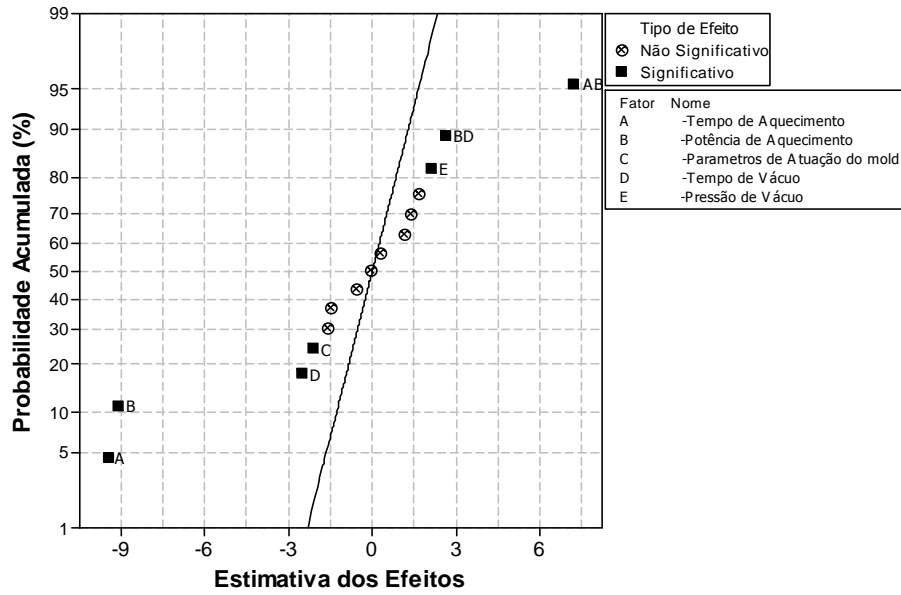


GRÁFICO 5.3 - Probabilidade normal da estimativa dos efeitos vs desvio geométrico de planeza do fundo da peça ( $\alpha=0,05$ ).

Por sua vez, no GRÁF. 5.4 é possível comprovar que apenas o fator "pressão de vácuo" não afeta significativamente o desvio dos ângulos laterais e que as interações A\*B, B\*D e C\*E possuem grande influência sobre erro dos ângulos laterais. Ao mesmo tempo, independentemente do material do molde, a variação do fator "pressão de vácuo" (F) não influenciou esse desvio, ao contrário das variáveis de entrada "parâmetros de aquecimento" e "tempo de vácuo".




GRÁFICO 5.4 - Probabilidade da estimativa dos efeitos desvio geométrico médio dos ângulos laterais da peça ( $\alpha=0,05$ ).

Por último, no GRÁF. 5.5, que relaciona o desvio do comprimento da diagonal, é visto que apenas a variável de entrada "potência de aquecimento" isoladamente ou sua interação com os "parâmetros de atuação do molde" interfere no desvio do comprimento da diagonal superior da amostra. Com base nos resultados dos testes anteriores, é possível abstrair que as causas desse tipo de desvio são modificadas conforme a matéria-prima do molde.




GRÁFICO 5.5 - Probabilidade da estimativa dos efeitos vs desvio dimensional do comprimento da diagonal da peça ( $\alpha=0,05$ ).

Complementando as análises apresentadas, a TAB. 5.2 transcreve o resumo dos cálculos da ANOVA para o desvios vs os fatores estudados, com nível de confiança de 95% ( $\alpha=0,05$ ), ou seja, o valor crítico de teste para a distribuição  $F$  é  $f_{0,05;1;17} = 4,45$ . Assim sendo, a análise da tabela permite concluir que os fatores significativos apresentados nos GRÁF. 5.2 a 5.5 e discutidos são significativos, portanto, merecem ser avaliados para cada um dos desvios. E, ainda, de maneira geral, pode-se afirmar que os fatores críticos para o controle do produto são aqueles relacionados ao aquecimento.

TABELA 5.2

Resumo da ANOVA para os efeitos das fontes de variação sobre os desvios dimensionais e geométricos nas amostras: testes experimentais

Fonte de Variação		Respostas / Tipos de Desvio							
Fator / Termo	Descrição	Desvio dimensional da altura total da peça (mm)		Desvio geométrico de planeza do fundo da peça (mm)		Desvio geométrico médio dos ângulos laterais da peça (°)		Desvio dimensional do comprimento da diagonal da peça (mm)	
		$F_{(0)}$	p-valor	$F_{(0)}$	p-valor	$F_{(0)}$	p-valor	$F_{(0)}$	p-valor
A	Tempo de aquecimento	10,2*	<u>0,005</u>	89,7*	<u>0,000</u>	77,72*	<u>0,000</u>	0,42	0,542
B	Potência de aquecimento	37,0*	<u>0,000</u>	82,6*	<u>0,000</u>	86,23*	<u>0,000</u>	22,5*	<u>0,000</u>
C	Parâmetros de atuação do molde	0,30	0,592	4,6*	<u>0,046</u>	8,93*	<u>0,008</u>	1,44	0,246
D	Tempo de vácuo	0,98	0,336	6,43*	<u>0,021</u>	56,03*	<u>0,000</u>	0,02	0,899
E	Pressão de vácuo	0,08	0,776	4,50*	<u>0,049</u>	1,36	0,259	0,34	0,567
A*B	-	1,92	0,184	52,1*	<u>0,000</u>	43,81*	<u>0,000</u>	3,91	0,065
A*C	-	4,86*	<u>0,042</u>	2,73	0,117	6,24*	<u>0,023</u>	0,27	0,612
A*D	-	6,13*	<u>0,024</u>	1,29	0,271	5,58*	<u>0,030</u>	2,27	0,150
A*E	-	1,87	0,189	2,63	0,123	2,04	0,171	0,29	0,596
B*C	-	5,66*	<u>0,029</u>	0,01	0,943	0,42	0,525	5,04*	<u>0,038</u>
B*D	-	0,05	0,833	6,98*	<u>0,017</u>	30,14*	<u>0,000</u>	0,12	0,739
B*E	-	0,63	0,438	0,08	0,783	2,45	0,136	0,89	0,359
C*D	-	0,03	0,867	1,81	0,196	1,54	0,232	0,14	0,709
C*E	-	3,02	0,100	2,23	0,154	29,55*	<u>0,000</u>	1,12	0,305
D*E	-	4,89*	<u>0,041</u>	0,37	0,550	0,25	0,817	1,38	0,257

S = 0,0648608;  $R^2 = 70,26\%$  e;  $R^2_{(adj)} = 42,28\%$

\* = Significativo pelo teste F, respectivamente,  $\alpha = 0,05$  e  $f_{0,05;1;17} = 4,45$ ; ANOVA: Análise de Variância;  $S = \sqrt{MQ_E}$ ;  $R^2$  = Coeficiente de determinação e;  $R^2_{(adj)}$  = Coeficiente de determinação ajustado.

Complementar ao exposto, a análise global da TAB. 5.2 leva a concluir que nenhum fator pode ser eliminado de um estudo ou modelagem posterior dos desvios dimensionais ou geométricos e que, por fim, a variação de qualquer variável de entrada gera modificações em ao menos um tipo de desvio.

Considerando as análises apresentadas e a evidência dos fatores significativos, fez-se necessário o estudo das interações dos fatores vs os desvios estudados, para que se pudesse determinar como eles conjuntamente influenciam o processo e em que níveis se encontram os desvios mais baixos. Assim, os GRÁF. 5.6 a 5.9

demonstram as interações dos fatores vs desvios estudados, sendo que para à análise dos mesmo deve-se verificar qual combinação dos níveis de cada par de fatores, se encontra em patamar mais próximo de zero (0,00).

No GRÁF. 5.6 têm-se as interações vs o desvio dimensional da altura total da peça. Nele se verificam que as combinações que reduzem esse tipo de desvios são predominantemente as combinações do fator tempo de aquecimento em 90s (alto), potência em 100% (alto) e para os demais fatores não existe um padrão de nível que minimize o desvio. Também se vê que o resultado do ponto central se aproxima de níveis mais baixos, onde existem erros em valores significativos.

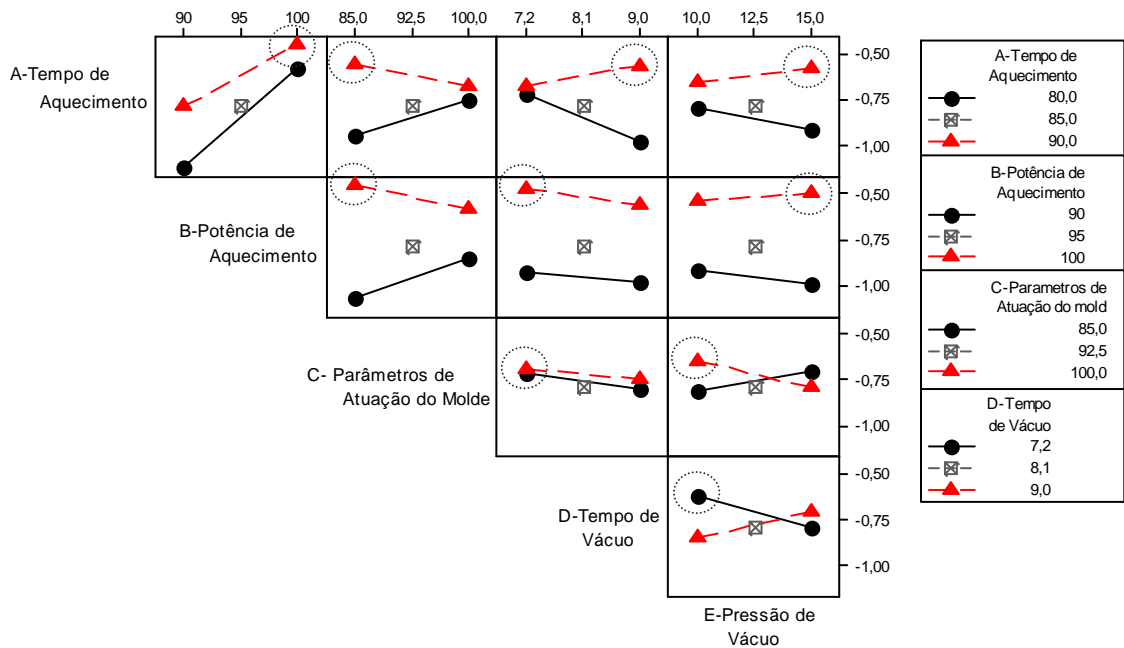


GRÁFICO 5.6 - Interações dos fatores vs desvio dimensional da altura total da peça.

Já no GRÁF. 5.7, que apresenta as interações para o desvio geométrico de planeza, é possível inferir que os parâmetros dominantes são o tempo de aquecimento e potência de aquecimento em níveis altos. E para os outros fatores não existe um comportamento padrão que minimize o desvio. Quanto ao comportamento do ponto central, constata-se que seu valor nesse desvio se aproxima de níveis altos, onde os erros são minimizados.

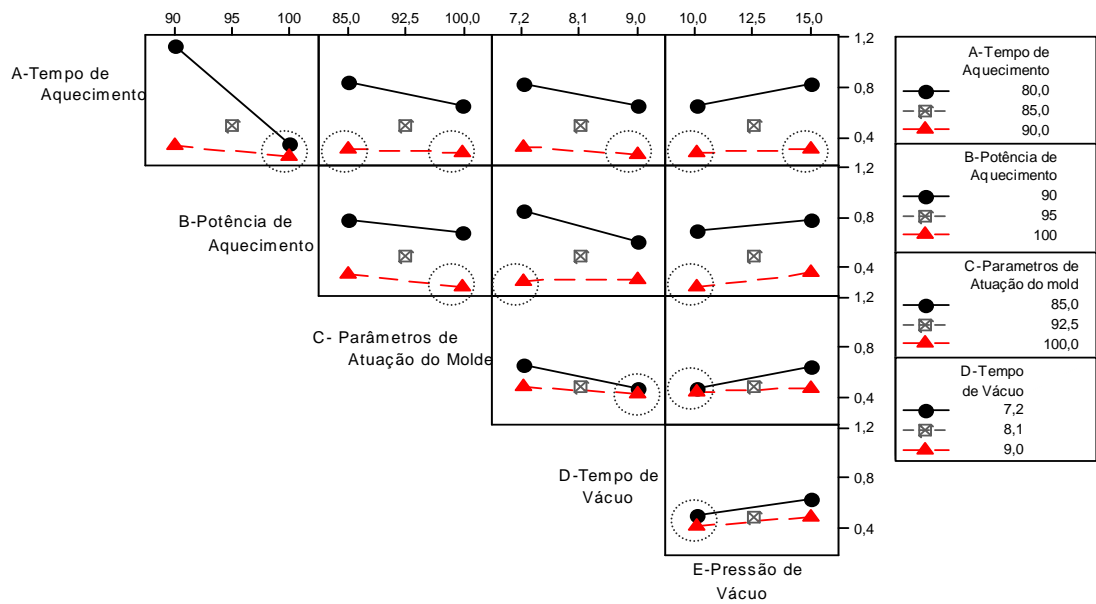


GRÁFICO 5.7 - Interações dos fatores vs desvio geométrico de planeza do fundo da peça.

Por sua vez, a inspeção do GRÁF. 5.8, que representa as interações vs o desvio geométrico dos ângulos laterais, permite concluir que preponderantemente os fatores tempo de aquecimento, potência de aquecimento, parâmetros de atual do molde e tempo de vácuo devem ser mantidos próximos dos níveis altos para que esse tipo de erro seja reduzido. E com exceção dos pares de fatores C vs D e D vs E, os outros apresentam interações significativas não proporcionais ou inversamente proporcionais.

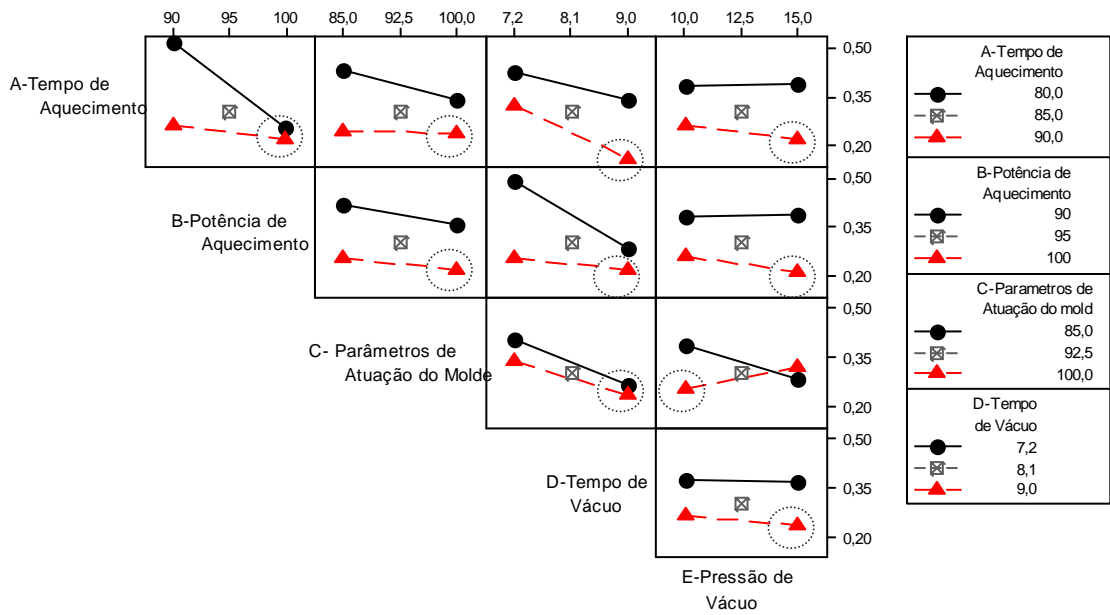


GRÁFICO 5.8 - Interações dos fatores vs desvio geométrico médio dos ângulos laterais da peça.

Ainda pela análise do GRÁF. 5.9, que apresenta as interações para o desvio dimensional do comprimento diagonal, conclui-se que o fator preponderante para a redução do desvio é potência de aquecimento em nível baixo (90%) e em nível menor o tempo de vácuo alto (9,0 s) e pressão de vácuo baixa (10,0). As interações restantes, fatores e o ponto central não possuem uma tendência ou nível de interação predominante.



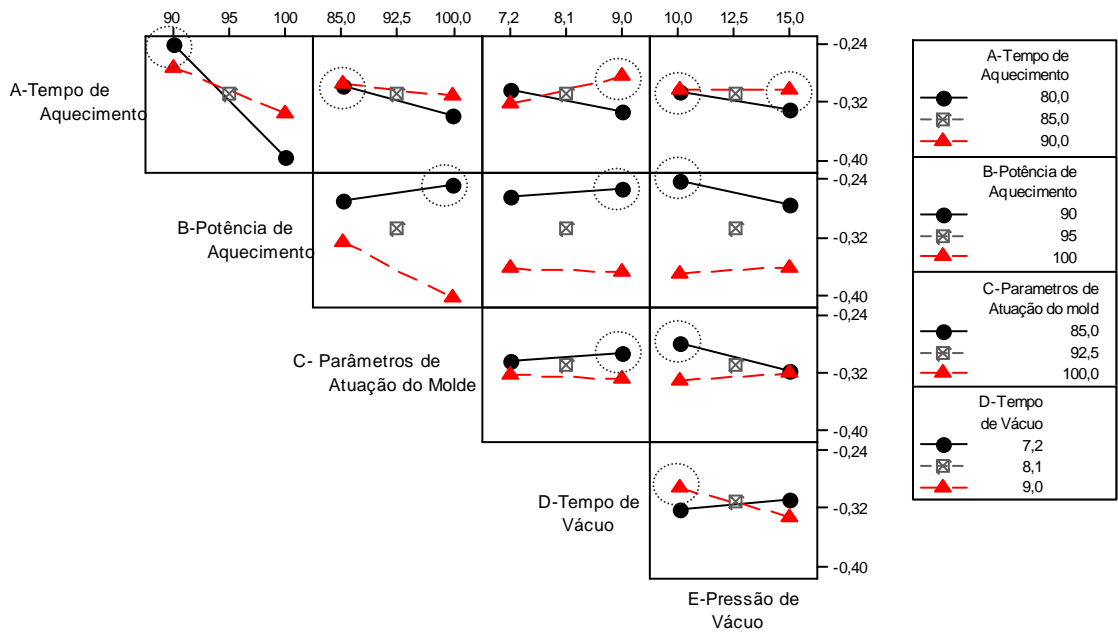


GRÁFICO 5.9 - Interações dos fatores vs desvio dimensional do comprimento da diagonal da peça.

Por fim, de maneira geral, os parâmetros tempo de aquecimento e potência de aquecimento são os fatores críticos do controle dos desvios do processo, sendo essa relação inversa e não proporcional. Também, a análise dos gráficos sugere de forma geral a existência de interação entre todos os fatores para todos os desvios estudados e ainda revela que não existe qualquer tendência preponderante de comportamento entre os níveis dos fatores e faixas inferiores de desvios. Pode-se abstrair disso que a modificação dos níveis dos fatores não pode ser estudada isoladamente.

### 5.3 Considerações preliminares

Diante do exposto, é possível evidenciar algumas relações entre diferentes parâmetros de fabricação e níveis ideais de desvios, como: a) o fator "tempo de aquecimento" e "potência de aquecimento" em níveis altos resulta em menores desvios dimensionais de altura, planeza e ângulos laterais; b) o "tempo de vácuo" e "potência de vácuo" ora possuem correlação direta, ora inversa, para reduzir os níveis de desvios; c) o "tempo de vácuo" e o "parâmetros de atuação do molde" possuem correlação direta em todos os desvios; d) o parâmetro "tempo de

aquecimento" em 90s (alto) propicia, em geral, menores desvios e) entre os fatores analisados, o "parâmetro de atuação do molde" tem a menor taxa de razão em seus níveis e, em geral, para desvio "comprimento diagonal superior" os fatores manifestam comportamento inverso em relação aos demais desvios.

Assim sendo, infere-se que, dada a necessidade de análise conjunta de parâmetros de fabricação e desvios dimensionais geométricos (entradas e saídas), as respostas ideais para o conjunto de saídas encontraram-se em espaços n-dimensionais. Então, uma solução ótima do conjunto de saídas está na região espacial, onde a combinação das configurações dos parâmetros de fabricação otimiza simultaneamente o conjunto de desvios.

O GRÁF. 5.10 apresenta a solução da otimização de respostas, processado no programa computacional de análises estatísticas *Minitab*®. Nesse gráfico, na parte superior encontram-se os parâmetros estudados e na linha "Cur" em destaque o valor para cada fator que minimiza os conjuntos de desvios. Na lateral esquerda, nas linhas "y" em destaque, o valor de desvio calculado pelo modelo para cada erro estudado. Assim sendo, pela inspeção do gráfico, tem-se que a configuração ótima encontrada pelo modelo de otimização de múltiplas respostas do *software Minitab*® é: A = 90,0 s, B = 100 %, C = 7,2 s, D = 15 mbar, e E = 1 00 %. Ressalta-se que a solução alcançada pelo modelo MOMR está em consonância com as análises já apresentadas nesta seção e na seção 5.2.

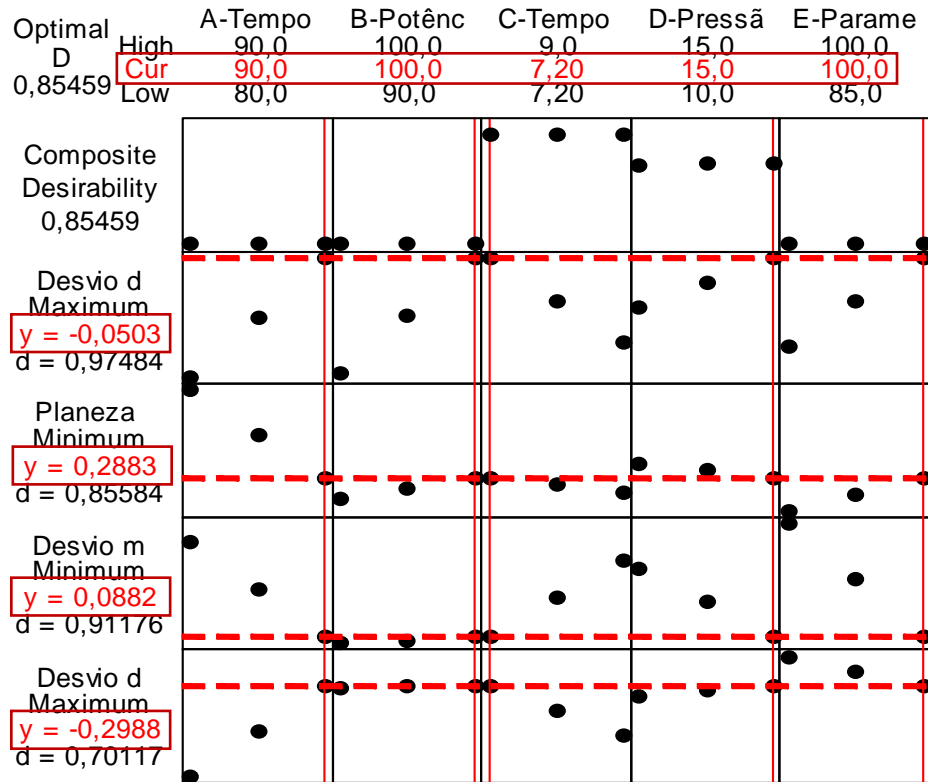


GRÁFICO 5.10 - Solução conjunta da otimização das respostas para o desvio dimensional e geométrico da peça.

## 6 DESENVOLVIMENTO DOS MODELOS DE PREVISÃO E OTIMIZAÇÃO

Neste capítulo são apresentadas as metodologias e os procedimentos utilizados para desenvolver os modelos computacionais de estimativa e otimização dos desvios dimensionais e geométricos para o processo de termoformagem a vácuo, analisado neste trabalho.

Para tal, no cap. 5 foi estudado o comportamento de um grupo de parâmetros de fabricação vs os desvios das peças, com o intuito de produzir um conjunto de dados de entrada e saída (parâmetros fabricação e desvios, ex. TAB 5.2) que permita identificar a influência dos parâmetros de fabricação na qualidade das peças produzidas.

Baseado nesse conjunto de dados gerados pelas análises e testes, nesta pesquisa duas técnicas computacionais de estimação foram testadas, a saber, as redes neurais artificiais (RNAs) e os modelos de regressão múltipla (MRMs). Essas técnicas tiveram como característica principal aproximar, estimar e generalizar o comportamento dos desvios estudados, tendo como informação base esse conjunto de dados de fabricação. Assim, com base nesses dados, foram desenvolvidos quatro (04) modelos de previsão e otimização dos desvios, utilizando duas metodologias distintas.

Na primeira, desenvolveu-se um algoritmo do MOMR, que objetiva generalizar e estimar novos valores ótimos de desvios. Para tal, utilizou-se o *software Minitab®* para o cálculo dos coeficientes de regressão dos modelos de regressão múltipla, e posteriormente, foi programado um código *script* no *software* de programação de cálculos e análises numéricas *MATLAB®*, que usa esses coeficientes e variáveis do MRM para desenvolver o algoritmo do MOMR. Já a segunda metodologia primeiramente utilizou os dados de parâmetros fabricação e desvios dimensionais e geométricos das peças para desenvolver os códigos de programação *script* dos modelos de RNA para as estimativas dos desvios no *software MATLAB®*.

Posteriormente, utiliza os modelos de RNA em outro código *script* para modelar computacionalmente o algoritmo que generaliza, estima e otimiza os valores dos desvios. As etapas de programação, testes de funcionamento e implementação dos códigos *scripts* dos modelos de regressão múltipla, dos modelos de neurais artificiais, dos algoritmos de previsão e de otimização foram desenvolvidos no período de "estágio de doutorado sanduíche" na *Escuela de Ingeniería Minera e Industrial de Almadén* - UCLM.

Assim, as características das RNAs e dos MOMR, suas arquiteturas, seus código de programação *script*, os valores de performance e suas estimativas serão apresentados nos subcapítulos a seguir e/ou nos referenciados quando citados.

## **6.1 Desenvolvimento dos modelos de estimativa e otimização dos desvios utilizando modelos de regressão múltipla**

Neste item descreve-se o desenvolvimento dos MOMRs para os desvios dimensionais e geométricos da peça. Para tal, concomitantemente discute-se a construção de submodelos de regressão múltipla para cada tipo de variável de resposta, ou seja, para cada desvio analisado, necessários ao desenvolvimento dos MOMRs. Posteriormente, os algoritmos dos MOMRs foram utilizados para procurar um conjunto de parâmetros de fabricação (fatores) que otimize todas as respostas mediante valores objetivos ou, pelo menos, as aproxime de limites ótimos desejados.

### **6.1.1 Primeira etapa: modelagem da estimativa dos desvios da peça utilizando modelo de otimização de múltiplas respostas**

Para modelagem computacional do modelo de estimação para os desvios dimensionais e geométricos da peça utilizando modelos de regressão múltipla, primeiramente, com base no planejamento de experimentos desenvolvido (APÊNDICE C) e nos respectivos desvios mensurados nas peças (TAB. 5.1), foram calculados os coeficientes de regressão das estimativas do modelo estatístico de regressão linear múltipla (RLM) para cada tipo de desvio analisado, utilizando-se o

software *MATLAB*®. O APÊNDICE D apresenta os coeficientes calculados para cada tipo de desvio.

Em seguida, foram realizadas as análises dos desempenhos dos MRMs por meio dos cálculos da SSE, MSE, MAE e do coeficiente de determinação ( $R^2$ ). Para esses cálculos e equacionamentos de cada modelo foram considerados, respectivamente, os coeficientes de regressão dos efeitos principais, das interações de segunda ordem e também da constante do ajuste do ponto central. A TAB. 6.1 disponibiliza o resumo dos resultados para cada tipo de modelo generalizado e ainda o desempenho total geral.

TABELA 6.1

Resumo das análises dos desempenhos dos modelos de regressão múltipla para os desvios dimensionais e geométricos da peça

MRM Generalizado	Análise do desempenho / variância			
	SSE	MSE	MAE	$R^2$
MRM desvio dimensional da altura total da peça	0,1950	0,1950	0,0484	94,29%
MRM desvio geométrico de planeza do fundo da peça	0,0149	0,0002	0,0149	99,97%
MRM desvio geométrico médio de ângulos laterais da peça	0,0040	0,0000	0,0040	99,98%
MRM desvio dimensional do comprimento diagonal da peça	0,0016	0,0000	0,0016	99,99%
<b>Total geral</b>	0,0539	0,0488	0,0172	98,56%

Na TAB. 6.1 vê-se que os modelos generalizados possuem os  $R^2$  acima de 90% e médias dos erros de ajustamento abaixo da faixa centesimal. Assim, conclui-se que os modelos se ajustam de forma satisfatória aos valores observados/mensurados e são representativos para estimar os desvios.

Por último, foi desenvolvido um algoritmo que calcula os múltiplos desvios (saídas), dado um conjunto de parâmetros (entradas), utilizando o conjunto de modelos de regressão e coeficientes desenvolvidos, ou seja, um modelo de otimização de múltiplas respostas dos valores dos desvios.

Para tal, primeiramente, os coeficientes das estimativas foram codificados e convertidos em um arquivo de dados (matriz). Posteriormente, foi programado um código *script* que recebe os valores de entrada a serem testados, processa cada uma das equações de desvio utilizando a matriz de dados e, por fim, codifica e

salva na matriz de saída os resultados dos desvios. Esse procedimento foi desenvolvido e implementado no *software MATLAB®*. A FIG. 6.1 representa esquematicamente esse algoritmo.

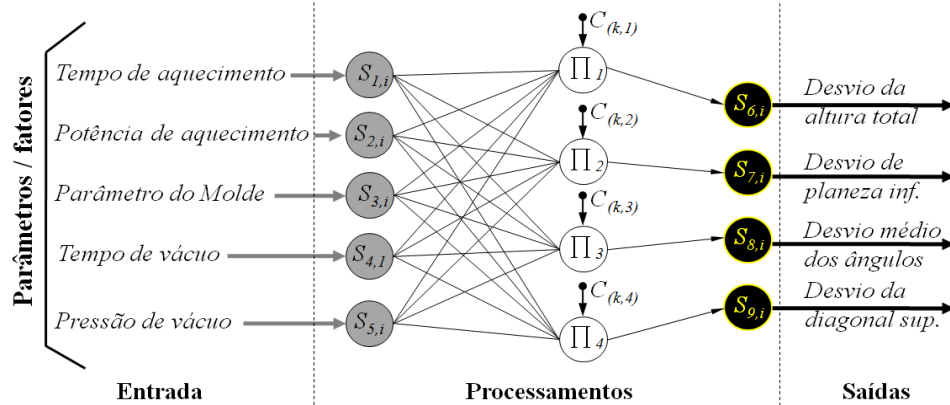


FIGURA 6.1 - Representação esquemática do algoritmo de cálculo do modelo otimização de múltiplas respostas utilizado na pesquisa.

### 6.1.2 Segunda etapa: estimativa do melhor conjunto de parâmetros que otimiza os desvios da peça utilizando modelo de otimização de múltiplas respostas

Para seleção dos parâmetros ótimos da estimativa do menor conjunto de desvios, utilizando-se o modelo de otimização de múltiplas respostas, inicialmente fez-se necessário desenvolver uma equação que quantifica o conjunto de desvio, de forma que as soluções geradas pelo modelo pudessem ser comparadas e classificadas.

O procedimento adotado foi conforme apresentado na seção 3.5. Foram definidos os erros admissíveis para cada tipo de desvio, ou seja, os desvios admissíveis para que um conjunto de estimativa seja aceito.

Pelo critério de importância no produto final foram definidos os pesos 2, 3, 1 e 2, respectivamente, para o desvio dimensional da altura total, o desvio geométrico de planeza do fundo, o desvio geométrico médio dos ângulos laterais e o desvio dimensional do comprimento da diagonal da peça.

Então, o fator de desempenho da previsão da estimativa dos desvios foi equacionado conforme a EQ.6.1, sendo que  $j$  representa a  $j$ -ésima previsão do modelo e  $i$  o  $i$ -ésimo tipo de desvio.

$$Fator\ de\ desempenho_j = \frac{1}{8} \sum_{i=1}^4 \left\{ \left( \frac{desvio\ estimado_{i,j}}{erro\ admissível_i} \right) * peso_i \right\} \quad (6.1)$$

Por meio dessa equação é avaliado se uma solução  $j$  gerada pelo MOMR é melhor que uma amostra idealizada, ou seja, são quantificados os desvios da solução e comparados com uma solução ideal. Assim, o valor solução igual a 1,0 representa para esta equação um conjunto de desvios iguais aos aceitáveis, uma resposta menor que 1,0 uma solução melhorada e um valor solução maior que 1,0 uma solução rejeitada. Salienta-se que se deve buscar valores menores que 1,0, ou seja, soluções melhoradas.

Por fim, foi escrito um código *script* que, primeiramente, discretiza os valores de entrada (parâmetros) em  $j$ -ésimas possíveis soluções, em seguida utiliza o algoritmo descrito na seção 6.1.1 para calcular os desvios de uma previsão  $j$ . Depois, por meio da EQ.6.1, calculou-se o desempenho da previsão e, por fim, comparou-se e ranqueou-se o conjunto das 10 melhores soluções, buscando minimizar o fator de desempenho. Esse código foi implementado no *software* Matlab.

Assim, utilizando o procedimento supradescrito, foi realizada a primeira busca dos parâmetros ótimos da estimativa para o menor conjunto de desvios. O espaço de busca (domínio) e a discretização utilizada foram definidos conforme TAB. 6.2.



TABELA 6.2

Espaço de busca e discretização utilizados no primeiro processo de busca

<b>Fator / Termo</b>	<b>Domínio</b>		<b>Discretização</b>	<b>Total de pontos gerados</b>
	$\leq$	$\geq$	<i>UN</i>	<b>QT.</b>
<i>A - Tempo de Aquecimento(s)</i>	80	90	5,0	3,0
<i>B - Potências de Aquecimento(%)</i>	90	100	5,0	3,0
<i>C - Parâmetro do Molde (%)</i>	85	100	7,5	3,0
<i>D - Tempo de Vácuo (s)</i>	7,2	9	0,9	3,0
<i>E - Pressão de Vácuo (mBar)</i>	10	15	2,5	3,0
			<b>Total</b>	243

Conforme apresentado na TAB. 6.2, esse espaço de busca e a discretização representam os mesmos pontos que foram utilizados no planejamento da ANOVA, acrescidos dos conjugados do ponto central, totalizando, assim, 243 configurações distintas.

Na TAB. 6.3 conhecem-se as classificações em ordem crescente das 10 melhores estimativas dos desvios dimensionais e geométricos da peça e, respectivamente, os parâmetros de entrada para a primeira etapa, previsão. Pela inspeção da mesma fica evidente que apenas um (01) conjunto de parâmetros se apresenta como melhor solução, ou seja, A = 50 s, B = 100 %, C = 7,2 s, D = 15,0 mbar e E = 100 % para um fator de desempenho = 0,18.

TABELA 6.3

Resumo das melhores classificações da primeira etapa de estimativa de parâmetros ótimos para a otimização dos desvios dimensionais e geométricos da peça utilizando MOMR

<b>Fator / Termo</b>	<b>Fator de desempenho</b>									
	0,18	0,25	0,27	0,27	0,28	0,29	0,30	0,32	0,33	0,33
<i>A - Tempo de Aquecimento(s)</i>	90	90	90	81	90	90	90	90	90	90
<i>B - Potências de Aquecimento(%)</i>	100	100	100	100	100	95	100	100	100	100
<i>C - Parâmetro do Molde (%)</i>	100	100	93	85	100	100	93	100	93	100
<i>D - Tempo de Vácuo (s)</i>	7,2	7,2	7,2	9,0	8,1	7,2	7,2	7,2	7,2	8,1
<i>E - Pressão de Vácuo (mBar)</i>	15,0	12,5	15,0	10,0	15,0	15,0	12,5	10,0	10,0	12,5

Após a primeira busca foi realizada uma segunda busca dos parâmetros ótimos, visando extrapolar o espaço solução e discretização iniciais, ou seja, testar a capacidade de generalização do modelo. Para essa nova busca e discretização foram utilizados os valores da TAB. 6.4.

TABELA 6.4  
Espaço de busca e discretização utilizados no segundo processo de busca

Fator / Termo	Domínio		Discretização	Total de pontos gerados
	$\leq$	$\geq$	UN	QT.
A - Tempo de Aquecimento(s)	75	95	2,5	09
B - Potências de Aquecimento(%)	85	105	2,5	09
C - Parâmetro do Molde (%)	77,5	100	2,5	05
D - Tempo de Vácuo (s)	6,3	9,9	0,9	04
E - Pressão de Vácuo (mBar)	7,5	15	2,5	09
<b>Total</b>				11.340

Na TAB. 6.4 observam-se os valores extrapolados, em alguns casos a redução da discretização dos parâmetros e, ainda, significativo aumento da quantidade de combinações de parâmetros testadas, agora, 11.340.

A TAB. 6.5 apresenta, em ordem crescente, as 10 melhores previsões dos desvios dimensionais e geométricos do produto e, respectivamente, os parâmetros de entrada para a segunda busca.

TABELA 6.5  
Resumo das melhores classificações da segunda etapa de estimativa de parâmetros ótimos para a otimização dos desvios dimensionais e geométricos da peça utilizando MOMR

Fator / Termo	Fator de desempenho									
A - Tempo de Aquecimento(s)	0,05	0,06	0,06	0,08	0,08	0,08	0,09	0,09	0,09	0,09
B - Potências de Aquecimento(%)	94,5	94,5	94,5	81,0	78,8	83,3	78,8	78,8	83,3	94,5
C - Parâmetro do Molde (%)	97,5	95,0	95,0	105,0	105,0	105,0	105,0	100,0	105,0	97,5
D - Tempo de Vácuo (s)	92,5	96,3	100,0	92,5	92,5	92,5	96,3	81,3	88,8	96,3
E - Pressão de Vácuo (mBar)	6,3	6,3	7,2	7,2	7,2	7,2	7,2	9,9	7,2	6,3

### 6.1.3 Considerações finais

Pode-se concluir inicialmente, pela análise das TAB. 6.3 e 6.5, que as buscas indicam duas soluções possíveis para o melhor conjunto de parâmetros. Na TAB 6.3, a busca dentro dos valores do planejamento inicial mostra que existe possivelmente melhor configuração para fabricação das peças, as quais não foram produzidas nas etapas de teste (GRA. 5.10). Já na TAB. 6.4, vê-se primeiramente que o algoritmo consegue prever outras  $n$  configurações, melhores que as apresentadas na TAB. 6.3. Ainda registra-se que a melhor solução encontra-se fora do espaço solução da primeira busca, ou seja, em faixa de valores ainda não testados. Assim sendo, para a continuidade da pesquisa serão utilizadas as primeiras melhores soluções de cada busca.

## **6.2 Desenvolvimento do modelo da estimativa e otimização dos desvios utilizando RNA**

### 6.2.1 Primeira etapa: modelagem da estimativa dos desvios da peça utilizando modelo de RNA

Para modelagem computacional da previsão e otimização para os desvios dimensionais e geométricos da peça utilizando RNA, os dados de entrada da rede formam os valores dos parâmetros de fabricação (fatores) utilizados na segunda etapa de testes experimentais (APÊNDICE C) e, respectivamente, os valores de saída. Os objetivos formam os desvios dimensionais e geométricos encontrados nas peças produzidas (TAB. 5.1). Para tal, esses valores foram codificados em arquivos de dados com a estrutura "específica" de modelagem por RNA, considerando-se para cada par de peças a respectiva média dos valores dos desvios.

A TAB. 6.6 demonstra esse procedimento, em que cada conjugado de coluna de entrada e saída apresenta a rede, uma condição a ser treinada e aprendida.

TABELA 6.6 - Exemplo da codificação realizada para treinamento da rede

		Conjunto de dados n.º							
		01	02	03	04	05	06	...	17
		<i>Arquivo de dados de entrada (apresentados)</i>							
Fatores de entrada	A - Tempo de aquecimento	80,0	90,0	80,0	90,0	80,0	90,0	...	85,0
	B - Potência de aquecimento	90,0	90,0	100,0	100,0	90,0	90,0	...	95,0
	C - Parâmetro de atua. Molde	100,0	85,0	85,0	100,0	85,0	100,0	...	92,5
	D - Tempo de vácuo	7,2	7,2	7,2	7,2	9,0	9,0	...	8,1
	E - Pressão de vácuo	10,0	10,0	10,0	10,0	10,0	10,0	...	12,5
		<i>Arquivo de dados de saída (apresentados)</i>							
Variáveis de saída	Desvio dimensional da alt.total	-1,300	-0,871	-0,408	-0,293	-0,596	-0,971	...	-0,789
	Desvio geométrico de planeza do fundo	1,541	0,411	0,349	0,323	1,100	0,366	...	0,481
	Desvio geométrico médio dos ângulos laterais	0,635	0,455	0,351	0,188	0,476	0,407	...	0,304
	Desvio dimensional do comprimento da diagonal	-0,263	-0,308	-0,335	-0,310	-0,222	-0,259	...	-0,309

Para programação computacional e testes dos modelos de estimação utilizando RNA foram programados códigos *script* que utilizam os arquivos de dados codificados (TAB. 6.6) e modelos de RNA implementados no *software MATLAB®*.

Quanto aos tipos de RNA, foram programadas e testadas redes neurais multicamadas com algoritmos de treinamento *backpropagation* e *Levenberg-Marquardt* com diversas arquiteturas. Em relação às funções de transferências, foi utilizada na primeira camada a função “*tansig*” e nas demais camadas foram testadas variações de combinações das funções de transferências “*purelin*” e “*tansig*”.

Em termos de arquitetura, as redes testadas foram compostas de uma camada de entrada com cinco dados ( $X_i$ ), uma camada de saída com quatro valores ( $Y_{j(p)}^l$ ), e, ainda,  $l$  camada(s) escondida(s) com  $j$  neurônios em cada.

A FIG. 6.2 apresenta a estrutura genérica da rede neural artificiais de multicamada proposta para o desenvolvimento do modelo de previsão para os desvios dimensionais e geométricos da peça.




FIGURA 6.2 - Estrutura genérica da RNA proposta para o desenvolvimento da pesquisa.

Como parâmetros gerais de treinamento dessas redes foi definido no código *script* de programação que: a taxa de aprendizagem = 0,001; o decremento da taxa de aprendizagem = 0,001 e; o incremento máximo do erro = 0,001. E, ainda, como parâmetros gerais de parada, que: a "*performance goal*" = 0; a mínima performance do gradiente = 10E-26; número máximo de épocas = 10.000; o valor máximo do incremento da validação = 100; o "*momentum constant maximum*" = 1E308.

Quanto aos critérios de desempenho verificados nos modelo, primeiramente foram analisadas as MAE das estimativas, e posteriormente, comparados os valores encontrados com os valores obtidos pelos modelos de regressão múltipla. Caso o modelo alcançasse erros de estimação próximos do MRM ele seria considerado, a princípio, um modelo satisfatório.

Os procedimentos para desenvolvimento da melhor estimativa foram: testar continuamente por até 2.000 vezes ou pelo tempo total de simulação de 1.020 minutos cada tipo de modelo de RNA, sendo que a cada simulação era verificado o desempenho do submodelo. Nesse processo de teste e verificação, caso um submodelo alcançasse um valor satisfatório, o programa gravava-o em uma sequência ranqueada. Se não, finalizava a simulação quando atingido algum critério de parada, descartando o modelo. E a cada inicialização do modelo eram atualizados com novos valores aleatórios todos os pesos e *bias*.

Por fim, quando o modelo se adequava de forma satisfatória ao processo, eram

desenvolvidos e processados novos modelos que contemplassem a redução da arquitetura da rede e/ou as modificações de parâmetros de sua RNA. Este procedimento foi realizado continuamente até que em um modelo reduzido os valores dos erros e o critério de desempenho fossem considerados satisfatórios, sendo que esses códigos *scripts* dos algoritmos dos modelos de RNA foram implementados, testados e processados no *software MATLAB®*.

A TAB. 6.7 apresenta o resumo dos principais modelos de RNA desenvolvidos e testados, suas estruturas, algoritmos, erros das estimativas e parâmetros de desempenho.

TABELA 6.7

Resumo das principais características e valores de desempenho dos modelos de RNA desenvolvidos e testados

Modelo	Arquitetura da rede	Dados treina- dos	Dados testados/ validados	Algoritmo de treinamento	Função transf. (1ª camada)	Função transf. (camadas ocultas)	Erro desejado (MAE)	Erro alcançado (MAE)	Erro desejava- do (MSE)	Erro alcançado (MSE)	N.º Épocas / Intera- ções	Tempo proces- samento (s)
Z	10-8-4	14	6	'trainlm' mu_max=1E308	tansig'	tansig'	0,0172	0,0001	0,0488	0,0000001	461	5,347
Y	10-8-4	12	4	'trainlm' mu_max=1E308	tansig'	tansig'	0,0172	0,0002	0,0488	0,0000003	873	6,728
X	10-8-4	11	3	'trainlm' mu_max=1E308	tansig'	tansig'	0,0172	0,0301	0,0488	0,0000163	832	8,004
W	10-8-4	11	3	'traingd' $\eta = 0.001$ ; $\rho=0.001$ ; $\tau=0.001$ ;	tansig'	tansig'	0,0172	0,0877	0,0488	0,0720541	10.359	39,575
V	10-8-4	11	3	'trainlm' mu_max=1E308	tansig'	'purelin', 'tansig'	0,0172	0,0303	0,0488	0,0000795	685	6,192
T	16-8-4	11	3	'trainlm' mu_max=1E308	'tansig'	'purelin', 'tansig'	0,0172	0,0164	0,0488	0,0000976	19.855	220,040
P	5-4-8-4	11	3	'trainlm' mu_max=1E308	'tansig'	'purelin', 'tansig', 'purelin'	0,0172	0,0319	0,0488	0,0000000	762	58,800
O	8-8-8-4	11	3	'trainlm' mu_max=1E308	'tansig'	'purelin', 'tansig', 'purelin'	0,0172	0,0085	0,0488	0,0000105	4.482	64,461
M	16-8-8-4	11	3	'trainlm' mu_max=1E308	'tansig'	'purelin', 'tansig', 'purelin'	0,0172	0,0320	0,0488	0,0000620	7.444	140,268
K	24-12-8-4	11	3	'traingd' $\eta = 0.001$ ; $\rho=0.001$ ; $\tau=0.001$ ;	'tansig'	'purelin', 'tansig', 'purelin'	0,0172	0,1529	0,0488	0,1669912	11.882	74,772
H	24-12-8-4	11	3	'trainlm' mu_max=1E308	'tansig'	'purelin', 'tansig', 'purelin'	0,0172	0,0256	0,0488	0,0000000	9.340	490,485
D	32-16-8-4	11	3	'traingd' $\eta = 0.001$ ; $\rho=0.001$ ; $\tau=0.001$ ;	'tansig'	'purelin', 'tansig', 'purelin'	0,0172	0,1832	0,0488	0,1938314	1.656	07,900
A	32-16-8-4	11	3	'trainlm' mu_max=1E308	'tansig'	'purelin', 'tansig', 'purelin'	0,0172	0,02135	0,0488	0,0005825	3.507	205,544

Na TAB. 6.7, o modelo "A" representa a primeira modelagem que obteve aproximação satisfatória da previsão para os desvios da peça e o modelo "Z", a última. Os modelos intermediários representam de forma sequencial alguns exemplos de modificações realizadas durante os testes, com a finalidade de simplificar o modelo e/ou melhorar seu desempenho.

Nos resultados apresentados na TAB. 6.7, primeiramente verifica-se a evolução do processo de redução das arquiteturas das redes. Posteriormente, as tentativas de melhoria da rede mediante a modificação de combinações das funções de transferência e algoritmos. Por último, a melhoria do desempenho global e local por meio do aumento na quantidade de dados utilizados para treinar e testar a RNA.

Quanto à definição do modelo a ser adotado na pesquisa, primeiramente, por meio do processo de redução da arquitetura da rede, chegou-se ao modelo "V". Esse modelo exibe desempenho satisfatório, entretanto, quando comparado a outros modelos (X, Y e Z) gera superfícies de solução com "grandes" regiões curvilíneas e, conseqüentemente, problemas de generalização das saídas. A FIG. 6.3 exemplifica esse problema.

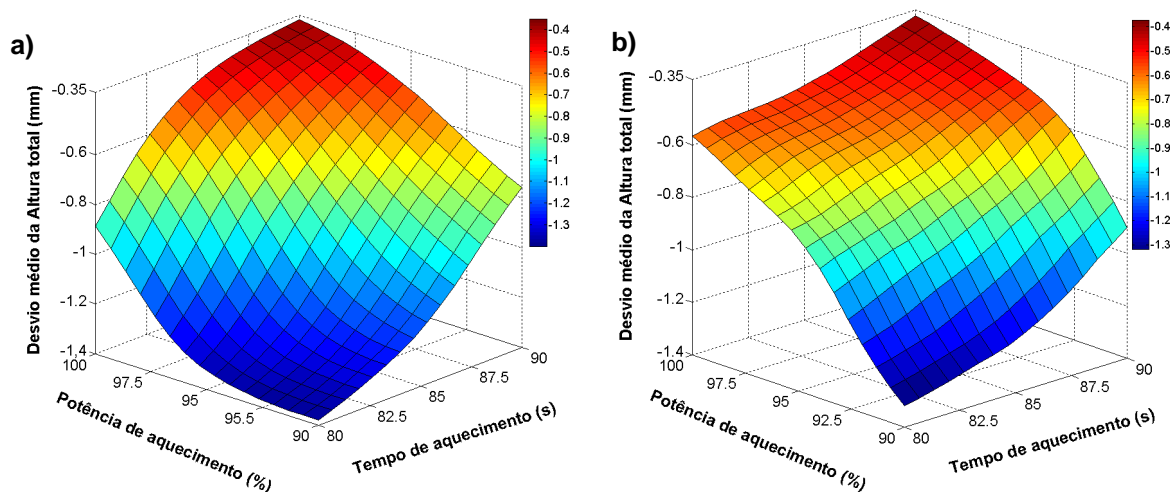


FIGURA 6.3 - Gráficos de superfície do tempo de aquecimento vs potência de aquecimento vs desvio médio da altura total do produto: a) modelo "V" e; b) modelo "Z".

A análise da FIG. 6.3 e os dados da TAB. 6.7 leva a concluir que o uso de uma função de transferência com ajuste linear (*purelin*) no meio da rede reduzida



proporcionou, principalmente em pontos extremos do modelo "V", erros de generalização, os quais foram se amenizando com o uso em sequência de funções de transferência com ajuste hiperbólico sigmoidal (*tansig*), modelo "X".

Ainda na TAB. 6.7 é possível abstrair que os modelos "Y" e "Z" representam numericamente o ganho de desempenho em função do aumento no número de dados treinados e validados e, conseqüentemente, melhoria na aproximação e generalização dos dados totais. Para corroborar essa conclusão, os GRA. 6.1, 6.2, 6.3 e 6.4 apresentam os resíduos totais dos modelos citados vs os tipo de desvio.

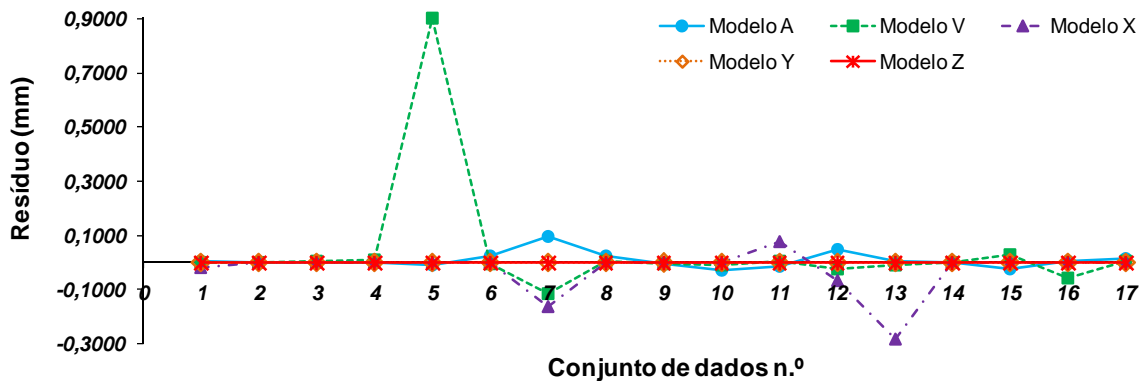


GRÁFICO 6.1 - Modelos desenvolvidos vs desvio dimensional da altura total.




GRÁFICO 6.2 - Modelos desenvolvidos vs desvio geométrico de planeza do fundo.




GRÁFICO 6.3 - Modelos desenvolvidos vs desvio geométrico médio dos ângulos laterais.




GRÁFICO 6.4 - Modelos desenvolvidos vs desvio dimensional do comprimento da diagonal.

A análise dos GRA. 6.1 a 6.4 e da TAB. 6.7 revela que a modificação nas funções de transferência e o aumento no número de dados treinados e validados proporcionaram, ao modelo "Z", melhor generalização dos dados e resíduos em valores insignificantes para todos os desvios, tornando-o o modelo mais adequado para o desenvolvimento das próximas etapas da pesquisa.

### 6.2.2 Segunda etapa: estimativa do melhor conjunto de parâmetros que otimiza os desvios da peça utilizando modelos de RNA

Assim como na seção 6.1.2, o presente subitem visa a desenvolver, por meio de algoritmos de otimização implementados no *software MATLAB®*, a seleção dos parâmetros de fabricação que otimizem a estimativa do conjunto de desvios, entretanto, utilizará o modelo de RNA desenvolvido.

Assim sendo, foram considerados os erros admissíveis, pesos de cada tipo de

desvio e o cálculo do fator de desempenho (EQ. 6.1), com base nas formulações descritas na seção 6.1.2.

Analogamente aos procedimentos da seção 6.1.2, foi implementado no *software MATLAB®* o código *script* de um algoritmo de otimização que, primeiramente, discretiza o espaço solução em *j-ésimas* soluções possíveis e em seguida utiliza o modelo RNA (Z) desenvolvido na seção 6.2.1 para calcular os desvios das soluções, depois, por meio da EQ.6.1, calcula o fator de desempenho das estimativas. Por fim, compara e classifica o conjunto das 10 melhores soluções existentes. Então, para a primeira etapa de busca dos parâmetros que otimizam os desvios, esse algoritmo foi processado continuamente até percorrer todo o conjunto solução, sendo considerado o mesmo espaço de busca e discretização apresentados na TAB. 6.2.

A TAB. 6.8 apresenta a classificação das 10 melhores estimativas dos desvios dimensionais e geométricos para a primeira etapa de busca e, respectivamente, os parâmetros de entrada ou fabricação.

TABELA 6.8

Resumo das melhores classificações da primeira etapa de estimativa de parâmetros ótimos para a otimização dos desvios dimensionais e geométricos da peça utilizando RNA

<b>Fator / Termo</b>	<b>Fator de desempenho</b>									
	0,27	0,27	0,27	0,28	0,28	0,28	0,28	0,29	0,29	0,30
<i>A - Tempo de Aquecimento(s)</i>	90	90	85,5	90	90	90	85,5	90	90	85
<i>B - Potências de Aquecimento(%)</i>	100	100	100	95	100	95	95	95	100	95
<i>C - Parâmetro do Molde (%)</i>	100	92,5	100	100	85	100	100	92,5	100	100
<i>D - Tempo de Vácuo (s)</i>	8,1	7,2	7,2	8,1	8,1	7,2	7,2	7,2	7,2	7,2
<i>E - Pressão de Vácuo (mBar)</i>	12,5	12,5	12,5	12,5	10,0	12,5	12,5	12,5	12,5	12,5

Já para a segunda etapa de busca são listadas, em ordem crescente, as 10 melhores estimativas dos desvios com seus respectivos parâmetros de entrada na TAB. 6.9. Para essa nova busca foram utilizados os valores da TAB. 6.4.

TABELA 6.9

Resumo das melhores classificações da segunda etapa de estimativa de parâmetros ótimos para a otimização dos desvios dimensionais e geométricos da peça utilizando RNA

<b>Fator / Termo</b>	<b>Fator de desempenho</b>										
	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,24	0,25	
<i>A - Tempo de Aquecimento(s)</i>	92,3	94,5	94,5	94,5	94,5	94,5	94,5	94,5	92,3	94,5	94,5
<i>B - Potências de Aquecimento(%)</i>	90	90	87,5	90	87,5	90	87,5	90	87,5	87,5	87,5
<i>C - Parâmetro do Molde (%)</i>	100	100	100	100	100	96,3	96,3	96,3	100	96,3	96,3
<i>D - Tempo de Vácuo (s)</i>	7,2	8,1	7,2	7,2	6,3	8,1	6,3	7,2	8,1	7,2	7,2
<i>E - Pressão de Vácuo (mBar)</i>	12,5	12,5	12,5	12,5	10	12,5	10	12,5	12,5	12,5	12,5

A partir da análise inicial das TAB. 6.8 e 6.9, verifica-se que cada qual das duas buscas conseguiu encontrar soluções com o mesmo fator de desempenho, ou seja, tecnicamente equivalentes. Assim sendo, na TAB. 6.8, a busca dentro dos valores do planejamento inicial prevê que existem três possíveis configurações com desempenho igual a 0,27, os quais não foram produzidos nas etapas de testes. E na TAB. 6.9 nota-se que, o algoritmo consegue prever outras  $n$  configurações melhores que as apresentadas na TAB. 6.8, nove empatadas tecnicamente com o valor de 0,24. Verificou-se também, neste caso, que todas as soluções possuem tempo de aquecimento com valores fora do planejamento inicial.

Diante do exposto, para corroborar a seleção do conjunto de parâmetro a ser utilizado nas TAB. 6.8 e 6.9, foi calculado por meio da ANOVA, e posteriormente desenvolvido, o gráfico conjunto das estimativas dos efeitos principais vs tipos de desvios da peça, o GRÁF. 6.5. Nele é apresentado separadamente cada tipo de parâmetro de fabricação e as curvas das MSE, calculadas para os três níveis estudados em cada tipo de desvio. O valor ideal para qualquer ponto calculado é zero (0), ou seja, quanto mais próximo de zero o valor se encontra, menor é o desvio do fator no nível.

Assim, pelas análises do GRÁF. 6.5 é possível concluir que, para se obter os menores desvios dimensionais do produto, o parâmetro "tempo de aquecimento" deve estar em níveis altos (90 s). Ainda, de forma geral, a "potência de

aquecimento" deve-se manter em valores próximos de 100%. Já o fator "tempo de vácuo" deve estar em valores iguais ou superiores a 8,1 segundos, associado a valores iguais ou inferiores a 12,5 mbar para o parâmetro "pressão de vácuo". E, por último, as configurações dos "parâmetros de atuação do molde" devem estar próximas de 100%.

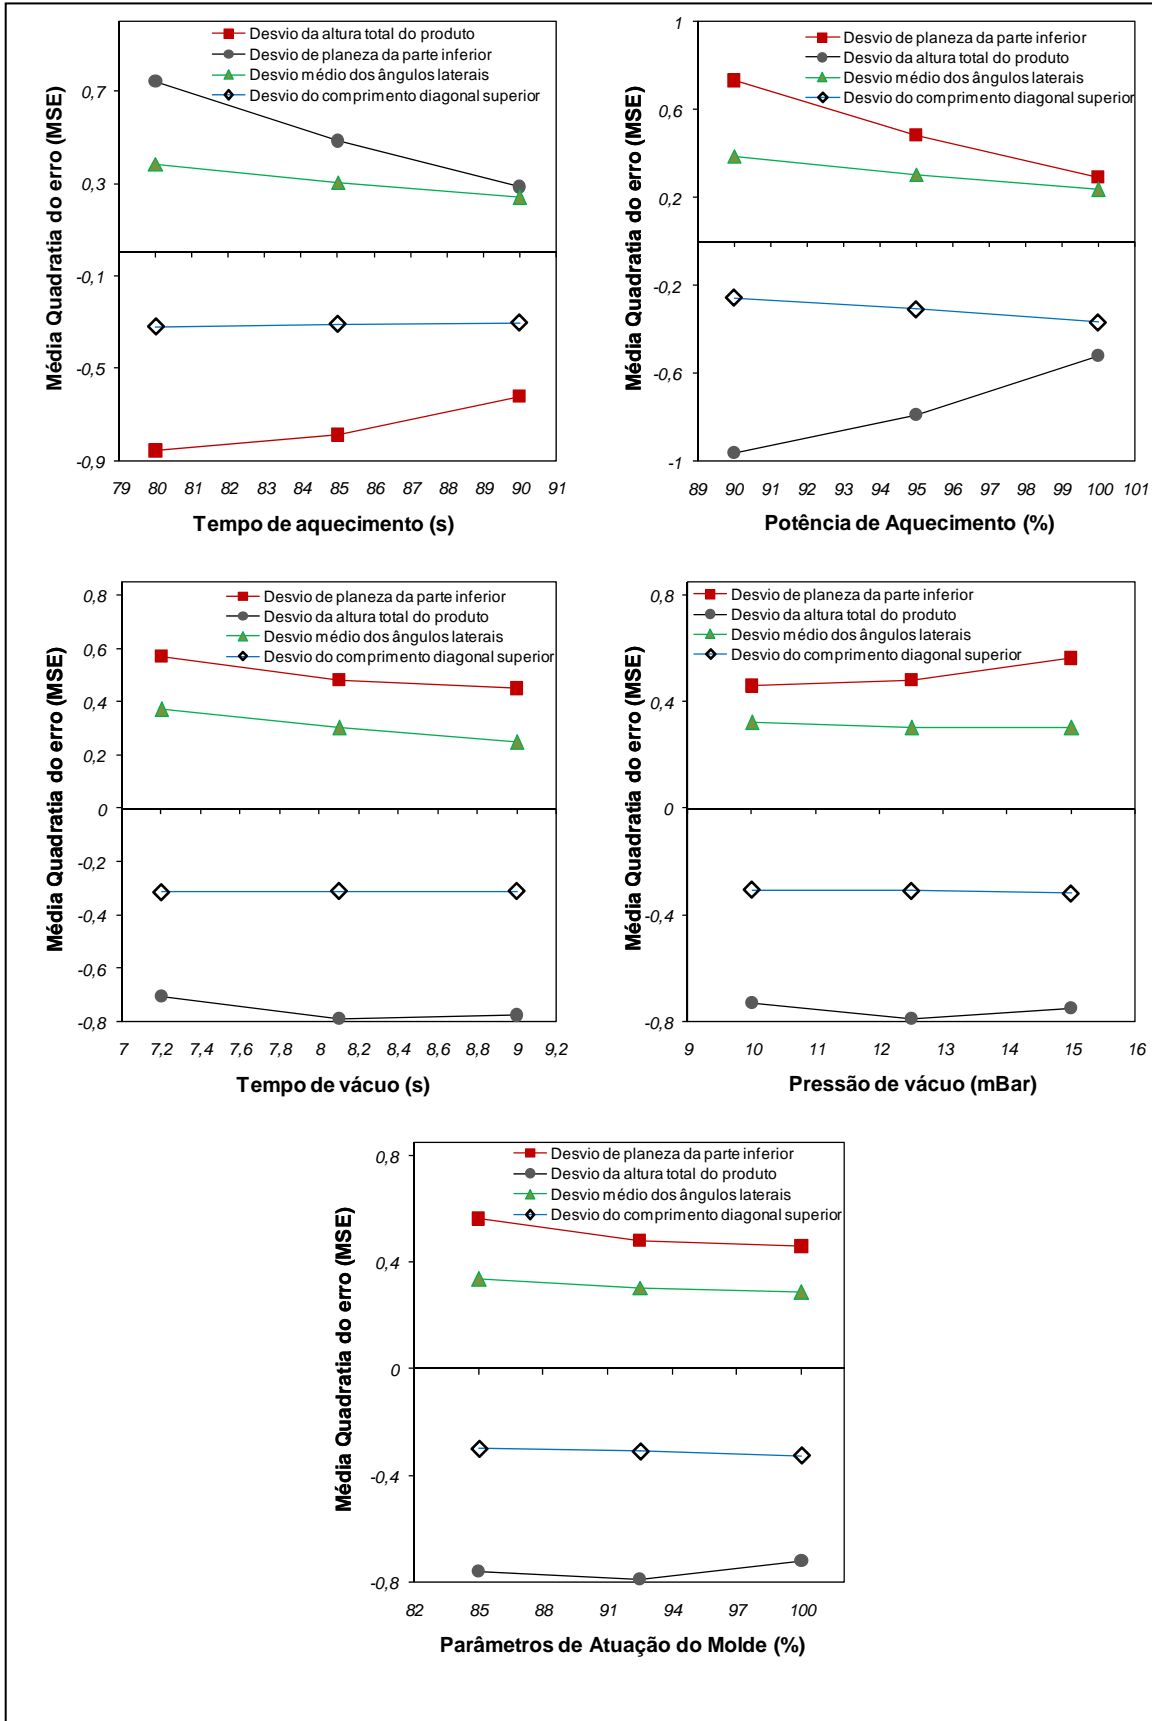


GRÁFICO 6.5 - Solução conjunta da estimativa dos efeitos principais vs desvios dimensionais e geométricos analisados: testes experimentais.

### 6.2.3 Considerações preliminares

Conforme dados apresentados no GRÁF. 6.5 e discursos finais da seção 5.2, é possível concluir que na TAB. 6.8 deve ser utilizada a primeira configuração (A = 90 s, B = 90%, C = 100%, D = 8,1 s, D = 12,5 mbar e E = 100 %) e na TAB. 6.9, a segunda (A = 94,5 s, B = 90%, C = 90%, D = 8,1 s, D = 12,5 mbar e E = 100 %).

## **7 TESTES DE VALIDAÇÃO DOS MODELOS DE ESTIMATIVA E OTIMIZAÇÃO DE DESVIOS**

Neste capítulo são apresentados os resultados dos testes de validação dos modelos de otimização que utilizam RNA e dos modelos de otimização de múltiplas respostas desenvolvidos no capítulo 6, para encontrar as configurações ideais dos parâmetros de fabricação que minimizam os desvios da peça.

O objetivo desses testes de validação foi, primeiramente, avaliar em novas condições experimentais a capacidade de cada modelo em estimar os desvios dimensionais e geométricos da peça e em uma segunda etapa comparar a eficiência de aproximação entre os modelos.

Para tal, foram realizados quatro sequências de testes, sendo dois utilizando-se as configurações dos parâmetros de fabricação desenvolvidos pelos MOMRs, apresentados nas TAB. 6.3 e 6.5, e outros dois conjuntos de testes com configurações apresentadas na TAB. 6.8 e 6.9, desenvolvidas com modelos de otimização que utilizam RNA.

Por fim, são apresentados tabelas e gráficos comparativos dos resultados dos quatro testes desenvolvidos e análises dos modelos de otimização testados.

### **7.1 Realização dos testes de validação dos modelos de estimativa e otimização de desvios**

Para desenvolvimento dos testes de validação foi gerado o planejamento de execução, conforme a seleção de modelos apresentada nas seções 6.1.2 e 6.2.2 e, respectivamente, dados das TAB. 6.3, 6.5, 6.8 e 6.9. Para cada configuração foram processadas de forma contínua cinco peças.



A TAB. 7.1 mostra os fatores e níveis utilizados nos testes de validação do MOMR 01 e do MOMR 02, conjuntamente com as configurações do primeiro modelo que utiliza RNA (MORNA 01) e do segundo (MORNA 02).

TABELA 7.1

Fatores e níveis desenvolvidos para testes de validação dos modelos de estimativa e otimização de desvios

Teste	Fatores / Termo					
	A	B	C		D	E
	Tempo de aquecimento (s)	Potência de aquecimento (%)	Parâmetros de atuação do molde		Tempo de vácuo (s)	Pressão de vácuo (mbar)
Pressão (bar)			Velocidade (cm/s)			
<b>MOMR 01</b>	90	100	4,0	21,6	7,2	15
<b>MOMR 02</b>	94,5	97,5	3,7	20,0	6,3	15
<b>MORNA 01</b>	90	100	4,0	21,6	8,1	12,5
<b>MORNA 02</b>	94,5	90,0	4,0	21,6	8,1	12,5

Para o processamento dos testes de validação foi utilizada uma matéria-prima para o molde, o MDF, e folhas com espessura de 1,5 mm, mantendo-se o mesmo cenário de testes da etapa de testes experimentais, bem como os equipamentos, *softwares* e sistemas aquisição de dados. A sequência de testes foi realizada conforme a TAB. 7.1, utilizando os respectivos parâmetros de fabricação que foram reprogramados no microcontrolador e/ou regulados nos equipamentos. Para a execução dos testes, foram seguidas as mesmas etapas dos testes anteriores (FIG. 4.1), sendo fabricadas cinco peças de cada modelo.

Por fim, após o resfriamento das peças, elas foram inspecionadas, adotado-se os mesmos procedimentos, equipamentos e *softwares* já descritos na seção 3.5. Novamente os dados foram tabulados e processados no microcomputador. O APÊNDICE E apresenta as tabelas com os desvios mensurados nas peças em cada corrida de teste.

As TAB. 7.2, 7.3, 7.4 e 7.5 mostram as médias dos desvios das peças com seus respectivos limites inferiores (LI) e superiores (LS). Ao mesmo tempo, registram-se os valores das previsões para os desvios do modelo em análise e do outro modelo equivalente.

Primeiramente, na TAB. 7.2 faz-se o resumo dos resultados para o MOMR 01. Nela, apura-se que o desempenho do desvio geral está 73% abaixo do mínimo, conseqüentemente, os desvios encontrados nas peças estão dentro da faixa de valores aceitáveis. Porém, os valores previstos pelo modelo MOMR 01 estão fora da faixa encontrada nas peças.

TABELA 7.2

Resumo dos resultados nas peças do teste com o MOMR 01

RESULTADOS	MODELOS		PEÇAS		
	<i>MOMR 01</i>	<i>MORNA 01</i>	<i>Encontrado</i>		
	<i>Previsto</i>	<i>Previsto</i>	<i>LI</i>	<i>Média</i>	<i>LS</i>
<i>Desvio dimensional da altura total da peça (mm)</i>	-0,075	-0,354	-0,111	-0,227	-0,343
<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	0,273	0,307	0,135	0,194	0,253
<i>Desvio geométrico médio dos ângulos laterais da peça (°)</i>	0,084	0,116	0,142	0,233	0,325
<i>Desvio dimensional do comp. da diagonal da peça (mm)</i>	-0,297	-0,342	-0,452	-0,496	-0,540
<i>Fator de desempenho</i>	0,18	0,32	0,18	0,27	0,36

Ao mesmo tempo, a TAB. 7.3 apresenta o resultado das peças dos testes com o MOMR 02. Similar ao teste anterior realizado com modelo de múltiplas respostas, nota-se que o desempenho geral dos desvios encontra-se em valores bem abaixo do mínimo estipulado. E, também, que os desvios previstos pelo modelo estão, em sua maioria, distantes dos valores encontrados nas peças.

TABELA 7.3

Resumo dos resultados nas peças do teste com o MOMR 02

RESULTADOS	MODELOS		PEÇAS		
	MOMR 02	MORNA 02	Encontrado		
	Previsto	Previsto	LI	Média	LS
<i>Desvio dimensional da altura total da peça (mm)</i>	-0,006	-0,681	-0,117	-0,253	-0,388
<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	0,029	0,200	0,138	0,188	0,238
<i>Desvio geométrico médio dos ângulos laterais da peça (°)</i>	0,055	0,080	0,101	0,172	0,244
<i>Desvio dimensional do comp. da diagonal da peça (mm)</i>	-0,230	-0,354	-0,287	-0,339	-0,391
<i>Fator de desempenho</i>	0,05	0,42	0,15	0,25	0,34

Já a TAB. 7.4 traz o resumo dos resultados dos desvios mensurados no teste do primeiro model, que utiliza uma RNA em seu algoritmo, o MORNA 01. Por ela, percebe-se que as peças produzidas possuem desvios dimensionais médios em patamares baixos. Os desvios previstos pelo modelo MORNA 01 encontram-se dentro dos limites mensurados nas peças. Desta forma, o produto possui, em média, o valor do fator de desempenho em um percentual de 77% abaixo do aceitável, sendo este um valor próximo do previsto.

TABELA 7.4

Resumo dos resultados nas peças do teste com o MORNA 01

RESULTADOS	MODELOS		PEÇAS		
	MOMR 01	MORNA 01	Encontrado		
	Previsto	Previsto	LI	Média	LS
<i>Desvio dimensional da altura total da peça (mm)</i>	-0,407	-0,294	-0,213	-0,255	-0,298
<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	0,241	0,185	0,050	0,134	0,218
<i>Desvio geométrico médio dos ângulos laterais da peça (°)</i>	0,180	0,188	0,156	0,193	0,231
<i>Desvio dimensional do comp. da diagonal da peça (mm)</i>	-0,324	-0,376	-0,263	-0,341	-0,419
<i>Fator de desempenho</i>	0,33	0,27	0,17	0,23	0,30

Por último, os resultados dos testes do segundo modelo que utiliza RNA, o MORNA 02, são apresentados na TAB. 7.5. Na mesma obtêm-se as análises e conclusões

análogas às da TAB. 7.4, em que há peças com desvios em patamares abaixo do estipulado e os desvios previstos encontram-se dentro das faixas dos valores mensurados nas peças.

TABELA 7.5  
Resumo dos resultados nas peças do teste com o MORNA 02

RESULTADOS	MODELOS		PEÇAS		
	<i>MOMR 02</i>	<i>MORNA 02</i>	<i>Encontrado</i>		
	<i>Previsto</i>	<i>Previsto</i>	<i>LI</i>	<i>Média</i>	<i>LS</i>
<i>Desvio dimensional da altura total da peça (mm)</i>	-0,613	-0,293	-0,252	-0,366	-0,480
<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	-0,080	0,182	0,068	0,136	0,204
<i>Desvio geométrico médio dos ângulos laterais da peça (°)</i>	0,125	0,099	0,078	0,108	0,139
<i>Desvio dimensional do comp. da diagonal da peça (mm)</i>	-0,291	-0,242	-0,225	-0,246	-0,267
<i>Fator de desempenho</i>	0,34	0,24	0,17	0,25	0,33

## 7.2 Considerações finais

Em síntese, tem-se que os testes produziram peças dentro dos limites de tolerâncias definidas neste estudo, mesmo os limites inferiores e superiores dos desvios encontram-se em patamares aceitáveis. Para representar graficamente essa síntese, no GRA. 7.1 visualizam-se os valores das médias dos desvios das peças vs tipo de desvio. Analisando esse gráfico, abstrai-se que, mesmo em diferente patamares, todos os desvios seguem uma mesma tendência, independentemente das configurações ótimas dos modelos. Entretanto, quando se verificam os desvios previstos pelos modelos, conclui-se que os que utilizam otimização de múltiplas respostas foram incapazes de estimar com aproximação regular os desvios das amostras. Já os modelos que utilizam as RNAs conseguiram boas estimações dos desvios das peças.




GRÁFICO 7.1 - Valores das médias dos desvios dimensionais e geométricos das peças por tipo de modelo de otimização testado.

Diante do exposto, o GRÁF. 7.2 explicita em termos de porcentagem o quanto cada modelo conseguiu se aproximar de cada tipo de desvios analisados, ou seja, o erro das estimativas sobre as amostras por tipo de modelo de otimização desenvolvido. Assim, a inspeção do GRÁF. 7.2 evidencia graficamente e numericamente as conclusões anteriores de que os modelos de otimização que utilizam RNA apresentam-se com mais eficiência para estimar os desvios das peças dentro de limites ótimos de tolerâncias preestabelecidos. Supõe-se que as RNAs sejam uma alternativa promissora para a obtenção de parâmetros de fabricação que minimizem os desvios dimensionais e geométricos das peças termoformadas a vácuo.




GRÁFICO 7.2 - Erro das estimativas sobre as amostras por tipo de modelo de otimização desenvolvido.

## 8 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Conforme descrito por diversos autores e verificado no desenvolvimento deste trabalho, tanto o processo de termoformagem a vácuo quanto a sua modelagem computacional apresentam características de não linearidade e de interações conflitantes entre os parâmetros de fabricação e a eficiência do processo.

Desta forma, considerando-se o propósito do desenvolvimento deste trabalho, diversas conclusões podem ser feitas, a saber:

- a) A metodologia adotada permitiu modelar conjuntamente os parâmetros de fabricação e os desvios dimensionais e geométricos de uma peça termoformada a vácuo, com reduzida quantidade de testes em uma infraestrutura laboratorial desenvolvida.
- b) De forma geral, em uma escala decrescente, os fatores principais "matéria-prima do molde" e "espessura da folha" são os que possuem mais influência sobre o controle geral do processo, seguidos dos parâmetros de aquecimento "tempo de aquecimento" e "potência de aquecimento".
- c) Os fatores predominantes quanto à análise dos desvios da peça são o "tempo de aquecimento" e "potência de aquecimento", que possuem efeito significativo sobre as variáveis de controle "desvio da altura total do produto", "desvio de planeza da parte inferior" e "desvio médio dos ângulos laterais". Esses desvios são minimizados quando o tempo de aquecimento é igual ou superior a 90 segundos.
- d) Para peças produzidas com molde em MDF, com exceção da interação entre os fatores "parâmetros de atuação do molde" e "tempo de vácuo", as demais são significativas para estudo dos desvios listados nesta pesquisa. Elas não possuem algum padrão de comportamento quanto aos desvios analisados.
- e) A compreensão das interações ora inversas ora conflitantes, os fatores principais "tempo de aquecimento" e "potência de aquecimento" vs o conjunto de desvios analisados torna-se o ponto crítico para a minimização dos desvios de peças produzidas em molde de MDF.

- f) Os métodos de mensuração dos desvios da peça propostos e utilizados foram capazes de atender satisfatoriamente aos objetivos deste trabalho, podendo ser utilizados como base para trabalhos futuros.
- g) Os desvios dimensionais estudados se mostraram também conflitantes quanto à busca conjunta de minimizá-los em função dos parâmetros de fabricação. Os algoritmos desenvolvidos, que buscam valores ótimos dos desvios, utilizam a EQ.6.1 com o intuito de solucionar esse conflito entre os desvios e selecionar a configuração que minimiza conjuntamente os desvios da peça.
- h) Os modelos computacionais desenvolvidos foram capazes de ajustar-se de forma satisfatória aos valores observados e mensurados e ainda apresentaram médias dos erros de ajustamento abaixo da faixa centesimal.
- i) O uso reduzido de amostras para o desenvolvimento dos modelos computacionais que utilizam RNA mostrou-se eficiente.
- j) Conforme já descrito por outros autores em desenvolvimento de modelos RNA com poucos dados amostrais para treinamento e validação, o aumento progressivo da quantidade de dados apresentados à rede reduz significativamente os resíduos e pode melhorar a aproximação da rede.
- k) A redução gradativa da arquitetura da RNA associada a alterações na rede, como a modificação de combinações das funções de transferência, a mudança de algoritmos e quantidade de dados treinados e validados, proporcionou nesta pesquisa o desenvolvimento de um modelo com quantidade reduzida de neurônios e níveis satisfatórios de erro de generalização e estimativas.
- l) Os testes de validação produziram peças para ambas as metodologias dentro dos limites de tolerância definidas neste estudo.
- m) A realização dos testes de validação permite verificar que, para se obter menores desvios do produto, deve-se configurar os parâmetros de fabricação: "tempo de aquecimento" entre 90-94,5s, "potência de aquecimento" dentro da faixa de 90-100%, "parâmetros de atuação do molde" no intervalo de 92,5 a 100%, "tempo de vácuo" durante 6,3 a 8,1 segundos e "pressão de vácuo" 12,5 a 15 mbar.
- n) Apesar dos modelos com regressão linear múltipla, que incluem termos das interações de segunda ordem, serem teoricamente não lineares, ou seja,



superfícies de resposta, nesta pesquisa eles foram incapazes de generalizar as características não lineares dos parâmetros de fabricação e, conseqüentemente, de estimar com aproximação regular os desvios das amostras em novas situações de teste.

- o) Para generalização e estimativas em novas situações não testadas do processo em estudo, concluiu-se que os modelos com RNA conseguiram resultados mais promissores, principalmente quanto à extrapolação do espaço de análise. Os modelos computacionais desenvolvidos por ambas as metodologias foram capazes de convergir para as regiões onde existe pelo menos uma configuração otimizada dos desvios da peça, mesmo que com erros significativos das estimativas dos valores dos desvios. Entretanto, só os modelos com RNA conseguiram obter erros de estimativa dentro dos limites dos valores encontrados nos testes de validação.
- p) O procedimento experimental realizado neste trabalho mostrou-se uma proposta promissora para a obtenção de dados e parâmetros de fabricação necessários para o adequado conhecimento do comportamento do processo de termoformagem a vácuo e, também, para o desenvolvimento de modelos e algoritmos de controle baseados em modelos de RNA.

A partir do estudo realizado e dos resultados obtidos, algumas sugestões para continuidade das investigações apresentadas neste trabalho podem ser feitas. A seguir, seguem algumas sugestões para trabalhos futuros.

- a) Estudar os efeitos dos parâmetros de fabricação em outros desvios dimensionais ou geométricos do produto, agregando esse novo estudo aos dados deste trabalho.
- b) Utilizar a metodologia adotada neste trabalho para estudar novamente esse processo, porém com a geometria fabricada em um molde com formato positivo, de maneira que seja possível comparar os resultados encontrados em ambas as pesquisas.
- c) Replicar a metodologia utilizada para o estudo do processo com outras matérias-primas para o molde, folhas, bem como outras espessuras de folhas, de tal forma que seja possível comparar os novos resultados com os apresentados neste trabalho.

- d) Estudar e testar métodos de análise qualitativos aplicáveis a produtos termoformados a vácuo com o objetivo de agregar novos critérios de aprovação dos produtos a pesquisas e/ou modelos.
- e) Isolar os parâmetros de aquecimento dos demais fatores e realizar novos testes para estudar as interações os fatores "tempo de aquecimento" e "potência de aquecimento" e suas relações na qualidade final do produto.
- f) Desenvolver um sistema de controle dinâmico das temperaturas do equipamento e molde, de forma a permitir um estudo controlado da análise da influência das temperaturas do sistema e molde na qualidade da peça.
- g) Desenvolver um sistema de aquisição de dados de temperatura do molde, sistema de aquecimento e folha que permita a análise dessas variáveis vs a propriedade qualitativa ou quantitativa das peças.
- h) Estudar os efeitos do sistema de aquecimento e seus parâmetros sobre as zonas térmicas da folha no momento da conformação, visando à análise de sua influência em características qualitativas e quantitativas da peça.
- i) Desenvolver e testar novos modelos computacionais com outras técnicas de inteligência computacional de modo a comparar os resultados alcançados com os apresentados neste trabalho.
- j) Fazer um estudo completo da fabricação de peças termoformadas a vácuo e analisar a influência do uso parcial dos dados para desenvolvimento dos modelos de previsão que utilizam RNA.
- k) Comparar os resultados de aproximação e estimativa desta pesquisa com resultados obtidos por outras técnicas de modelagem computacional de processos ou modelos de regressão.
- l) Desenvolver e testar com os dados desenvolvidos e mensurados neste trabalho modelos de RNAs inversas, que estimem os parâmetros de fabricação de um conjunto de desvios predefinido. Comparar os resultados alcançados com os apresentados neste trabalho.

## ABSTRACT

In the process of vacuum forming, the final quality of the piece depends on many variants of the system that make its prevision and the computational mathematical modeling of the system a multivariable complex process, with non-linear characteristics and of conflicting objectives. Therefore, the expectations in relation to the dimensional and geometrical deviations of the workpiece are sometimes subjective, due to the nature of the sub-processes and the executor's previous knowledge or learning. In this sense, this work intends to develop computational models using algorithms based on Artificial Neural Networks (ANN) that properly estimate and minimize values of the deviations in vacuum forming parts inside of the optimized limits of tolerance. In this way, firstly, in order to identify the meaningful fabrication parameters (factors) it was developed two series of experimental tests of the vacuum forming of a typical piece in polystyrene(PS). This initial study was able to identify all main factors are meaningful in at least one of the dimensional or geometrical deviations of the piece. Later, new methodologies base on mathematical modeling of multiple responses for the process, were investigates with the objective of properly estimating the deviations and their fabrication parameters. In this study, ANNs were programmed and tested with various architectures, training algorithms and transference function and comparatively multiple response optimization (MRO). The results showed that the ANN and MRO models were capable of converging for configurations of fabrication parameters that optimize the deviations of the piece. However, only the models with ANN were able to obtain estimative errors within the limits of the values found in the validation tests. In this way, it was demonstrated that the computational models that use algorithms based on RNA are a promising proposal for the development of mathematical and algorithms models that estimate and minimize deviations of vacuum forming parts.

**Key words:** Vacuum Forming. Artificial Neural Network. Dimensional and Geometric Deviations. Design and Analysis of Experiments.

## REFERÊNCIAS

1. ABDELWAHED, M.S.; EL-BAZ, M.A.; EL-MIDANY, T.T. A proposed performance prediction approach for manufacturing processes using ANNs. **World Academy of Science, Engineering and Technology**, v. 61, pp. 924-929, 2012.
2. AHMAD, Z.; MAT NOOR, R.A.; ZHANG, J. Multiple neural networks modeling techniques in process control: a review. **Asia-Pacific Journal of Chemical Engineering**, v. 4, pp. 403-419, 2009.
3. ALMEIDA, P.E.M.; EVSUKOFF, A.G. Sistemas fuzzy. *In*: RESENDE, S.O. **Sistemas inteligentes: fundamentos e aplicações**. 1. ed., cap. 7, Baurer-SP: Manole, 2003. ISBN: 8520416837.
4. ANTSAKLIS, P.J.; PASSINO, K.M.; WANG, S.J. An introduction to autonomous control systems. **IEEE Control Systems Magazine**, v. 11, n. 4, p. 5-13, June 1991.
5. ATI. ASSOCIATED THERMOFORMING, INC 2013. **Typical Thermoform & pressure form tolerances**. [on line]: Disponível em: [http://www.atiforms.com/ati\\_tolerances.pdf](http://www.atiforms.com/ati_tolerances.pdf). Acesso em: jun. 2013.
6. BCC Products, 2015. **BCC Products: Products**. [on line]. Disponível em: <http://bccproducts.com/>. Acesso em: maio de 2015.
7. BRAGA, A.P.; CARVALHO, A.C.P.L.F.; LUDERMIR, T.B. Redes neurais artificiais. *In*: RESENDE, S.O. **Sistemas Inteligentes: fundamentos e aplicações**, 1. ed., cap. 6, Baurer-SP, Manole, 2003. ISBN: 8520416837.
8. CARDIM, R. **Projeto de controladores baseados em Imis: realimentação derivativa e sistemas chaveados utilizando estrutura variável**. (Tese de Doutorado em Engenharia Elétrica) - Universidade Estadual Paulista "Júlio de Mesquita Filho", *Campus* de Ilha Solteira, SP, 2009.
9. CARVALHO, A.C.P.L.F.; BRAGA, A.P.; LUDEMIR, B. Computação evolutiva. *In*: RESENDE, S.O. **Sistemas inteligentes: fundamentos e aplicações**. 1. ed., cap. 9, Baurer-SP: Manole, 2003. ISBN: 8520416837.
10. CHANG, Y.Z.; WEN, Y.Z.; LIU, S.J. Derivation of optimal processing parameters of polypropylene foam thermoforming by an artificial neural network. **Journal of Polymer Engineering and Science**, v. 45, n. 3, pp. 375-384. 2005.
11. CHEN, S.; LAI, W. Control system software design of injection molding machine based on neural network. *In*: SECOND INTERNATIONAL CONFERENCE ON MECHANIC AUTOMATION AND CONTROL ENGINEERING. **Anais...**, Hohhot, pp. 1119-1122, 2011.

12. CHEN, W.C.; TSAI, H.C.; LAI, T.T. Optimization of MIMO plastic injection molding using DOE, BPNN, and GA. *In: INTERNATIONAL CONFERENCE ON INDUSTRIAL ENGINEERING AND ENGINEERING MANAGEMENT. Anais...*, Xiamen, pp. 676 - 680, 2010.
13. DARWIN, C. **On the origin of species by means of natural selection.** London: John Murray, 1859.
14. DEMUTH, H.; BEALE, M. **Neural network toolbox, user's guide.** Version 4. The MathWorks, Inc., Natick, MA, revised for version 4.0.4 edition, 2004. Disponível em: <http://www.mathworks.com>. Disponível em: março 2014.
15. EFE, M.Ö. Background of neurocontrol. *In: WILAMOWSKI, B.M.; IRWIN, J.D. Industrial electronics handbook: intelligent systems.* 2. edition, part III, chapter 1, CRC Press. 2011.
16. ENGELMANN, S.; SALMANG, R. Optimizing a thermoforming process for packaging in advanced thermoforming methods. *in: ENGELMANN, S. Machines and materials, applications and automation.* 1. editon, chapter 2, New Jersey, EUA: John Wiley & Sons, 2012.
17. ESTEBAN, L.G. *et al.* Artificial neural networks in variable process control: application in particleboard manufacture. **Journal Investigación Agraria: Sistemas y Recursos Forestales**, v. 18, n. 1, pp. 92-100, 2009.
18. FLORJANIČ, B.; GOVEKAR, E.; KUZMAN, K. Neural network-based model for supporting the expert driven project estimation process in mold manufacturing. **Journal of Mechanical Engineering**, v. 59, n.1, pp. 3-13, 2013.
19. GRUENWALD, G. **Thermoforming: a plastics processing guide.** 2. edition, Pennsylvania, EUA: CRC. 1998
20. GOVINDHASAMYA, J. *et al.* Neural modelling, control and optimisation of an industrial grinding process. **Control Engineering Practice**, v. 13, pp. 1243-1258, 2005.
21. GOYAL, S. Predicting properties of cereals using artificial neural networks: A review scientific. **Journal of Crop Science**, v. 2, n. 7, pp. 95-115, 2013.
22. GREŠOVNIK, I. *et al.* Application of artificial neural networks to improve steel production process. *In: PROCEEDINGS OF THE IASTED INTERNATIONAL CONFERENCE. Anais...*, Napoli- Italy, 2012.
23. HAGAN, M.T.; MENHAJ, M.B. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, pp. 989-993, 1994.
24. HAKIMPOOR, H. *et al.* Artificial neural networks' applications in management. **World Applied Sciences Journal**, v. 14, n. 7, pp. 1008-1019, 2011.

25. HAO, H.; HAI, C.; ZHU, X. Research of quality control for plastic injection gear based on CAE technology. *In: INTERNATIONAL CONFERENCE ON MECHANIC AUTOMATION AND CONTROL ENGINEERING. Anais...*, WUHAN, PP, 3742-3747, 2010.
26. HAO, Y.U.; WILAMOWSKI, B.M. Levenberg-Marquardt training. *In: WILAMOWSKI, B.M.; IRWIN, J.D. Industrial electronics handbook: intelligent systems. 2. edition, part III, chapter 12*, CRC Press, 2011.
27. HOLLAND, J.H. **Adaptation in natural and artificial systems**. Ann Arbor, MI: The University of Michigan Press, 1975.
28. HUANG, S.H.; ZHANG, H.C. Artificial neural networks in manufacturing: concepts, applications, and perspectives. **IEEE Components, Packaging, and Manufacturing Technology**, v. 17, n. 2, p. 212-228, part I, June 1994.
29. HUI, C.L.P.; FUN, N.S.; CONNIE, I.P. Review of application of artificial neural networks in textiles and clothing industries over last decades. *In: SUZUKI, K. Artificial neural networks: industrial and control engineering applications*, p. 1, chap. 1, pp. 3-34, 2011. ISBN 978-953-307-220-3.
30. KARJUST, K.; KÜTTNER, R.; PONLAK, M. The design and production technology of large composite plastic products. **Journal of Proceedings of the Estonian Academy of Sciences, Engineering**. v. 13, n. 2, pp. 117-128. 2007.
31. KARNIK, S.R. *et al.* Delamination analysis in high speed drilling of carbon fiber reinforced plastics (CFRP) using artificial neural network model. **Materials and Design**. v. 29. p. 1768-1776. 2008. (doi:10.1016/j.matdes.2008.03.014).
32. KAUR, A. Impact of training function based neural network on reusable software modules. **International Journal of Computer Science and Information Technologies**, v. 3, n. 3, 4024-4027, 2012.
33. KAWATO, M.; FURUKAWA, K.; SUZUKI, R. A hierarchical neural-network model or control and learning of voluntary movement. **Biological Cybernetics**, v. 57, p. 169-185, 1987.
34. KLEIN, P. **Fundamentals of plastics thermoforming**. First published, Morgan & Claypool, 2009. ISBN: 9781598298840.
35. KOSKO, B. **Neural networks and fuzzy systems: A dynamical systems approach to machine intelligence**. New Delhi, India: Prentice-Hall, 1994.
36. KOWALSKA, T.O.; SZABAT, K. Fuzzy logic controllers. *In: WILAMOWSKI, B.M.; IRWIN, J.D. Industrial electronics handbook: intelligent systems. 2. edition, part III, chapter 19*, CRC Press, 2011.
37. KOZA, J. **Genetic programming: on the programming of computers by means of natural selection**. Cambridge, MA: MIT Press, 1992.

38. KUMAR, K.; THAKUR, G.S.M. Advanced applications of neural networks and artificial intelligence: a review. **International Journal Information Technology and Computer Science**, v. 6, pp.57-68, 2012.
39. KUMAZAWA, A.H. **Estudos sobre misturas espectrais usando algoritmo genético**. Trabalho de formatura supervisionado (Ciência da Computação). Universidade de São Paulo, SP, 2003.
40. LALITHAMMA, G.A.; PUTTASWAMY, P.S. novel shannon-based low-power full-adder architecture for neural network applications. **Emerging Research in Electronics, Computer Science and Technology**, v. 248, pp. 891-901, 2014.
41. LANXESS, 2014. **Shrinkage and distortion calculation**. [on line]. Disponível em:  
<http://techcenter.lanxess.com/scp/americas/en/techServscp/79017/article.jsp?print=true&docId=79015>. Acesso em: fevereiro de 2014.
42. LEITE, W.O. **Cenário de manufatura integrada: desenvolvimento e fabricação de moldes para produtos de plásticos**. (Dissertação de Mestrado em Engenharia de Produção), Escola de Engenharia, Programa de Pós-Graduação em Engenharia de Produção – UFMG, 2011.
43. LU, C.H. *et al.* Predictive control based on recurrent neural network and application to plastic injection molding processes. *In: THE 33RD ANNUAL CONFERENCE OF THE IEEE INDUSTRIAL ELECTRONICS SOCIETY*. Taipei, Taiwan, **Anais...**, v. 5-8, pp. 792-797, 2007.
44. LU, C.H.; TSAI, C.C. Design and application of predictive controller using neural networks. *In: CONFERENCE ON SYSTEM SCIENCE AND ENGINEERING*, Taiwan, **Anais...**, pp. 257-262, 2010.
45. MACARRÃO, L.J. **Importância do uso de mock-ups e de técnicas de prototipagem e ferramental rápido no processo de desenvolvimento de produto na indústria automotiva**. (Dissertação de Mestrado em Engenharia Automotiva), Escola Politécnica, Universidade de São Paulo - USP, 2004.
46. MANJUNATH PATEL, G.C.; KRISHNA, P. A review on application of artificial neural networks for injection moulding and casting processes. **International Journal of Advances in Engineering Sciences**, v. 3, n. 1, pp. 1-12, 2013.
47. MAT NOOR, R.A. *et al.* Modelling and control of different types of polymerization processes using neural networks technique: a review. **The Canadian Journal of Chemical Engineering**, v. 88, n. 6, pp. 1065-1084, 2010.

48. MEKRAS, N.; ARTEMAKIS, I. Using artificial neural networks to model extrusion processes for the manufacturing of polymeric micro-tubes. International Conference on Structural Nano Composites, Series: **Materials Science and Engineering**, v. 40, n. 1, 2012.
49. MEZIANE, F. *et al.* Intelligent systems in manufacturing: current developments and future prospects. **Integrated Manufacturing Systems**, v. 11, n. 4, pp. 218-238, 2000.
50. MONTGOMERY, D.C. **Design and analysis of experiments**. 8. ed., Wiley, NY, 2013.
51. MONTGOMERY, D.C.; RUNGER, G.C. **Estatística aplicada e probabilidade para engenheiros**. 4. ed., LTC, 2009.
52. MURALISRINIVASAN, N.S. **Update on troubleshooting in thermoforming**. 1. ed., United Kingdom, EUA: Smithers Rapra. 2010. ISBN: 978-1-84735-137-1.
53. NARENDRA, K.S.; PARTHASARATHY, K. Identification and control of dynamical systems using neural networks. **IEEE Transactions on Neural Networks**, v. 1, p. 4-27, 1990.
54. PALIWAL, P.; KUMAR, U.A. Neural networks and statistical techniques: A review of applications. **Expert Systems with Applications**, v. 36, pp. 2-17, 2009.
55. PHAM, D.T.; PHAM, P.T.N. Computational intelligence for manufacturing, *In*: WANG, J. *et al.* (ed.). **Computational intelligence in manufacturing handbook**. 1. edition, part I, Boca Raton: CRC Press LLC, 2001. ISBN 0-8493-0592-6.
56. PRECUP, R.E.; HELLENDORRN, H. A survey on industrial applications of fuzzy control. **Journal Computers in Industry**, v. 62, pp. 213-226, 2011.
57. PRIORE, P. *et al.* Utilización de las redes neuronales en la toma de decisiones. Aplicación a un problema de secuenciación. **Anales de Mecánica y Electricidad**, v. 79, n. 6, pp 28-34, 2002.
58. RESENDE, S.O.; PUGLIESI, J.B.; VAREJÃO, F.M. Sistemas baseados no conhecimento. *In*: RESENDE, S, O. **Sistemas inteligentes: fundamentos e aplicações**. 1. ed. 1, cap. 2. Baueri-SP, Manole, 2003. ISBN: 8520416837.
59. ROSENBLATT, F. **Principles of neurodynamics**. Washington D.C.: Spartan Press, 1961.
60. ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychology Revue**, v. 65, pp. 386-408, 1958.



61. ROSEN, S.R. **A history of the growth of the thermoforming industry. Chapter I Thermoforming Pioneers 1930-1950.** [on line], 2002. Disponível em: [http://thermoformingdivision.com/wp-content/uploads/History\\_of\\_thermoforming\\_chap1.pdf](http://thermoformingdivision.com/wp-content/uploads/History_of_thermoforming_chap1.pdf). Acesso em: 10 de fevereiro de 2014.
62. ROSE, S. **Thermoforming: improving process performance.** 1. ed., Dearborn, EUA: Society of Manufacturing Engineers. 2002.
63. SALA, G.; LANDRO, L.D.; CASSAGO, D. A numerical and experimental approach to optimise sheet stamping technologies: polymers thermoforming. **Journal of Materials and Design**, v. 23, pp. 21-39, 2002.
64. SCHALKOFF, R.J. **Artificial neural networks.** McGraw-Hill Companies, p. 448, 1997.
65. SHABAN, A. *et al.* Automated Identification of basic control charts patterns using neural networks. **Journal Software Engineering & Applications**, v. 3, pp. 208-220, 2010.
66. SLOMP, J.; KLINGENBERG, W. A proposal to use artificial neural networks for process control of punching/blanking operations. *In: INTERNATIONAL CONFERENCE ON FLEXIBLE AUTOMATION AND INTELLIGENT MANUFACTURING*, Toronto, v. 1, pp. 556-562, **Anais...**, 2004.
67. SOROUSH, A.R.; NAKHAI, K.A.I.; BAHREININEJAD, A. Review on application of artificial neural networks in supply chain management and its future. **World Applied Sciences Journal**, v. 6, n. 7, pp. 12-18, 2009.
68. SPINA, R. Optimisation of injection moulded parts by using ANN-PSO approach. **Journal of Achievements in Materials and Manufacturing Engineering**, v. 15, n. 1-2, pp. 146-152, 2006.
69. SUZUKI, K. **Artificial neural networks: industrial and control engineering applications.** 1 ed, Ed. InTech, Rijeka-Croacia, p. 478, 2011. ISBN 978-953-307-220-3.
70. TADEUSIEWICZ, R. Introduction to intelligent systems. *In: WILAMOWSKI, B.M.; IRWIN, J.D. Industrial electronics handbook: intelligent systems.* 2. edition, part I, CRC Press, 2011.
71. THRONE, J.L. **Technology of thermoforming.** New York: Hanser Publishers, 1. ed, v. 1, pp. 922, 1996.
72. THRONE, J. **Thermoforming.** *In: KUTZ, M. Applied plastics engineering handbook: processing and materials.* 1. edition, part III, chapter 19, Waltham, EUA: Elsevier. 2011.
73. THRONE, J.L. **Understanding thermoforming.** 2. edition, 2008. ISBN-10: 1569904286.

74. TOOLING TECHNOLOGY, 2015. **Tooling Technology and Automation: Metapor Mold Material.** [on line]. Disponível em: <http://toolingtechgroup.com/metapor-mold.asp>. Acesso em: maio de 2015.
75. VELSKER, M. *et al.* Artificial neural networks and evolutionary algorithms in engineering design. **Journal of Achievements in Materials and Manufacturing Engineering**, v. 44, n. 1, pp. 88-95, 2011.
76. WERBOS, P.J. **From Backpropagation to neurocontrol in:** industrial electronics handbook - intelligent systems. 2. edition, Part I, Chapter 2, CRC Press, 2011.
77. WIDROW, B.; STERNS, S.D. **Adaptive signal processing.** New York: Prentice-Hall, 1985.
78. YANG, C.; HUNG, S.W. Modeling and Optimization of a Plastic Thermoforming Process. **Journal of Reinforced Plastics and Composites**, v. 23, n. 1, pp. 109-121. 2004.
79. YANG, C.; HUNG, S.W. Optimising the thermoforming process of polymeric foams: an approach by using the Taguchi method and the utility concept. **International Journal Adv Manufacturing Technology**, v. 24, p. 353-360, 2004. DOI 10.1007/s00170-003-1591-4.
80. YOUSIF, Y.K.; DAWS, K.M.; KAZEM, B.I. Prediction of friction stir welding characteristic using neural network. **Journal of Mechanical and Industrial Engineering**, v. 2, n. 3, pp. 151-155, 2008.
81. ZADEH, L.A. Fuzzy sets. **Journal Information Control**, v. 8, p. 338-353, 1965.
82. ZARENEZHAD, B.; AMINIAN, A. Application of the neural network-based model predictive controllers in nonlinear industrial systems: case study. **Journal of the University of Chemical Technology and Metallurgy**, v. 46, n. 1, pp. 67-74. 2011.
83. ZULKEFLEE, S.,A.; AZIZ, N. Control implementation in bioprocess system: a review. **International Conference on Control, Instrumentation and Mechatronics Engineering**, Johor Bahru, pp. 798-804, 2007.

## ANEXO E APÊNDICES

ANEXO A: Temperaturas recomendadas para processamento de plásticos termoformáveis.....	172
APÊNDICE A: .....	173
Apêndice A.1: Diagrama de fluxo de atividade da metodologia de pesquisa adotada, subetapa 01.....	173
Apêndice A.2: Diagrama de fluxo de atividade da metodologia de pesquisa adotada, subetapa 02.....	174
Apêndice A.3: Diagrama de fluxo de atividade da metodologia de pesquisa adotada, subetapa 03.....	174
APÊNDICE B: Tabela do Planejamento Fatorial Fracionado 26-2IV codificado e sequência de execução para a etapa de testes exploratórios .....	175
APÊNDICE C: Tabela do Planejamento Fatorial Fracionado 25-1V codificado e sequência de execução para a etapa de testes experimentais.....	176
APÊNDICE D:.....	177
Apêndice D.1: Tabela dos resultados dos cálculos dos coeficientes de regressão da regressão múltipla para os dados do desvio dimensional da altura total da peça.....	177
Apêndice D.2: Tabela dos resultados dos cálculos dos coeficientes de regressão da regressão múltipla para os dados do desvio geométrico de planeza do fundo da peça.....	178
Apêndice D.3: Tabela dos resultados dos cálculos dos coeficientes de regressão da regressão múltipla para os dados do desvio geométrico médio dos ângulos laterais da peça.....	178
Apêndice D.4: Tabela dos resultados dos cálculos dos coeficientes de regressão da regressão múltipla para os dados do desvio dimensional do comprimento da diagonal superior da peça.....	179

APÊNDICE E:.....	180
Apêndice E.1: Tabela dos desvios mensurados nas amostras do teste com primeiro modelos de otimização de múltiplas respostas vs tipo de desvios.....	180
Apêndice E.2: Tabela dos desvios mensurados nas amostras do teste com segundo modelos de otimização de múltiplas respostas vs tipo de desvios.....	180
Apêndice E.3 Tabela dos desvios mensurados nas amostras do teste com primeiro modelos de otimização de redes neurais artificiais vs tipo de desvios.....	181
Apêndice E.4: Tabela dos desvios mensurados nas amostras do teste com segundo modelos de otimização de redes neurais artificiais vs tipo de desvios.....	181


## ANEXO A

### Temperaturas recomendadas para processamento de plásticos termoformáveis


Polymer	Glass transition temperature		Melt temperature		Heat distortion temperature		Set and mold temperature		Lower forming temperature		Orienting temperature		Normal forming temperature		Upper forming temperature	
	(°C)	(°F)	(°C)	(°F)	(0.46 N/mm <sup>2</sup> / 66 psi)	(°C)	(°F)	(°C)	(°F)	(°C)	(°F)	(°C)	(°F)	(°C)	(°F)	
<i>Amorphous polymers</i>																
Polystyrene	94	200	–	–	68–96	155–204	85	185	127	260	135	275	149	300	182	360
PMMA	100	212	–	–	74–113	165–235	85	185	149	300	163	325	177	350	193	380
PMMA/PVC alloy	105	221	–	–	81	177	79	175	143	290	154	310	171	340	182	360
ABS	88–120	190–248	–	–	77–113	170–235	82	180	127	260	137	280	146	295	182	360
Polycarbonate	150	300	–	–	138	280	132	270	168	335	177	350	191	375	204	400
Rigid PVC	77	170	–	–	57–82	135–180	66	150	104	220	118	245	138	280	154	310
Modified PPO	104–110	219–230	–	–	110	230	99	210	165	325	182	360	188	375	204	400
Polysulfone	190	374	–	–	181	358	163	325	191	375	213	415	246	475	302	575
Polyethersulfone (PES)	230	445	–	–	216	420	204	400	274	525	293	560	316	600	343	650
20% GR PES	225	437	–	–	216	420	210	410	279	535	293	560	316	600	357	675
Polyamide-imide	275	527	–	–	302	575	232	450	357	675	371	700	404	760	427	800
<i>Crystalline polymers</i>																
LOPE	–25	–13	115	239	40–44	104–112	66	150	116	240	129	265	132	270	168	335
EVA	–	–	107	225	62	114	77	170	127	260	138	280	146	295	182	360
HDPE	–110	166	134	273	79	91	175	196	77	170	127	260	132	270	146	295
Cellulose acetate	70, 100	158, 212	230	445	52–93	125–200	71	160	127	260	141	285	154	310	182	360
Cellulose butyrate	120	248	140	284	54–108	130–227	79	175	127	260	138	280	146	295	182	360
Cellulose propionate	–	–	190	374	64–121	147–250	88	190	127	260	137	280	146	295	182	360
Polypropylene, homo-	5	41	168	334	107–121	225–250	88	190	132	270	138	280	154–163	310–325	166	330
Polypropylene, co-	–20	–4	150–175	302–347	85–104	185–220	88	190	143	290	177	350	185	365	193	380
40% GR PP	5	41	168	334	166	330	91	195	129	265	141	285	204	400	232	450
Polymethyl pentene	47	117	235	455	85	185	77	170	260	500	274	525	277	530	288	550
PVDC	0	32	160	320	68	155	66	150	163	325	177	350	182	360	199	390
Acrylonitrile	95	203	135	275	78	172	82	180	127	260	137	280	149	300	182	360
PET	70	158	255	490	49	120	77	170	121	250	138	280	149	300	166	330
PBT, neat	–80, 70	–112, 158	245	473	185	365	177	350	260	500	274	525	274	525	288	550
Nylon 6 (PA 6)	58	136	220	428	80	176	91	195	216	420	224	435	227	440	238	460
Nylon 66 (PA 66)	78	169	255	491	105	221	104	220	249	480	260	500	274	525	288	550
POM, copolymer	–55	–67	165	329	110–125	230–257	99	210	163	325	177	350	182	360	204	400
30% GR POM	–50	–58	166	331	163	325	104	220	163	325	177	350	182	360	204	400
PTFE	–55	–67	327	621	46	115	99	210	234	435	249	480	260	500	282	540
FEP	55	67	275	527	70	158	149	300	232	450	246	475	260	500	279	535
PEEK	100, 149	212, 300	334	633	140	284	160	320	399	750	413	775	418	785	427	800
<i>Foams</i>																
Polystyrene foam	70–85	158–185	–	–	55–65	131–149	50	122	88	190	96	205	104	220	113	235
Rigid PVC foam	70	158	–	–	65	149	66	150	110	230	124	255	143	290	171	340

## APÊNDICE A


### A.1 Diagrama de fluxo de atividade da metodologia de pesquisa adotada, subetapa 01



## A.2 Diagrama de fluxo de atividade da metodologia de pesquisa adotada, subetapa 02



## A.3 Diagrama de fluxo de atividade da metodologia de pesquisa adotada, subetapa 03



## APÊNDICE B

**Tabela do Planejamento Fatorial Fracionado  $2^{6-2}_{IV}$  codificado e sequencia de execução para a etapa de testes exploratórios**

Corrida		Fatores do Planejamento / Parâmetros de fabricação Codificados					
Ordem padrão	Ordem de execução	A	B	C	D	E=ABC	F=BCD
		Matéria-prima do Molde	Espessura da folha	Parâmetros de aquecimento	Parâmetros de atuação do molde	Tempo de vácuo	Pressão de vácuo
1	1	-1	1	-1	-1	5,5	10
2	18	1	1	-1	-1	7	10
3	7	-1	1,5	-1	-1	7	12,5
4	27	1	1,5	-1	-1	5,5	12,5
5	11	-1	1	1	-1	7	12,5
6	21	1	1	1	-1	5,5	12,5
7	14	-1	1,5	1	-1	5,5	10
8	26	1	1,5	1	-1	7	10
9	12	-1	1	-1	1	5,5	12,5
10	28	1	1	-1	1	7	12,5
11	5	-1	1,5	-1	1	7	10
12	30	1	1,5	-1	1	5,5	10
13	10	-1	1	1	1	7	10
14	25	1	1	1	1	5,5	10
15	4	-1	1,5	1	1	5,5	12,5
16	29	1	1,5	1	1	7	12,5
17	3	-1	1	-1	-1	5,5	10
18	32	1	1	-1	-1	7	10
19	9	-1	1,5	-1	-1	7	12,5
20	31	1	1,5	-1	-1	5,5	12,5
21	6	-1	1	1	-1	7	12,5
22	19	1	1	1	-1	5,5	12,5
23	8	-1	1,5	1	-1	5,5	10
24	20	1	1,5	1	-1	7	10
25	16	-1	1	-1	1	5,5	12,5
26	22	1	1	-1	1	7	12,5
27	2	-1	1,5	-1	1	7	10
28	17	1	1,5	-1	1	5,5	10
29	13	-1	1	1	1	7	10
30	23	1	1	1	1	5,5	10
31	15	-1	1,5	1	1	5,5	12,5
32	24	1	1,5	1	1	7	12,5



## APÊNDICE C

**Tabela do Planejamento Fatorial Fracionado  $2^{5-1}_v$  codificado e sequencia de execução para a etapa de testes experimentais**

Corrida		Fatores do Planejamento / Parâmetros de fabricação Codificados				
Ordem padrão	Ordem de execução	A	B	C	D=AB	E=AC
		Tempo de aquecimento (s)	Potência de aquecimento (%)	Parâmetros de atuação do molde (%)	Tempo de vácuo (s)	Pressão de vácuo (mbar)
1	31	80	90	100	7,2	10
2	33	90	90	85	7,2	10
3	9	80	100	85	7,2	10
4	1	90	100	100	7,2	10
5	2	80	90	85	9	10
6	10	90	90	100	9	10
7	24	80	100	100	9	10
8	14	90	100	85	9	10
9	18	80	90	85	7,2	15
10	25	90	90	100	7,2	15
11	28	80	100	100	7,2	15
12	4	90	100	85	7,2	15
13	21	80	90	100	9	15
14	13	90	90	85	9	15
15	30	80	100	85	9	15
16	29	90	100	100	9	15
17	26	80	90	100	7,2	10
18	19	90	90	85	7,2	10
19	16	80	100	85	7,2	10
20	11	90	100	100	7,2	10
21	17	80	90	85	9	10
22	12	90	90	100	9	10
23	15	80	100	100	9	10
24	32	90	100	85	9	10
25	6	80	90	85	7,2	15
26	3	90	90	100	7,2	15
27	34	80	100	100	7,2	15
28	8	90	100	85	7,2	15
29	23	80	90	100	9	15
30	5	90	90	85	9	15
31	20	80	100	85	9	15
32	7	90	100	100	9	15
33	27	85	95	92,5	8,1	12,5
34	22	85	95	92,5	8,1	12,5

## APÊNDICE D

**D.1 Tabela dos resultados dos cálculos dos coeficientes de regressão da regressão múltipla para os dados do desvio dimensional da altura total da peça**

Preditor		Coeficiente de regressão
<i>Termo</i>	<i>Descrição</i>	
Constante	Constante de ajuste	-27,94977729
A	Tempo de Aquecimento	0,147198177
B	Potência de Aquecimento	0,309674115
C	Parâmetros de atua. molde	-0,166175729
D	Tempo de Vácuo	4,21983015
E	Pressão de Vácuo	-0,992314896
A*B	Tempo de Aquecimento*Potência de Aquecimento	-0,002028656
A*D	Tempo de Aquecimento* Tempo de Vácuo	-0,017926562
A*E	Tempo de Aquecimento* Pressão de Vácuo	0,007246438
A*C	Tempo de Aquecimento*Parâmetros de atua. molde	0,001335354
B*D	Potência de Aquecimento*Tempo de Vácuo	-0,019336285
B*E	Potência de Aquecimento*Pressão de Vácuo	-0,000626063
B*C	Potência de Aquecimento*Parâmetros de atua. molde	0,000775354
D* E	Tempo de Vácuo*Pressão de Vácuo	0,002764931
D*C	Tempo de Vácuo*Parâmetros de atua. molde	-0,009421644
E*C	Pressão de Vácuo*Parâmetros de atua. molde	0,004313208
Ct Pt	Constante de ajuste do ponto central	-0,049108594

**D.2 Tabela dos resultados dos cálculos dos coeficientes de regressão da regressão múltipla para os dados do desvio geométrico de planeza do fundo da peça**

<b>Preditor</b>		<b>Coefficiente de regressão</b>
<b>Termo</b>	<b>Descrição</b>	
Constante	Constante de ajuste	69,06537083
A	Tempo de Aquecimento	-0,710060972
B	Potência de Aquecimento	-0,713180139
C	Parâmetros de atua. molde	0,13143250
D	Tempo de Vácuo	-0,459804784
E	Pressão de Vácuo	-0,739571944
A*B	Tempo de Aquecimento*Potência de Aquecimento	0,006966083
A*D	Tempo de Aquecimento* Tempo de Vácuo	0,008850926
A*E	Tempo de Aquecimento* Pressão de Vácuo	0,002194667
A*C	Tempo de Aquecimento*Parâmetros de atua. molde	-0,001043778
B*D	Potência de Aquecimento*Tempo de Vácuo	-0,000390741
B*E	Potência de Aquecimento*Pressão de Vácuo	0,005097667
B*C	Potência de Aquecimento*Parâmetros de atua. molde	0,000180222
D* E	Tempo de Vácuo*Pressão de Vácuo	0,014426852
D*C	Tempo de Vácuo*Parâmetros de atua. molde	-0,005333642
E*C	Pressão de Vácuo*Parâmetros de atua. molde	-0,000784556
Ct Pt	Constante de ajuste do ponto central	-0,029714583

**D.3 Tabela dos resultados dos cálculos dos coeficientes de regressão da regressão múltipla para os dados do desvio geométrico médio dos ângulos laterais da peça**

<b>Preditor</b>		<b>Coefficiente de regressão</b>
<b>Termo</b>	<b>Descrição</b>	
Constante	Constante de ajuste	27,41648221
A	Tempo de Aquecimento	-0,208447796
B	Potência de Aquecimento	-0,221828149
C	Parâmetros de atua. molde	0,007012008
D	Tempo de Vácuo	-1,188922512
E	Pressão de Vácuo	-0,250265384
A*B	Tempo de Aquecimento*Potência de Aquecimento	0,002162254
A*D	Tempo de Aquecimento* Tempo de Vácuo	0,004532616
A*E	Tempo de Aquecimento* Pressão de Vácuo	-0,001543027
A*C	Tempo de Aquecimento*Parâmetros de atua. molde	-0,000311275
B*D	Potência de Aquecimento*Tempo de Vácuo	0,001178064
B*E	Potência de Aquecimento*Pressão de Vácuo	0,003586834
B*C	Potência de Aquecimento*Parâmetros de atua. molde	-0,000340673
D* E	Tempo de Vácuo*Pressão de Vácuo	0,004500225
D*C	Tempo de Vácuo*Parâmetros de atua. molde	0,006576914
E*C	Pressão de Vácuo*Parâmetros de atua. molde	-0,000218731
Ct Pt	Constante de ajuste do ponto central	-0,007910518

**D.4 Tabela dos resultados dos cálculos dos coeficientes de regressão da regressão múltipla para os dados do desvio dimensional do comprimento da diagonal superior da peça**

<b>Preditor</b>		<b>Coefficiente de regressão</b>
<b>Termo</b>	<b>Descrição</b>	
Constante	Constante de ajuste	9,868354195
A	Tempo de Aquecimento	-0,127872101
B	Potência de Aquecimento	-0,06433608
C	Parâmetros de atua. molde	-0,047886613
D	Tempo de Vácuo	0,274325867
E	Pressão de Vácuo	-0,005321494
A*B	Tempo de Aquecimento*Potência de Aquecimento	0,000906562
A*D	Tempo de Aquecimento* Tempo de Vácuo	0,001316982
A*E	Tempo de Aquecimento* Pressão de Vácuo	0,001383035
A*C	Tempo de Aquecimento*Parâmetros de atua. molde	0,000165253
B*D	Potência de Aquecimento*Tempo de Vácuo	-0,005722334
B*E	Potência de Aquecimento*Pressão de Vácuo	-0,000311248
B*C	Potência de Aquecimento*Parâmetros de atua. molde	0,000287991
D* E	Tempo de Vácuo*Pressão de Vácuo	-0,001937292
D*C	Tempo de Vácuo*Parâmetros de atua. molde	0,001797519
E*C	Pressão de Vácuo*Parâmetros de atua. molde	-0,000717682
Ct Pt	Constante de ajuste do ponto central	0,003270649

## APÊNDICE E

### E.1 Tabela dos desvios mensurados nas amostras do teste com primeiro modelos de otimização de múltiplas respostas vs tipo de desvios

CORRIDA		RESULTADO			
<i>Ordem padrão</i>	<i>Ordem de execução</i>	<i>Desvio dimensional da altura total da peça (mm)</i>	<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	<i>Desvio geométrico médio dos ângulos laterais da peça (°)</i>	<i>Desvio dimensional do comprimento da diagonal da peça (mm)</i>
1	1	-0,25276	0,07970	0,23073	-0,37287
2	2	-0,27351	0,29870	0,17979	-0,48407
3	3	-0,18526	0,06070	0,24153	-0,27482
4	4	-0,31976	0,09870	0,13767	-0,28265
5	5	-0,24551	0,13270	0,17778	-0,29240

Desvios mensurados vs tipo de desvios.

### E.2 Tabela dos desvios mensurados nas amostras do teste com segundo modelos de otimização de múltiplas respostas vs tipo de desvios

CORRIDA		RESULTADO			
<i>Ordem padrão</i>	<i>Ordem de execução</i>	<i>Desvio dimensional da altura total da peça (mm)</i>	<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	<i>Desvio geométrico médio dos ângulos laterais da peça (°)</i>	<i>Desvio dimensional do comprimento da diagonal da peça (mm)</i>
1	1	-0,25276	0,07970	0,23073	-0,37287
2	2	-0,27351	0,29870	0,17979	-0,48407
3	3	-0,18526	0,06070	0,24153	-0,27482
4	4	-0,31976	0,09870	0,13767	-0,28265
5	5	-0,24551	0,13270	0,17778	-0,29240

**E.3 Tabela dos desvios mensurados nas amostras do teste com primeiro modelos de otimização de redes neurais artificiais vs tipo de desvios**

<b>CORRIDA</b>		<b>RESULTADO</b>			
<i>Ordem padrão</i>	<i>Ordem de execução</i>	<i>Desvio dimensional da altura total da peça (mm)</i>	<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	<i>Desvio Geométrico médio dos ângulos laterais da peça (°)</i>	<i>Desvio dimensional do comprimento da diagonal da peça (mm)</i>
1	1	-0,25276	0,07970	0,23073	-0,37287
2	2	-0,27351	0,29870	0,17979	-0,48407
3	3	-0,18526	0,06070	0,24153	-0,27482
4	4	-0,31976	0,09870	0,13767	-0,28265
5	5	-0,24551	0,13270	0,17778	-0,29240

**E.4 Tabela dos desvios mensurados nas amostras do teste com segundo modelos de otimização de redes neurais artificiais vs tipo de desvios**

<b>CORRIDA</b>		<b>RESULTADO</b>			
<i>Ordem padrão</i>	<i>Ordem de execução</i>	<i>Desvio dimensional da altura total da peça (mm)</i>	<i>Desvio geométrico de planeza do fundo da peça (mm)</i>	<i>Desvio geométrico médio dos ângulos laterais da peça (°)</i>	<i>Desvio dimensional do comprimento da diagonal da peça (mm)</i>
1	1	-0,25276	0,07970	0,23073	-0,37287
2	2	-0,27351	0,29870	0,17979	-0,48407
3	3	-0,18526	0,06070	0,24153	-0,27482
4	4	-0,31976	0,09870	0,13767	-0,28265
5	5	-0,24551	0,13270	0,17778	-0,29240