

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO

**OTIMIZAÇÃO ROBUSTA DO PROCESSO  
DE APLAINAMENTO DA MADEIRA *Pinus*  
*taeda***

**Diego Jean de Melo**

Itajubá, maio de 2019

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO

**Diego Jean de Melo**

**Otimização Robusta do Processo de  
Aplainamento da Madeira *Pinus taeda***

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para obtenção do título de **Mestre em Ciências em Engenharia de Produção**.

**Área de Concentração:** Engenharia de Produção

**Orientador:** Prof. Dr. Anderson Paulo de Paiva

Itajubá, maio de 2019

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO

**Diego Jean de Melo**

**Otimização Robusta do Processo de  
Aplainamento da Madeira *Pinus taeda***

Dissertação aprovada por banca examinadora em 17 de maio de 2019, conferindo ao autor o título de **Mestre em Ciências em Engenharia de Produção**.

**Banca Examinadora:**

Prof. Dr. Anderson Paulo de Paiva (Orientador)

Prof. Dr. José Reinaldo Moreira da Silva (UFLA)

Prof. Dr. José Henrique de Freitas Gomes (UNIFEI)

Itajubá, maio de 2019

---

## DEDICATÓRIA

*À Deus, por me permitir esse momento  
e aos meus pais e irmão, que sempre  
estão ao meu lado.*

---

## AGRADECIMENTOS

À Deus por me proporcionar viver esse momento marcante e especial em minha vida. Pela motivação, fé, dedicação e força para nunca desistir de realizar todos os meus sonhos, mesmos aqueles mais difíceis. Por me mostrar sempre todos os caminhos e me dar sabedoria para trilhar todo esse caminho de forma consciente.

Aos meus pais Antônio e Neide, pela dedicação, apoio, amor, carinho e total incentivo me dado ao longo da minha vida. Ao meu irmão, Deiver, por estar ao meu lado, sendo um grande conselheiro e exemplo de garra e força de vontade.

À minha namorada Ana Iara, principal pessoa a entrar em meu caminho nessa estrada. Obrigado pelos grandes momentos, sorrisos, alegria, paciência, atenção, carinho, amizade e companheirismo.

Ao meu orientador Anderson Paiva, por me acolher como aluno e orientado. Obrigado pelos ensinamentos transmitidos, por acreditar nesse grande desafio da usinagem da madeira, pelas críticas construtivas, questionamentos e opiniões que foram fundamentais para o sucesso no desenvolvimento dessa dissertação e artigos nacionais e internacionais.

Ao Professor João Roberto, por ser um grande conselheiro ao longo do meu mestrado, questionando minhas ideias e me incentivando no desenvolvimento de trabalhos inovadores em usinagem da madeira.

Ao professor Robson Pereira, pelo ensinamento transmitido durante minha graduação, pela amizade, por ser o principal responsável por me mostrar o caminho e incentivar a realizar o mestrado na UNIFEI.

À doutoranda Taiane Guedes, pela amizade e parceria na realização dessa dissertação e no desenvolvimento de diversos outros trabalhos e artigo científico publicado em periódico internacional.

Ao professor José Reinaldo, pelas ideias, presença, auxílio e ensinamentos passados no desenvolvimento desse trabalho.

Aos amigos Rodrigo Reis, Laila Alves, Aline Alvim, Yasmin Martins e Kaíque Osório, pela amizade, companheirismo, pesquisas, estudos e publicações em artigos em anais de eventos e periódicos. Juntos vencemos essa etapa importante em nossas vidas.

Aos amigos do GEPE Qualidade Taynara Incerti, Fabrício Almeida, Vinícius Renó, Julio Mosquera e Lucas Guedes pelas pesquisas, estudos, publicação de artigos em anais de

eventos e momentos de descontração.

Aos amigos da República Mansão e Rose, pelos momentos compartilhados e histórias inesquecíveis.

À UNIFEI, pelo programa de pós-graduação em Engenharia de Produção e oportunidade de crescimento pessoal e intelectual.

À UFLA, pelo espaço cedido no laboratório de usinagem da madeira do departamento de Ciências Florestais e todo o material necessário para o desenvolvimento desse trabalho.

A todos os professores de pós-graduação em Engenharia de Produção da UNIFEI, pelos ensinamentos e experiências compartilhados.

A todos os amigos que tive a oportunidade de conhecer durante meu mestrado, todos foram extremamente importantes nessa minha caminhada.

Ao CNPq, pelo auxílio financeiro.

---

## EPÍGRAFE

*"Há mais pessoas que desistem do que  
pessoas que fracassam." (Henry Ford)*

---

## RESUMO

O aplainamento é um processo de usinagem muito utilizado para retirada de material e obtenção de boa qualidade de superfícies de madeiras. Esse processo está fortemente presente em indústrias do setor moveleiro, em que se utiliza o aplainamento para adequar as medidas do produto pela retirada de material e melhorar a qualidade visual, aumentando assim o valor agregado do produto final. Para avaliar esse processo de usinagem, é importante utilizar-se de métodos de planejamento de experimentos, modelagem robusta e otimização multi-objetivo para assim obter os melhores resultados possíveis em diferentes respostas. O presente trabalho apresenta a otimização robusta multi-objetivo do aplainamento da madeira *Pinus taeda*. Os experimentos foram conduzidos baseado em no planejamento composto central combinando variáveis de controle de velocidade de corte, velocidade de avanço e profundidade de penetração e a variável de ruído definida como o percentual da umidade presente na madeira. Foram aplicados a metodologia de superfície de resposta, juntamente com o projeto de parâmetro robusto, análise de componentes principais, a otimização do erro quadrático médio e o método da restrição normal normalizado. Foram discutidos os efeitos de cada variável de controle e de ruído e suas interações. As respostas analisadas foram de corrente elétrica, tensão, torque, potência mecânica, energia consumida, energia específica de corte e espessura média dos cavacos não deformados. A otimização multi-objetivo foi realizada pela ponderação entre os componentes principais identificados. Foram obtidos modelos de média e variância para cada resposta e para o componente principal ponderado. Foram elaboradas fronteiras de Pareto para todas as respostas. Ensaios de confirmação foram realizados com o objetivo de verificar a robustez das respostas. Foi concluído que o ponto ótimo global para o aplainamento que minimiza o efeito da umidade da madeira é obtido utilizando os parâmetros de  $11,25 \text{ m}\times\text{s}^{-1}$  para velocidade de corte,  $3,65 \text{ m}\times\text{min}^{-1}$  para velocidade de avanço e  $0,95 \text{ mm}$  para profundidade de penetração.

**Palavras-Chaves:** Aplainamento, *Pinus taeda*, metodologia de superfície de resposta, projeto de parâmetro robusto, método da restrição normal normalizado.



---

## ABSTRACT

The planing is a machining process widely used for material removal and obtaining good quality of wood surfaces. This process is strongly present in industries in the furniture industry, where the planing is used to adjust product measurements by removing material and improving visual quality, thus increasing the value added of the final product. To evaluate this machining process, it is important to use experimental designs methods, robust modeling and multi-objective optimization to obtain the best possible results in different responses. The present work presents the robust multi-objective optimization of the planing of *Pinus taeda* wood. The experiments were conducted based on the central composite design combining variables of control of cutting speed, feed rate and depth of penetration and the noise variable defined as the percentage of moisture present in the wood. Response surface methodology was applied along with the robust parameter design, principal component analysis, the mean squared error optimization, and the normalized normal constraint. The effects of each control and noise variable and their interactions were discussed. The analyzed responses were of electric current, voltage, torque, mechanical power, energy consumed, specific cutting energy and mean thickness of the undeformed chips. The multi-objective optimization was performed by weighting the identified principal components. Mean and variance models were obtained for each response and for the weighted principal component. Pareto frontiers were constructed for all responses. Confirmation tests were performed with the purpose of verifying the robustness of the responses. It was concluded that the optimum global point for planing that minimizes the effect of wood moisture is obtained using the parameters of  $11.25 \text{ m}\times\text{s}^{-1}$  for cutting speed,  $3.65 \text{ m}\times\text{min}^{-1}$  for feed rate and  $0.95 \text{ mm}$  for depth of penetration.

**Keywords:** Planing wood, *Taeda Pinus*, response surface methodology, robust parameter design, normal normalized constraint method.

---

## LISTA DE FIGURAS

Figura 2.1 - Família de corte (MCKENZIE, 1960) .....	7
Figura 2.2 - Ângulos básicos de usinagem da madeira .....	9
Figura 2.3 - Fatores da matéria-prima na usinagem da madeira (NASIR e COOL, 2018) .....	11
Figura 2.4 - Usinagem da madeira (a) contra a direção das fibras, (b) perpendicular a direção das fibras, (c) ao longo da direção das fibras, e (d) paralelo a direção das fibras (PORANKIEWICZ, 2014) .....	12
Figura 2.5 – Usinagem por (a) plaina desempenadeira e (b) fresa .....	13
Figura 2.6 - Posição da faca fixa no (a) corte ortogonal e (b) corte oblíquo .....	13
Figura 2.7 - Visão superior do aplainamento .....	14
Figura 2.8 - Visão lateral do aplainamento .....	14
Figura 2.9 - Planejamento de experimentos (a) $2^2$ (b) $2^3$ (c) $2^4$ .....	20
Figura 2.10 - Gráfico de efeito principal .....	21
Figura 2.11 - Gráficos de interação em que (a) não significativo e (b) significativo .....	22
Figura 2.12 - Arranjo Composto Central (a) 2 fatores e (b) 3 fatores .....	23
Figura 2.13 - Modelo geral de um processo (MONTGOMERY, 2017) .....	25
Figura 2.14 - Método da Interseção Normal à Fronteira (NBI) com unidades originais .....	30
Figura 2.15 - Método da Interseção Normal à Fronteira (NBI) normalizado.....	31
Figura 2.16 - NNC para problema bi-objetivo .....	34
Figura 2.17 - Comparativo entre processos (a) sem acurácia e sem precisão, (b) sem acurácia mas com precisão, (c) com acurácia mas sem precisão e (d) com acurácia e precisão .....	35
Figura 3.1 - (i) duto do exaustores, (ii) ajuste de altura do carrinho de avanço, (iii) liga-desliga do motor de avanço, (iv) carrinho de avanço, (v) motor, (vi) cabeçote das facas de corte, (vii) liga-desliga e ajuste do rpm do motor, (viii) ajuste da rotação do motor do cabeçote das facas de corte e (ix) mesa suporte .....	44
Figura 3.2 - Sequência de atividades de setup do processo de aplainamento da madeira.....	45
Figura 3.3 - Relação entre respostas do processo e objetivos .....	46
Figura 4.1 - Gráfico de Pareto para corrente .....	52
Figura 4.2 - Gráfico de efeitos lineares e quadráticos para corrente .....	52
Figura 4.3 - Gráfico de interação para corrente.....	53

Figura 4.4 - Superfície de resposta para corrente, $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	55
Figura 4.5 - Fronteira de Pareto para $E[C] \times Var[C]$ .....	57
Figura 4.6 - Superfícies de resposta para $MSE_C$ , $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	59
Figura 4.7 - Gráfico de Pareto para Tensão .....	60
Figura 4.8 - Função U no espaço experimental codificado, $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	62
Figura 4.9 - Gráfico de Pareto para torque .....	63
Figura 4.10 - Gráfico de efeitos lineares e quadráticos para torque .....	63
Figura 4.11 - Gráfico de interação para torque .....	64
Figura 4.12 - Superfície de resposta para corrente, $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	66
Figura 4.13 - Fronteira de Pareto para $E[M] \times Var[M]$ .....	68
Figura 4.14 - Superfícies de resposta para $MSE_M$ , $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	70
Figura 4.15 - Gráfico de Pareto para potência mecânica .....	71
Figura 4.16 - Gráfico de efeitos lineares e quadráticos para potência mecânica .....	71
Figura 4.17 - Gráfico de interação para potência mecânica .....	72
Figura 4.18 - Superfície de resposta para potência mecânica, $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	75
Figura 4.19 - Superfícies de resposta para $MSE_P$ , $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	76
Figura 4.20 - Gráfico de Pareto para energia .....	77
Figura 4.21 - Gráfico de efeitos lineares e quadráticos para energia .....	78
Figura 4.22 - Gráfico de interação para energia .....	78
Figura 4.23 - Superfície de resposta para energia, $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	81
Figura 4.24 - Fronteira de Pareto para $E[W] \times Var[W]$ .....	82
Figura 4.25 - Superfícies de resposta para $MSE_W$ , $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	84
Figura 4.26 - Gráfico de Pareto para energia específica de corte .....	85
Figura 4.27 - Gráfico de efeitos lineares e quadráticos para $E_s$ .....	85
Figura 4.28 - Gráfico de interação para energia específica de corte .....	86
Figura 4.29 - Superfície de resposta para energia específica de corte, $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	88
Figura 4.30 - Fronteira de Pareto para $E[E_s] \times Var[E_s]$ .....	90
Figura 4.31 - Superfícies de resposta para $MSE_{E_s}$ , $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	92

Figura 4.32 - Função $h_m$ no espaço experimental codificado, $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	93
Figura 4.33 - Dendograma de Ward para $C, U, M, P, W, E_s$ e $h_m$ .....	97
Figura 4.34 - Gráfico de Pareto para WPC.....	99
Figura 4.35 - Gráfico de efeitos lineares e quadráticos para WPC.....	99
Figura 4.36 - Gráfico de interação para WPC .....	100
Figura 4.37 - Superfície de resposta para energia específica de corte, $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	102
Figura 4.38 - Fronteira de Pareto para $E[WPC] \times Var[WPC]$ .....	104
Figura 4.39 - Superfícies de resposta para $MSE_{WPC}$ , $\mathbf{x}_{fixo} = \mathbf{x}_{CtPt}$ .....	106
Figura 4.40 - Curva do poder do teste para WPC.....	107
Figura 4.41 - Teste de variâncias para $C$ .....	108
Figura 4.42 - Teste de variâncias para $U$ .....	109
Figura 4.43 - Teste de variâncias para $M$ .....	109
Figura 4.44 - Teste de variâncias para $P$ .....	110
Figura 4.45 - Teste de variâncias para $W$ .....	110
Figura 4.46 - Teste de variâncias para $E_s$ .....	111
Figura 4.47 - Teste de médias para $C$ .....	112
Figura 4.48 - Teste de médias para $U$ .....	112
Figura 4.49 - Teste de médias para $M$ .....	113
Figura 4.50 - Teste de médias para $P$ .....	113
Figura 4.51 - Teste de médias para $W$ .....	114
Figura 4.52 - Teste de médias para $E_s$ .....	114

---

## LISTA DE TABELAS

Tabela 2.1 - Ordem padrão do planejamento fatorial $2^k$ .....	21
Tabela 2.2 - Ordem padrão do Arranjo Composto Central .....	24
Tabela 2.3 - Arranjo CCD combinado (PEREIRA, 2017) .....	26
Tabela 3.1 - Variáveis de controle e ruído com seus respectivos níveis .....	47
Tabela 4.1 - Planejamento experimental com respostas.....	49
Tabela 4.2 - ANOVA para corrente.....	54
Tabela 4.3 - Matriz <i>pay-off</i> para $E[C] \times Var[C]$ .....	56
Tabela 4.4 - Resultados da otimização entre $E[C]$ e $Var[C]$ pelo método NNC.....	58
Tabela 4.5 - Otimização de $MSE_C$ .....	59
Tabela 4.6 - ANOVA para tensão .....	61
Tabela 4.7 - ANOVA para torque .....	65
Tabela 4.8 - Matriz <i>pay-off</i> para $E[M] \times Var[M]$ .....	67
Tabela 4.9 - Resultados da otimização entre $E[M]$ e $Var[M]$ pelo método NNC.....	69
Tabela 4.10 - Otimização de $MSE_M$ .....	70
Tabela 4.11 - ANOVA para potência mecânica .....	73
Tabela 4.12 - Matriz <i>pay-off</i> para $E[P] \times Var[P]$ .....	76
Tabela 4.13 - Otimização de $MSE_P$ .....	77
Tabela 4.14 - ANOVA para energia.....	80
Tabela 4.15 - Matriz <i>pay-off</i> para $E[W] \times Var[W]$ .....	82
Tabela 4.16 - Resultados da otimização de $W$ pelo método NNC.....	83
Tabela 4.17 - Otimização de $MSE_W$ .....	84
Tabela 4.18 - ANOVA para energia específica de corte .....	87
Tabela 4.19 - Matriz <i>pay-off</i> para $E[E_s] \times Var[E_s]$ .....	89
Tabela 4.20 - Resultados da otimização de $E_s$ pelo método NNC .....	91
Tabela 4.21 - Otimização de $MSE_{E_s}$ .....	92
Tabela 4.22 - Otimização de $h_m$ .....	94
Tabela 4.23 - Matriz de correlação.....	95

Tabela 4.24 - Valores das componentes principais .....	96
Tabela 4.25 - Análise dos valores de PC's.....	96
Tabela 4.26 - Análise vetorial de cada resposta para cada PC .....	97
Tabela 4.27 - Valores de PC's e WPC para o processo de aplainamento .....	98
Tabela 4.28 - ANOVA para WPC .....	101
Tabela 4.29 - Matriz <i>pay-off</i> para $E[WPC] \times Var[WPC]$ .....	103
Tabela 4.30 - Resultados da otimização de WPC pelo método NNC .....	105
Tabela 4.31 - Otimização de $MSE_{WPC}$ .....	106
Tabela 4.32 - Experimentos de confirmação .....	107
Tabela 4.33 - Significância das variáveis de ruído pela ANOVA.....	115

---

## LISTA DE ABREVIATURAS E SIGLAS

ANOVA	<i>analysis of variance</i> - análise de variância
CCD	<i>central composite design</i> - arranjo composto central
DOE	<i>design of experiments</i> - planejamento de experimentos
GRG	<i>generalized reduced gradient</i> - gradiente reduzido generalizado
MOOP	<i>multi-objective optimization problem</i> - problema de otimização multi-objetivo
MRR	<i>material removal rate</i> - taxa de remoção de material
MSE	<i>mean square error</i> - erro quadrático médio
NBI	<i>normal boundary intersection</i> - interseção normal à fronteira
NNC	<i>normalized normal constraint</i> - método da restrição normal normalizado
PC	<i>principal component</i> - componente principal
PCA	<i>principal component analysis</i> - análise de componentes principais
PSF	ponto de saturação das fibras
RPD	robust parameter design - projeto de parâmetro robusto
RSM	response surface methodology - metodologia de superfície de resposta
OLS	<i>ordinary least squares</i> - mínimos quadrados ordinários
RSM	<i>response surface methodology</i> - metodologia de superfície de resposta
UFLA	Universidade Federal de Lavras
UNIFEI	Universidade Federal de Itajubá
WMSE	<i>weighted mean square error</i> - erro quadrático médio ponderado
WLS	<i>weighted least squares</i> - mínimos quadrados ponderados

---

## LISTA DE SÍMBOLOS

### **Símbolos de processo de aplainamento:**

$v_c$  - velocidade de corte em  $[m \times s^{-1}]$

$v_f$  - velocidade de avanço  $[m \times \text{min}^{-1}]$

$a_e$  - profundidade de penetração [mm]

$a_p$  - profundidade de corte [mm]

$c$  - comprimento da peça usinada [m]

$u$  - umidade da madeira

$f_z$  - avanço por dente [mm]

$Z$  - número de facas

$\gamma$  - ângulo de ataque

$\alpha$  - ângulo de folga

$\beta$  - ângulo de ferramenta

$D$  - diâmetro do cabeçote [mm]

$n$  - rotação do motor [rpm]

$C$  - corrente [A]

$U$  - tensão [V]

$M$  - torque  $[N \times m]$

$P$  - potência [kW]

$W$  - energia [kJ]

$E_s$  - energia específica de corte  $[kJ \times \text{mm}^{-3}]$

$h_m$  - espessura média dos cavacos não deformados [mm]

$t$  - tempo de usinagem [min]

$MRR$  - taxa de remoção de material  $[m^3 \times \text{seg}^{-1}]$

### **Símbolos de Superfície de resposta**

$y$  - resposta

$x_1, x_2, \dots, x_k$  - variáveis de controle

$k$  - número de variáveis de controle

$f$  - função de resposta



$\varepsilon$  - erro experimental

$\sigma^2$  - variância

$y$  - aproximação do modelo de superfície de resposta

$\beta$  - coeficiente de regressão

$\mathbf{X}$  - matriz das variáveis de controle

$\boldsymbol{\beta}$  - vetor do coeficiente de regressão

$\boldsymbol{\varepsilon}$  - vetor de erro experimental

$e$  - resíduo

$S$  - desvio padrão experimental

$R^2$  - coeficiente de determinação

$R_{adj}^2$  - coeficiente de determinação ajustado

$R_{pred}^2$  - coeficiente de determinação para a previsão

$\alpha$  - nível de significância

$n$  - número de corridas experimentais

$\rho$  - distância entre um ponto central e um ponto axial em um arranjo CCD

$n_f$  - número de pontos fatoriais

$n_a$  - número de pontos axiais

$n_c$  - número de pontos centrais

$\hat{\beta}$  - estimativa do coeficiente de regressão

$\mathbf{b}$  - vetor com as estimativas dos coeficientes dos termos lineares

$\mathbf{x}$  - vetor com as variáveis de controle

$\mathbf{B}$  - matriz dos termos quadráticos e das interações de segunda ordem

$x_0$  - ponto estacionário

$\lambda_1, \lambda_2, \dots, \lambda_k$  - autovalores da matriz  $\mathbf{B}$

$\mathbf{I}$  - matriz identidade

$GL$  - graus de liberdade

$SQ$  - soma dos quadrados

$QM$  - quadrado médio

$PRESS$  - *prediction error sum of squares*

### **Símbolos do RPD e MSE**

$z_1, z_2, \dots, z_q$  - variáveis de ruído

$r$  - número de variáveis de ruído

$MSE$  - erro quadrático médio

$T$  - alvo

$\mathbf{Z}$  - matriz das variáveis de ruído

$\mathbf{W}^*$  - matriz de pesos da regressão por WLS

$\gamma$  - vetor de coeficientes lineares para variáveis de ruído

$\Delta$  - matriz de coeficientes de interação processo  $\times$  ruído

### **Símbolos de análise de componentes principais**

$\Sigma$  - matriz de covariâncias

$\mathbf{P}$  - matriz de autovetores de  $\Sigma$

$\Lambda$  - matriz de autovalores de  $\Sigma$

### **Símbolos de otimização multi-objetivo / NNC**

$f$  - vetor de funções objetivos

$\bar{f}$  - vetor de funções objetivo normalizadas

$f_1^*, \dots, f_m^*$  - funções objetivo

$f^U$  - ponto de utopia

$f^N$  - ponto de nadir

$f^{PN}$  - ponto de pseudo-nadir

$m$  - número de funções objetivos

$\bar{N}_r$  - vetor linha de utopia

$n_{sub}$  - número de subproblemas

$\mathbf{T}$  - matriz para transformação linear da *pay-off*

$w_{ij}$  - peso

$\bar{Q}_{ij}$  - ponto por hiperplano de utopia

$\mathbf{w}$  - vetor peso

$\delta_r$  - incremento normalizado

$\Phi$  - matriz *pay-off*

$\bar{\Phi}$  - matriz *pay-off* normalizada

---

# SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>1</b>
1.1 Justificativa .....	4
1.2 Objetivos .....	5
1.2.1 Objetivo geral.....	5
1.2.2 Objetivo específico .....	5
1.3 Classificação da pesquisa científica.....	6
1.4 Delimitações do estudo .....	6
<b>2. FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>7</b>
2.1 Usinagem da madeira.....	7
2.1.1 Fatores que influenciam no corte da madeira .....	8
2.1.1.1 Equipamento e ferramenta .....	9
2.1.1.2 Matéria-prima .....	10
2.1.2 Aplainamento.....	12
2.1.3 Energia e potência.....	16
2.1.3.1 Energia específica de corte (Es).....	16
2.2 Planejamento de experimentos .....	18
2.2.1 Metodologia de superfície de resposta.....	18
2.2.2 Projeto de parâmetro robusto .....	24
2.3 Otimização robusta multi-objetivo .....	28
2.3.1 Interseção Normal à Fronteira .....	29
2.3.2 Método da Restrição Normal Normalizada .....	32
2.4 Erro quadrático médio.....	35
2.5 Análise de componentes principais.....	36
2.5.1 Definição e classificação dos componentes principais .....	37
<b>3. PROCEDIMENTO EXPERIMENTAL .....</b>	<b>44</b>
3.1 Plaina desempenadeira.....	44
3.2 Respostas avaliadas, variáveis de controle e de ruído .....	45
3.3 Planejamento experimental.....	47
<b>4. RESULTADOS E DISCUSSÃO .....</b>	<b>49</b>
4.1 Corrente utilizada no aplainamento da madeira <i>Pinus taeda</i> .....	51

4.2	Tensão utilizada para o aplainamento da madeira <i>Pinus taeda</i> .....	59
4.3	Torque utilizado para o aplainamento da madeira <i>Pinus taeda</i> .....	62
4.4	Potência mecânica utilizado para o aplainamento da madeira <i>Pinus taeda</i> .....	70
4.5	Energia utilizada para o aplainamento da madeira <i>Pinus taeda</i> .....	77
4.6	Energia específica de corte utilizada para o aplainamento da madeira <i>Pinus taeda</i> 84	
4.7	Espessura média dos cavacos não deformados para o aplainamento da madeira <i>Pinus taeda</i>	92
4.8	Otimização multi-objetivo do processo de aplainamento da madeira <i>Pinus taeda</i> 94	
4.8.1	Análise de correlação entre as respostas do processo .....	94
4.8.2	Otimização dos componentes principais ponderados .....	98
4.9	Experimentos de confirmação.....	106
<b>5.</b>	<b>CONCLUSÕES.....</b>	<b>116</b>
5.1	Contribuições do trabalho .....	117
5.2	Sugestão para trabalhos futuros .....	118
<b>6.</b>	<b>REFERÊNCIAS .....</b>	<b>120</b>
<b>7.</b>	<b>APENDECES .....</b>	<b>123</b>
	Apêndice A. Artigos aprovados para publicação em periódicos .....	123
	Apêndice B. Artigos publicados em anais de congressos .....	124

# 1. INTRODUÇÃO

A madeira é uma matéria-prima utilizada em diferentes seguimentos, pode ser encontrada em produção de móveis, materiais, processamento químico e até mesmo como um dos principais componentes na construção civil (BENDIKIENE e KETURAKIS, 2017; KAPLAN *et al.*, 2018).

No processamento de madeiras, diferentes tipos de equipamentos e processos são necessários, em que o processo de fresamento é uma das etapas de usinagem mais utilizadas e difundidas (BENDIKIENE e KETURAKIS, 2017). Dentre os tipos de fresamento, o processo de aplainamento periférico é um dos mais aplicado (GURLEYEN e BUDAKC, 2015; UGULINO e HERNÁNDEZ, 2017).

Há busca constante para o uso eficiente da madeira evitando seu desperdício, visto que se trata de um recurso natural. Desse modo, estudos são realizados com o objetivo de reduzir perdas, a partir do desenvolvimento de novos equipamentos e métodos de processos (GURLEYEN, 2010).

Durante a usinagem da madeira, parâmetros da máquina podem alterar a força de corte, o que conseqüentemente altera a energia consumida durante o processo (AGUILERA e MARTIN, 2001). Assim a determinação de valores ótimos dos parâmetros de máquina se torna o grande desafio para reduzir o custo final da produção, sendo o grande interesse das indústrias madeireiras, visto que esse tipo de operação também é complexo, demorado e trabalhoso (TIRYAKI *et al.*, 2017).

O fresamento da madeira tem dependência direta do consumo de energia elétrica, o que torna a energia elétrica o insumo o mais utilizado e, conseqüentemente, o de maior custo dentre os presentes nesse processo (BARCÍK *et al.*, 2010), com isso muitos trabalhos buscam otimizar e melhorar o fresamento aumentando a produtividade e processos de corte mais econômicos a partir da redução de todos os custos de máquina (DARMAWAN *et al.*, 2011).

A otimização dos mecanismos de corte em processos de usinagem é considerada uma tarefa difícil (KOVÁČ e MIKLEŠ, 2011), uma vez que a espécie da madeira, direção de corte, umidade, temperatura, geometria do dente de corte, dureza do dente, entre outros fatores, são de grande representatividade na força necessária de corte (ORLOWSKI *et al.*, 2017).

Vobrouček (2015) demonstra o desvio das empresas em garantir a alta produtividade nos processos de usinagem da madeira e simultaneamente reduzir seus custos de equipamento. Thibaut *et al.* (2016) destaca que para aumentar a produtividade e reduzir os custos de equipamento, muitos trabalhos acadêmicos e industriais são desenvolvidos abordando melhorias para usinagem da madeira, algumas vezes utilizando de técnicas, métodos e inovações abordadas em usinagem de outros materiais.

Experimentos são frequentemente utilizados para entender como sistemas e processos funcionam em diversas áreas científica e de engenharia. O planejamento prévio tem papel fundamental na condução dos experimentos para obtenção de melhor desempenho de processos, uma vez que a forma com que os experimentos são conduzidos tem papel fundamental nos resultados obtidos (MONTGOMERY e RUNGER, 2013).

Os métodos tradicionais de experimentos são realizados alterando uma variável por corrida experimental. Porém esses métodos exigem muito tempo e alto consumo de recursos e conseqüentemente alto custo (AMIRI *et al.*, 2019). Já os métodos de planejamento de experimentos (do inglês, *Design of Experiments* - DoE) visam em seus arranjos alterar mais de uma variável por corrida experimental, reduzindo assim a quantidade necessária de experimentos a serem realizados, tornando a análise mais precisa, rápida e com menor custo (MONTGOMERY, 2017).

Muitas análises experimentais de produtos e processos envolvem grande número de variáveis que podem ou não influenciar nas respostas finais. Para esses casos é utilizado a metodologia de superfície de resposta (do inglês, *Response Surface Methodology* - RSM) que busca subdividir o processo experimental em fases, visando identificar as variáveis significativas, reduzindo o número de variáveis experimentais e posteriormente determinando o ponto ótimo, sendo fundamental para o entendimento de diferentes processos industriais (MYERS *et al.*, 2016).

Muitos sistemas, podendo ser produto ou processo, contem fatores que não são possíveis de serem controlados (ruídos) durante a produção ou uso do produto e resultam na variabilidade considerável nos resultados (MONTGOMERY, 2017). Esses fatores em geral são causados por condições ambientais, propriedade das matérias-primas e envelhecimento do produto ou por limitações e restrições do processo ou produto. Para minimizar os efeitos gerados pelas variáveis de ruído, o projeto de parâmetro robusto (do inglês, *Robust Parameter Design* - RPD) é uma alternativa possível de ser aplicada, visando reduzir a variabilidade do processo (MYERS *et al.*, 2016).

A umidade da madeira é um dos principais fatores responsáveis pela variabilidade de diversas respostas do aplainamento como qualidade e produtividade (NASIR E COOL, 2018). A madeira antes de ser usinada é posta a um processo de secagem, porém o armazenamento da madeira em diferentes locais com diferentes climas após sua secagem faz com que a umidade presente em suas fibras oscile, afetando os resultados durante a usinagem.

A maioria dos processos de manufatura apresentam mais de uma característica de interesse em que devem ser otimizadas. Porém tais interesse são em sua maioria conflitantes. Com isso, pesquisas em relação a otimização de problemas multi-objetivos (do inglês, *multi-objective optimization problems* - MOPs) tem-se ampliado, uma vez que métodos tradicionais de único objetivo não são suficientes para otimizar vários objetivos conflitantes (MIETTINEN, 1998). Não há como obter os valores ótimos para todas as características de desempenho, mas sim o conjunto de soluções denominado de soluções ótimas de Pareto, em que se melhora uma das funções objetivos e pelo menos uma das demais funções apresentam pioras (HOSSEINI *et al.*, 2016).

Não diferentemente, o processo de usinagem da madeira possui interesses distintos que podem ser conflitantes. Muitos trabalhos são desenvolvidos destacando alguns desses interesses e determinando melhores parâmetros que otimizem o processo como desenvolvidos por Griebeler *et al.* (2018) e Ramanantoandro *et al.* (2018) para qualidade superficial do produto, Kubš *et al.* (2016), Sedlecký e Gašparík (2017) e Sedlecký *et al.* (2019) para consumo de energia, Moradpour *et al.* (2013) e Podziewski *et al.* (2018) para forças de corte, Ratnasingam (1999) para custos de produção.

A otimização das respostas que possuem como característica a qualidade do produto, produtividade, sustentabilidade e custo para o aplainamento da madeira *Pinus taeda* visa ampliar a competitividade desse processo. Para isso, foi realizado a otimização de múltiplas respostas buscando identificar um valor e parâmetros ótimo global. Também foi realizado a otimização individual de cada resposta, assim podendo representar o aplainamento em diferentes cenários de produção.

Para a otimização multi-objetivo foi utilizado a análise de componentes principais (do inglês, *principal component analysis* - PCA) para reduzir o número de respostas analisadas e eliminar a correlação existente entre elas, uma vez que as variáveis latentes não apresentam correlação.

A otimização de duas funções objetivos foi realizada pelo método da Restrição Normal Normalizada (do inglês, *Normalized Normal Constraint* - NNC) a fim de garantir a boa exploração da fronteira de Pareto.

O presente trabalho visa responder as perguntas: Quais os parâmetros ideais para cada resposta do aplainamento da madeira *Pinus taeda*? E quais os parâmetros que otimize todas as respostas? É possível minimizar a variação causada pela umidade da madeira?

## 1.1 Justificativa

A utilização de técnicas não triviais de planejamentos experimentais é fundamental para obter valores ideais de qualidade, produtividade e sustentabilidade de processo (COSTA *et al.*, 2016). Objetivos como produtividade, qualidade e consumo específico de energia da máquina para atingirem valores ótimos levam a resultados contraditórios de forma que tais objetivos devem ser equilibrados atingindo um resultado satisfatório para todos (YAN e LI, 2013).

Com o intuito de obter processos sustentáveis, o projeto de parâmetros robusto é aplicado a partir de técnicas e ferramentas de engenharia que visam minimizar fatores incontroláveis do processo (GREMYR *et al.*, 2014). Como na usinagem pode possuir fatores incontroláveis relativos a matéria-prima, projeto do produto, condições ambientais, entre outros, o projeto de parâmetros robusto é aplicado na usinagem de diversos materiais para otimização de consumo de energia, produtividade e qualidade como encontrado em furação (YAN e LI, 2013), fresamento de extremidade (BRITO *et al.*, 2014), fresamento de topo (BRITO *et al.*, 2015), torneamento (ROCHA *et al.*, 2016), furação helicoidal (PEREIRA *et al.*, 2017), entre outros. Com a aplicação do projeto de parâmetros robusto o processo se torna menos sensível a variação das variáveis incontroláveis, obtendo assim resultados de processo mais consistentes.

Algumas das técnicas de projeto de parâmetros robusto também são utilizadas na usinagem da madeira como apresentado por Sutcu (2013), Tiryaki *et al.* (2015) e Sofuoglu (2017). Apesar de alguns trabalhos utilizarem do projeto de parâmetros robusto em usinagem da madeira, nenhum deles buscam minimizar o efeito gerado pela umidade no corpo usinado, que por sua vez é uma variável difícil de ser controlada durante a usinagem e de grande influência nos resultados. Dos trabalhos que aplicam os métodos



de parâmetros robustos, nenhum utiliza a metodologia de superfície de resposta (RSM) para o desenvolvimento da otimização do processo de usinagem da madeira.

Outra lacuna existente nos estudos de usinagem da madeira é analisar e consideração da correlação existente entre as respostas envolvendo produtividade, sustentabilidade e custo. Chiao e Hamada (2001) e Paiva *et al.* (2007) destacam que a não consideração da correlação entre as respostas pode levar a valores que não são ótimos para o processo, chegando a conclusões insatisfatória quando analisados de forma multivariada.

Apesar do aplainamento ser muito utilizado no setor industrial não foi encontrado, até o presente trabalho, estudos que se utilizem de métodos de planejamento experimental e otimização multi-objetivo robusto para esse processo.

A madeira *Pinus taeda*, juntamente com as de espécies de *Eucaliptus*, faz parte de um grupo de madeiras de com características de rápido plantio e crescimento, sendo denominadas de árvores de ciclo curto. Assim sua utilização é abrangente na indústria, principalmente moveleira (GONÇALVES e NÉRI, 2005). Devido a isso, estudos de otimização de processo de usinagem dessas espécies de madeiras faz-se necessário.

## **1.2 Objetivos**

### **1.2.1 Objetivo geral**

Essa dissertação tem como objetivo geral de realizar a otimização multi-objetivo robusta do processo de aplainamento da madeira *Pinus taeda* tornando o processo mais sustentável, econômico e produtivo.

### **1.2.2 Objetivo específico**

O objetivo geral se desdobra nos seguintes objetivos específicos:

- Identificar quais as variáveis de controle e de ruído e suas interações que possuem efeitos significativos sobre o aplainamento da madeira;
- Modelar as variáveis de corrente, tensão, torque, potência mecânica, energia consumida, energia específica de corte e espessura média dos cavacos para o processo de aplainamento da madeira *Pinus taeda*;

- Identificar a região ótima que minimiza os efeitos gerado pela variável de ruído para cada resposta em que o mesmo foi significativo;
- Propor valores para as variáveis de controle que otimizem o aplainamento;
- Confrontar os modelos matemáticos e resultados obtidos com o processo real por meio dos experimentos de confirmação.

### **1.3 Classificação da pesquisa científica**

Esta dissertação se classifica como de natureza aplicada, uma vez que o estudo é aplicado em problemas reais presente em indústrias e laboratórios. Classifica seu objetivo como explicativa, visto que se busca analisar os efeitos causados pelas variáveis do processo com o intuito de explicar os fenômenos ocorridos. Possui abordagem quantitativa, uma vez que o estudo é baseado em números gerados por métodos estatísticos.

Quanto ao método é caracterizado como experimental, pois procura-se explicar os fenômenos ocorridos em um processo através de métodos experimentais (MARTINS *et al.*, 2014).

### **1.4 Delimitações do estudo**

Os resultados dessa pesquisa estão delimitados a modelagem e otimização do processo de aplainamento da madeira *Pinus taeda* minimizando o efeito da umidade presente no corpo usinado. Outras delimitações dos resultados são:

- Foram considerados as respostas de energia específica de corte, média dos cavacos não deformados, taxa de remoção de material, torque e corrente.
- Os experimentos foram conduzidos segundo ao RPD juntamente com RSM com arranjo CCD combinado visando o menor número possível de experimentos com maior confiabilidade, garantindo assim economia de processo e matéria-prima.
- Apenas o PCA foi empregado para reduzir o número de respostas utilizadas no processo de otimização e eliminar o efeito de correlação existente entre elas.
- Para a otimização individual das respostas, os métodos de NBI foi utilizado para determinar a região ótima e o MSE para identificar o melhor ponto presente dentro da região ótima.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1 Usinagem da madeira

A usinagem da madeira teve seu desenvolvimento juntamente com os avanços do setor metalúrgico e de energia (KISSER *et al.*, 1967) e vem se tornando um processo bastante utilizado, uma vez que sua matéria-prima pode ser renovável, além de apresentar considerável resistência mecânica e se esteticamente agradável (KUBŠ, 2016).

A madeira é dividida em três planos denominados de transversal, longitudinal radial e longitudinal tangencial. Cada plano da madeira é composto pela associação de dois eixos. O plano transversal é composto pelos eixos radial e tangencial, o plano longitudinal radial é composto pelos eixos radial e longitudinal (axial) e o plano longitudinal tangencial é composto pelos eixos tangencial e longitudinal (axial) (ZOBEL e BUIJTENEN, 2012).

O primeiro ângulo é determinado entre a aresta de corte da ferramenta com o eixo axial das fibras da madeira. O segundo ângulo é determinado entre a direção de corte e o eixo axial das fibras da madeira. Desse modo obtém-se famílias denominadas de 90-0, 90-90 e 0-90 (MCKENZIE, 1960). A Figura 2.1 representa as três famílias de corte ortogonal.




Figura 2.1 - Família de corte (MCKENZIE, 1960)

Na família 90-90 a aresta de corte e o movimento da ferramenta são perpendiculares à direção das fibras. Na família 0-90 a aresta de corte é paralela a direção das fibras, porém o movimento da ferramenta é perpendicular. Na família 90-0 a aresta de corte é perpendicular a direção das fibras, porém o movimento da ferramenta é paralelo (MCKENZIE, 1960).

No processo de usinagem da madeira existem dois tipos de corte, o ortogonal e o periférico, em que ambos possuem características próximas. A principal diferença entre eles é que no corte periférico o processo de usinagem as ferramentas de corte são inseridas na periferia do cabeçote rotativo. Processos de aplainamento e torneamento são tipos de corte periférico (NERI, 2003).

### **2.1.1 Fatores que influenciam no corte da madeira**

De acordo com Bonduelle *et al.* (2002) o sistema de tecnologia da usinagem da madeira consiste nas seguintes características:

- Matéria-prima: tipo de madeira, umidade, densidade, dureza, temperatura, dimensões da peça, entre outros;
- Máquina: ângulo de corte, número de dentes, propriedades do material da ferramenta de corte, comprimento capaz de corte, entre outros;
- Metodologia: velocidade de corte, velocidade de avanço, ângulo de corte, espessura de corte, desempenho de motores, entre outros;
- Mão de obra: habilidade do operador, nível de treinamento, conhecimento sobre o equipamento, entre outros;
- Meio ambiente: condições ambientais de processamento, quantidade de resíduo gerado, degradações, entre outros.

Para cada grupo de característica, existem fatores que influenciam o resultado esperado do processo de usinagem da madeira. Valores corretamente utilizados desses fatores permitem que o processo de usinagem se torne eficiente e preciso, em que a eficiência do processo pode ser mensurada pelo baixo custo e alto rendimento (PORANKIEWICZ, 2014).

Os efeitos ocorridos no processo de usinagem devido fatores de equipamento e da madeira são importantes para determinação dos custos de produtos (PINKOWSKI *et al.* 2018).

### 2.1.1.1 Equipamento e ferramenta

A ferramenta de corte é um dos principais fatores responsáveis das forças de corte. Alguns estudos como a escolha do tipo de corte entre oblíquo e ortogonal (MOURA e HERNÁNDEZ, 2007) e variação da angulação da aresta principal de corte (KIVIMAA, 1950; JIN e CAI, 1996; UGULINO e HERNÁNDEZ, 2017) demonstram a oscilação das forças de corte quando esses parâmetros são alterados.

A geometria do cavaco permite tirar muitas conclusões do processo de usinagem, em que cada geometria pode variar principalmente a qualidade da peça usinada (RATNASINGAM *et al.*, 1999). A angulação da aresta de corte e a profundidade de penetração são principais fatores responsáveis pelas diferentes geometrias de cavaco (JIN e CAI, 1997).

Woodson e Koch (1970) destaca que os três ângulos básicos de usinagem interferem diretamente os resultados do processo de usinagem. O ângulo de ataque ( $\gamma$ ) tem relação direta com a força de corte, em que o aumento do ângulo de ataque resulta na queda das forças de corte. O ângulo de folga ( $\alpha$ ) é responsável pelo contato da superfície de folga da ferramenta com a peça usinada. O ângulo de cunha ou dente ( $\beta$ ) possui relação com a resistência da ferramenta de corte. A Figura 2.2 representa o processo de usinagem da madeira com os ângulos de cunha.




Figura 2.2 - Ângulos básicos de usinagem da madeira

A profundidade de corte, velocidade de corte e velocidade de avanço são fatores bastante explorados em processos de usinagem. A profundidade de corte tem efeito direto

com o torque do equipamento, quanto maior a penetração maior será o torque para que o processo ocorra. O aumento da velocidade de corte também resulta no aumento do torque do equipamento, reduzindo assim o avanço por dente, resultando em um menor comprimento do cavaco (KRILEL *et al.*, 2014).

Não apenas isoladamente, mas a interação entre os parâmetros de máquina e a variação da ferramenta de corte podem exercer variação nos resultados de usinagem. Cool e Hernández (2012) demonstram como a variação da velocidade de corte juntamente com a variação do ângulo de folga da ferramenta podem resultar em diferenças significativas nos resultados esperados.

### **2.1.1.2 Matéria-prima**

Por se tratar de um polímero heterogêneo complexo composto por celulose, hemiceluloses e lignina, a madeira possui diversas características que influenciam a usinagem de sua superfície (COTE, 1983; DAVIM, 2011; NAYLOR e HACKNEY, 2013), se diferenciando assim de usinagem de outros materiais como aço, metal, plástico e alumínio (EYMA *et al.*, 2004).

Os resultados do processo de usinagem podem oscilar de acordo com as estruturas celulares da madeira, principalmente nos processos de acabamento (WILLIAMS *et al.*, 1996). Sendo o entendimento da influência da variação dos componentes da madeira essencial para identificar os parâmetros que permitam uma melhor usinabilidade (COELHO *et al.*, 2008).

A Figura 2.3 representa o diagrama desenvolvido por Nasir e Cool (2018) em que se destaca alguns dos fatores presentes na madeira que durante a usinagem alteram significativamente os resultados do processo.

A espécie da madeira utilizada possui alta influência nos resultados do processo de usinagem (KIVIMAA, 1950; MALKOÇOĞLU e OZDEMIR, 2006). Isso ocorre, pois, diferentes espécies de madeiras possuem diferentes densidades (WALKER, 2006; BARNETT e JERONIMIDIS, 2009; DAVIM, 2011). A usinagem por se basear em tensão de ruptura faz com que a densidade da madeira influencie na força necessária de corte. Visto que a densidade tem associação a resistência mecânica (NÉRI, 2003).

Além da espécie, a idade da árvore quando foi cortada influencia os resultados do processo de usinagem. Gonçalves e Néri (2005) demonstraram os diferentes resultados

de força de corte obtidos usinando madeiras juvenil e adulta da espécie *Pinus taeda*, em que a força de corte aumentava com a madeira de árvores de maior idade.

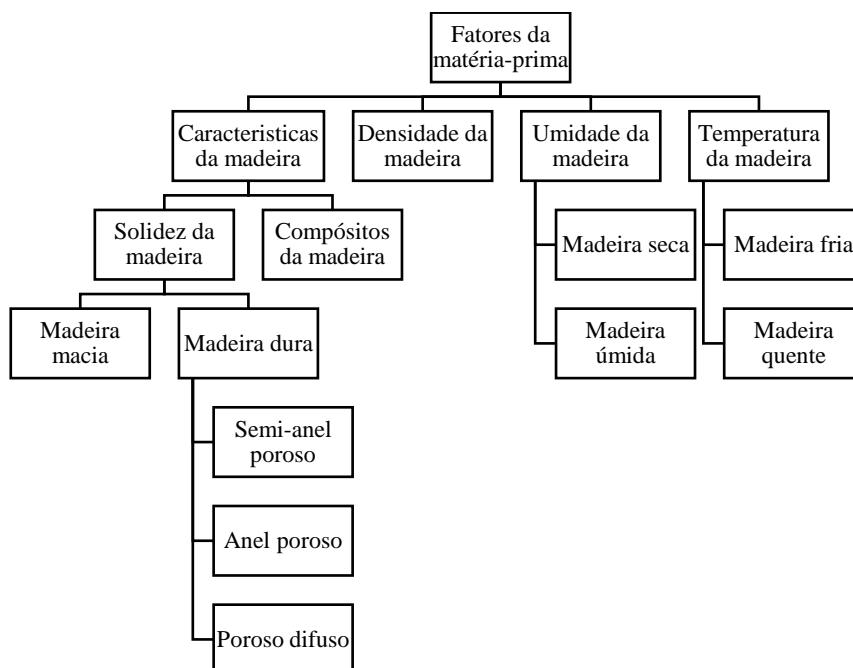


Figura 2.3 - Fatores da matéria-prima na usinagem da madeira (NASIR e COOL, 2018)

Belleville *et al.* (2016) demonstraram os efeitos de diferentes idades da madeira ao realizar experimentos de aplainamento com sete espécies diferentes com idades entre 15 a 40 anos. Os resultados obtidos foram comparados com os resultados de aplainamento das mesmas espécies, porém com idade superior. Com isso foi possível identificar diferenças em algumas espécies, em que a utilização de madeiras de árvores mais jovens apresentou melhores resultados de produtividade e qualidade.

A resistência da madeira pode ser alterada com diferentes temperaturas durante o processo de usinagem. Temperaturas mais elevadas facilitam o corte da madeira. Para alguns processos a forma de evitar o efeito da temperatura da madeira é a partir do tratamento térmico da matéria-prima, colocando todas as madeiras na mesma temperatura (KOCH, 1964).

A disposição das fibras da madeira em relação a direção de corte é um parâmetro de grande importância que proporciona diferentes resultados para qualidade da superfície usinada, forças de corte e mecânica de corte (PORANKIEWICZ e GOLI, 2014). A Figura 2.4 demonstra as diferentes direções de usinagem em relação a disposição da fibra da madeira.




Figura 2.4 - Usinagem da madeira (a) contra a direção das fibras, (b) perpendicular a direção das fibras, (c) ao longo da direção das fibras, e (d) paralelo a direção das fibras (PORANKIEWICZ, 2014)

Um dos fatores que exerce grande influência na usinagem da madeira é a umidade presente na matéria-prima, alterando resultados de qualidade, produtividade e custo do processo (ÖHMAN *et al.*, 2016).

No que se refere a qualidade do produto, a umidade na madeira pode causar mudanças em suas dimensões gerando problemas de colagem, usinagem, acabamento e desgaste biológico (ESPINOZA *et al.*, 2007).

As propriedades físicas e mecânicas da madeira também se modificam de acordo com a umidade na qual ela se apresenta, resultando assim na variação da produtividade e custo do processo (HERNÁNDEZ, 1993). A madeira tende a se tornar mais dura à medida que está mais seca, tornando-se assim mais resistente e aumentando a força necessária de usinagem (NADERI e HERNÁNDEZ, 1999).

### 2.1.2 Aplainamento

O processo de aplainamento, em alguns casos denominado também de fresamento periférico, pode realizar operações de desbaste ou acabamento superficial. Sua operação consiste no conjunto de facas posicionados estrategicamente para remove uma quantidade de camada de material da parte superior da peça usinada gerando cavaco (NAYLOR e HACKNEY, 2013). O corte realizado por aplainamento é denominado de corte livre, ou seja, a largura do material usinado é menor que o comprimento da aresta de corte (DAVIM, 2011).

Os cortes oblíquo, ortogonal e por fresa são as técnicas mais utilizadas para o processo de aplainamento. (DE MORA *et al.*, 2010). A Figura 2.5 demonstra dois tipos



distintos de usinagem superficial, em que (a) é a usinagem por plaina desempenadeira e (b) por fresa.




Figura 2.5 – Usinagem por (a) plaina desempenadeira e (b) fresa

O corte ortogonal se assemelha com o corte oblíquo, sendo que a sua diferença está na geometria da ferramenta de usinagem no ângulo do fio da faca. O aplainamento é um tipo de usinagem periférica no qual o fio da foga pode ou não possuir angulação. (MOURA e HERNÁNDEZ, 2007). A Figura 2.6 demonstra esses dois tipos de processos de usinagem, onde  $i$  representa o ângulo de inclinação da faca fixa de corte em relação à madeira usinada.

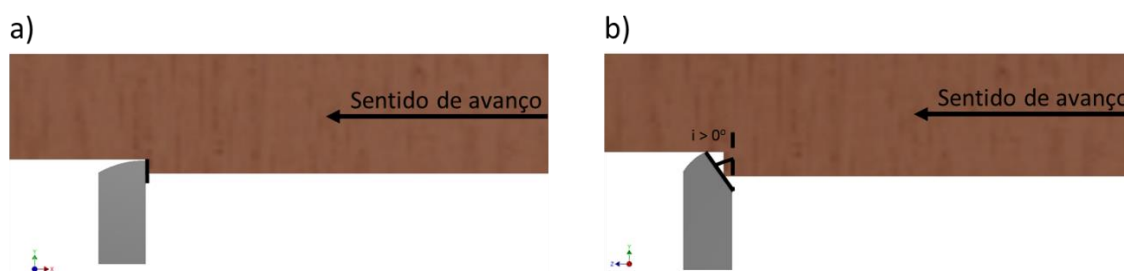


Figura 2.6 - Posição da faca fixa no (a) corte ortogonal e (b) corte oblíquo

O corte ortogonal possui sua força resultante decomposta de duas formas: em dois componentes ortogonais (forças paralelas e normais) e em dois componentes faciais (forças de inclinação e de folga) (MARCHAL *et al.*, 2009).

A Figura 2.7 demonstra as variáveis de controle do aplainamento por três facas na visão superior ao processo. Desta visão são representadas as variáveis de velocidade de avanço ( $v_f$ ) e a profundidade de corte ( $a_p$ ).




Figura 2.7 - Visão superior do aplainamento

A Figura 2.8 demonstra as variáveis de controle do aplainamento por três facas na visão lateral ao processo. Desta visão são representadas as variáveis de velocidade de avanço ( $v_f$ ), velocidade de corte ( $v_c$ ) e profundidade de penetração ( $a_p$ ). Por essa imagem pode-se destacar que a plaina usina em movimento discordante, ou seja, a direção de  $v_c$  e  $v_f$  são opostos.




Figura 2.8 - Visão lateral do aplainamento

A velocidade de corte ( $v_c$ ) em  $\text{m}\times\text{s}^{-1}$  no aplainamento é a velocidade com que o cabeçote com a ferramenta de corte rotaciona. Seu cálculo é baseado no diâmetro do cabeçote ( $D$ ) em mm e na rotação do motor ( $n$ ) em rpm e pode ser obtido conforme Equação 2.1 (RATNASINGAM *et al.*, 1999).

$$v_c = \frac{\pi \times D \times n}{60000} \quad (2.1)$$

A velocidade de avanço ( $v_f$ ) em  $\text{m} \times \text{min}^{-1}$  no aplainamento é a velocidade com que o material usinado se desloca em direção à ferramenta de corte. Com isso, seu cálculo é obtido pela relação do comprimento da peça a ser usinada ( $c$ ) em m e tempo necessário para usinagem da peça ( $t$ ) em min conforme Equação 2.2 (RATNASINGAM *et al.*, 1999).

$$v_f = \frac{c}{t} \quad (2.2)$$

O avanço por dente ( $f_z$ ), ou gume, em mm é o deslocamento da peça usinada de um dente ao outro. A definição do valor de  $f_z$  depende do número de facas ( $Z$ ) presente no cabeçote rotativo e os valores de  $v_f$  e  $n$ , conforme Equação 2.3 (RATNASINGAM *et al.*, 1999).

$$f_z = \frac{1000 \times v_f}{n \times Z} \quad (2.3)$$

A taxa de remoção de material ( $MRR$ ) em  $\text{mm}^3/\text{min}$  é um dos meios de se analisar a produtividade da usinagem. Quanto maior o valor de  $MRR$ , mais produtivo é a usinagem. A definição de  $MRR$  é determinada pelo produto entre a penetração de trabalho ( $a_e$ ) em mm, profundidade de corte ( $a_p$ ) em mm e velocidade de avanço  $\text{mm} \times \text{min}^{-1}$  conforme representado na Equação 2.4 (RATNASINGAM *et al.*, 1999).

$$MRR = a_e \times a_p \times v_f \quad (2.4)$$

O cavaco gerado durante a usinagem da madeira tem de ser exaurido da superfície da peça usinada para assim garantir o processo contínuo. Processos com alto volume de cavaco gerado exigirão sistema de exaustão maiores, gerando assim maior custo. A quantidade de cavaco gerado é influenciada pela espessura média dos cavacos não deformados ( $h_m$ ). O valor de  $h_m$  em mm pode ser definido considerando  $f_z$  em mm,  $a_e$

em mm e  $c$  em mm conforme representado na Equação 2.5 (RATNASINGAM *et al.*, 1999).

$$h_m = f_z \times \sqrt{\frac{a_e}{c}} \quad (2.5)$$

### 2.1.3 Energia e potência

A energia é uma importante resposta a ser considerada na usinagem, em que o seu princípio é a transformação de energia elétrica em energia mecânica dos motores. Um indicador para o consumo de energia elétrica e a potência elétrica, onde é possível mensurar o quanto de energia está se utilizando por unidade de tempo (GUEDES, 2016).

A energia pode ser definida com base na tensão, corrente e potência que são geradas durante a usinagem, em que esses dados são coletados de forma *on-line* por um medidor de energia elétrica que gera relatórios precisos e os armazenam em um banco de dados (FLUKE CORPORATE, 2000).

A análise da energia consumida no processo é um dos indicadores que afeta os custos de usinagem, uma vez que o aumento do consumo de energia pode levar ao crescimento drástico nos custos totais do processo (CUI *et al.*, 2019). Dessa forma se torna um desafio para as empresas reduzir seu consumo de forma a se tornarem mais competitiva (GAFF *et al.*, 2016).

#### 2.1.3.1 Energia específica de corte ( $E_s$ )

A energia específica de corte ( $E_s$ ) é uma das métricas mais adotadas para analisar a produtividade de equipamentos de usinagem, sendo utilizado em trabalhos em fresamento (VINCENT *et al.*, 2016; EDEM e BALOGUN *et al.*, 2018; SARIİŞIK e ÖZKAN, 2018), torneamento (PRIARONE *et al.*, 2016), processos de usinagem em alta velocidade (do inglês, *high-speed machining* – HSM) (WANG *et al.*, 2016; WARSI *et al.*, 2018; CHETAN *et al.*, 2018), usinagem a laser (AHN *et al.*, 2016; WOO e LEE, 2018), entre outros.

A  $E_s$  é calculada baseando-se em esforços do equipamento durante o processo de usinagem. De acordo com a abordagem empregada por Souza *et al.* (2011), a potência

mecânica e a energia consumida durante o processo de usinagem podem ser obtidas pelas Equações 2.6 e 2.7, respectivamente.

$$P = \frac{T \times n \times 0,0014 \times 736}{1000} \quad (2.6)$$

Em que a  $P$  é a potência mecânica em kW;  $T$  é o torque exercido pelo equipamento de usinagem em kgf.m; e  $n$  é a rotação do motor do equipamento de usinagem em rpm.

$$E = \left( \frac{P \times c}{v_f} \right) \times 60 \quad (2.7)$$

Em que  $E$  é a energia consumida em kJ;  $c$  é o diâmetro ou o comprimento da peça a ser usinada em m; e  $v_f$  é a velocidade de avanço em m/min.

A  $E_s$  é a energia efetiva consumida durante o processo de usinagem em relação ao volume de material removido da peça usinada. Dessa forma o objetivo é reduzir ao máximo o valor de  $E_s$  pela redução do consumo de energia e o aumento do volume de material removido (SALMON, 1992). A função de  $E_s$  pode ser representada conforme a Equação 2.8 (GUEDES, 2016).

$$E_s = \frac{P}{MRR} \quad (2.8)$$

Em que  $E_s$  é a energia específica de corte em  $\text{kJ} \times \text{m}^{-3}$ ;  $P$  é a potência utilizada pelo equipamento em W;  $MRR$  é a taxa de remoção de material em  $\text{m}^3 \times \text{s}^{-1}$ . Baseando-se nas Equações 2.7 e 2.8, uma outra forma de definir o valor de  $E_s$  é descrito na Equação 2.9.

$$E_s = \frac{E}{a_p \times a_e \times c} \quad (2.9)$$

## 2.2 Planejamento de experimentos

### 2.2.1 Metodologia de superfície de resposta

Desenvolvido para solucionar problemas de otimização, a Metodologia de Superfície de Resposta (do inglês *Response Surface Methodology* - RSM) foi inicialmente aplicado em resolução de experimentos químicos (BOX E WILSON, 1951).

A RSM é um tipo de planejamento de experimentos (do inglês *Design of Experiments* - DoE) e possui sua estrutura e filosofia presente em estudos de diversos artigos e livros (HILL e HUNTER, 1966). O RSM está presente em experimentação de pesquisas industriais, desenvolvimento, manufatura e comercialização de tecnologia (MYERS *et al.*, 2004).

A RSM trata-se de um conjunto de técnicas estatísticas e matemáticas utilizadas com a finalidade de desenvolver, melhorar e otimizar determinada resposta em que sofre influência por diversas variáveis (MYERS *et al.*, 2016; MONTGOMERY, 2017). O RSM visa relacionar uma função desconhecida complexa com polinômio de primeira ou segunda ordem, o que faz dos projetos que ajustam a tais modelos serem considerados de alta relevância (ANDERSON-COOK *et al.*, 2009).

Os modelos de primeira e segunda ordem gerados pela RSM que representam a resposta experimental é descrita de acordo com as Equações 2.10 e 2.11, respectivamente (MYERS *et al.*, 2016; MONTGOMERY, 2017).

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^{k-1} \sum_{j=2}^k \beta_{ij} x_i x_j + \varepsilon \quad (2.10)$$

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^{k-1} \sum_{j=2}^k \beta_{ij} x_i x_j + \sum_{i=1}^k \beta_{ii} x_i^2 + \varepsilon \quad (2.11)$$

Em que  $y$  é a resposta experimental;  $x_i$  e  $x_j$  são as variáveis independentes;  $k$  é o número de variáveis independentes;  $\beta_0$ ,  $\beta_i$  e  $\beta_{ij}$  ( $i = 0, 1, 2, \dots, k$ ;  $j = 0, 1, 2, \dots, k$ ) são coeficientes de regressão dos termos independente, linear, quadrático e intercessão respectivamente; e  $\varepsilon$  representa o erro amostral.

A determinação dos coeficientes de regressão ( $\beta$ 's) é realizada a partir do método dos mínimos quadrados de forma a minimizar a soma dos quadrados dos erros ( $\varepsilon$ 's) (MONTGOMERY, 2017).

A RSM trata-se um planejamento de experimentação moderno e com aplicação sistemática, visando identificar melhores padrões de processos. Para a aplicação da RSM a sequência de fases é seguida sistematicamente, conforme descrita por Myers *et al.* (2016):

- Fase zero: são realizados experimentos de investigação de fatores. O objetivo nessa fase é eliminar fatores que não são importantes para a resposta do processo, garantindo assim o menor número de experimentos na fase seguinte. Esse tipo de experimento é denominado de experimento de triagem.
- Fase um: após identificação dos fatores significativos, verifica-se se os experimentos com os níveis dos fatores utilizados resultam na resposta próxima ou afastada do ponto ótimo. Caso resulte em um ponto afastado, o ajuste nos níveis dos fatores deve ser feito. Para essa fase modelos de primeira ordem são utilizados.
- Fase dois: nessa última fase os experimentos buscam o modelo que aproxime o máximo da função resposta na região em torno do ótimo. Nessa fase modelos de segunda ordem são utilizados para identificar a curvatura do processo. A partir do modelo gerado, pode-se determinar as condições ótimas do processo.

Existem diversos métodos de planejamento de superfície de resposta, em que o método a ser empregado dependerá da forma como reage o modelo de previsão da superfície de resposta. Em geral, as comparações são realizadas de acordo com a variância dos arranjos utilizados, critérios de otimalidade do arranjo e representação gráfica (MYERS *et al.*, 2016).

Os planejamentos fatoriais são utilizados em experimentos para analisar os efeitos gerados por fatores e suas interações em relação a uma ou mais determinadas respostas (MONTGOMERY, 2017), sendo esses planejamentos os melhores a se adequar a estratégia sequencial existente no RSM, sendo utilizado para o desenvolvimento da fase zero do RSM (BOX E WILSON, 1951; MYERS *et al.*, 2016).

No planejamento fatorial  $2^k$  as variáveis de controle apresentam dois níveis, sendo esses níveis qualitativos ou quantitativos, em que  $k$  representa o número de variáveis de controle,  $x_1, x_2, \dots, x_p$ , e  $2^k$  o número de experimentos a serem realizados. Os níveis dos

fatores são em geral considerados como “baixo” ou “-” e “alto” ou “+” (MONTGOMERY, 2017). No planejamento experimental com réplicas dos pontos fatoriais, o número total de experimentos a ser realizado é igual a  $n2^k$ , em que  $n$  representa o número de réplicas.

A representação codificada dos níveis dos fatores no planejamento é de “-1” e “+1” para o nível baixo e alto dos fatores respectivamente, sendo denominado de codificação ortogonal ou codificação de efeitos (MONTGOMERY, 2017). Dessa forma a distância entre os níveis de fatores é igual a 2, possibilitando assim a ilustração hipercubo no espaço  $k$ -dimensional com arestas sendo a diferença entre os níveis dos fatores e seu centro na origem, testando assim os vértices do cubo (BOX E WILSON, 1951). A Figura 2.9 é a representação de três planejamentos com diferentes números de fatores.




Figura 2.9 - Planejamento de experimentos (a)  $2^2$  (b)  $2^3$  (c)  $2^4$

A sequência padrão de realização dos experimentos codificados do planejamento fatorial  $2^k$  é descrito conforme a Tabela 2.1.



Tabela 2.1 - Ordem padrão do planejamento fatorial  $2^k$ 

Ordem padrão	$x_1$	$x_2$	$x_3$	...	$x_k$
1	-1	-1	-1	...	-1
2	+1	-1	-1	...	-1
3	-1	+1	-1	...	-1
4	+1	+1	-1	...	-1
5	-1	-1	+1	...	-1
6	+1	-1	+1	...	-1
7	-1	+1	+1	...	-1
8	+1	+1	+1	...	-1
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
$2^k$	+1	+1	+1	...	+1

A mudança de nível é tomada a cada  $2^{k-1}$  linhas, ou seja, o primeiro fator mudará seu nível a cada  $2^0 = 1$  linha, o segundo fator mudará seu nível a cada  $2^1 = 2$  linhas e assim sucessivamente até o último fator experimental. Para que o erro experimental seja normalmente e independentemente distribuído, deve-se realizar os experimentos de forma aleatória (MONTGOMERY, 2017).

A Figura 2.10 apresenta um gráfico de efeito principal ou linear para determinada análise experimental (MONTGOMERY, 2017).




Figura 2.10 - Gráfico de efeito principal

O efeito gerado pela mudança de nível de cada variável é determinado a partir da diferença entre as médias em cada nível das variáveis, ou seja, é a diferença entre as médias nos níveis da variável -1 e +1. Desse modo, o efeito de A pode ser definido conforme a Equação 2.12 (MONTGOMERY, 2017).

$$A = \bar{y}_{A(+)} - \bar{y}_{A(-)} \quad (2.12)$$

O coeficiente linear é determinado pela inclinação da reta que liga a média das respostas da variável em -1 a +1, em que é definida pela tangente angular de inclinação, sendo a razão entre o efeito e a distância entre os níveis fatoriais (+1 - (-1) = 2). A Equação 2.13 representa a determinação do coeficiente  $\beta_1$  pela análise da variável A (MONTGOMERY, 2017).

$$\beta_1 = \tan \alpha = \frac{\bar{y}_{A(+)} - \bar{y}_{A(-)}}{2} \quad (2.13)$$

Define-se graficamente que a interação entre duas variáveis é significativa quando a alteração do nível de uma variável muda o sentido de direção da reta do efeito de outra variável. Quando o efeito de uma variável se mantém constante mesmo que se mude o nível de outra variável, diz-se que não existe interação entre as variáveis analisadas. A Figura 2.11 representa dois gráficos de interação em que (a) não existe a interação entre as duas variáveis e (b) existe interação entre as duas variáveis (MONTGOMERY, 2017).

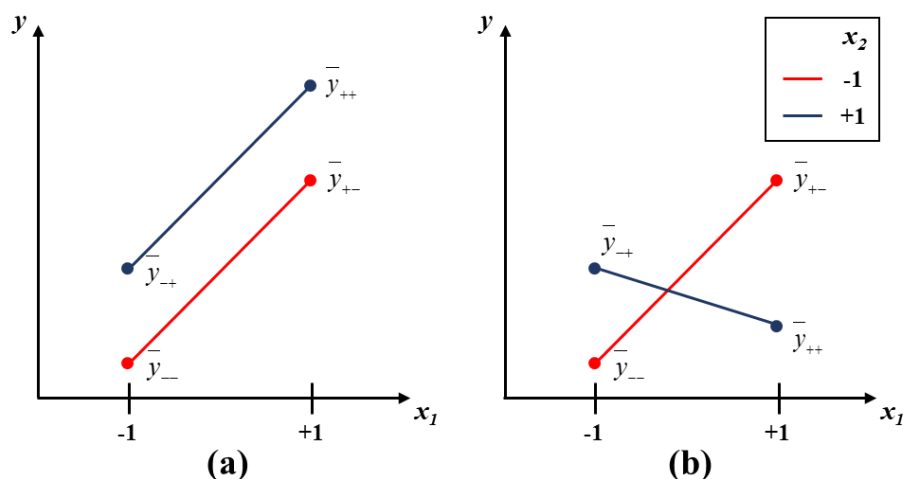


Figura 2.11 - Gráficos de interação em que (a) não significativo e (b) significativo

Calcula-se o efeito da interação  $AB$  com a média dos efeitos da variável  $A$  analisado nos dois níveis da variável  $B$ , conforme representado na Equação 2.14. Já o coeficiente da interação  $AB$  é determinado de acordo com a inclinação da reta que liga os pontos nos dois níveis e é calculado conforme Equação 2.15 (MONTGOMERY, 2017).

$$AB = \frac{(\bar{y}_{+-} - \bar{y}_{--}) + (\bar{y}_{++} - \bar{y}_{-+})}{2} \quad (2.14)$$

$$\beta_{12} = \frac{AB}{2} \quad (2.15)$$

O Arranjo Composto Central (do inglês *Central Composite Design* - CCD) desenvolvido por Box e Wilson (1951), é um dos arranjos experimentais que permite gerar modelos de segunda ordem, buscando assim identificar a curvatura do processo. Dessa forma o CCD se adequa a aplicação da fase dois do RSM.

O arranjo CCD consiste em três grupos experimentais, o primeiro sendo um planejamento fatorial  $2^k$  com  $n_f$  números de experimentos, o segundo composto de pontos axiais com  $2k$  números de experimentos e o terceiro por pontos centrais com  $n_c$  números de experimentos. Desse modo o número total de experimentos a ser realizado denominado de  $n$  é determinado por  $n = 2^k + 2k + n_c$  (MONTGOMERY, 2017).

A Figura 2.12 representa dois Arranjos Composto Central com diferentes números de fatores.

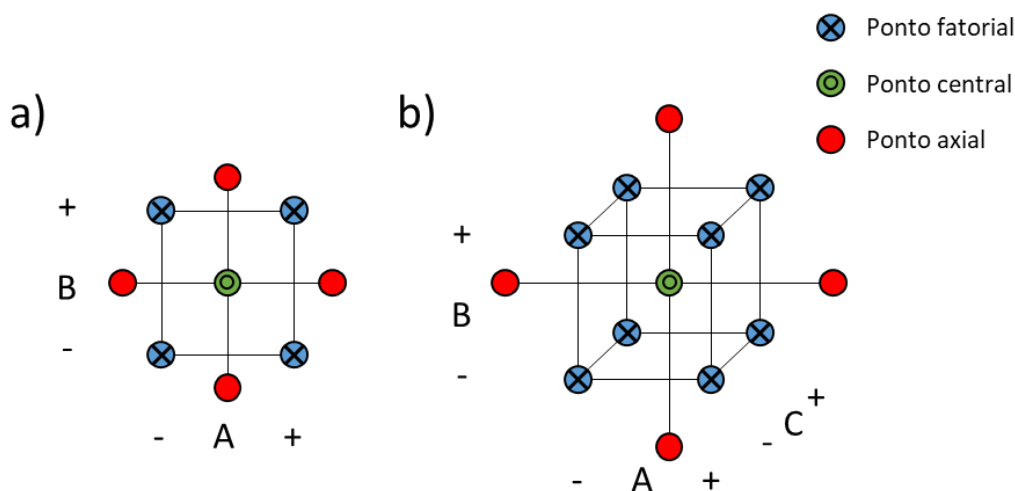


Figura 2.12 - Arranjo Composto Central (a) 2 fatores e (b) 3 fatores

A sequência padrão dos experimentos codificados para o CCD é descrito conforme Tabela 2.2.

Tabela 2.2 - Ordem padrão do Arranjo Composto Central

Ordem padrão	$x_1$	$x_2$	...	$x_k$
1	-1	-1	...	-1
2	1	-1	...	-1
3	-1	1	...	-1
4	1	1	...	-1
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
$n_f=2^k$	1	1	...	1
1	$-\rho$	0	...	0
2	$\rho$	0	...	0
3	0	$-\rho$	...	0
4	0	$\rho$	...	0
$\vdots$	$\vdots$	$\vdots$	...	$-\rho$
$n_a = 2k$	0	0	...	$\rho$
1	0	0	...	0
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
$n_c$	0	0	...	0

### 2.2.2 Projeto de parâmetro robusto

Todo processo consiste na combinação de variáveis controláveis e de ruído (incontroláveis) que transformam as entradas em saídas (respostas) conforme representado na Figura 2.13, em que  $x_1, x_2, \dots, x_p$  são as variáveis de controle; e  $z_1, z_2, \dots, z_q$  são de ruídos. (MONTGOMERY, 2017).

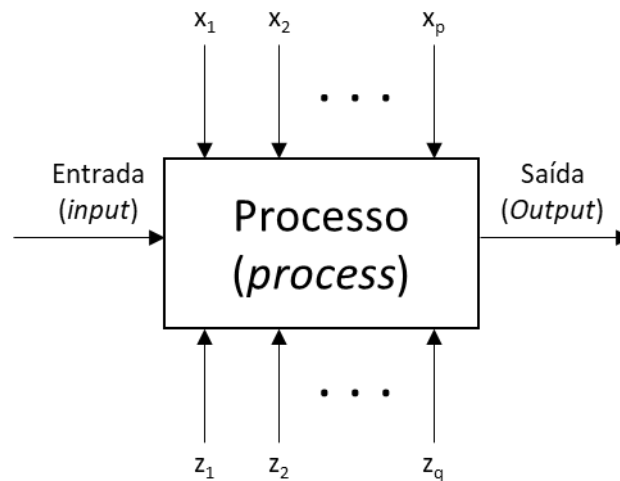


Figura 2.13 - Modelo geral de um processo (MONTGOMERY, 2017)

Os processos de fabricação podem conter diversas variações de fatores que podem causar o fraco rendimento do processo. O controle de processos se torna mais caro quando sensível a essas variações (DEHNAD, 1989). Dentre os custos que compõe o produto, o custo de processo é um dos que é repassado diretamente ao cliente, o que leva a percepção de que o produto de maior qualidade possui menor custo operacional.

O Projeto de Parâmetro Robusto (do inglês *Robust Parameter Design* - RPD) tem a finalidade de minimizar os custos operacionais e assim manter o produto de alta qualidade (PHADKE, 1989). Para isso o RPD foca-se em determinar os níveis das variáveis de controle (ou parâmetros) do processo ou produto para atingir os objetivos de garantir que a média da resposta analisada atinja o alvo planejado e que a variabilidade dos dados ao entorno do alvo seja mínima possível (MONTGOMERY, 2017)

Das variáveis presentes em processos, as de ruído são consideradas as mais difíceis ou mais caras de serem controladas (NAIR *et al.*, 1992), com isso, o RPD tem como objetivo identificar parâmetros das variáveis de controle que minimizem as variáveis de ruído, tornando o processo mais robusto as mesmas (AL-GHAMDI, 2013).

Para o desenvolvimento experimental do RPD o uso do RSM pode ser utilizado para permitir um desenvolvimento sistemático (MATSUURA *et al.*, 2011). Vining e Myers (1990) apresentaram a aplicação do RSM na determinação de média e variância, obtidas separadamente em um RPD e posteriormente otimizando os resultados pela abordagem com restrição.

Uma das classes utilizadas para o desenvolvimento do RPD é a utilização de arranjo combinado para o planejamento experimental (TAN e NG, 2009). O arranjo

combinado insere no mesmo arranjo experimental as variáveis de controle e de ruído, permitindo assim analisar interações entre elas, além de economizar no número de experimentos comparado com os demais tipos de arranjo (EVANGELARAS e KOUKOUVINOS, 2006).

O CCD combinado é um dos planejamentos que pode ser utilizado na identificação da região ótima do RSM combinado com o RPD (PEREIRA *et al.*, 2017). A Tabela 2.3 descreve um arranjo CCD combinado.

Tabela 2.3 - Arranjo CCD combinado (PEREIRA, 2017)

Ordem padrão	$x_1$	$x_2$	...	$x_k$	$z_1$	$z_2$	...	$z_k$
1	-1	-1	...	-1	-1	-1	...	-1
2	1	-1	...	-1	-1	-1	...	-1
3	-1	1	...	-1	-1	-1	...	-1
4	1	1	...	-1	-1	-1	...	-1
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
$n_f = 2^{k+r}$	1	1	...	1	1	1	...	1
1	$-\rho$	0	...	0	0	0	...	0
2	$\rho$	0	...	0	0	0	...	0
3	0	$-\rho$	...	0	0	0	...	0
4	0	$\rho$	...	0	0	0	...	0
$\vdots$	$\vdots$	$\vdots$	...	$-\rho$	...	...	...	...
$n_a = 2k$	0	0	...	$\rho$	0	0	...	0
1	0	0	...	0	0	0	...	0
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$	$\vdots$	$\ddots$	0
$n_c$	0	0	...	0	0	0	...	0

O CCD combinado gera três grupos de pontos distintos. O primeiro grupo possui  $n_f = 2^{k+r}$  pontos fatoriais que são responsáveis por garantir a estimativa dos efeitos lineares e interações entre variáveis de controle e entre variáveis de controle e de ruído. O segundo grupo possui  $n_a = 2^k$  pontos axiais responsáveis por garantir a estimativa dos efeitos de segunda ordem das variáveis de controle. O terceiro grupo possui  $n_c$  pontos centrais de variáveis de controle e de ruído responsáveis por estimar o erro experimental.

O modelo de regressão gerado a partir do projeto experimental, que é a função dos fatores de controle, de ruído e interação entre estes, excluindo efeitos de fatores quadráticos de ruído e de interações de fatores de ruído não existentes pode ser representado matricialmente conforme Equação 2.16 (KUHN, 2003).

$$y = \beta_0 + \mathbf{x}^T \boldsymbol{\beta} + \mathbf{x}^T \mathbf{B} \mathbf{x} + \mathbf{z}^T \boldsymbol{\gamma} + \mathbf{x}^T \boldsymbol{\Delta} \mathbf{z} + \varepsilon \quad (2.16)$$

Em que a resposta da função é descrita segundo as variáveis de controle do processo,  $\mathbf{x}^T = (x_1, x_2, \dots, x_k)$ , e de ruído,  $\mathbf{z}^T = (z_1, z_2, \dots, z_r)$ ;  $\beta_0$  é uma constante;  $\boldsymbol{\beta}$  é o vetor de coeficientes lineares das variáveis controláveis do processo;  $\mathbf{B}$  é a matriz contendo os coeficientes quadráticos e de interação das variáveis controláveis do processo;  $\boldsymbol{\gamma}$  é o vetor de coeficientes lineares das variáveis de ruído; e  $\boldsymbol{\Delta}$  é a matriz de termos de interação entre variáveis controláveis do processo e ruído, sendo desse modo (KUHN, 2003):

$$\boldsymbol{\beta}_{c \times 1} = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_c \end{bmatrix}; \mathbf{B}_{c \times c} = \begin{bmatrix} \beta_{11} & \frac{1}{2} \beta_{12} & \cdots & \frac{1}{2} \beta_{1c} \\ \frac{1}{2} \beta_{11} & \beta_{22} & \cdots & \frac{1}{2} \beta_{2c} \\ \vdots & \vdots & \ddots & \vdots \\ sym & \cdots & \beta_{cc} \end{bmatrix}; \boldsymbol{\gamma}_{n \times 1} = \begin{bmatrix} \gamma_1 \\ \vdots \\ \gamma_n \end{bmatrix}; \boldsymbol{\Delta}_{c \times 1} = \begin{bmatrix} \delta_{11} & \delta_{12} & \cdots & \delta_{1n} \\ \delta_{21} & \delta_{22} & \cdots & \delta_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \delta_{c1} & \delta_{c2} & \cdots & \delta_{cn} \end{bmatrix}$$

De forma geral, o modelo algébrico pode ser descrito conforme Equação 2.17, em que  $k$  e  $r$  são os números de variáveis de controle do processo e de ruído, respectivamente.

$$y(\mathbf{x}, \mathbf{z}) = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i < j} \beta_{ij} x_i x_j + \sum_{i=1}^k \gamma_i z_i + \sum_{i=1}^k \sum_{j=1}^r \delta_{ij} x_i z_j + \varepsilon \quad (2.17)$$

Assumindo que  $E[z] = 0$  e  $V[z] = \Sigma z$  no processo, o modelo de resposta para média e variância pode ser obtidos pelas Equações 2.18 e 2.19, respectivamente (MATSUURA *et al.*, 2011).

$$E[y] = \beta_0 + \mathbf{x}^T \boldsymbol{\beta} + \mathbf{x}^T \mathbf{B} \mathbf{x} \quad (2.18)$$

$$V[y] = (\Delta^T \mathbf{x} + \boldsymbol{\gamma})^T \Sigma_z (\Delta^T \mathbf{x} + \boldsymbol{\gamma}) + \sigma^2 \quad (2.19)$$

Em que os valores para média e variância do modelo de resposta podem ser expressados algebricamente conforme Equações 2.20 e 2.21, respectivamente.

$$E_z[y(\mathbf{x}, \mathbf{z})] = f(\mathbf{x}) \quad (2.20)$$

$$V_z[y(\mathbf{x}, \mathbf{z})] = \sigma_{z_i}^2 \left\{ \sum_{i=1}^r \left[ \frac{\partial y(\mathbf{x}, \mathbf{z})}{\partial z_i} \right]^2 \right\} + \sigma^2 \quad (2.21)$$

Para obter o valor mínimo de  $V_z[y(\mathbf{x}, \mathbf{z})]$  e, simultaneamente, o valor ótimo (maximização ou minimização) de  $E_z[y(\mathbf{x}, \mathbf{z})]$  é necessário utilizar métodos de *trade-off* de otimização bi-objetivos, uma vez que, o valor mínimo de  $V_z[y(\mathbf{x}, \mathbf{z})]$  pode não ser o valor ótimo de  $E_z[y(\mathbf{x}, \mathbf{z})]$  (NAVES *et al.*, 2017).

## 2.3 Otimização robusta multi-objetivo

A escolha do método a ser utilizado para a otimização de problemas multi-objetivo é fundamental para atingir resultados ótimos e reais. O método de otimização deve atender os atributos de (1) o método deve gerar o conjunto par de pontos de Pareto sem negligenciar qualquer região, (2) o método deve ser capaz de gerar todas as soluções Pareto ótimas possíveis, (3) o método deve gerar apenas soluções de Pareto e (4) o método deve ser relativamente fácil aplicação (CHEN *et al.*, 1999).

A seguir são apresentados dois principais métodos de otimização utilizados em problemas multi-objetivo. Respaldo nos atributos descritos por Chen *et al.* (1999) e nas características do processo de aplainamento da madeira *Pinus taeda*, no desenvolvimento deste trabalho foi empregado apenas o método NNC.



### 2.3.1 Interseção Normal à Fronteira

Para solucionar problemas multi-objectivo o método de interseção normal à fronteira (do inglês, *normal boundary intersection* - NBI) apresenta alta eficácia, se destacando na distribuição de pontos na criação da fronteira de Pareto (IZADBAKHSI *et al.*, 2015).

O NBI foi desenvolvido para solucionar o problema presente no método das somas ponderadas (do inglês, *Weighted Sum* - WS) em identificar soluções não-dominadas e equispaçadas em fronteiras de Pareto não-convexas (Das e Dennis, 1998).

O método NBI consiste em inicialmente definir a matriz *Payoff*  $\Phi$  das respostas analisadas, em que no problema composto por  $m$  funções objetivos  $f_i(x)$  é calculado o mínimo individual de cada função objetivo  $f_i^*(x_i^*)$  obtida a partir da solução  $x_i^*$  (VAHIDINASAB e JADID, 2010). As demais funções objetivo que compõem a matriz *Payoff*  $\Phi$  são representadas por  $f_1(x_i^*), f_2(x_i^*), \dots, f_{i-1}(x_i^*), f_{i+1}(x_i^*), \dots, f_m(x_i^*)$  (AHMADI *et al.*, 2015). Dessa forma a matriz *Payoff*  $\Phi$  pode ser representada conforme Equação 2.22 (Brito *et al.*, 2014).

$$\begin{aligned} \Phi &= \begin{bmatrix} f_1^*(x_1^*) & \cdots & f_1(x_i^*) & \cdots & f_1(x_m^*) \\ \vdots & \ddots & & & \vdots \\ f_i(x_1^*) & \cdots & f_i^*(x_i^*) & & f_i(x_m^*) \\ \vdots & & & \ddots & \vdots \\ f_m(x_1^*) & \cdots & f_m(x_i^*) & \cdots & f_m^*(x_m^*) \end{bmatrix} \\ &= \begin{bmatrix} \bar{f}_1 & \cdots & \bar{f}_1 & \cdots & \bar{f}_1(x_m^*) \\ \vdots & \ddots & & & \vdots \\ \bar{f}_i & & \bar{f}_i & & \bar{f}_i(x_m^*) \\ \vdots & & & \ddots & \vdots \\ \bar{f}_m(x_1^*) & \cdots & \bar{f}_m(x_i^*) & \cdots & \bar{f}_m(x_m^*) \end{bmatrix} = \bar{\Phi} \end{aligned} \quad (2.22)$$

Os ótimos individuais compostos na matriz *Payoff*  $\Phi$  na diagonal principal é descrito em vetor como  $f^U = [f_1^*(x_1^*), \dots, f_i^*(x_i^*), \dots, f_m^*(x_m^*)]^T$ , em que tal vetor é denominado de Utopia. No mesmo sentido, o agrupamento dos valores não-ótimos de

cada função objetivo tem-se o vetor  $f^N = [f_1(x), \dots, f_i(x_i), \dots, f_m(x_m)]^T$ , em que esse vetor é denominado de Nadir. Tanto os pontos contidos no vetor de Utopia quanto de Nadir correspondem a pontos fora da região viável (NAVES *et al.*, 2017). O ponto denominado de pseudo Nadir é representado pela combinação dos piores pontos presentes dentro da região viável, representada vetorialmente como  $f^{PN} = [f_1^{PN}, \dots, f_i^{PN}, \dots, f_m^{PN}]^T$ , sendo a  $i$ -ésima função objetivo definida como  $f_i^{PN} = \text{Max}_{(x \in \Omega)} \{f_i(\mathbf{x}_1^*), \dots, f_i(\mathbf{x}_p^*)\}$  (PEREIRA *et al.* 2017).

Com matriz *Payoff*  $\Phi$  pode-se formar a Evolutória Convexa de Mínimos Individuais (do inglês, *convex hull of individual mínima* - CHIM) a partir de combinações convexas de cada linha da matriz, sendo também a linha de utopia, que representa o melhor valor possível para uma das respostas (DAS e DENNIS, 1998), conforme representada na Figura 2.14, em que as distâncias “c” e “d” são pesos ou grau de importância dado para cada função objetivo e os pontos “a” e “b” são calculados a partir do peso atribuídos às funções objetivo.

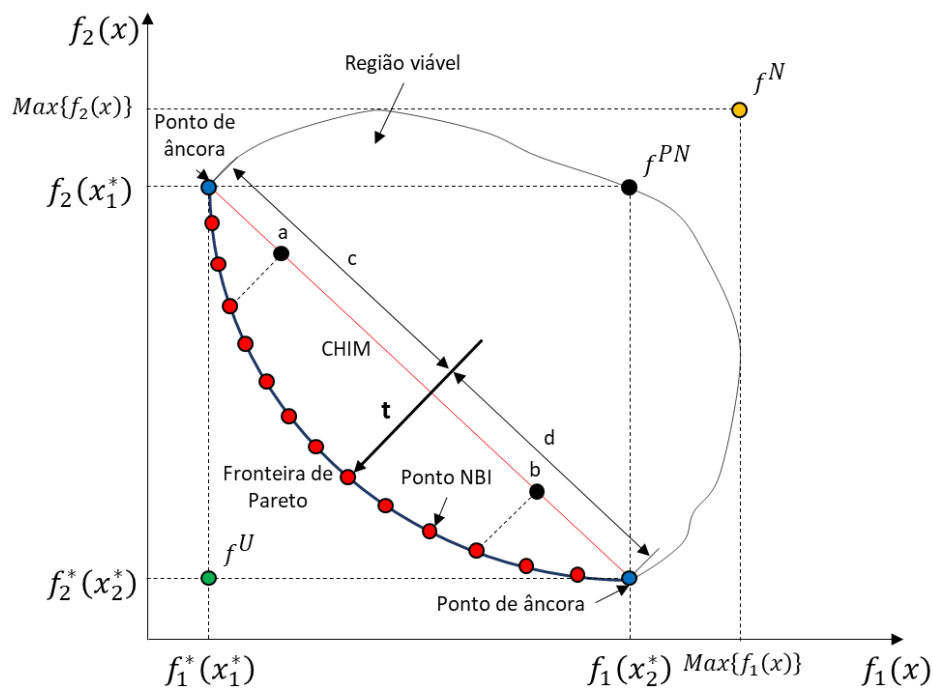


Figura 2.14 - Método da Interseção Normal à Fronteira (NBI) com unidades originais

Os pontos denominados de pontos de âncora são conectados pela linha CHIM e são definidos pelos mínimos individuais de cada função objetivo,  $f_1^*$ , ...,  $f_i^*$ , ...,  $f_m^*$ , determinando assim o vetor ótimo  $x_i^*$  (JIA e IERAPETRITOU, 2007).

Com os vetores de Utopia e Nadir é possível obter a normalização das funções objetivo de acordo com a Equação 2.23 (DUARTE COSTA *et al.* 2016), assim pode-se definir a CHIM de forma padronizada conforme representado na Figura 2.15.

$$\bar{f}(x) = \frac{f_i(x) - f_i^U}{f_i^N - f_i^U} \quad (2.23)$$

A utilização do método NBI para solucionar caso biobjetivo pode ser utilizada conforme Equação 2.24, em que  $w_1$  refere-se ao peso atribuído a primeira função objetivo, e  $w_1 + w_2 = 1$  e  $0 \leq w_i \leq 1$ ,  $i = 1, 2$  (LIM *et al.* 2001), sendo possível assim a representação gráfica conforme as Figura 2.14 e Figura 2.15.

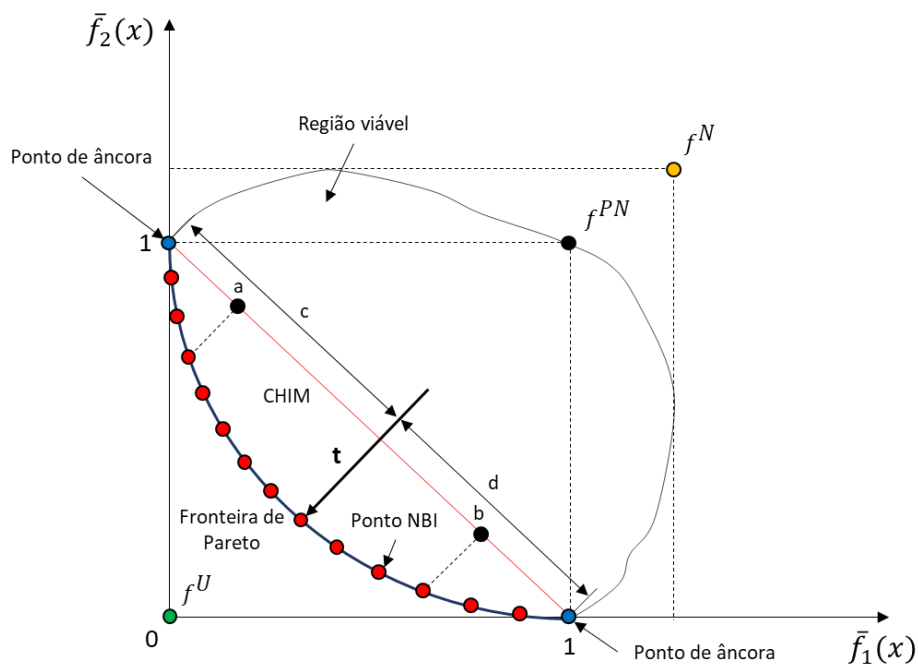


Figura 2.15 - Método da Interseção Normal à Fronteira (NBI) normalizado

$$\min_{(x \in \Omega)} f_2(\mathbf{x})$$

Sujeito a: (2.24)

$$f_2(x) - f_1(x) + 2w_1 - 1 = 0$$

### 2.3.2 Método da Restrição Normal Normalizada

O método da Restrição Normal Normalizado (do inglês, *normalized normal constraint* - NNC) foi proposto inicialmente por Messac *et al.* (2003) e consiste nos mesmos princípios do NBI, em que se analisa e determina o ponto ótimo entre respostas conflitantes pelo *trade-off*. Porém o NBI pode apresentar em sua resolução pontos que não pertencem a solução de Pareto, sendo assim sua principal diferença em relação ao método NNC.

Primeiramente, no método NNC, deve-se definir os pontos de âncora e o vetor do hiperplano de utopia das funções. A Equação 2.25 representa a formula de ligação entre o  $r$ -ésimo ponto de âncora  $\bar{f}_r^*$ ,  $r = 1, \dots, m-1$ , até o  $m$ -ésimo ponto de âncora  $\bar{f}_m^*$  (PEREIRA *et al.*, 2017).

$$\bar{N}_r = \bar{f}_m^* - \bar{f}_r^* \quad (2.25)$$

O número de pontos de soluções Pareto ótimas é determinado pelo incremento normalizado  $\delta_r$ , conforme descrito na Equação 2.26, em que o vetor  $\bar{N}_r$  é particionado em  $\eta_r - 1$  segmentos.

$$\delta_r = \frac{1}{\eta_r - 1} \quad (2.26)$$

A Equação 2.27 é utilizada para garantir a distribuição equidistante de um número desejado de pontos de soluções Pareto ótimas,  $\eta_1$ , ao longo do vetor  $\bar{N}_r$ . Essa função é aplicada uma vez que possa existir diferença entre as variáveis do *trade-off* de cada função objetivo, variando assim a distância entre os pontos de âncora da solução de Pareto (PEREIRA, 2017).

$$\eta_r = \frac{\eta_1 \|\bar{N}_r\|}{\|\bar{N}_1\|} \quad (2.27)$$

Os pontos no hiperplano de utopia são definidos a partir da combinação linear entre os pontos de âncora normalizados e o vetor de pesos,  $w_{ij}$ , que proporciona a importância para cada função objetivo. A Equação 2.28 representa o cálculo dos pontos no hiperplano de utopia segundo as restrições descritas nas Equações 2.29 e 2.30 (PEREIRA, 2017).

$$\bar{Q}_{ij} = \sum_{i=1}^m w_{ij} \times \bar{f}_i^* \quad (2.28)$$

$$0 \leq w_{ij} \leq 1 \quad (2.29)$$

$$\sum_{i=1}^m w_{ij} = 1 \quad (2.30)$$

O número de soluções ótimas de Pareto, segundo Das e Dennis (1998), para o problema de otimização multi-objetivo é determinado segundo a Equação 2.31, em que  $m$  representa o número de funções objetivos e  $\eta_r - 1$  é o intervalo do espaço  $\delta_r$  entre dois pesos consecutivos.

$$n_{sub} = \binom{m + \eta_r - 2}{\eta_r - 1} \quad (2.31)$$

Com cada ponto no plano de utopia definido  $\bar{Q}_{ij}$ ,  $j = 1, \dots, n_{sub}$ , o método NNC pode ser então resolvido para assim obter o ponto ótimo de Pareto associado. A Equação 2.32 representa a otimização pelo método NNC (MESSAC *et al.*, 2003).

$$\text{Min}_{(x \in \Omega)} \{ \bar{f}_m \}$$

Sujeito à: (2.32)

$$\bar{N}_r^T (\bar{f} - \bar{Q}_{ij}) \leq 0$$

A restrição descrita na Equação 2.32 representa o produto interno entre os vetores do hiperplano de utopia  $\bar{N}_r$  e o vetor  $\bar{f} - \bar{Q}_{ij}$ , em que o ponto  $\bar{Q}_{ij}$  no hiperplano de utopia é ligado a solução na fronteira de Pareto. Devido a isso a restrição é nomeada de restrição normal normalizada (MESSAC e MATTSON, 2013). Contudo, a restrição não é igualada a zero, mas sim menor ou igual a zero ( $\leq 0$ ), desse modo o vetor pode não ser ortogonal ao plano de utopia (PEREIRA, 2017).

A restrição normal normalizada tem a função de reduzir o espaço viável, a partir da definição de  $\bar{Q}_{ij}$ . A Figura 2.16 apresenta a redução do espaço amostral para o caso bi-objetivo. À medida com que o ponto  $Q_{ij}$  no plano de utopia vai variando, a região viável reduzida também vai se modificando em que um ponto diferente na fronteira de Pareto é obtido.

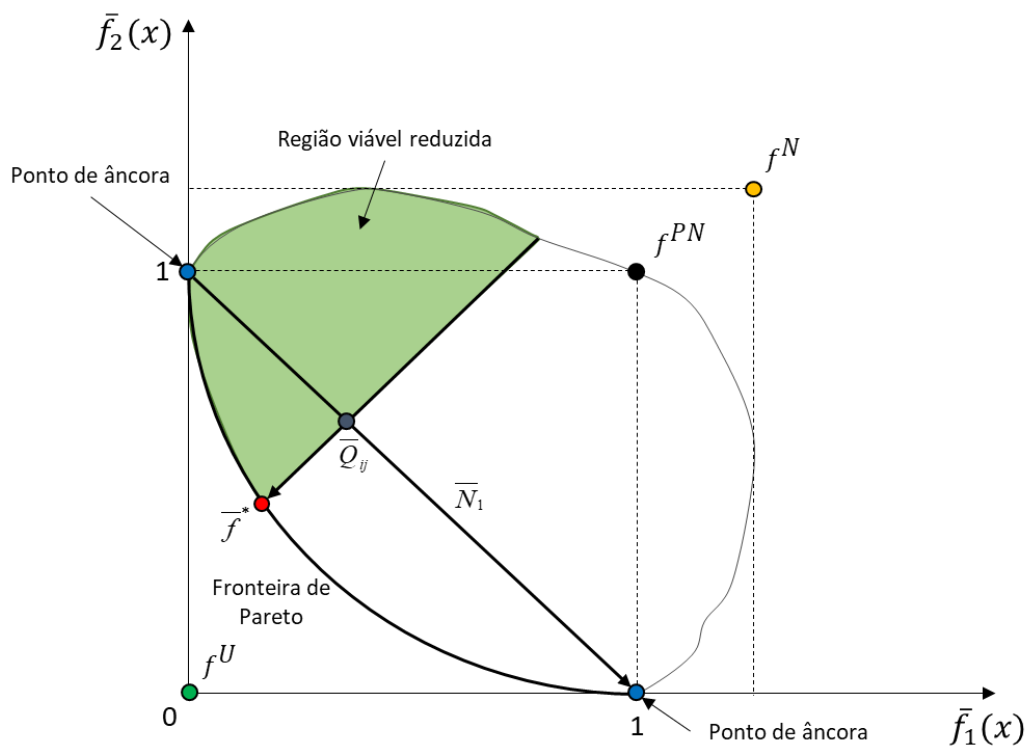


Figura 2.16 - NNC para problema bi-objetivo

## 2.4 Erro quadrático médio

Grande parte das indústrias possuem dois objetivos fundamentais para melhorar os seus resultados produtivos, a distância da média dos seus indicadores de processo em relação a meta em que foi estipulada ( $T$ ) e a variância dentro de cada indicador ( $\sigma^2$ ) (PAIVA *et al.*, 2009).

A variação da média e da variância ou desvio padrão do processo pode denota-lo como sendo preciso e acuras. O processo no qual sua média está próximo a meta estipulada é denominado de preciso, ou seja, tem capacidade de atender a determinada especificação ou valor. O processo no qual seu desvio padrão é mínimo é denominado de acuras, ou seja, os resultados do processo possuem pouca variação (BUSSAB e MORETTIN, 2017).

A Figura 2.17 representa a exemplificação das diferenças entre acurácia e precisão.

Para se alcançar melhores resultados nos objetivos de média e variância das respostas de processo, a superfície de resposta dupla (do inglês, *dual response surface - DRS*) pode atingir os valores propostos em cada objetivo. Para isso, superfícies de respostas de média ( $\omega_\mu$ ) e de variância ou desvio padrão ( $\omega_\sigma$ ) devem ser obtidas (PAIVA *et al.*, 2009).




Figura 2.17 - Comparativo entre processos (a) sem acurácia e sem precisão, (b) sem acurácia mas com precisão, (c) com acurácia mas sem precisão e (d) com acurácia e precisão

Lin e Tu (1995) descrevem que o ponto ótimo que atende os objetivos do DRS pode ser obtido pela função do erro quadrático médio (do inglês, *Mean Square Error - MSE*) representado pela Equação 2.33.

$$MSE = (\hat{\omega}_\mu - T)^2 + \hat{\omega}_\sigma^2 \quad (2.33)$$

Em que  $\hat{\omega}_\mu$  e  $\hat{\omega}_\sigma^2$  são superfícies de resposta para média e variância, respectivamente, e  $T$  é o valor alvo desejado para a média a ser alcançada. Para determinar o ponto ótimo entre a combinação entre média, variância e alvo, a Equação 2.33 deve ser minimizado (Paiva *et al.*, 2014). Onde o alvo é assumido como o maior ou menor valor possível nas otimizações de maximização ou minimização, respectivamente.

O MSE considera vieses e variância como termos-chave. Como os valores de respostas são obtidos através de experimentos e estimativas, o critério MSE permite uma distância do alvo e busca manter a variância baixa (Li e Tu, 1995).

O MSE é uma função que apresenta termos de quarta ordem, uma vez que ela é o desvio quadrático da média em relação ao seu alvo e somado com a variância, em que tanto a função de média e variância são funções quadráticas.

## 2.5 Análise de componentes principais

Processos de manufatura, principalmente processos contínuos, apresentam correlação entre as respostas de interesse, desse modo a utilização de métodos multivariados permite obter modelos de processos mais satisfatórios (PAIVA *et al.*, 2007).

A análise de componentes principais (do inglês, *principal component analysis - PCA*) é uma técnica estatística multivariada em que foi inicialmente desenvolvida por Pearson (1901) e posteriormente aprimorada por Hotelling (1933), em que denominou seu método de análise fatorial.

O PCA tem como principal objetivo descrever a variabilidade existente em um grupo de variáveis correlacionadas por suas componentes principais, permitindo assim reduzir possíveis redundâncias (CHUERUBIM e DA SILVA, 2018). Abdi e Williams



(2010) destacam que a PCA é aplicada em diversos campos da ciência como uma técnica de análise intermediária para a investigação de grandes conjuntos de dados.

A PCA é a geração de variáveis latentes que representam um conjunto de variáveis originais relacionadas em que as variáveis latentes geradas são não-correlacionadas. As variáveis latentes são geradas por combinações lineares em que o número de combinações é igual ao número de variáveis originais. Analisando geometricamente, isso permite que haja uma rotação rígida dos eixos de coordenadas, de forma que os novos eixos se posicionem no sentido de maior variabilidade (FERREIRA, 2011).

A definição dos valores dos componentes principais é baseada na matriz de covariâncias gerada a partir do conjunto das variáveis originais. Os componentes principais são ordenados de forma decrescente em relação às suas variâncias.

Em conjuntos de dados com  $p$  variáveis relacionadas, se tem  $p$  variáveis latentes, que a primeira variável latente é a combinação linear com maior variância, a segunda variável latente é a combinação linear de segunda maior variância e assim sucessivamente até a  $p$ -ésima variável latente que possui a menor variância.

Após a definição e ordenação das variáveis latentes, um critério deve ser adotado de forma a reter apenas algumas das variáveis que possam representar grande porção da variação total. Dessa forma tem-se selecionado  $k < p$  variáveis que explica grande parte da variação total.

### 2.5.1 Definição e classificação dos componentes principais

Um conjunto de dados com  $p$  variáveis  $X_1, X_2, \dots, X_p$ , com médias  $\mu_1, \mu_2, \dots, \mu_p$  e variâncias  $\sigma_1, \sigma_2, \dots, \sigma_p$  em que suas variáveis são correlacionadas, existindo assim covariância não nula entre a  $i$ -ésima e  $k$ -ésima variável definida como  $\sigma_{ik}$ , em que  $i \neq k = 1, 2, \dots, p$  pode ser escrito da forma vetorial como  $\mathbf{X} = [X_1, X_2, \dots, X_p]^T$  para o conjunto de  $p$  variáveis,  $\boldsymbol{\mu} = [\mu_1, \mu_2, \dots, \mu_p]^T$  para o conjunto de médias e  $\boldsymbol{\Sigma}$  para matriz de covariâncias expressada como

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{21} & \sigma_2^2 & \cdots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \cdots & \sigma_p^2 \end{bmatrix}$$

Em que a diagonal principal da matriz  $\Sigma$  é composta pelas variâncias. Com isso, a  $i$ -ésima componente principal pode ser definida conforme a Equação 2.34.

$$\mathbf{Y}_i = \mathbf{e}_i^T \mathbf{X} = e_{i1}X_1 + e_{i2}X_2 + \dots + e_{ip}X_p \quad (2.34)$$

Em que  $\mathbf{e}_i$  é a  $i$ -ésima combinação linear, para  $i = 1, 2, \dots, p$ . A variância de  $Y_i$  e a covariância entre  $Y_i$  e  $Y_k$  ( $i \neq k$ ) são definidos conforme as Equações 2.35 e 2.36, respectivamente.

$$\text{Var}(Y_i) = \text{Var}(\mathbf{e}_i^T \mathbf{X}) = \mathbf{e}_i^T \text{Var}(\mathbf{X}) \mathbf{e}_i = \mathbf{e}_i^T \Sigma \mathbf{e}_i \quad (2.35)$$

$$\text{Cov}(Y_i, Y_k) = \text{Cov}(\mathbf{e}_i^T \mathbf{X}, \mathbf{e}_k^T \mathbf{X}) = \mathbf{e}_i^T \text{Var}(\mathbf{X}) \mathbf{e}_k = \mathbf{e}_i^T \Sigma \mathbf{e}_k \quad (2.36)$$

Para definição dos componentes principais deve-se buscar a maximização de sua variância. Porém conforme cresce os componentes do vetor  $\mathbf{e}_i$ , a variância tenderá ao infinito. Para solucionar essa questão, a restrição da soma ao quadrado dos coeficientes dos vetores seja igual a unidade deve ser imposta. Aplicando o conceito de Lagrangeana na maximização da variância  $\text{Var}(Y_i) = \mathbf{e}_i^T \Sigma \mathbf{e}_i$  tem-se a Equação 2.37.

$$\text{Max}_{\mathbf{e}_i} \left[ \mathbf{e}_i^T \Sigma \mathbf{e}_i - \lambda_i (\mathbf{e}_i^T \mathbf{e}_i - 1) \right] \quad (2.37)$$

Sujeito à:

$$\mathbf{e}_i^T \mathbf{e}_i = 1$$

Em que  $\lambda_i$  é o multiplicador de Lagrange. Para maximizar a função resultante, deriva-se a função em relação a  $\mathbf{e}_i$  e iguala-se a equação a zero, chegando-se a Equação 2.38.

$$\begin{aligned}
L\{\mathbf{e}_i, \lambda\} &= \mathbf{e}_i^T \boldsymbol{\Sigma} \mathbf{e}_i - \lambda_i (\mathbf{e}_i^T \mathbf{e}_i - 1) \\
\frac{\partial^2 L\{\mathbf{e}_i, \lambda\}}{\partial \mathbf{e}_i} &= 2\mathbf{e}_i \boldsymbol{\Sigma} - 2\mathbf{e}_i \lambda_i = 0 \\
(\boldsymbol{\Sigma} - \lambda_i \mathbf{I}) \mathbf{e}_i &= 0
\end{aligned} \tag{2.38}$$

Sendo  $\mathbf{I}$  a matriz identidade de  $p \times p$ . Baseado na Equação 2.38 pode-se chegar na Equação 2.39.

$$\boldsymbol{\Sigma} \mathbf{e}_i = \lambda_i \mathbf{e}_i \tag{2.39}$$

A definição das componentes principais são obtidas a partir dos autovetores e autovalores de  $\boldsymbol{\Sigma}$ , em que os autovalores  $\lambda_i (i=1,2,\dots,p)$  são as variâncias dos componentes principais e os autovetores  $\mathbf{e}_i (i=1,2,\dots,p)$  representam o sentido de rotação conforme descrito na Equação 2.39. Dessa forma pode-se ordenar os autovalores de forma decrescente  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$  e  $Y_1 = \mathbf{e}_1^T \mathbf{X}, Y_2 = \mathbf{e}_2^T \mathbf{X}, \dots, Y_p = \mathbf{e}_p^T \mathbf{X}$  sendo suas respectivas componentes principais.

A partir da Equação 2.39 pode-se definir a variância e covariância dos componentes principais conforme as Equações 2.40 e 2.41, respectivamente.

$$Var(Y_i) = \mathbf{e}_i^T \boldsymbol{\Sigma} \mathbf{e}_i = \mathbf{e}_i^T \lambda_i \mathbf{e}_i = \lambda_i \mathbf{e}_i^T \mathbf{e}_i = \lambda_i \tag{2.40}$$

$$Cov(Y_i, Y_k) = \mathbf{e}_i^T \boldsymbol{\Sigma} \mathbf{e}_k = \mathbf{e}_i^T \lambda_k \mathbf{e}_k = \lambda_k \mathbf{e}_i^T \mathbf{e}_k = 0 \tag{2.41}$$

Em que  $\mathbf{e}_i$  e  $\mathbf{e}_k$  são ortogonais e  $i \neq k$ , justificando o valor de zero para covariância.

Johson e Wichern (1998) realizaram a decomposição espectral da matriz  $\boldsymbol{\Sigma}$ , em que  $\boldsymbol{\Sigma} = \mathbf{P} \boldsymbol{\Lambda} \mathbf{P}^T$ ,  $\mathbf{P}$  e  $\boldsymbol{\Lambda}$  são as matrizes de autovetores e autovalores de  $\boldsymbol{\Sigma}$ , respectivamente, concluído que:

$$tr(\Sigma) = tr(\mathbf{P}\Lambda\mathbf{P}^T) = tr(\Lambda\mathbf{P}\mathbf{P}^T) = tr(\Lambda\mathbf{I}) = tr(\Lambda) = \sum_{i=1}^p \lambda_i \quad (2.42)$$

Sabendo-se que:

$$tr(\Sigma) = \sum_{i=1}^p \sigma_i^2 \quad (2.43)$$

Então:

$$\sum_{i=1}^p \lambda_i = \sum_{i=1}^p \sigma_i^2 \quad (2.44)$$

Assim pode-se afirmar que a variabilidade total das variáveis originais é igual à variabilidade total dos componentes principais.

Para se justificar a utilização dos componentes principais deve-se selecionar  $k < p$  componentes que represente grande parte da variância do conjunto de variáveis originais. Johnson e Wichern (1998) adotaram o critério de que o número de componentes retirados deve explicar no mínimo 80% da variação total.

O percentual de explicação de cada componente pode ser expressada conforme a Equação 2.45.

$$P_k^2 = \frac{\lambda_k}{\sum_{i=1}^p \sigma_i^2} \times 100 \quad (2.45)$$

E o percentual de explicação acumulado dos  $k$  componentes pode ser expressados conforme a Equação 2.46.

$$\rho_k^2 = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^p \sigma_i^2} \times 100 \quad (2.46)$$

Considerando que o vetor componente principal  $\mathbf{Y} = [Y_1, Y_2, \dots, Y_p]^T$  pode ser obtido conforme a Equação 2.47, em que  $\mathbf{P}$  é ortogonal, então é possível de se identificar o vetor variáveis originais  $\mathbf{X}$  pela transformação não linear descrita na Equação 2.48.

$$\mathbf{Y} = \mathbf{P}^T \mathbf{X} \quad (2.47)$$

$$\mathbf{X} = \mathbf{P} \mathbf{Y} \quad (2.48)$$

Com o número definido de componentes principais a ser considerado, tal que  $k < p$ , onde  $\mathbf{Y} = [Y_1, Y_2, \dots, Y_k]^T$  tem-se que a determinação dos componentes principais é então obtida conforme a Equação 2.49.

$$\mathbf{Y} = \mathbf{P}_k^T \mathbf{X} \quad (2.49)$$

A partir da redução dos componentes principais pode-se recuperar as observações originais, porém com apenas algum grau de precisão, dependendo de quanto o modelo se ajustou à matriz de covariâncias. As variáveis originais podem ser preditas conforme a Equação 2.50.

$$\tilde{\mathbf{X}} = \mathbf{P}_k \mathbf{Y} \quad (2.50)$$

Considerando que a covariância do vetor  $\mathbf{Y}$  ( $p \times 1$ ) pode ser obtida conforme Equação 2.51, a covariância do modelo parcimonioso dos componentes principais  $k < p$  é então obtida conforme Equação 2.52.

$$Cov(\mathbf{Y}) = Cov(\mathbf{P}^T \mathbf{X}) = \mathbf{P}^T Cov(\mathbf{X}) \mathbf{P} = \mathbf{P}^T \Sigma \mathbf{P} = \mathbf{P}^T \mathbf{P} \Lambda \mathbf{P}^T \mathbf{P} = \Lambda \quad (2.51)$$

$$Cov(\mathbf{Y}) = Cov(\mathbf{P}_k^T \mathbf{X}) = \mathbf{P}_k^T Cov(\mathbf{X}) \mathbf{P}_k = \mathbf{P}_k^T \Sigma \mathbf{P}_k = \mathbf{P}_k^T \mathbf{P} \Lambda \mathbf{P}^T \mathbf{P}_k = \Lambda_k \quad (2.52)$$

Em que:

$$\Lambda_k = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_k \end{bmatrix}$$

Algumas vezes os conjuntos de variáveis originais possuem unidades de medidas diferentes, o que pode provocar grandes distâncias na análise de componentes principais. Com isso, opta-se na maioria das vezes utilizar os componentes principais padronizados. A padronização das escalas dos componentes principais é obtida conforme a Equação 2.53.

$$\mathbf{Y}^* = \Lambda^{-1/2} \mathbf{P}^T (\mathbf{X} - \boldsymbol{\mu}) = \begin{bmatrix} \frac{\sum_{i=1}^p e_{1i} (X_i - \mu_i)}{\sqrt{\lambda_1}} \\ \frac{\sum_{i=1}^p e_{2i} (X_i - \mu_i)}{\sqrt{\lambda_2}} \\ \vdots \\ \frac{\sum_{i=1}^p e_{pi} (X_i - \mu_i)}{\sqrt{\lambda_p}} \end{bmatrix} \quad (2.53)$$

A média dos componentes principais padronizados é nula  $E(\mathbf{Y}^*) = 0$  e covariância igual a identidade  $Cov(\mathbf{Y}^*) = \mathbf{I}$ .

A definição da covariância entre o vetor das variáveis originais e os componentes principais é obtida conforme Equação 2.54.

$$\text{Cov}(\mathbf{Y}, \mathbf{X}) = \text{Cov}(\mathbf{P}^T \mathbf{X}, \mathbf{X}) = \mathbf{P}^T \text{Cov}(\mathbf{X}) = \mathbf{P}^T \boldsymbol{\Sigma} = \boldsymbol{\Lambda} \mathbf{P}^T \quad (2.54)$$

Baseado na Equação 2.54 pode-se determinar a matriz de correlação entre o vetor de componentes principais e o vetor de variáveis originais conforme Equação 2.55.

$$\rho_{\mathbf{Y}, \mathbf{X}} = \boldsymbol{\Lambda}^{-1/2} \boldsymbol{\Lambda} \mathbf{P}^T \mathbf{V}^{-1/2} = \boldsymbol{\Lambda}^{1/2} \mathbf{P}^T \mathbf{V}^{-1/2} \quad (2.55)$$

Sendo  $\mathbf{V}$  é a matriz diagonal das variâncias originais  $\mathbf{V} = \text{diag}(\sigma_i^2)$ . O coeficiente de correlação entre  $\mathbf{Y}_i$  e  $\mathbf{Y}_k$  está presente na  $i$ -ésima linha e  $k$ -ésima coluna da matriz de correlação  $\rho_{\mathbf{Y}, \mathbf{X}}$  e sua forma escalar dada conforme Equação 2.56.

$$\rho_{Y_i, X_i} = \frac{\sqrt{\lambda_i} e_{ik}}{\sqrt{\sigma_k^2}} \quad (2.56)$$

### 3. PROCEDIMENTO EXPERIMENTAL

Todos os experimentos foram realizados no laboratório de usinagem da madeira do departamento de Ciências Florestais da Universidade Federal de Lavras (UFLA) situada na cidade de Lavras, Minas Gerais. Os corpos de prova também foram preparados no laboratório de usinagem da madeira e conservados na câmara climática para que mantivessem suas características necessárias de umidade.

Todas as coletas de dados foram realizadas de forma *on-line*, ou seja, durante o processo de experimentação. A comunicação entre os inversores e o microcomputador foram realizadas pela *interface serial RC-232 PC/Drive* e registrado no *software SuperDrive*. Foram utilizados os programas *Microsoft Excel*, *Minitab* e *Matlab* para análise dos dados após a coleta.

#### 3.1 Plaina desempenadeira

Na Figura 3.1 é demonstrado a plaina desempenadeira utilizada para os experimentos e suas respectivas características.




Figura 3.1 - (i) duto do exaustores, (ii) ajuste de altura do carrinho de avanço, (iii) liga-desliga do motor de avanço, (iv) carrinho de avanço, (v) motor, (vi) cabeçote das facas de corte, (vii) liga-desliga e ajuste do rpm do motor, (viii) ajuste da rotação do motor do cabeçote das facas de corte e (ix) mesa suporte



A plaina é da marca OMIL de modelo DES 400. O cabeçote é composto por 3 facas novas de corte. O setup de preparação da máquina é descrito conforme o diagrama da Figura 3.2.

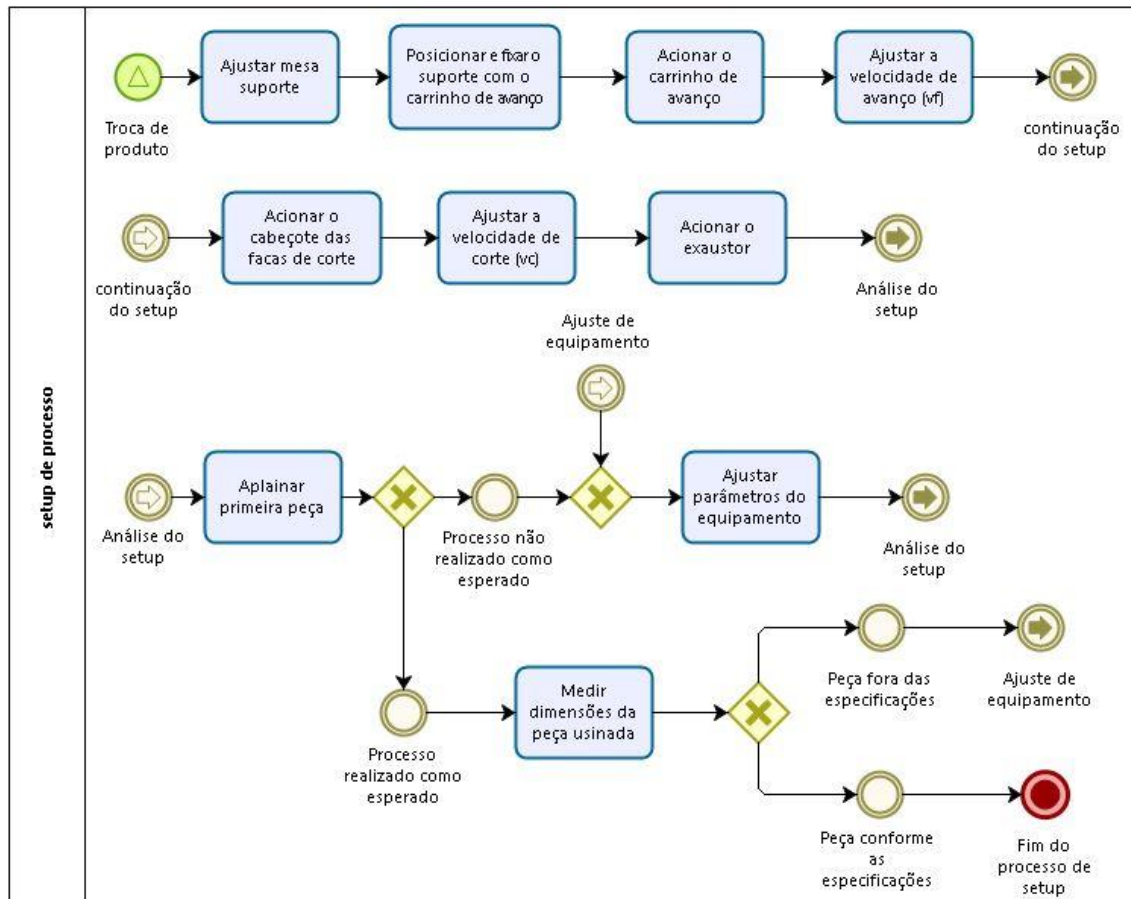


Figura 3.2 - Sequência de atividades de setup do processo de aplainamento da madeira

### 3.2 Respostas avaliadas, variáveis de controle e de ruído

As respostas ( $Y$ ) consideradas nesse trabalho foram de:

- corrente em A;
- tensão em V;
- torque em  $N \times m$ ;
- potência mecânica em kW;
- energia consumida em kJ;
- $E_s$  em  $kJ \times cm^{-3}$

- $h_m$  em mm.

As respostas de corrente, tensão e torque eram coletadas e registradas de forma contínua a cada segundo com o equipamento em funcionamento. Desse modo o valor registrado em cada corrida de experimentos representa a média das mesmas durante o momento em que a peça está sendo aplainada. As demais respostas foram obtidas a partir de cálculos entre os dados coletados e parâmetros definidos para o processo de aplainamento.

As respostas analisadas visam otimizar o processo de aplainamento de forma a torna-lo mais sustentável, produtivo, alta qualidade superficial da madeira e menor custo de processos. A Figura 3.3 representa a associação entre as respostas analisadas e os objetivos.

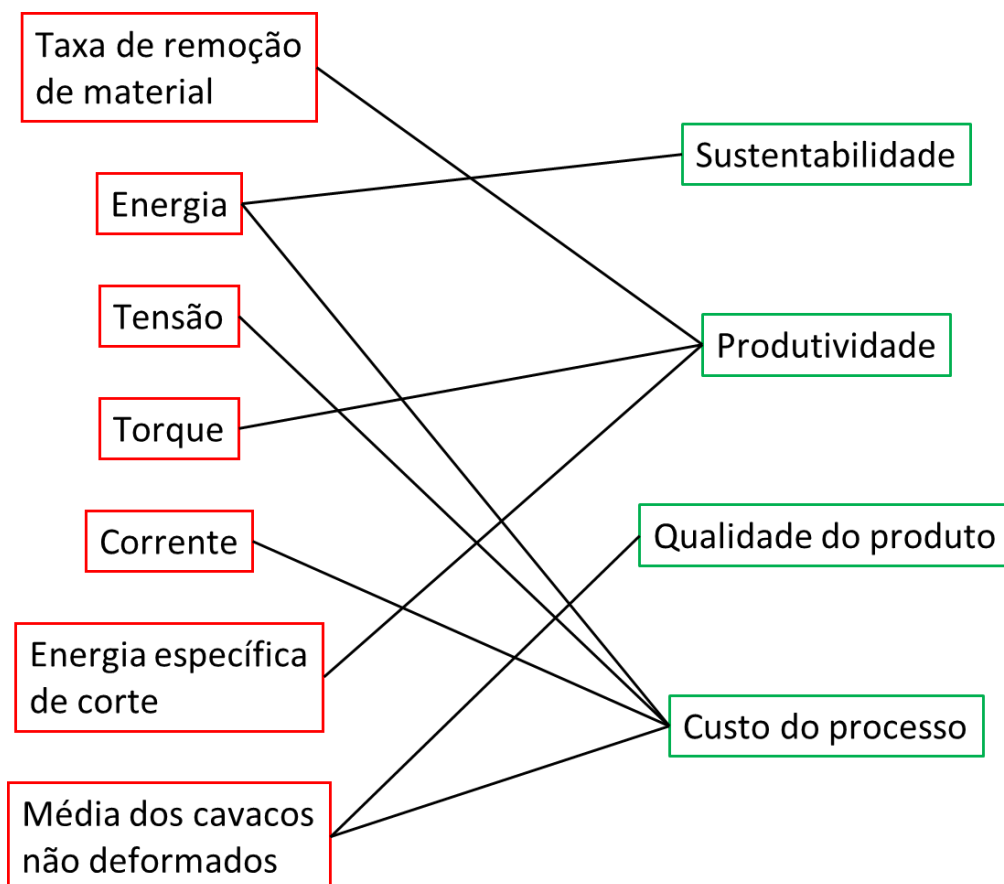


Figura 3.3 - Relação entre respostas do processo e objetivos

As variáveis de controle (**X**) definidas foram:

- velocidade de corte ( $v_c$ ) em  $m \times s^{-1}$ ;
- velocidade de avanço ( $v_f$ ) em  $m \times min^{-1}$ ;

- penetração de trabalho ( $a_e$ ) em mm.

Essas variáveis são importantes pois são capazes de influenciar na produtividade, na geração de cavacos, na qualidade da superfície usinada, no consumo de energia, entre outros.

A variável de ruído ( $Z$ ) do processo a ser minimizada é a umidade presente no corpo de prova. A umidade da madeira foi considerada uma variável de ruído por ser uma difícil de manter seu nível de umidade após o processo de secagem e mantida em estoque a espera de ser processada. Diferentes ambientes fazem oscilar a umidade presente na madeira.

A minimização do efeito da umidade poderia permitir a redução do uso de secagem da matéria-prima, pois minimizando seus efeitos no processo de aplainamento a secagem não precisaria ser rigorosa.

A Tabela 3.1 representa os valores adotados para as variáveis de controle e ruído, definidos com base na literatura, experimentos de pré-teste e orientações segundo o fabricante do equipamento.

Tabela 3.1 - Variáveis de controle e ruído com seus respectivos níveis

Variáveis de controle		Níveis					Unidade
		-2	-1	0	1	2	
$x_1$	$v_c$	8,25	11,00	13,75	16,50	19,25	$m \times s^{-1}$
$x_2$	$v_f$	2,25	3,50	4,75	6,00	7,25	$m \times \text{min}^{-1}$
$x_3$	$a_e$	0,5	1,0	1,5	2,0	2,5	mm
Variável de ruído							Unidade
$z_1$	umidade	-	Úmida	Ambiente	Seca	-	%

Em que úmida representa 100%, ambiente 50% e seca 0% de teor de umidade presente no corpo de prova usinado.

### 3.3 Planejamento experimental

Baseado na Metodologia de Superfície de Resposta (RSM) com a utilização do Arranjo Composto Central (CCD) para geração de modelo de segunda ordem e assim obtendo uma superfície de resposta foram realizadas 30 corridas experimentais. Sendo que dezesseis são experimentos de fatorial completo ( $n_f = 2^k = 2^4$ ), oito pontos centrais e

seis pontos axiais ( $n_a = 2k = 2 \times 3$ ) em que os dois pontos axiais referente a variável de ruído são retirados. Os experimentos foram aleatorizados de forma que variáveis não consideradas fossem diluídas entre os resultados.

Para analisar a significância de cada variável de controle e de ruído e suas interações o método dos mínimos quadrados foi utilizado, permitindo também um modelo para cada resposta analisada.

## 4. RESULTADOS E DISCUSSÃO

A Tabela 4.1 descreve os resultados dos experimentos de aplainamento da madeira *Pinus taeda*. Os experimentos foram conduzidos conforme o planejamento composto central combinando as variáveis de controle e de ruído.

Tabela 4.1 - Planejamento experimental com respostas

Ordem padrão	Variáveis de controle			Ruído	Respostas						
	$v_c$	$v_f$	$a_e$	$u$	$C$	$U$	$M$	$P$	$W$	$E_s$	$h_m$
	[m×s <sup>-1</sup> ]	[m×min <sup>-1</sup> ]	[mm]	-	[A]	[V]	[N×m]	[kW]	[kJ]	[kJ×cm <sup>-3</sup> ]	[mm]
1	11,00	3,50	1,0	-1	6,09	126,96	16,70	3,59	30,79	0,2970	0,0261
2	16,50	3,50	1,0	-1	6,95	189,31	20,85	6,71	57,50	0,4965	0,0174
3	11,00	6,00	1,0	-1	6,84	129,42	20,96	4,55	22,76	0,3764	0,0447
4	16,50	6,00	1,0	-1	7,08	190,18	21,21	6,83	34,15	0,5646	0,0298
5	11,00	3,50	2,0	-1	6,68	128,63	19,66	4,26	36,50	0,3522	0,0369
6	16,50	3,50	2,0	-1	6,83	188,71	19,89	6,39	54,80	0,5284	0,0246
7	11,00	6,00	2,0	-1	7,22	130,29	23,89	5,21	26,06	0,4307	0,0632
8	16,50	6,00	2,0	-1	7,43	191,64	23,89	7,71	38,55	0,6373	0,0421
9	11,00	3,50	1,0	1	6,13	126,63	14,42	3,09	26,52	0,2558	0,0261
10	16,50	3,50	1,0	1	7,74	190,38	25,61	8,28	70,98	0,4612	0,0174
11	11,00	6,00	1,0	1	6,98	129,20	21,62	4,70	23,48	0,3884	0,0447
12	16,50	6,00	1,0	1	6,77	187,70	18,83	6,05	30,24	0,5001	0,0298
13	11,00	3,50	2,0	1	7,25	130,09	25,23	5,52	47,29	0,4561	0,0369
14	16,50	3,50	2,0	1	7,67	190,95	25,16	8,13	69,73	0,6725	0,0246
15	11,00	6,00	2,0	1	8,67	135,00	32,39	7,18	35,92	0,5936	0,0632
16	16,50	6,00	2,0	1	8,27	192,20	29,51	9,57	47,87	0,7913	0,0421
17	8,25	4,75	1,5	0	7,77	102,13	28,24	4,72	29,82	0,3903	0,0578

18	19,25	4,75	1,5	0	6,51	201,50	20,35	7,63	48,20	0,6310	0,0248
19	13,75	2,25	1,5	0	6,71	159,96	19,16	5,20	69,29	0,4117	0,0164
20	13,75	7,25	1,5	0	7,83	163,30	26,39	7,23	29,91	0,5977	0,0529
21	13,75	4,75	0,5	0	5,85	156,19	13,03	3,49	22,06	0,2888	0,0200
22	13,75	4,75	2,5	0	8,49	165,71	32,02	8,83	55,79	0,7307	0,0448
23	13,75	4,75	1,5	0	6,62	157,67	18,15	4,85	30,66	0,4015	0,0347
24	13,75	4,75	1,5	0	6,47	156,33	17,75	4,74	29,95	0,3919	0,0347
25	13,75	4,75	1,5	0	6,59	156,71	17,83	4,77	30,13	0,3948	0,0347
26	13,75	4,75	1,5	0	6,45	156,83	16,65	4,46	28,15	0,3961	0,0347
27	13,75	4,75	1,5	0	6,75	158,64	19,44	5,21	32,88	0,4307	0,0347
28	13,75	4,75	1,5	0	6,90	158,50	20,92	5,61	35,43	0,4637	0,0347
29	13,75	4,75	1,5	0	6,98	158,11	20,15	5,41	34,19	0,4475	0,0347
30	13,75	4,75	1,5	0	7,00	146,99	21,31	5,29	33,39	0,4378	0,0347

---

A corrente utilizada pelo equipamento de aplainamento apresentou variação de 5,85 A à 8,67 A, com desvio padrão de 0,683 A. Para tensão, os valores oscilaram entre 102,13 V a 201,50 V, com desvio padrão de 26,286 V. Quanto ao torque, que representa a força utilizada pelo equipamento para a execução do aplainamento, apresentou variação entre 13,03 N×m à 32,39 N×m, com desvio padrão de 4,739 N×m.

Quanto à potência mecânica, valores entre 3,09 kW a 9,57 kW foram obtidos com um desvio padrão de 1,646 kW. A energia consumida pelo equipamento durante o aplainamento oscilou entre 22,06 kJ a 70,98 kJ, com desvio padrão de 14,271 kJ. A energia específica de corte foi obtida entre o intervalo de 0,1303 kJ×cm<sup>-3</sup> a 0,7098 kJ/cm<sup>3</sup>, com desvio padrão de 0,1253 kJ × cm<sup>-3</sup>. Para a resposta de  $h_m$  foi obtido resultado de 0,0164 mm a 0,0632 mm com desvio padrão de 0,0125 mm.

Este trabalho apresenta a análise individual e conjunta das respostas de aplainamento.

Para a análise individual das respostas foi identificado interações significativas além de analisar os resíduos dos experimentos. As respostas que apresentaram efeitos significativos para a variável de ruído foram definidas a elas a média e a variância que minimizam o efeito da variável de ruído. Posteriormente foi identificado a fronteira de Pareto e realizado a otimização multi-objetivo de cada resposta para suas respectivas funções de média e a variância. As respostas que não apresentaram efeitos significativos para a variável de ruído foram realizadas a otimização da equação de resposta.

Para a análise conjunta das respostas foi aplicado o método de estatística multivariada WPC. Através do WPC foi identificado as variáveis significativas e interações. Como a variável de ruído foi significativa, foi definido as equações de média e variância que minimizam os efeitos dessa variável. Posteriormente foi identificado a fronteira de Pareto e realizado a otimização multi-objetivo. A fim de comprovar os resultados obtidos, experimentos de confirmação foram realizados com a definição das variáveis de controle que otimizam o aplainamento.

#### **4.1 Corrente utilizada no aplainamento da madeira *Pinus taeda***

A Figura 4.1 representa o gráfico de Pareto para a resposta de corrente. Pode-se observar que as variáveis de controle de profundidade de penetração ( $a_e$ ), velocidade de

corrente consumida pelo equipamento.




Figura 4.1 - Gráfico de Pareto para corrente

A Figura 4.2 apresenta o gráfico de efeitos lineares e quadráticos para a resposta corrente. Pode-se observar que para  $v_c$  e  $v_f$  apresentaram convexidade voltada para baixo, ou seja, menores valores de corrente são obtidos quando se utiliza valores próximos aos seus pontos centrais. Já valores menores de  $a_e$  proporcionam menores valores de corrente. Em relação a  $u$ , quanto maior é o percentual de  $u$  presente na madeira menor é a corrente necessária para o aplainamento.




Figura 4.2 - Gráfico de efeitos lineares e quadráticos para corrente



A Figura 4.3 apresenta os gráficos de interações entre as variáveis de controle e ruído. Pode-se observar que nenhuma das interações são significativas para a resposta de corrente, pois as curvas de cada variável não modificam sua direção quando alterado o valor da variável analisada em conjunto.




Figura 4.3 - Gráfico de interação para corrente

O modelo de resposta da corrente, obtido por WLS, é representado conforme Equação 4.1. O erro experimental para o modelo de resposta da corrente é de  $\hat{\sigma}_c^2 = 0,1834$  e os coeficientes de determinação são de  $R_{aj}^2 = 60,59\%$  e  $R_{prev}^2 = 0,00\%$ . Apesar do modelo não ter capacidade de previsão, o mesmo apresentou distribuição normal para os resíduos, assim foi utilizado o modelo para análise nos experimentos de confirmação.

$$\begin{aligned}
 C(\mathbf{x}, \mathbf{z}) = & 6,737 + 0,0141 \times v_c + 0,2551 \times v_f + 0,4467 \times a_e + 0,272 \times u + 0,1181 \times v_c^2 \\
 & + 0,1495 \times v_f^2 + 0,1245 \times a_e^2 - 0,201 \times v_c \times v_f - 0,133 \times v_c \times a_e - 0,002 \times v_c \times u \\
 & + 0,151 \times v_f \times a_e - 0,009 \times v_f \times u + 0,191 \times a_e \times u
 \end{aligned} \quad (4.1)$$

A Tabela 4.2 apresenta a ANOVA para a resposta de corrente. Com nível de significância de  $\alpha = 0,05$  pode-se confirmar os resultados apresentados na Figura 4.1, em que os efeitos lineares de  $a_e$ ,  $v_f$  e  $u$  foram significativos com  $p\text{-valor} < \alpha$ , conforme

destacado na Tabela 4.2, sendo todos positivos conforme os coeficientes apresentados na Equação 4.1. Dessa forma pode-se verificar que à medida que  $a_e$ ,  $v_f$  e  $u$  aumentam, a corrente necessária para o aplainamento também aumenta, confirmando assim os resultados apresentados pela Figura 4.2.

Quanto aos efeitos quadráticos, nenhum apresentou efeito significativo, ou seja, todos possui  $p\text{-valor} > \alpha$ . Os efeitos de interação também não foram significativos conforme apresentado na Figura 4.3, apresentando também  $p\text{-valor} > \alpha$ .

Tabela 4.2 - ANOVA para corrente

FV	GL	SQ	MQ	F-valor	P-valor
Modelo	13	10,5802	0,81386	4,43	<b>0,003</b>
Linear	4	7,5415	1,88537	10,26	<b>0,000</b>
$v_c$	1	0,0048	0,00480	0,03	0,874
$v_f$	1	1,5622	1,56216	8,50	<b>0,010</b>
$a_e$	1	4,7896	4,78962	26,07	<b>0,000</b>
$u$	1	1,1849	1,18491	6,45	<b>0,022</b>
Quadrado	3	1,1654	0,38845	2,11	0,139
$v_c \times v_c$	1	0,3903	0,39029	2,12	0,164
$v_f \times v_f$	1	0,6259	0,62590	3,41	0,084
$a_e \times a_e$	1	0,4339	0,43387	2,36	0,144
Interações	6	1,8734	0,31223	1,70	0,185
$v_c \times v_f$	1	0,6447	0,64474	3,51	0,079
$v_c \times a_e$	1	0,2828	0,28282	1,54	0,233
$v_c \times u$	1	0,0000	0,00004	0,00	0,988
$v_f \times a_e$	1	0,3628	0,36277	1,97	0,179
$v_f \times u$	1	0,0012	0,00118	0,01	0,937
$a_e \times u$	1	0,5818	0,58182	3,17	0,094
Erro	16	2,9398	0,18374		
Falta de ajuste	9	2,5956	0,28840	5,87	0,015
Erro Puro	7	0,3442	0,04917		
Total	29	13,5200			
$S$	$R^2$	$R_{aj}^2$	$R_{prev}^2$		
0,42865	78,26%	60,59%	0,00%		

As Equações 2.20 e 2.21 são as equações de média e variância, respectivamente, que minimizam o efeito gerado pela umidade da madeira sobre a corrente. A Figura 4.4 são as superfícies de resposta geradas a partir das equações de média e variância.

$$E[C(\mathbf{x}, \mathbf{z})] = 6,7368 + 0,0141 \times v_c + 0,2551 \times v_f + 0,4467 \times a_e + 0,1181 \times v_c^2 + 0,1495 \times v_f^2 + 0,1245 \times a_e^2 - 0,2007 \times v_c \times v_f - 0,1330 \times v_c \times a_e + 0,1506 \times v_f \times a_e \quad (4.2)$$

$$\text{Var}[C(\mathbf{x}, \mathbf{z})] = 0,2578 - 0,0009 \times v_c - 0,0047 \times v_f + 0,1038 \times a_e + 3 \times 10^{-6} \times v_c^2 + 0,0001 \times v_f^2 + 0,0364 \times a_e^2 + 3 \times 10^{-5} \times v_c \times v_f - 0,0006 \times v_c \times a_e - 0,0033 \times v_f \times a_e \quad (4.3)$$




Figura 4.4 - Superfície de resposta para corrente,  $\mathbf{X}_{fixo} = \mathbf{X}_{CtPt}$

$E[C]$  apresenta em seus autovalores de sinais positivos  $\lambda_{E[C]} = [0,2946; 0,0653; 0,0321]^T$ , logo a função da média da resposta  $C$  apresenta convexidade voltada para cima, contendo assim um ponto de mínimo ótimo. Já  $Var[C]$  apresenta autovalores de sinais mistos  $\lambda_{Var[C]} = [0,0364; -4,24 \times 10^{-22}; -4,24 \times 10^{-22}]^T$ , sendo então a função da variância da resposta  $C$  é uma sela em que apresenta um ponto estacionário de sela. Desse modo a otimização para a variância deve ser realizado de forma restrita ao espaço amostral, uma vez que sua otimização não será direcionada a um ponto de mínimo ou máximo.

Inicialmente para realizar a otimização bi-objetivo pelo método NNC, foi analisado o conflito existente entre a média e a variância da resposta  $C$  na determinação da matriz *pay-off*. A matriz *pay-off* para resposta  $C$  é descrito conforme a Tabela 4.3. A otimização teve como restrição o espaço amostral codificado  $\mathbf{X}^T \mathbf{X} = v_c^2 + v_f^2 + a_e^2 \leq 2,8284 = \rho^2$ , em que pontos estacionários não solucionam o problema. Na matriz *pay-off* encontra-se os valores de ótimos individuais em sua diagonal principal, os valores de pseudo nadir na antidiagonal e os pontos de âncora correspondente a cada coluna da matriz.

Tabela 4.3 - Matriz *pay-off* para  $E[C] \times Var[C]$

$E[C]$	<b>6,2051</b>	6,3587
$Var[C]$	0,1844	<b>0,1837</b>

Posterior a definição da matriz *pay-off*, foi gerado soluções de Pareto ótimas com incremento  $\delta = 0,05$ , gerando assim  $\eta_r = 21$  soluções. As funções objetivo foram normalizadas e o vetor linha de utopia  $N_1$  no espaço normalizado. A fronteira de Pareto é então representada pela Figura 4.5 da otimização bi-objetivo com  $f_1 = E[C]$  e  $f_2 = Var[C]$ .

Pela fronteira de Pareto pode-se visualizar que à medida que uma função atinge seu objetivo de minimização, a função remanescente vai sendo maximizada, ou seja, vai em sentido contrário a seu valor ótimo. Cada ponto da fronteira de Pareto representa um resultado com peso distribuído entre  $f_1 = E[C]$  e  $f_2 = Var[C]$ , em que a obtenção de

menor média de corrente é dado maior peso para  $f_1 = E[C]$  e a obtenção de menor variância das respostas é dado maior peso a  $f_2 = Var[C]$ .




Figura 4.5 - Fronteira de Pareto para  $E[C] \times Var[C]$

A Tabela 4.4 apresenta os 21 pontos de otimização da fronteira de Pareto da Figura 4.5 com os níveis codificados e decodificados das variáveis de controle, os valores de  $E[C]$ ,  $Var[C]$  e  $S[C]$ , em que  $S[C] = \sqrt{Var[C]}$ . Com base nos dados tabulados pode-se verificar que os níveis robustos para a corrente estão nos intervalos das variáveis de controle de  $v_c \sim [11,36;12,09] \text{ m} \times \text{s}^{-1}$ ,  $v_f \sim [4,03;4,21] \text{ m} \times \text{min}^{-1}$  e  $a_e \sim [0,77;0,84] \text{ mm}$ . Com esses níveis de fatores a oscilação dos resultados de corrente devido a umidade presente na madeira usinada é minimizada. Pode-se observar também que os nove primeiros pontos não apresentam variação entre os valores de  $E[C]$  e  $Var[C]$ , se sobrepondo assim os pontos na Figura 4.5.

Para obter valores de  $C$  com melhor precisão e simultaneamente melhor acurácia, foi modelado o erro quadrático médio  $MSE_C = [E(C) - T_C]^2 + Var(C)$ , em que o alvo foi definido como a utopia da média da corrente  $T_C = 6,2051 \text{ A}$ . A Figura 4.6 representa a superfície de resposta para  $MSE$ .

Pela superfície de resposta pode-se verificar que diferentes combinações de parâmetros de variáveis alteram significativamente os resultados de  $MSE$ . A combinação de valores baixos de  $v_c$  com  $v_f$  e  $v_c$  com  $a_e$  reduzem o valor de  $MSE$ . Já  $v_f$  com  $a_e$ , quando um dos fatores é mantido em seu nível mais baixo, obtém-se resultados menores para  $MSE$ . Porém quando  $v_f$  e  $a_e$  são utilizados em seu valor máximo, o valor de  $MSE$  aumenta drasticamente.

Tabela 4.4 - Resultados da otimização entre  $E[C]$  e  $Var[C]$  pelo método NNC

$w_1$	Codificados			Decodificados			Respostas		
	$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[C]$	$Var[C]$	$S[C]$
				m/s	m/min	mm	A	A <sup>2</sup>	A
0,00	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,05	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,10	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,15	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,20	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,25	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,30	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,35	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,40	-0,61	-0,58	-1,46	12,09	4,03	0,77	6,2266	0,1837	0,4286
0,45	-0,64	-0,54	-1,46	11,99	4,07	0,77	6,2204	0,1837	0,4286
0,50	-0,77	-0,43	-1,43	11,64	4,21	0,78	6,2091	0,1838	0,4287
0,55	-0,79	-0,46	-1,41	11,57	4,18	0,79	6,2075	0,1838	0,4287
0,60	-0,81	-0,48	-1,40	11,53	4,15	0,80	6,2067	0,1839	0,4288
0,65	-0,82	-0,49	-1,38	11,50	4,13	0,81	6,2062	0,1839	0,4289
0,70	-0,83	-0,51	-1,37	11,47	4,12	0,81	6,2058	0,1840	0,4289
0,75	-0,84	-0,52	-1,36	11,45	4,10	0,82	6,2056	0,1841	0,4290
0,80	-0,84	-0,53	-1,36	11,43	4,09	0,82	6,2054	0,1841	0,4291
0,85	-0,85	-0,54	-1,35	11,41	4,08	0,83	6,2052	0,1842	0,4292
0,90	-0,86	-0,54	-1,34	11,39	4,07	0,83	6,2051	0,1842	0,4292
0,95	-0,86	-0,55	-1,34	11,38	4,06	0,83	6,2051	0,1843	0,4293
1,00	-0,87	-0,56	-1,33	11,36	4,05	0,84	6,2051	0,1844	0,4294

A minimização de  $MSE_C$  é demonstrado resumidamente na Tabela 4.5. Analisando a otimização de  $MSE_C$  pode-se observar que o valor está próximo entre o equilíbrio da otimização entre a média e a variância,  $w_1 = 0,5$  na Tabela 4.4, havendo assim uma ponderação entre as duas funções.




Figura 4.6 - Superfícies de resposta para  $MSE_C$ ,  $\mathbf{X}_{fixo} = \mathbf{X}_{CIPt}$

Tabela 4.5 - Otimização de  $MSE_C$

Codificados			Decodificados			Respostas			
$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[C]$	$Var[C]$	$S[C]$	$MSE_C$
			$m \times s^{-1}$	$m \times min^{-1}$	mm	A	$A^2$	A	$A^2$
-0,76	-0,42	-1,44	11,67	4,23	0,78	6,21	0,18	0,43	0,18

## 4.2 Tensão utilizada para o aplainamento da madeira *Pinus taeda*

A Figura 4.7 representa o gráfico de Pareto para a tensão ( $U$ ) do equipamento durante o processo de aplainamento. Analisando o gráfico de Pareto, verificou que apenas a variável de controle  $v_c$  apresenta efeito significativo sobre  $U$ , sendo possível confirmar também pela ANOVA (Tabela 4.6).




Figura 4.7 - Gráfico de Pareto para Tensão

O modelo de resposta da tensão, obtido por WLS, é representado conforme Equação 4.4. O erro experimental obtido para o modelo de resposta da corrente é de  $\hat{\sigma}_U^2 = 19,20$  e os coeficientes de determinação são de  $R_{aj}^2 = 97,22\%$  e  $R_{prev}^2 = 93,50\%$ . Desse modo o modelo apresenta bom ajuste dos dados e boa capacidade de previsão do modelo de resposta, sendo então capaz de representar a amostra e prever novos valores a partir da Equação 4.4.

$$\begin{aligned}
 U(\mathbf{x}, \mathbf{z}) = & 156,64 + 28,483 \times v_c + 0,860 \times v_f + 1,531 \times a_e + 0,44 \times u - 0,791 \times v_c^2 \\
 & + 1,663 \times v_f^2 + 1,492 \times a_e^2 - 0,58 \times v_c \times v_f - 0,37 \times v_c \times a_e - 0,26 \times v_c \times u \\
 & + 0,47 v_f \times a_e - 0,12 \times v_f \times u + 0,68 \times a_e \times u
 \end{aligned} \quad (4.4)$$

A Tabela 4.6 representa o cálculo da ANOVA para  $U$ . Pela tabela da ANOVA é possível confirmar a representação do gráfico de Pareto que apenas a variável de controle  $v_c$  foi significativo para  $U$  com  $p\text{-valor} < \alpha$  conforme destacado na Tabela 4.6. As demais variáveis e interações apresentarão  $p\text{-valor} > \alpha$ .

Como para  $U$  a variável de ruído não foi significativa, a análise dessa resposta foi resumida a apenas em função das variáveis de processo. O efeito da variável de ruído foi então retirado e a análise de  $U$  novamente realizada.



Tabela 4.6 - ANOVA para tensão

FV	GL	SQ	MQ	F-valor	P-valor
Modelo	13	19730,1	1517,7	79,06	<b>0,000</b>
Linear	4	19548,5	4887,1	254,57	<b>0,000</b>
$v_c$	1	19471,3	19471,3	1014,26	<b>0,000</b>
$v_f$	1	17,8	17,8	0,93	0,350
$a_e$	1	56,3	56,3	2,93	0,106
$u$	1	3,1	3,1	0,16	0,693
Quadrado	3	161,8	53,9	2,81	0,073
$v_c \times v_c$	1	17,5	17,5	0,91	0,354
$v_f \times v_f$	1	77,4	77,4	4,03	0,062
$a_e \times a_e$	1	62,3	62,3	3,25	0,090
Interações	6	19,8	3,3	0,17	0,981
$v_c \times v_f$	1	5,3	5,3	0,28	0,605
$v_c \times a_e$	1	2,2	2,2	0,11	0,742
$v_c \times u$	1	1,1	1,1	0,06	0,812
$v_f \times a_e$	1	3,5	3,5	0,18	0,673
$v_f \times u$	1	0,2	0,2	0,01	0,916
$a_e \times u$	1	7,5	7,5	0,39	0,541
Erro	16	307,2	19,2		
Falta de ajuste	9	204,6	22,7	1,55	0,288
Erro Puro	7	102,6	14,7		
Total	29	20037,3			
$S$	$R^2$	$R^2_{aj}$	$R^2_{prev}$		
4,3815	98,47%	97,22%	93,50%		

A Figura 4.8 representa o comportamento de  $U$  em relação as variáveis de controle. Pode-se verificar que  $v_c$  exerce grande influência sobre  $U$ , em que o aumento do valor de  $v_c$  resulta no aumento do valor de  $U$ , ou seja, quanto maior a velocidade de corte maior é a tensão. Já  $v_f$  e  $a_e$ , quando analisados juntamente com  $v_c$  não exercem grande influência sobre  $U$ .

Na análise das variáveis  $v_f$  e  $a_e$  o ponto central para as duas variáveis representa o menor valor para  $U$ , e conforme  $v_f$  e  $a_e$  se distancia de seus respectivos pontos centrais, o valor de  $U$  aumenta.




Figura 4.8 - Função  $U$  no espaço experimental codificado,  $\mathbf{X}_{fixo} = \mathbf{X}_{CIPI}$

### 4.3 Torque utilizado para o aplainamento da madeira *Pinus taeda*

A Figura 4.9 representa o gráfico de Pareto para a resposta de torque ( $M$ ). Pode-se observar que as variáveis de controle  $a_e$ ,  $v_f$  e de ruído  $u$  apresentam efeitos significativos sobre a torque exercido pelo equipamento durante o aplainamento. Em relação aos efeitos quadráticos, apenas  $v_c \times v_c$  possui efeito significativo, dessa forma a superfície de resposta contendo  $v_c$  apresenta curvatura, tendo um ponto de mínimo ou máximo.

A Figura 4.10 representa o gráfico de efeitos lineares e quadráticos para a resposta torque. Pode-se observar que para  $v_c$  e  $v_f$  apresentaram convexidade voltada para baixo, ou seja, menores valores de torque são obtidos quando se utiliza valores próximos aos seus pontos centrais. Em relação a  $a_e$ , menores valores dessa variável de controle proporcionam menores valores de torque. Em relação a variável de ruído, quanto maior é

o percentual de umidade presente na madeira menor é o torque necessária para o aplainamento.




Figura 4.9 - Gráfico de Pareto para torque




Figura 4.10 - Gráfico de efeitos lineares e quadráticos para torque

A Figura 4.11 apresenta os gráficos de interações entre as variáveis de controle e de ruído. Pode-se observar que apenas a interação  $a_e \times u$  apresentou efeito significativo, pois as alterações das variáveis mudam o sentido das retas no gráfico. Desse modo, a alteração simultânea dos fatores de  $a_e$  e  $u$  proporciona diferentes resultados de  $M$ .




Figura 4.11 - Gráfico de interação para torque

O modelo de resposta de  $M$ , obtido por WLS, é representado conforme Equação 4.5. O erro experimental para o modelo de resposta da corrente é de  $\hat{\sigma}_M^2 = 7,42$  e os coeficientes de determinação são de  $R_{aj}^2 = 66,96\%$  e  $R_{prev}^2 = 6,14\%$ . Apesar do modelo apresentar uma baixa capacidade de previsão de novos resultados, o mesmo apresentou distribuição normal para os resíduos, assim foi utilizado o modelo para análise nos experimentos de confirmação.

$$\begin{aligned}
 M(\mathbf{x}, \mathbf{z}) = & 19,089 - 0,2381 \times v_c + 1,6350 \times v_f + 3,2231 \times a_e + 1,6079 \times u + 1,3657 \times v_c^2 \\
 & + 0,9856 \times v_f^2 + 0,9226 \times a_e^2 - 1,3072 \times v_c \times v_f - 0,9698 \times v_c \times a_e + 0,0504 \times v_c \times u \\
 & + 0,9189 \times v_f \times a_e - 0,0574 \times v_f \times u + 1,5127 \times a_e \times u
 \end{aligned} \quad (4.5)$$

A Tabela 4.7 apresenta a ANOVA para a resposta de torque. Com nível de significância  $\alpha = 0,05$  pode-se confirmar os resultados apresentados na Figura 4.9, onde os efeitos lineares das variáveis de controle  $a_e$ ,  $v_f$  e o da variável de ruído  $u$  foram significativos com  $p\text{-valor} < \alpha$  como destacado na tabela, sendo todos positivos conforme os coeficientes apresentados na Equação 4.5. Dessa forma pode-se concluir que a medida

que o nível dos fatores de  $a_e$ ,  $v_f$  e  $u$  aumentam, o torque necessário para o aplainamento também aumenta, confirmando assim os resultados apresentados pela Figura 4.10.

Quanto aos efeitos quadráticos, apenas  $v_c \times v_c$  apresentou efeito significativo, ou seja, possui  $p\text{-valor} < \alpha$ , proporcionando assim uma curvatura no modelo de resposta. Já os efeitos de interação, apenas a interação entre  $a_e \times u$  foi significativo conforme representado Figura 4.11, apresentando  $p\text{-valor} > \alpha$ .

Tabela 4.7 - ANOVA para torque

FV	GL	SQ	MQ	F-valor	P-valor
Modelo	13	532,509	40,962	5,52	<b>0,001</b>
Linear	4	356,203	89,051	12,00	<b>0,000</b>
$v_c$	1	1,36	1,36	0,18	0,674
$v_f$	1	64,156	64,156	8,65	<b>0,010</b>
$a_e$	1	249,322	249,322	33,60	<b>0,000</b>
$u$	1	41,364	41,364	5,57	<b>0,031</b>
Quadrado	3	83,705	27,902	3,76	<b>0,032</b>
$v_c \times v_c$	1	52,221	52,221	7,04	<b>0,017</b>
$v_f \times v_f$	1	27,197	27,197	3,67	0,074
$a_e \times a_e$	1	23,835	23,835	3,21	0,092
Interações	6	92,601	15,434	2,08	0,113
$v_c \times v_f$	1	27,339	27,339	3,68	0,073
$v_c \times a_e$	1	15,047	15,047	2,03	0,174
$v_c \times u$	1	0,041	0,041	0,01	0,942
$v_f \times a_e$	1	13,51	13,51	1,82	0,196
$v_f \times u$	1	0,053	0,053	0,01	0,934
$a_e \times u$	1	36,612	36,612	4,93	<b>0,041</b>
Erro	16	118,722	7,42		
Falta de ajuste	9	98,997	11,00	3,90	0,043
Erro Puro	7	19,725	2,818		
Total	29	651,231			
$S$	$R^2$	$R_{aj}^2$	$R_{prev}^2$		
4,3815	81,77%	66,96%	6,14%		

As Equações 4.6 e 4.7, de média e variância respectivamente, foram obtidas a fim de minimizar o efeito gerado pela umidade da madeira na resposta de  $M$ . A Figura 4.12 apresenta as superfícies de resposta para as funções de média e variância.

$$E[M(\mathbf{x}, \mathbf{z})] = 19,0884 - 0,2381 \times v_c + 1,6350 \times v_f + 3,2231 \times a_e + 1,3657 \times v_c^2 + 0,9856 \times v_f^2 + 0,9226 \times a_e^2 - 1,3072 \times v_c \times v_f - 0,9698 \times v_c \times a_e + 0,9189 \times v_f \times a_e \quad (4.6)$$

$$Var[M(\mathbf{x}, \mathbf{z})] = 10,0052 + 0,1620 \times v_c - 0,1845 \times v_f + 4,8644 \times a_e + 0,0025 \times v_c^2 + 0,0033 \times v_f^2 + 2,2883 \times a_e^2 - 0,0058 \times v_c \times v_f + 0,1524 \times v_c \times a_e - 0,1736 \times v_f \times a_e \quad (4.7)$$




Figura 4.12 - Superfície de resposta para corrente,  $\mathbf{X}_{fixo} = \mathbf{X}_{CiPt}$

$E[M]$  apresenta os autovalores  $\lambda_{E[M]} = [2, 2015; 0, 6158; 0, 4565]^T$ , logo a função da média da resposta  $M$  apresenta convexidade voltada para cima, contendo assim um ponto de mínimo. Já  $Var[M]$  apresenta autovalores de sinais mistos  $\lambda_{Var[M]} = [2, 2941; -5, 04 \times 10^{-37}; -5, 04 \times 10^{-37}]^T$ , sendo então a função da variância da resposta  $M$  é uma sela em que apresenta um ponto estacionário de sela. Desse modo a otimização para a variância deve ser realizado de forma restrita, delimitando a superfície pelo espaço amostral.

A matriz *pay-off* para resposta  $M$  é descrito na Tabela 4.8, demonstrando o conflito existente entre a média e a variância de  $M$ , em que o valor que minimiza a média, maximiza a variância e o mesmo ocorre no caso inverso.

A otimização bi-objetivo teve como restrição o espaço amostral codificado  $\mathbf{X}^T \mathbf{X} = v_c^2 + v_f^2 + a_e^2 \leq 2, 8284 = \rho^2$ , em que pontos estacionários não solucionam o problema, uma vez que eles se encontrem fora do espaço amostral.

Na matriz *pay-off* encontra-se os valores de ótimos individuais em sua diagonal principal, os valores de pseudo nadir na antidiagonal e os pontos de âncora correspondente a cada coluna da matriz. Os pontos da fronteira de Pareto estarão presentes entre os pontos de âncora.

Tabela 4.8 - Matriz *pay-off* para  $E[M] \times Var[M]$

$E[M]$	<b>15,8177</b>	16,2499
$Var[M]$	7,9145	<b>7,4201</b>

Posterior a definição da matriz *pay-off*, foi gerado soluções de Pareto ótimas com incremento  $\delta = 0,05$ , gerando assim  $\eta_r = 21$  soluções. As funções objetivo foram normalizadas e o vetor linha de utopia  $N_1$  no espaço normalizado. A fronteira de Pareto é então representada pela Figura 4.13 da otimização bi-objetivo com  $f_1 = E[M]$  e  $f_2 = Var[M]$ .

Cada ponto da fronteira de Pareto representa um resultado com peso distribuído entre  $f_1 = E[M]$  e  $f_2 = Var[M]$ , caso o processo tenha como objetivo reduzir a média de  $M$ , então deve-se utilizar pontos da fronteira de Pareto em que o peso é maior para

$f_1 = E[M]$ . Caso o objetivo seja reduzir a variância do processo, então deve-se utilizar pontos da fronteira de Pareto em que o peso é maior para  $f_2 = Var[M]$ .




Figura 4.13 - Fronteira de Pareto para  $E[M] \times Var[M]$

A Tabela 4.9 apresenta os 21 pontos de otimização da fronteira de Pareto representado graficamente na Figura 4.13. A tabela apresenta em suas colunas os níveis codificados e decodificados das variáveis de controle, os valores de  $E[M]$ ,  $Var[M]$  e  $S[M]$ , onde  $S[M] = \sqrt{Var[M]}$ .

Com base nos dados tabulados pode-se verificar que os níveis robustos para a corrente estão nos intervalos das variáveis de controle de  $v_c \sim [11,40;12,17] \text{ m} \times \text{s}^{-1}$ ,  $v_f \sim [3,58;4,23] \text{ m} \times \text{min}^{-1}$  e  $a_e \sim [0,74;0,96] \text{ mm}$ . A utilização de qualquer um dos níveis das variáveis de controle que pertencem a esses intervalos faz com que o processo seja robusto a oscilação da resposta de  $M$  causada pela umidade presente na madeira a se usinada.

Pode-se observar que nenhum dos pontos de  $E[M]$  e apenas dois pontos de  $Var[M]$  não apresentam variação entre os valores, em que o peso da otimização é maior para  $f_2 = Var[M]$ .



Tabela 4.9 - Resultados da otimização entre  $E[M]$  e  $Var[M]$  pelo método NNC

$w_1$	Codificados			Decodificados			Respostas		
	$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[M]$	$Var[M]$	$S[M]$
				$m \times s^{-1}$	$m \times \min^{-1}$	mm	$N \times m$	$(N \times m)^2$	$N \times m$
0,00	-0,85	-0,94	-1,07	11,40	3,58	0,96	16,22	7,42	2,72
0,05	-0,82	-0,93	-1,07	11,50	3,58	0,96	16,21	7,42	2,72
0,10	-0,66	-0,78	-1,09	11,94	3,77	0,96	16,16	7,42	2,72
0,15	-0,66	-0,77	-1,12	11,92	3,79	0,94	16,13	7,43	2,73
0,20	-0,67	-0,76	-1,15	11,90	3,80	0,92	16,09	7,44	2,73
0,25	-0,68	-0,75	-1,18	11,89	3,81	0,91	16,06	7,45	2,73
0,30	-0,68	-0,74	-1,21	11,87	3,83	0,90	16,03	7,47	2,73
0,35	-0,69	-0,73	-1,24	11,86	3,84	0,88	16,00	7,49	2,74
0,40	-0,69	-0,72	-1,26	11,84	3,85	0,87	15,98	7,51	2,74
0,45	-0,70	-0,71	-1,29	11,83	3,86	0,86	15,96	7,53	2,74
0,50	-0,70	-0,70	-1,31	11,82	3,87	0,85	15,94	7,56	2,75
0,55	-0,71	-0,69	-1,33	11,80	3,88	0,83	15,92	7,58	2,75
0,60	-0,71	-0,69	-1,35	11,79	3,89	0,82	15,90	7,61	2,76
0,65	-0,70	-0,66	-1,38	11,81	3,92	0,81	15,88	7,64	2,77
0,70	-0,69	-0,63	-1,40	11,85	3,96	0,80	15,87	7,68	2,77
0,75	-0,67	-0,60	-1,42	11,89	4,00	0,79	15,85	7,71	2,78
0,80	-0,66	-0,57	-1,44	11,94	4,04	0,78	15,84	7,75	2,78
0,85	-0,64	-0,53	-1,46	11,99	4,08	0,77	15,83	7,78	2,79
0,90	-0,62	-0,50	-1,48	12,04	4,13	0,76	15,83	7,82	2,8
0,95	-0,60	-0,46	-1,50	12,10	4,17	0,75	15,82	7,87	2,81
1,00	-0,57	-0,42	-1,52	12,17	4,23	0,74	15,82	7,91	2,81

Para obter valores de  $M$  com melhor precisão e simultaneamente melhor acurácia, foi modelado o erro quadrático médio  $MSE_M = [E(M) - T_M]^2 + Var(M)$ , em que o alvo foi definido como a utopia da média da corrente  $T_M = 15,8177$  A.

A Figura 4.14 representa a superfície de resposta para  $MSE$ . Baixos valores de  $v_c$  resultam em maiores valores de  $MSE_M$ , enquanto baixos valores de  $v_f$  e  $a_e$  resultam em um menor valor de  $MSE_M$ .

A minimização de  $MSE_M$  é demonstrado resumidamente na Tabela 4.10. Analisando a otimização de  $MSE_M$  pode-se observar que o valor está próximo da otimização da variância do que da média,  $w_1 = 0,25$  na Tabela 4.9, ou seja, a uma ponderação de 25% para a otimização de média e 75% para a otimização da variância.




Figura 4.14 - Superfícies de resposta para  $MSE_M$ ,  $\mathbf{X}_{fixo} = \mathbf{X}_{CIPI}$

Tabela 4.10 - Otimização de  $MSE_M$

Codificados			Decodificados			Respostas			
$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[M]$	$Var[M]$	$S[M]$	$MSE_M$
			$m \times s^{-1}$	$m \times \text{min}^{-1}$	mm	$N \times m$	$(N \times m)^2$	$N \times m$	$(N \times m)^2$
-0,68	-0,75	-1,18	11,89	3,81	0,91	16,06	7,45	2,73	7,51

#### 4.4 Potência mecânica utilizado para o aplainamento da madeira *Pinus taeda*

A Figura 4.15 representa o gráfico de Pareto para a resposta de potência mecânica ( $P$ ). Pode-se observar que todas as variáveis de controle ( $v_c$ ,  $v_f$ ,  $a_e$ ) e de ruído  $\mu$  apresentam efeitos significativos sobre as respostas de  $P$ . Em relação aos efeitos quadráticos das variáveis de controle, todos apresentaram efeitos significativos ( $v_c \times v_c$ ,  $v_f \times v_f$  e  $a_e \times a_e$ ).




Figura 4.15 - Gráfico de Pareto para potência mecânica

A Figura 4.16 apresenta o gráfico de efeitos lineares e quadráticos para a resposta potência mecânica ( $P$ ). Pode-se observar que apenas  $v_f$  apresentaram convexidade voltada para baixo, ou seja, menores valores de  $P$  são obtidos quando se utiliza valor próximo ao seu ponto central. Em relação a  $v_c$  e  $a_e$ , menores valores dessas variáveis de controle proporcionam menores valores de  $P$ . Em relação a variável de ruído, quanto maior é o percentual de  $u$  presente na madeira menor será a potência mecânica utilizada.




Figura 4.16 - Gráfico de efeitos lineares e quadráticos para potência mecânica

A Figura 4.17 apresenta os gráficos de interações entre as variáveis de controle e de ruído. Pode-se observar que a interação  $v_c \times a_e$  apresenta efeito significativo. Dessa forma, as variáveis de  $v_c$  e  $a_e$  quando alteradas simultaneamente proporcionam resultados diferentes na potência mecânica ( $P$ ).

Já a interação  $a_e \times u$  apresentou resultado expressivo, porém seu efeito não foi significativo considerando  $\alpha = 0,05$ . Nesse caso a alteração simultânea entre as variáveis de  $a_e$  e  $u$  não modifica os resultados de potência mecânica ( $P$ ).




Figura 4.17 - Gráfico de interação para potência mecânica

O modelo de resposta de  $P$ , obtido por WLS, é representado conforme Equação 4.8. O erro experimental para o modelo de resposta da corrente é de  $\hat{\sigma}_M^2 = 0,5742$  (kW)<sup>2</sup> e os coeficientes de determinação são de  $R_{aj}^2 = 78,80\%$  e  $R_{prev}^2 = 37,08\%$ . Apesar do modelo apresentar baixa capacidade de previsão, o mesmo apresentou distribuição normal para os resíduos, assim foi utilizado o modelo para análise nos experimentos de confirmação.

$$\begin{aligned}
 P(\mathbf{x}, \mathbf{z}) = & 5,0831 + 1,1415 \times v_c + 0,4121 \times v_f + 0,8692 \times a_e + 0,4546 \times u + 0,3139 \times v_c^2 \\
 & + 0,3228 \times v_f^2 + 0,3106 \times a_e^2 - 0,2835 \times v_c \times v_f - 0,1433 \times v_c \times a_e + 0,0951 \times v_c \times u \\
 & + 0,3078 \times v_f \times a_e - 0,0546 \times v_f \times u + 0,3999 \times a_e \times u
 \end{aligned} \quad (4.8)$$

A Tabela 4.11 apresenta a ANOVA para a resposta de potência mecânica em que as variáveis que apresentaram P-valor  $< 0,05$  estão destacadas.

Tabela 4.11 - ANOVA para potência mecânica

FV	GL	SQ	MQ	F-valor	P-valor
Modelo	13	69,376	5,337	9,29	<b>0,000</b>
Linear	4	56,791	14,198	24,73	<b>0,000</b>
$v_c$	1	31,274	31,274	54,47	<b>0,000</b>
$v_f$	1	4,076	4,076	7,1	<b>0,017</b>
$a_e$	1	18,134	18,133	31,58	<b>0,000</b>
$u$	1	3,307	3,307	5,76	<b>0,029</b>
Quadrado	3	6,704	2,235	3,89	<b>0,029</b>
$v_c \times v_c$	1	2,759	2,759	4,81	<b>0,044</b>
$v_f \times v_f$	1	2,918	2,918	5,08	<b>0,039</b>
$a_e \times a_e$	1	2,701	2,701	4,7	<b>0,045</b>
Interações	6	5,881	0,980	1,71	0,183
$v_c \times v_f$	1	1,286	1,286	2,24	0,154
$v_c \times a_e$	1	0,329	0,329	0,57	0,460
$v_c \times u$	1	0,145	0,145	0,25	0,623
$v_f \times a_e$	1	1,516	1,516	2,64	0,124
$v_f \times u$	1	0,048	0,048	0,08	0,777
$a_e \times u$	1	2,558	2,558	4,46	0,051
Erro	16	9,187	0,574		
Falta de ajuste	9	8,097	0,900	5,77	0,015
Erro Puro	7	1,091	0,156		
Total	29	78,563			
$S$	$R^2$	$R_{aj}^2$	$R_{prev}^2$		
4,3815	88,31%	78,80%	37,08%		

Com nível de significância de  $\alpha = 0,05$  pode-se confirmar os resultados apresentados no gráfico de Pareto da Figura 4.15, em que os efeitos lineares das variáveis de controle  $v_c$ ,  $v_f$ ,  $a_e$  e o da variável de ruído  $u$  foram significativos com p-valor  $< \alpha$ , sendo todos positivos conforme os coeficientes apresentados na Equação 4.8. Dessa forma a medida que  $v_c$ ,  $v_f$ ,  $a_e$  e  $u$  aumentam seus níveis de fatores, ou seja, aumentando as velocidades de corte, avanço, profundidade de penetração e reduzindo a umidade

presente no corpo de prova a potência mecânica necessária para o aplainamento também aumenta, confirmando assim os resultados apresentados pela Figura 4.16.

Quanto aos efeitos quadráticos das variáveis de controle, pode-se confirmar que todos ( $v_c \times v_c$ ,  $v_f \times v_f$  e  $a_e \times a_e$ ) apresentaram efeitos significativos, ou seja, possui p-valor  $< \alpha$  conforme também apresentado na Figura 4.15.

Para as interações entre  $v_c \times a_e$  apresentou efeito significativo com p-valor  $< \alpha$  conforme representado graficamente pela Figura 4.17. Quanto a interação entre  $a_e \times u$ , seu p-valor foi de 0,051, valor bem próximo ao de  $\alpha$ , porém superior, o que não apresenta assim efeito significativo.

As Equações 4.9 e 4.10 foram obtidos a fim de minimizar o efeito gerado pela umidade da madeira em  $P$ .  $E[P]$  e  $Var[P]$  apresentam em suas funções autovalores de  $\lambda_{E[P]} = [0,5647; 0,2411; 0,1415]^T$  e  $\lambda_{Var[M]} = [0,1719; 1,73 \times 10^{-18}; 1,73 \times 10^{-18}]^T$  respectivamente, logo a função da média e variância da resposta  $P$  apresentam convexidade voltada para cima, contendo assim ponto de mínimo.

$$E[P(\mathbf{x}, \mathbf{z})] = 5,0831 + 1,1415 \times v_c + 0,4121 \times v_f + 0,8692 \times a_e + 0,3139 \times v_c^2 + 0,3228 \times v_f^2 + 0,3106 \times a_e^2 - 0,2835 \times v_c \times v_f - 0,1433 \times v_c \times a_e + 0,3078 \times v_f \times a_e \quad (4.9)$$

$$Var[P(\mathbf{x}, \mathbf{z})] = 0,7809 + 0,0865 \times v_c - 0,0497 \times v_f + 0,3636 \times a_e + 0,0090 \times v_c^2 + 0,0030 \times v_f^2 + 0,1599 \times a_e^2 - 0,0104 \times v_c \times v_f + 0,0760 \times v_c \times a_e - 0,0437 \times v_f \times a_e \quad (4.10)$$

A Figura 4.18 apresenta as superfícies de resposta para as funções de média e variância. Valores baixos de  $v_c$ ,  $v_f$  e  $a_e$  proporcionam menores resultados de potência mecânica, à medida que os fatores dessas variáveis de controle aumentam, a potência mecânica também aumenta. Na combinação entre  $v_f$  e  $a_e$  a potência mecânica pode atingir valores mais altos.

Para variância, valores baixos de  $v_c$ ,  $v_f$  e  $a_e$  fazem com que o processo seja mais preciso, ou seja, com baixa variância. Apenas a associação ente  $v_c$  e  $v_f$  em que  $v_f$  em seu valor mais alto atinge a minimização da variância da potência de corte. A associação

entre  $v_c$  e  $a_e$  é a que mais sensibiliza as respostas de potência mecânica, atingindo valores mais alto de variância.




Figura 4.18 - Superfície de resposta para potência mecânica,  $\mathbf{X}_{fixo} = \mathbf{X}_{CtPt}$

A matriz *pay-off* para potência mecânica ( $P$ ) é descrito na Tabela 4.12, demonstrando o conflito existente entre a média e a variância de  $P$ . A otimização bi-objetivo teve como restrição o espaço amostral codificado

$\mathbf{X}^T \mathbf{X} = v_c^2 + v_f^2 + a_e^2 \leq 2,8284 = \rho^2$ , em que pontos estacionários não solucionam o problema. Na matriz *pay-off* encontra-se os valores ótimos individuais em sua diagonal principal, os valores de pseudo nadir na antidiagonal e os pontos de âncora correspondente a cada coluna da matriz.

Tabela 4.12 - Matriz *pay-off* para  $E[P] \times Var[P]$

$E[P]$	<b>3,2421</b>	4,2355
$Var[P]$	0,5742	<b>0,5742</b>

A matriz *pay-off* demonstrou que a variância não se altera conforme se aplica a otimização NNC. Isso ocorre devido suas restrições que limitam a região experimental.

Para obter valores de  $P$  com melhor precisão e simultaneamente melhor acurácia, foi modelado o erro quadrático médio  $MSE_P = [E(P) - T_p]^2 + Var(P)$ , onde o alvo foi definido como a utopia da média da potência mecânica  $T_p = 3,2421$  A. A Figura 4.19 representa a superfície de resposta para  $MSE$ .




Figura 4.19 - Superfícies de resposta para  $MSE_P$ ,  $\mathbf{X}_{fixo} = \mathbf{X}_{CtPt}$



A Tabela 4.13 demonstra a otimização de  $MSE$  para potência mecânica. Como a variância não se altera dentro das restrições, o valor ótimo de  $MSE$  é o mesmo valor ótimo de  $E[P]$  descrito na Tabela 4.12.

Tabela 4.13 - Otimização de  $MSE_p$

Codificados			Decodificados			Respostas			
$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[P]$	$Var[P]$	$S[P]$	$MSE_p$
			$m \times s^{-1}$	$m \times \text{min}^{-1}$	mm	kW	$(kW)^2$	kW	$(kW)^2$
-1,34	-0,49	-0,88	10,05	4,13	1,06	3,25	0,57	0,76	11,09

## 4.5 Energia utilizada para o aplainamento da madeira *Pinus taeda*

A Figura 4.20 representa o gráfico de Pareto para a resposta de energia (W) consumida pela plaina durante o processo de usinagem. Pode-se observar que todas as variáveis de controle ( $v_c$ ,  $v_f$  e  $a_e$ ) e de ruído  $u$  apresentam efeitos significativos sobre energia consumida (W).




Figura 4.20 - Gráfico de Pareto para energia

A Figura 4.21 apresenta o gráfico de efeitos lineares e quadráticos para a resposta de energia ( $W$ ). Pode-se observar que valores menores para  $v_c$  e  $a_e$  proporcionam menores valores de  $W$ , enquanto  $v_f$  proporciona menores valores de  $W$  quando seu valor é alto. Em relação a  $u$ , quanto maior é o percentual de umidade presente na madeira menor é o valor de  $W$  necessária para o aplainamento.




Figura 4.21 - Gráfico de efeitos lineares e quadráticos para energia

A Figura 4.22 apresenta os gráficos de interações entre as variáveis de controle e ruído para a resposta  $W$ . Pode-se observar existe a interação entre  $v_c \times v_f$ .




Figura 4.22 - Gráfico de interação para energia

O modelo de resposta da corrente, obtido por WLS, é representado conforme Equação 4.11. O erro experimental para o modelo de resposta de  $W$  é de  $\hat{\sigma}_W^2 = 29,3549$  e os coeficientes de determinação são de  $R_{adj}^2 = 85,59\%$  e  $R_{prev}^2 = 56,26\%$ . Apesar do modelo não ter capacidade de previsão, o mesmo apresentou distribuição normal para os resíduos, assim foi utilizado o modelo para análise nos experimentos de confirmação.

$$\begin{aligned} W(\mathbf{x}, \mathbf{z}) = & 32,0335 + 7,9696 \times v_c - 8,9094 \times v_f + 5,3228 \times a_e + 3,1825 \times u + 1,9299 \times v_c^2 \\ & + 4,5769 \times v_f^2 + 1,9090 \times a_e^2 - 4,3314 \times v_c \times v_f - 1,5088 \times v_c \times a_e + 1,0453 \times v_c \times u \\ & + 0,9524 \times v_f \times a_e - 1,1826 \times v_f \times u + 2,4292 \times a_e \times u \end{aligned} \quad (4.11)$$

A Tabela 4.14 apresenta a ANOVA para a resposta de  $W$ . Com nível de significância de  $\alpha = 0,05$  pode-se confirmar os resultados apresentados na Figura 4.20, em que todas as variáveis de controle ( $v_c$ ,  $v_f$  e  $a_e$ ) e de ruído  $u$  apresentaram efeitos significativos sobre  $W$  com p-valor  $< \alpha$  conforme destacado na tabela, sendo que  $v_c$ ,  $v_f$  e  $a_e$  são positivos e  $v_f$  é negativo conforme os coeficientes apresentados na Equação 4.11. Dessa forma pode-se concluir que a medida que  $v_c$ ,  $v_f$  e  $a_e$  aumentam, a energia necessária para o aplainamento também aumenta e à medida que  $v_f$  diminui, a energia necessária para o aplainamento aumenta, confirmando assim os resultados apresentados pela Figura 4.21.

Quanto aos efeitos quadráticos, apenas  $v_f \times v_f$  apresentou efeito significativo com p-valor  $< \alpha$ . Já os efeitos de interação, apenas a interação entre processo  $\times$  processo entre  $v_c \times v_f$  apresentou efeito significativo com p-valor  $< \alpha$  conforme apresentado na Figura 4.22.

As Equações 4.12 e 4.13 apresentam as equações de média e variância de  $W$  que minimizam o efeito gerado pela umidade da madeira sobre  $W$ .  $E[W]$  apresenta em seus autovalores de sinais positivos  $\lambda_{E[W]} = [5,9453; 1,9029; 0,5677]^T$ , logo a função da média da resposta  $W$  apresenta convexidade voltada para cima, contendo assim um ponto de mínimo. Já  $Var[W]$  apresenta autovalores de sinais mistos  $\lambda_{Var[W]} = [8,3924; -6,1456 \times 10^{-16}; 2,2205 \times 10^{-16}]^T$ , sendo então a função da variância da

resposta  $W$  uma sela em que apresenta um ponto estacionário de sela. Desse modo a otimização para a variância de  $W$  deve ser realizado de forma restrita.

Tabela 4.14 - ANOVA para energia

FV	GL	SQ	MQ	F-valor	P-valor
Modelo	13	5436,33	418,18	14,25	<b>0,000</b>
Linear	4	4271,44	1067,86	36,38	<b>0,000</b>
$v_c$	1	1524,34	1524,34	51,93	<b>0,000</b>
$v_f$	1	1905,07	1905,07	64,90	<b>0,000</b>
$a_e$	1	679,97	679,97	23,16	<b>0,000</b>
$u$	1	162,06	162,06	5,52	<b>0,032</b>
Quadrado	3	679,51	226,50	7,72	<b>0,002</b>
$v_c \times v_c$	1	104,29	104,29	3,55	0,078
$v_f \times v_f$	1	586,55	586,55	19,98	<b>0,000</b>
$a_e \times a_e$	1	102,04	102,04	3,48	0,081
Interações	6	485,39	80,90	2,76	<b>0,049</b>
$v_c \times v_f$	1	300,17	300,17	10,23	<b>0,006</b>
$v_c \times a_e$	1	36,42	36,42	1,24	0,282
$v_c \times u$	1	17,48	17,48	0,60	0,452
$v_f \times a_e$	1	14,51	14,51	0,49	0,492
$v_f \times u$	1	22,38	22,38	0,76	0,396
$a_e \times u$	1	94,42	94,42	3,22	0,092
Erro	16	469,68	29,35		
Falta de ajuste	9	426,17	47,35	7,62	0,007
Erro Puro	7	43,50	6,21		
Total	29	5906,01			
$S$	$R^2$	$R_{aj}^2$	$R_{prev}^2$		
5,41801	92,05%	85,59%	56,26%		

$$E[W(\mathbf{x}, \mathbf{z})] = 32,0335 + 7,9696 \times v_c - 8,9094 \times v_f + 5,3228 \times a_e + 1,9299 \times v_c^2 + 4,5769 \times v_f^2 + 1,9090 \times a_e^2 - 4,3314 \times v_c \times v_f - 1,5088 \times v_c \times a_e + 0,9524 \times v_f \times a_e \quad (4.12)$$

$$Var[W(\mathbf{x}, \mathbf{z})] = 39,4834 + 6,6535 \times v_c - 7,5272 \times v_f + 15,4623 \times a_e + 1,0927 \times v_c^2 + 1,3985 \times v_f^2 + 5,9013 \times a_e^2 - 2,4724 \times v_c \times v_f + 5,0787 \times v_c \times a_e - 5,7456 \times v_f \times a_e \quad (4.13)$$

A Figura 4.4 apresenta as superfícies de resposta para as funções de média e variância.




Figura 4.23 - Superfície de resposta para energia,  $\mathbf{X}_{fixo} = \mathbf{X}_{ClPt}$

A matriz *pay-off* para resposta  $W$  é descrito na Tabela 4.15. A otimização teve como restrição o espaço amostral codificado  $\mathbf{X}^T \mathbf{X} = v_c^2 + v_f^2 + a_e^2 \leq 2,8284 = \rho^2$ , em que pontos estacionários não solucionam o problema. Na matriz *pay-off* encontra-se os

valores de ótimos individuais em sua diagonal principal, os valores de pseudo nadir na antidiagonal e os pontos de âncora correspondente a cada coluna da matriz.

Tabela 4.15 - Matriz *pay-off* para  $E[W] \times Var[W]$

$E[W]$	<b>18,5118</b>	27,3475
$Var[W]$	31,0096	<b>29,3549</b>

Posterior a definição da matriz *pay-off*, foi gerado soluções de Pareto ótimas com incremento  $\delta = 0,05$ , gerando assim  $\eta_r = 21$  soluções. As funções objetivo foram normalizadas e o vetor linha de utopia  $N_1$  no espaço normalizado. A fronteira de Pareto é então representada pela Figura 4.24 da otimização bi-objetivo com  $f_1 = E[W]$  e  $f_2 = Var[W]$ .




Figura 4.24 - Fronteira de Pareto para  $E[W] \times Var[W]$

A Tabela 4.16 apresenta os 21 pontos de otimização da fronteira de Pareto da Figura 4.23 com os níveis codificados e decodificados das variáveis de controle, os valores de  $E[W]$ ,  $Var[W]$  e  $S[W]$ , em que  $S[W] = \sqrt{Var[W]}$ . Com base nos dados tabulados pode-se verificar que os níveis robustos para a energia estão nos intervalos das variáveis

de controle de  $v_c \sim [9,55;11,28]$   $\text{m}\times\text{s}^{-1}$ ,  $v_f \sim [3,91;5,27]$   $\text{m}\times\text{min}^{-1}$  e  $a_e \sim [0,87;1,15]$  mm. Com esses níveis o processo é robusto a oscilação da umidade presente na madeira não causando mais efeito sobre a energia. Pode-se observar também que os nove primeiros pontos não apresentam variação entre os valores de  $Var[W]$ , dessa forma esses pontos se mantiveram em sequência quando a média ia se alterando conforme Figura 4.24.

Tabela 4.16 - Resultados da otimização de  $W$  pelo método NNC

$W_1$	Codificados			Decodificados			Respostas		
	$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[W]$	$Var[W]$	$S[W]$
				$\text{m}\times\text{s}^{-1}$	$\text{m}\times\text{min}^{-1}$	mm	kJ	$(\text{kJ})^2$	kJ
0,00	-0,90	-0,67	-1,25	11,28	3,91	0,87	27,35	29,36	5,42
0,05	-1,00	-0,64	-1,19	11,01	3,95	0,90	26,14	29,36	5,42
0,10	-1,10	-0,59	-1,13	10,73	4,01	0,94	24,90	29,36	5,42
0,15	-1,11	-0,59	-1,12	10,69	4,02	0,94	24,70	29,36	5,42
0,20	-1,28	-0,47	-0,99	10,23	4,17	1,01	22,71	29,36	5,42
0,25	-1,28	-0,47	-0,99	10,23	4,17	1,01	22,71	29,36	5,42
0,30	-1,34	-0,41	-0,93	10,07	4,24	1,03	22,05	29,36	5,42
0,35	-1,42	-0,30	-0,85	9,84	4,37	1,08	21,16	29,36	5,42
0,40	-1,53	-0,09	-0,70	9,55	4,64	1,15	20,28	29,36	5,42
0,45	-1,52	0,08	-0,71	9,57	4,85	1,14	19,70	29,41	5,42
0,50	-1,49	0,12	-0,78	9,66	4,90	1,11	19,40	29,52	5,43
0,55	-1,45	0,16	-0,83	9,75	4,95	1,08	19,18	29,65	5,44
0,60	-1,42	0,19	-0,87	9,83	4,99	1,06	19,02	29,78	5,46
0,65	-1,40	0,22	-0,91	9,91	5,02	1,04	18,88	29,92	5,47
0,70	-1,37	0,25	-0,95	9,99	5,06	1,03	18,78	30,07	5,48
0,75	-1,34	0,27	-0,98	10,07	5,09	1,01	18,69	30,22	5,50
0,80	-1,31	0,30	-1,02	10,16	5,13	0,99	18,62	30,37	5,51
0,85	-1,27	0,33	-1,05	10,24	5,16	0,98	18,57	30,52	5,52
0,90	-1,24	0,36	-1,08	10,33	5,20	0,96	18,54	30,68	5,54
0,95	-1,21	0,38	-1,11	10,43	5,23	0,95	18,52	30,85	5,55
1,00	-1,17	0,41	-1,13	10,53	5,27	0,93	18,51	31,01	5,57

Para obter valores de energia ( $W$ ) com melhor precisão e simultaneamente melhor acurácia, foi modelado o erro quadrático médio  $MSE_w = [E(W) - T_w]^2 + Var(W)$ , em que o alvo foi definido como a utopia da média da corrente  $T_w = 18,5118$  A. A Figura 4.25 representa a superfície de resposta para  $MSE$ . A otimização do valor de  $MSE$  consiste na minimização de sua função. A minimização de  $MSE_w$  é demonstrado resumidamente na Tabela 4.17. Analisando a otimização de  $MSE_w$  pode-se observar que o valor é o mesmo

identificado com  $w_1 = 0,70$  na Tabela 4.16, ou seja, proporcionando maior peso a função de média que a de variância. Isso ocorre devido a dispersão da média ser maior que a da variância.




Figura 4.25 - Superfícies de resposta para  $MSE_W$ ,  $\mathbf{X}_{fixo} = \mathbf{X}_{ClPt}$

Tabela 4.17 - Otimização de  $MSE_W$

Codificados			Decodificados			Respostas			
$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[W]$	$Var[W]$	$S[W]$	$MSE_W$
			$m \times s^{-1}$	$m \times min^{-1}$	mm	kJ	$(kJ)^2$	kJ	$(kJ)^2$
-1,37	0,25	-0,95	9,99	5,06	1,03	18,78	30,07	5,48	30,14

## 4.6 Energia específica de corte utilizada para o aplainamento da madeira *Pinus taeda*

A Figura 4.26 representa o gráfico de Pareto para a resposta de energia específica de corte ( $E_s$ ) para o processo de aplainamento. Pode-se observar que todas as variáveis



de controle ( $v_c$ ,  $v_f$  e  $a_e$ ) e a de ruído  $u$  apresentam efeitos significativos sobre  $E_s$ . Os resultados também demonstraram que os efeitos quadráticos de todas as variáveis de controle foram significativos.




Figura 4.26 - Gráfico de Pareto para energia específica de corte

A Figura 4.27 apresenta o gráfico de efeitos lineares e quadráticos para a resposta  $E_s$ . Pode-se observar que valores menores para  $v_c$ ,  $v_f$  e  $a_e$  proporcionam menores valores de  $E_s$  e à medida que vão aumentando o valor de  $E_s$  também aumenta. Em relação a variável de ruído  $u$ , quanto menor é o percentual de umidade presente na madeira, maior é o valor de  $E_s$  necessária para o aplainamento.




Figura 4.27 - Gráfico de efeitos lineares e quadráticos para  $E_s$

A Figura 4.28 apresenta os gráficos de interações entre as variáveis de controle e de ruído para a resposta  $E_s$ . Pode-se observar existe a interação entre a profundidade de penetração e a umidade da madeira ( $a_e \times u$ ).




Figura 4.28 - Gráfico de interação para energia específica de corte

O modelo de resposta da corrente, obtido por WLS, é representado conforme Equação 4.14. O erro experimental é de  $\hat{\sigma}_{E_s}^2 = 0,001435$  para o modelo de resposta de  $E_s$  e os coeficientes de determinação são de  $R_{adj}^2 = 91,43\%$  e  $R_{prev}^2 = 77,58\%$ . Dessa forma o modelo apresenta uma boa capacidade de previsão dos dados.

$$\begin{aligned}
 E_s(\mathbf{x}, \mathbf{z}) = & 0,4208 + 0,0826v_c + 0,0473 \times v_f + 0,0836 \times a_e + 0,0273 \times u + 0,0227 \times v_c^2 \\
 & + 0,0212 \times v_f^2 + 0,0225 \times a_e^2 - 0,0058 \times v_c \times v_f + 0,0058 \times v_c \times a_e - 0,0025 \times v_c \times u \\
 & + 0,0078 \times v_f \times a_e + 0,0058 \times v_f \times u + 0,0434 \times a_e \times u
 \end{aligned} \quad (4.14)$$

A Tabela 4.18 apresenta a ANOVA para a resposta de  $E_s$  com os fatores que apresenta efeitos significativos destacados. Com um nível de significância de  $\alpha = 0,05$  pode-se confirmar os resultados apresentados na Figura 4.26, em que todas as variáveis

de controle ( $v_c$ ,  $v_f$  e  $a_e$ ) e de ruído ( $u$ ) apresentam efeitos significativos sobre  $E_s$  com p-valor  $< \alpha$ , sendo que  $v_c$ ,  $v_f$ ,  $a_e$  e  $u$  são positivos conforme os coeficientes apresentados na Equação 4.11. Dessa forma pode-se observar que à medida que as variáveis de controle e de ruído aumentam, a energia específica de corte do aplainamento também aumenta, confirmando assim os resultados apresentados pela Figura 4.27.

Quanto aos efeitos quadráticos, todos ( $v_c \times v_c$ ,  $v_f \times v_f$  e  $a_e \times a_e$ ) apresentaram efeitos significativos, ou seja, com p-valor  $< \alpha$ . Já os efeitos de interação, apenas a interação entre  $a_e \times u$  apresentou efeito significativo com p-valor  $< \alpha$  conforme demonstrado na Figura 4.28.

Tabela 4.18 - ANOVA para energia específica de corte

FV	GL	SQ	MQ	F-valor	P-valor
Modelo	13	0,4628	0,0356	24,80	<b>0,000</b>
Linear	4	0,3970	0,0993	69,15	<b>0,000</b>
$v_c$	1	0,1639	0,1639	114,16	<b>0,000</b>
$v_f$	1	0,0536	0,0536	37,36	<b>0,000</b>
$a_e$	1	0,1676	0,1676	116,78	<b>0,000</b>
$u$	1	0,0119	0,0119	8,29	<b>0,011</b>
Quadrado	3	0,0330	0,0110	7,66	<b>0,002</b>
$v_c \times v_c$	1	0,0144	0,0144	10,06	<b>0,006</b>
$v_f \times v_f$	1	0,0126	0,0126	8,78	<b>0,009</b>
$a_e \times a_e$	1	0,0142	0,0142	9,86	<b>0,006</b>
Interações	6	0,0328	0,0055	3,81	<b>0,015</b>
$v_c \times v_f$	1	0,0005	0,0005	0,38	0,546
$v_c \times a_e$	1	0,0005	0,0005	0,37	0,552
$v_c \times u$	1	0,0001	0,0001	0,07	0,798
$v_f \times a_e$	1	0,0010	0,0010	0,68	0,422
$v_f \times u$	1	0,0005	0,0005	0,38	0,548
$a_e \times u$	1	0,0301	0,0301	20,96	<b>0,000</b>
Erro	16	0,0230	0,0014		
Falta de ajuste	9	0,0175	0,0019	2,51	0,119
Erro Puro	7	0,0054	0,0008		
Total	29	0,4857			
$S$	$R^2$	$R^2_{aj}$	$R^2_{prev}$		
0,037886	95,27%	91,43%	77,58%		

As Equações 4.15 e 4.16 apresentam as equações de média e variância de  $E_s$  e a Figura 4.29 apresenta as superfícies de resposta geradas por essas equações.

$$E[E_s(\mathbf{x}, \mathbf{z})] = 0,4208 + 0,0826 \times v_c + 0,0473 \times v_f + 0,0836 \times a_e + 0,0227 \times v_c^2 + 0,0212 \times v_f^2 + 0,0225 \times a_e^2 - 0,0058 \times v_c \times v_f + 0,0058 \times v_c \times a_e + 0,0078 \times v_f \times a_e \quad (4.15)$$

$$\begin{aligned} \text{Var}[E_s(\mathbf{x}, \mathbf{z})] = & 0,0022 - 0,0001 \times v_c + 0,0003 \times v_f + 0,0024 \times a_e + 0,00001 \times v_c^2 \\ & + 0,00003 \times v_f^2 + 0,0019 \times a_e^2 - 0,00003 \times v_c \times v_f - 0,0002 \times v_c \times a_e \\ & + 0,0005 \times v_f \times a_e \end{aligned} \quad (4.16)$$




Figura 4.29 - Superfície de resposta para energia específica de corte,  $\mathbf{X}_{\text{fixo}} = \mathbf{X}_{\text{CtPt}}$

$E[E_s]$  apresenta em seus autovalores sinais positivos  $\lambda_{E[E_s]} = [5,9453; 1,9029; 0,5677]^T$ , logo a função da média da resposta  $E_s$  apresenta convexidade voltada para cima, contendo assim um ponto de mínimo para a função. Já  $Var[E_s]$  apresenta autovalores de sinais mistos  $\lambda_{Var[E_s]} = [8,3924; -6,1456 \times 10^{-16}; 2,2205 \times 10^{-16}]^T$ , sendo então a função da variância da resposta  $E_s$  uma sela em que apresenta um ponto estacionário de sela. Desse modo a otimização para a variância deve ser realizado de forma restrita.

Cada ponto gerado nas superfícies de respostas de média e variância são as combinações dos fatores das variáveis que minimizam o efeito gerado pela umidade da madeira sobre  $E_s$ . As variáveis de  $v_c$ ,  $v_f$  e  $a_e$  em seus valores mínimos proporcionam os menores consumos médios de energia durante o aplainamento.

Para as superfícies de resposta de variância, as variáveis de  $v_c$ ,  $v_f$  e  $a_e$  em seus pontos centrais, ou seja, com valores médios dentro do espaço amostral, proporcionam um aplainamento de respostas com menor desvio padrão, sendo mais acuras.

A matriz *pay-off* para resposta da energia específica de corte ( $E_s$ ) é descrito na Tabela 4.19. A otimização teve como restrição o espaço amostral codificado  $\mathbf{X}^T \mathbf{X} = v_c^2 + v_f^2 + a_e^2 \leq 2,8284 = \rho^2$ , em que pontos estacionários não solucionam o problema. Na matriz *pay-off* encontra-se os valores de ótimos individuais em sua diagonal principal, os valores de pseudo nadir na antidiagonal e os pontos de âncora correspondente a cada coluna da matriz.

Tabela 4.19 - Matriz *pay-off* para  $E[E_s] \times Var[E_s]$

$E[W]$	<b>0,2791</b>	0,2986
$Var[W]$	0,0018	<b>0,0014</b>

Posterior a definição da matriz *pay-off*, foram gerado soluções de Pareto ótimas com incremento  $\delta = 0,05$ , chegando assim  $\eta_r = 21$  soluções. As funções objetivo foram normalizadas e o vetor linha de utopia  $N_1$  no espaço normalizado. A fronteira de Pareto encontra-se representada pela Figura 4.30 para otimização bi-objetivo com  $f_1 = E[E_s]$  e  $f_2 = Var[E_s]$ .




Figura 4.30 - Fronteira de Pareto para  $E[E_s] \times Var[E_s]$

Pela fronteira de Pareto é possível perceber a existência de um conflito entre  $f_1 = E[E_s]$  e  $f_2 = Var[E_s]$ . Para menores valores de média de energia específica de corte ( $E_s$ ) mais inconsistente se torna os resultados, ou seja, maior a variância dos resultados. Em contrapartida para resultados de menor variância a média de energia específica de corte ( $E_s$ ) se mantém alta.

A Tabela 4.20 apresenta os 21 pontos de otimização da fronteira de Pareto da Figura 4.30 com os níveis codificados e decodificados das variáveis de controle, os valores de  $E[E_s]$ ,  $Var[E_s]$  e  $S[E_s]$ , em que  $S[E_s] = \sqrt{Var[E_s]}$ . Com base nos dados tabulados pode-se verificar que os níveis robustos para a corrente estão nos intervalos das variáveis de controle de  $v_c \sim [10,04; 11,08]$  m×s<sup>-1</sup>,  $v_f \sim [3,54; 3,90]$  m×min<sup>-1</sup> e  $a_e \sim [0,99; 1,22]$  mm. Com esses níveis o processo é robusto a oscilação da umidade presente na madeira usinada, ou seja, independente do percentual de umidade presente na madeira, o aplainamento vai proporcionar os mesmos resultados para média e variância de energia específica de corte.

Tabela 4.20 - Resultados da otimização de  $E_s$  pelo método NNC

$w_1$	Codificados			Decodificados			Respostas		
	$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[E_s]$	$Var[E_s]$	$S[E_s]$
				$m \times s^{-1}$	$m \times \min^{-1}$	mm	$\text{kJ} \times \text{cm}^3$	$(\text{kJ} \times \text{cm}^3)^2$	$\text{kJ} \times \text{cm}^{-3}$
0,00	-0,97	-0,90	-0,56	11,08	3,63	1,22	0,299	0,0014	0,0379
0,05	-1,02	-0,91	-0,56	10,95	3,62	1,22	0,297	0,0014	0,0379
0,10	-1,07	-0,92	-0,57	10,82	3,60	1,22	0,295	0,0014	0,0379
0,15	-1,11	-0,93	-0,57	10,68	3,59	1,22	0,293	0,0014	0,0379
0,20	-1,17	-0,95	-0,57	10,54	3,56	1,22	0,291	0,0014	0,0379
0,25	-1,22	-0,97	-0,57	10,38	3,54	1,22	0,289	0,0014	0,0379
0,30	-1,30	-0,89	-0,58	10,16	3,64	1,21	0,287	0,0014	0,0379
0,35	-1,35	-0,77	-0,64	10,04	3,79	1,18	0,285	0,0014	0,0379
0,40	-1,33	-0,76	-0,69	10,09	3,80	1,16	0,284	0,0014	0,0381
0,45	-1,31	-0,75	-0,73	10,13	3,81	1,14	0,283	0,0015	0,0383
0,50	-1,30	-0,75	-0,76	10,18	3,82	1,12	0,282	0,0015	0,0385
0,55	-1,28	-0,74	-0,80	10,23	3,82	1,10	0,281	0,0015	0,0388
0,60	-1,27	-0,73	-0,83	10,27	3,83	1,09	0,281	0,0015	0,0391
0,65	-1,25	-0,73	-0,86	10,31	3,84	1,07	0,280	0,0016	0,0395
0,70	-1,24	-0,72	-0,88	10,35	3,85	1,06	0,280	0,0016	0,0398
0,75	-1,22	-0,71	-0,91	10,39	3,86	1,05	0,280	0,0016	0,0402
0,80	-1,21	-0,71	-0,93	10,43	3,87	1,03	0,280	0,0016	0,0405
0,85	-1,19	-0,70	-0,96	10,47	3,87	1,02	0,279	0,0017	0,0409
0,90	-1,18	-0,69	-0,98	10,52	3,88	1,01	0,279	0,0017	0,0413
0,95	-1,16	-0,69	-1,00	10,56	3,89	1,00	0,279	0,0017	0,0417
1,00	-1,15	-0,68	-1,02	10,60	3,90	0,99	0,279	0,0018	0,0421

Para obter valores de  $E_s$  com melhor precisão e simultaneamente melhor acurácia, foi modelado o erro quadrático médio  $MSE_{E_s} = [E(E_s) - T_{E_s}]^2 + Var(E_s)$ , em que o alvo foi definido como a utopia da média da corrente  $T_{E_s} = 0,2791$  A. A Figura 4.31 representa a superfície de resposta para  $MSE$ .

A otimização do valor de  $MSE$  consiste na minimização de sua função. A minimização de  $MSE_{E_s}$  é demonstrado resumidamente na Tabela 4.21. Analisando a otimização de  $MSE_{E_s}$  pode-se observar que o valor é o mesmo identificado com  $w_1 = 0,80$  na Tabela 4.20, ou seja, proporcionando maior peso a função de média do que a de variância. Isso ocorre devido a dispersão da média ser maior que a da variância.

Desse modo para energia específica de corte ( $E_s$ ) ser mínima,  $v_c$  deve estar entre os pontos fatorial e axial, ambos inferiores. Já  $v_f$  e  $a_e$  devem estar entre os seus respectivos pontos central e fatorial inferior, mais próximos de seus pontos fatoriais

inferiores. Os valores exatos de cada variável de controle estão descritos também na Tabela 4.21.




Figura 4.31 - Superfícies de resposta para  $MSE_{E_s}$ ,  $\mathbf{X}_{fixo} = \mathbf{X}_{CtPt}$

Tabela 4.21 - Otimização de  $MSE_{E_s}$

Codificados			Decodificados			Respostas			
$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[E_s]$	$Var[E_s]$	$S[E_s]$	$MSE_{E_s}$
			$m \times s^{-1}$	$m \times min^{-1}$	mm	$kJ \times cm^{-3}$	$(kJ \times cm^{-3})^2$	$kJ \times cm^{-3}$	$(kJ/cm^3)^2$
-1,21	-0,71	-0,93	10,43	3,86	1,03	0,2795	0,0016	0,0405	0,0016

## 4.7 Espessura média dos cavacos não deformados para o aplainamento da madeira *Pinus taeda*

Para avaliar a qualidade da madeira usinada foi definido o cálculo da espessura média dos cavacos não deformados ( $h_m$ ) para todos os ensaios realizados conforme a Equação 2.5. A otimização então foi realizada sobre essa função determinística, uma vez



que a variável de ruído considerada nos experimentos não exerce nenhuma influência sobre o resultado. Desse modo, esse resultado foi resumido em função apenas das variáveis de processo.

A Figura 4.32 apresenta as superfícies de respostas para  $h_m$  baseado nas variáveis de controle. Na análise entre  $v_c$  e  $v_f$  pode-se observar que menores valores de  $v_c$  e maiores valores de  $v_f$  maximizam o valor de  $h_m$ . Isso ocorre pois ambos os fatores estão relacionados diretamente com o valor de  $f_z$  presente na Equação 2.5, em que  $v_c$  está no numerador e  $v_c$  no denominador da expressão que determina  $f_z$ .




Figura 4.32 - Função  $h_m$  no espaço experimental codificado,  $\mathbf{X}_{fixo} = \mathbf{X}_{CtPt}$

Realizando a minimização do valor de  $h_m$  sujeito à restrição de espaço experimental foi obtido o nível ótimo de  $h_m = 0,017$  mm com os valores de  $15,02 \text{ m}\times\text{s}^{-1}$ ,  $3,02 \text{ m}\times\text{min}^{-1}$  e  $1,08$  mm para  $v_c$ ,  $v_f$  e  $a_e$  respectivamente. A Tabela 4.22 apresenta os níveis ótimos das variáveis de controle nos formatos codificados e decodificados.

Tabela 4.22 - Otimização de  $h_m$ 

Codificados			Decodificados			Respostas
$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$h_m$
			$m \times s^{-1}$	$m \times \text{min}^{-1}$	mm	mm
0,46	-1,38	-0,84	15,02	3,02	1,08	0,017

## 4.8 Otimização multi-objetivo do processo de aplainamento da madeira *Pinus taeda*

### 4.8.1 Análise de correlação entre as respostas do processo

Analisar e definir o padrão ótimo de processo para o aplainamento da madeira *Pinus taeda* embasado apenas nas avaliações individuais de cada resposta pode resultar no processo deficiente em alguma de suas respostas. Isso ocorre pois os valores ótimos para determinada resposta podem levar a valores indesejáveis para as demais respostas. Com isso, o método de análise dos componentes principais foi utilizado a fim de reduzir o número de respostas, simplificando a otimização e garantindo que a correlação entre as respostas não influenciará o resultado de otimização.

A Tabela 4.23 apresenta a matriz de correlação entre as respostas de corrente ( $C$ ), tensão ( $U$ ), torque ( $M$ ), potência mecânica ( $P$ ), energia ( $W$ ), espessura média dos cavacos não deformados ( $h_m$ ) e energia específica de corte ( $E_s$ ). As respostas correlacionadas apresentam coeficiente de Pearson diferente de 0 e pode ser confirmado pela análise de p-valor em que o mesmo deve ser inferior ao nível de significância considerado. Estão destacadas na Tabela 4.23 as respostas correlacionadas com um nível de significância de 0,05.

Pode-se observar na Tabela 4.23 grande número de respostas correlacionadas em que  $p\text{-value} < 0,05$ , apenas entre  $C$  e  $U$ , entre  $U$  e  $M$ , entre  $P$  e  $h_m$  e entre  $h_m$  e  $E_s$  não apresentaram nenhuma correlação. Desse modo, para esse estudo, justifica-se a utilização da análise de componentes principais (PCA). Desse modo foi possível eliminar a dependência entre as respostas ao transformar as respostas originais em termos latentes e otimiza-los ao invés das originais.

Tabela 4.23 - Matriz de correlação

	<i>C</i>	<i>U</i>	<i>M</i>	<i>P</i>	<i>W</i>	<i>h<sub>m</sub></i>
<i>U</i>	0,125* 0,511**					
<i>M</i>	<b>0,981</b> <b>0,000</b>	0,047 0,803				
<i>P</i>	<b>0,769</b> <b>0,000</b>	<b>0,701</b>	<b>0,735</b> <b>0,000</b>			
<i>W</i>	<b>0,376</b> <b>0,041</b>	<b>0,551</b> <b>0,002</b>	<b>0,362</b> <b>0,049</b>	<b>0,635</b> <b>0,000</b>		
<i>h<sub>m</sub></i>	<b>0,554</b> <b>0,001</b>	<b>-0,495</b> <b>0,005</b>	<b>0,591</b> <b>0,001</b>	0,072 0,706	<b>-0,463</b> <b>0,010</b>	
<i>E<sub>s</sub></i>	<b>0,746</b> <b>0,000</b>	<b>0,646</b> <b>0,000</b>	<b>0,721</b> <b>0,000</b>	<b>0,950</b> <b>0,000</b>	<b>0,498</b> <b>0,005</b>	0,190 0,314

Os valores gerados das componentes principais (*PC*) foram a partir das sete respostas estão descritos na

Tabela 4.24. Os valores de cada *PC* estão ordenados conforme a ordem padrão dos experimentos da Figura 4.1. Cada linha de cada *PC* representa o valor latente que substitui o valor das respostas originais.

A Tabela 4.25 represa a análise dos valores dos *PC*'s. *PC1* e *PC2* explicam a variabilidade de 89,40% de todas as variáveis originais, além de seus autovalores corresponderem a 4,0822 e 2,1771 para *PC1* e *PC2*, respectivamente. Desse modo utilizar apenas *PC1* e *PC2* para analisar todas as respostas de aplainamento não prejudica os resultados finais. Devido a isso a otimização multi-objetivo foi considerado apenas os valores latentes de *PC1* e *PC2*.

Para identificar as respostas presentes nos *PC1* e *PC2* pela sua similaridade foi desenvolvido o Dendograma de Ward conforme demonstrado na Figura 4.33. Pode-se visualizar que *PC1* contempla as respostas de *C*, *M* e *h<sub>m</sub>*, enquanto *PC2* contempla as respostas *U*, *P*, *E<sub>s</sub>* e *W*.

Em *PC1* as variáveis de *C* e *M* apresentam grande similaridade, chegando a próximo de 100%. Já *h<sub>m</sub>* possui similaridade ao conjunto *C* e *M* de pouco mais de 70%. Em *PC2* as variáveis de *P* e *E<sub>s</sub>* possuem maior similaridade, chegando próximo a 100%. *U* se assemelha ao conjunto *P* e *E<sub>s</sub>* com similaridade de aproximadamente 80% e *W* se assemelha em 70% aproximadamente ao conjunto de respostas *P*, *E<sub>s</sub>* e *U*.

A Tabela 4.26 apresenta a análise vetorial de cada resposta para cada *PC*, representando o sentido e o tamanho de cada vetor de resposta presente em cada *PC*.

Tabela 4.24 - Valores das componentes principais

Ordem padrão	PC1	PC2	PC3	PC4	PC5	PC6	PC7
1	-2,9332	-0,1780	0,5587	0,0918	0,3684	-0,1898	-0,0202
2	0,7589	-2,1717	0,4493	-0,1752	-0,0655	-0,0072	0,0952
3	-1,4909	1,4415	-0,1083	-0,0376	0,0559	-0,1069	-0,0264
4	0,7620	-0,8942	-1,0611	-0,2840	0,1617	0,0522	0,0892
5	-1,6625	0,5671	0,6953	0,2090	-0,0224	-0,0156	-0,0654
6	0,6137	-1,8289	0,0580	0,2748	-0,2439	0,1100	0,0832
7	-0,3539	2,5693	-0,2722	0,4114	-0,6310	-0,1591	-0,0514
8	1,9648	-0,1709	-1,1555	0,0850	-0,1973	-0,0150	0,0010
9	-3,5014	-0,1440	0,4104	-0,1077	0,2293	0,1072	-0,1761
10	2,3243	-1,9985	1,4720	-0,8657	-0,4062	-0,2704	-0,0860
11	-1,2482	1,5108	-0,0463	-0,0974	0,1085	-0,0665	-0,0298
12	-0,2190	-0,9526	-1,1612	-0,2640	-0,0287	0,0790	0,0955
13	0,1929	0,7381	1,2276	0,2132	0,2803	-0,1316	0,0969
14	3,0015	-1,7369	0,6808	0,3208	0,0813	0,2102	-0,0484
15	2,7585	3,1952	0,3139	-0,2078	-0,0612	0,1661	0,0490
16	4,3117	0,1086	-0,7921	0,0100	0,3471	-0,0043	-0,1333
17	-0,1586	3,2993	1,0596	-0,0914	0,0171	-0,0385	0,1591
18	1,1742	-2,1147	-0,9496	0,5207	0,1201	-0,4025	0,0285
19	-0,3528	-2,0553	1,7986	0,4098	-0,1728	0,1833	0,0079
20	1,7780	1,5307	-0,8566	-0,0929	-0,0865	0,0264	-0,0567
21	-3,4225	-1,1507	-0,5176	-0,3083	0,1959	0,0221	0,0590
22	4,1659	0,8719	0,4527	0,1042	0,3406	0,0217	-0,0192
23	-1,3367	-0,1320	-0,3705	-0,0177	-0,1486	0,0599	-0,0088
24	-1,5636	-0,1648	-0,4033	0,0664	-0,1535	-0,0308	0,0028
25	-1,4510	-0,1229	-0,3750	-0,0169	-0,1562	0,0740	-0,0302
26	-1,7782	-0,1908	-0,5445	0,1124	-0,1427	0,1471	-0,0270
27	-0,8691	-0,1025	-0,2909	-0,0149	-0,0625	0,0253	0,0182
28	-0,3472	-0,0447	-0,1748	-0,0040	0,0564	-0,0194	0,0295
29	-0,5176	-0,0061	-0,1861	-0,1133	-0,0022	0,1383	-0,0361
30	-0,5998	0,3279	0,0887	-0,1307	0,2186	0,0347	0,0001

Tabela 4.25 - Análise dos valores de PC's

	PC1	PC2	PC3	PC4	PC5	PC6	PC7
Autovalor	4,0822	2,1771	0,5962	0,071	0,0503	0,0181	0,0052
Proporção	0,583	0,311	0,085	0,01	0,007	0,003	0,001
Acumulado	0,583	0,894	0,979	0,989	0,997	0,999	1,000

Pela da análise vetorial pode-se confirmar a representação da Figura 4.33, onde os vetores das respostas possuem maior valor no PC que o representa. Como foi definido dois PCs, é então considerado o maior valor das colunas PC1 e PC2. Desse modo as

respostas presentes em PC1 são de C, M e hm enquanto as respostas de U, P, Es e W estão presentes em PC2.




Figura 4.33 - Dendrograma de Ward para C, U, M, P, W, Es e  $h_m$

Tabela 4.26 - Análise vetorial de cada resposta para cada PC

	PC1	PC2	PC3	PC4	PC5	PC6	PC7
<i>C</i>	0,436	0,286	0,182	-0,508	-0,031	0,624	-0,217
<i>U</i>	0,269	-0,499	-0,496	-0,221	-0,471	0,115	0,385
<i>M</i>	0,424	0,319	0,24	-0,161	0,172	-0,404	0,665
<i>P</i>	0,481	-0,117	-0,154	-0,173	0,01	-0,587	-0,597
<i>W</i>	0,309	-0,379	0,684	0,409	-0,348	0,061	-0,037
<i>Es</i>	0,110	0,639	-0,237	0,389	-0,606	-0,036	-0,062
<i>h<sub>m</sub></i>	0,466	-0,049	-0,341	0,565	0,508	0,291	0,031

Para a otimização dos dois PC's simultaneamente foi utilizado o método de componentes principais por peso (WPC). Desse modo foi possível realizar a otimização ponderando considerando o percentual de explicação da variabilidade total das respostas do aplainamento de cada PC. A Tabela 4.27 representa os valores das componentes principais de PC1, PC2 e os valores de WPC ordenados conforme a ordem padrão dos experimentos da Tabela 4.1.

Para a otimização de todo o processo de aplainamento da madeira foi utilizado os valores latentes de WPC na otimização multi-objetivo.

Tabela 4.27 - Valores de PC's e WPC para o processo de aplainamento

Ordem padrão	PC1	PC2	WPC
1	-2,9332	-0,1780	-12,3616
2	0,7589	-2,1717	-1,6301
3	-1,4909	1,4415	-2,9478
4	0,7620	-0,8942	1,1639
5	-1,6625	0,5671	-5,5521
6	0,6137	-1,8289	-1,4764
7	-0,3539	2,5693	4,1490
8	1,9648	-0,1709	7,6485
9	-3,5014	-0,1440	-14,6068
10	2,3243	-1,9985	5,1373
11	-1,2482	1,5108	-1,8063
12	-0,2190	-0,9526	-2,9681
13	0,1929	0,7381	2,3943
14	3,0015	-1,7369	8,4713
15	2,7585	3,1952	18,2169
16	4,3117	0,1086	17,8376
17	-0,1586	3,2993	6,5356
18	1,1742	-2,1147	0,1893
19	-0,3528	-2,0553	-5,9148
20	1,7780	1,5307	10,5904
21	-3,4225	-1,1507	-16,4766
22	4,1659	0,8719	18,9045
23	-1,3367	-0,1320	-5,7441
24	-1,5636	-0,1648	-6,7418
25	-1,4510	-0,1229	-6,1907
26	-1,7782	-0,1908	-7,6743
27	-0,8691	-0,1025	-3,7711
28	-0,3472	-0,0447	-1,5149
29	-0,5176	-0,0061	-2,1262
30	-0,5998	0,3279	-1,7348

#### 4.8.2 Otimização dos componentes principais ponderados

Com a definição dos valores de WPC para cada combinação experimental, foi então analisado as variáveis de controle e ruído para o WPC. A Figura 4.34 representa o gráfico de Pareto para a resposta de WPC para o processo de aplainamento. Pode-se observar que as variáveis de controle  $v_f$ ,  $a_e$  e de ruído  $u$  apresentam efeitos significativos sobre WPC. Apesar da variável de controle  $v_c$  não ter sido significativo,

seu efeito quadrático, juntamente com o efeito quadrático de  $v_f$ , apresentaram efeito significativo sobre WPC.




Figura 4.34 - Gráfico de Pareto para WPC

A Figura 4.35 apresenta o gráfico de efeitos lineares e quadráticos para a resposta WPC. Pode-se observar que  $v_c$  e  $v_f$  apresentaram convexidade voltada para baixo, ou seja, menores valores de WPC são obtidos quando se utiliza valores próximos aos seus pontos centrais. Já valores menores para  $a_e$  proporcionam menores valores de WPC e à medida que seu valor aumenta o valor de WPC também aumenta. Para  $u$  quanto maior for o percentual de umidade presente na madeira menor é o valor de WPC.




Figura 4.35 - Gráfico de efeitos lineares e quadráticos para WPC

A Figura 4.36 apresenta os gráficos de interações entre as variáveis de controle e de ruído para a resposta WPC. Pode-se observar a existência de interação entre  $a_e \times u$ .




Figura 4.36 - Gráfico de interação para WPC

O modelo de resposta WPC, obtido por WLS, é representado conforme Equação 4.17. O erro experimental para o modelo de resposta de WPC é de  $\hat{\sigma}_{E_s}^2 = 18,6822$  e os coeficientes de determinação são de  $R_{adj}^2 = 76,15\%$  e  $R_{prev}^2 = 31,21\%$ .

$$\begin{aligned}
 WPC(\mathbf{x}, \mathbf{z}) = & -4,2972 + 1,4169v_c + 3,9137 \times v_f + 6,3529 \times a_e + 2,7309 \times u + 2,0549 \times v_c^2 \\
 & + 1,7988 \times v_f^2 + 1,5178 \times a_e^2 - 2,1599 \times v_c \times v_f - 1,2595 \times v_c \times a_e + 0,1163 \times v_c \times u \\
 & + 1,6945 \times v_f \times a_e - 0,0719 \times v_f \times u + 2,5387 \times a_e \times u
 \end{aligned} \quad (4.17)$$

A Tabela 4.28 apresenta a ANOVA para a resposta de WPC em que os efeitos significativos estão destacados. Com nível de significância de  $\alpha = 0,05$  pode-se confirmar os resultados apresentados na Figura 4.34, em que as variáveis de controle  $v_f$ ,  $a_e$  e de ruído  $u$  apresentam efeitos significativos sobre WPC com  $p\text{-valor} < \alpha$ , sendo que  $v_f$ ,  $a_e$  e  $u$  são positivos conforme os coeficientes apresentados na Equação 4.17. Dessa forma pode-se concluir que à medida que as variáveis de controle e de ruído aumentam,



o valor de WPC também aumenta, confirmando assim os resultados apresentados pela Figura 4.35.

Quanto aos efeitos quadráticos,  $v_c \times v_c$  e  $v_f \times v_f$  apresentaram efeitos significativos, ou seja, com  $p\text{-valor} < \alpha$ . Já os efeitos de interação, apenas a interação entre  $a_e \times u$  apresentou efeito significativo com  $p\text{-valor} < \alpha$  conforme apresentado na Figura 4.35.

Tabela 4.28 - ANOVA para WPC

FV	GL	SQ	MQ	F-valor	P-valor
Modelo	13	1973,13	151,779	8,12	<b>0,000</b>
Linear	4	1503,68	375,921	20,12	<b>0,000</b>
$v_c$	1	48,18	48,183	2,58	0,128
$v_f$	1	367,60	367,604	19,68	<b>0,000</b>
$a_e$	1	968,63	968,635	51,85	<b>0,000</b>
$u$	1	119,26	119,261	6,38	<b>0,022</b>
Quadrado	3	220,06	73,352	3,93	<b>0,028</b>
$v_c \times v_c$	1	118,24	118,238	6,33	<b>0,023</b>
$v_f \times v_f$	1	90,60	90,597	4,85	<b>0,043</b>
$a_e \times a_e$	1	64,50	64,504	3,45	0,082
Interações	6	249,39	41,564	2,22	0,094
$v_c \times v_f$	1	74,64	74,642	4,00	0,063
$v_c \times a_e$	1	25,38	25,383	1,36	0,261
$v_c \times u$	1	0,22	0,217	0,01	0,916
$v_f \times a_e$	1	45,94	45,942	2,46	0,136
$v_f \times u$	1	0,08	0,083	0,00	0,948
$a_e \times u$	1	103,12	103,120	5,52	<b>0,032</b>
Erro	16	298,91	18,682		
Falta de ajuste	9	256,71	28,524	4,73	0,026
Erro Puro	7	42,20	6,029		
Total	29	2272,04			
$S$	$R^2$	$R^2_{aj}$	$R^2_{prev}$		
4,32229	86,84%	76,15%	31,21%		

As Equações 4.18 e 4.19 apresentam as equações de média e variância que minimizam o enfeito gerado pela umidade da madeira em WPC e a Figura 4.37 apresenta as superfícies de resposta geradas por essas equações.

$$E[WPC(\mathbf{x}, \mathbf{z})] = -4,2972 + 1,4169 \times v_c + 3,9137 \times v_f + 6,3529 a_e + 2,0549 \times v_c^2 + 1,7988 \times v_f^2 + 1,5178 \times a_e^2 - 2,1599 v_c \times v_f - 1,2595 \times v_c \times a_e + 1,6945 \times v_f \times a_e \quad (4.18)$$

$$Var[WPC(\mathbf{x}, \mathbf{z})] = 26,1360 + 0,6353 \times v_c - 0,3924 \times v_f + 13,8622 \times a_e + 0,0135 \times v_c^2 + 0,0052 \times v_f^2 + 6,4450 \times a_e^2 - 0,0167 \times v_c \times v_f + 0,5907 \times v_c \times a_e - 0,3649 \times v_f \times a_e \quad (4.19)$$




Figura 4.37 - Superfície de resposta para energia específica de corte,  $\mathbf{X}_{fixo} = \mathbf{X}_{CtPt}$

$E[WPC]$  apresenta em seus autovalores de sinais positivos  $\lambda_{E[WPC]} = [3,5456; 1,1194; 0,7065]^T$ , logo a função da média da resposta WPC apresenta convexidade voltada para cima, contendo assim um ponto de mínimo. Já  $Var[WPC]$  apresenta autovalores de sinais mistos  $\lambda_{Var[WPC]} = [6,4637; -9,0514 \times 10^{-16}; -9,0513 \times 10^{-16}]^T$ , sendo então a função da variância da resposta WPC uma sela em que apresenta um ponto estacionário de sela. Desse modo a otimização para a variância deve ser realizado de forma restrita ao espaço amostral, uma vez que não possui ponto nem de máximo e nem de mínimo.

As variáveis de controle em conjunto de  $v_c$  com  $v_f$  e  $v_c$  com  $a_e$  em seus fatores mínimos, ou seja, com o mínimo possível de suas velocidades e com a menor profundidade de penetração mantem a média de WPC. Já  $v_f$  com  $a_e$  mantem a média de WPC baixo em seus pontos centrais, ou seja, nos valores médios de velocidade de avanço e profundidade de penetração utilizadas no experimento.

Para a variância dos resultados de WPC, no conjunto de  $v_c$  e  $v_f$ ,  $v_c$  deve ser mantido em valor mínimo e  $v_f$  em valor máximo para que a variação dos resultados sejam mínimas. Para o conjuntos de  $v_c$  com  $a_e$  e  $v_f$  com  $a_e$  os pontos centrais dos experimentos realizados minimizam a variação dos resultados de WPC.

A matriz *pay-off* para resposta WPC é descrito na Tabela 4.29 a fim de analisar o conflito existente entre a média e a variância. A otimização teve como restrição o espaço amostral codificado  $\mathbf{X}^T \mathbf{X} = v_c^2 + v_f^2 + a_e^2 \leq 2,8284 = \rho^2$ , em que pontos estacionários não solucionam o problema. Na matriz *pay-off* encontra-se os valores de ótimos individuais em sua diagonal principal, os valores de pseudo nadir na antidiagonal e os pontos de âncora correspondente a cada coluna da matriz.

Tabela 4.29 - Matriz *pay-off* para  $E[WPC] \times Var[WPC]$

$E[WPC]$	<b>-12,6613</b>	-12,3766
$Var[WPC]$	19,2161	<b>18,6822</b>

A partir da matriz *pay-off*, foi gerado soluções de Pareto ótimas com incremento  $\delta = 0,05$ , gerando assim  $\eta_r = 21$  soluções ótimas. As funções objetivo foram normalizadas e o vetor linha de utopia  $N_1$  no espaço normalizado. A fronteira de Pareto

é então representada pela Figura 4.38 da otimização bi-objetivo com  $f_1 = E[WPC]$  e  $f_2 = Var[WPC]$ .




Figura 4.38 - Fronteira de Pareto para  $E[WPC] \times Var[WPC]$

A Tabela 4.30 apresenta os 21 pontos de otimização da fronteira de Pareto da Figura 4.38 com os níveis codificados e decodificados das variáveis de controle, os valores de  $E[WPC]$ ,  $Var[WPC]$  e  $S[WPC]$ , sendo  $S[WPC] = \sqrt{Var[WPC]}$ .

Com base nos dados tabulados pode-se verificar que os níveis robustos para a WPC estão nos intervalos das variáveis de controle de  $v_c \sim [11,20;11,60]$   $m \times s^{-1}$ ,  $v_f \sim [3,60;3,95]$   $m \times min^{-1}$  e  $a_e \sim [0,83;0,97]$  mm. Com esses níveis o processo é robusto a oscilação dos resultados de WPC devido a umidade presente na madeira usinada.

Para cada ponto tabulado é atribuído um peso diferente para média e variância, conforme o valor de  $w$  vai aumento o peso atribuído a  $f_1 = E[WPC]$  vai decrescendo enquanto para  $f_2 = Var[WPC]$  vai aumentando. O peso atribuído depende então do nível da resposta desejado.

Para obter valores de WPC com melhor precisão e simultaneamente melhor acurácia, foi modelado o erro quadrático médio

$MSE_{WPC} = [E(WPC) - T_{WPC}]^2 + Var(WPC)$ , em que o alvo foi definido como a utopia da média de WPC  $T_{WPC} = -12,6613$  A.

Tabela 4.30 - Resultados da otimização de WPC pelo método NNC

$w_1$	Codificados			Decodificados			Respostas		
	$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[WPC]$	$Var[WPC]$	$S[WPC]$
				$m \times s^{-1}$	$m \times \min^{-1}$	mm			
0,00	-0,93	-0,92	-1,06	11,20	3,60	0,97	-12,38	18,68	4,32
0,05	-0,92	-0,91	-1,07	11,22	3,61	0,96	-12,40	18,68	4,32
0,10	-0,92	-0,90	-1,09	11,23	3,63	0,95	-12,43	18,69	4,32
0,15	-0,91	-0,88	-1,11	11,25	3,65	0,95	-12,45	18,70	4,32
0,20	-0,90	-0,87	-1,12	11,26	3,66	0,94	-12,48	18,71	4,33
0,25	-0,90	-0,86	-1,14	11,28	3,68	0,93	-12,50	18,72	4,33
0,30	-0,89	-0,84	-1,15	11,30	3,70	0,93	-12,52	18,74	4,33
0,35	-0,89	-0,83	-1,16	11,31	3,71	0,92	-12,54	18,75	4,33
0,40	-0,88	-0,82	-1,18	11,33	3,73	0,91	-12,55	18,78	4,33
0,45	-0,87	-0,80	-1,19	11,35	3,75	0,90	-12,57	18,80	4,34
0,50	-0,87	-0,79	-1,21	11,37	3,76	0,90	-12,59	18,82	4,34
0,55	-0,86	-0,77	-1,22	11,38	3,78	0,89	-12,60	18,85	4,34
0,60	-0,85	-0,76	-1,23	11,40	3,80	0,88	-12,61	18,88	4,35
0,65	-0,85	-0,75	-1,25	11,42	3,82	0,88	-12,62	18,91	4,35
0,70	-0,84	-0,73	-1,26	11,45	3,84	0,87	-12,63	18,95	4,35
0,75	-0,83	-0,72	-1,28	11,47	3,85	0,86	-12,64	18,99	4,36
0,80	-0,82	-0,70	-1,29	11,49	3,87	0,86	-12,65	19,03	4,36
0,85	-0,81	-0,69	-1,30	11,52	3,89	0,85	-12,65	19,07	4,37
0,90	-0,80	-0,67	-1,32	11,54	3,91	0,84	-12,66	19,12	4,37
0,95	-0,79	-0,65	-1,33	11,57	3,93	0,83	-12,66	19,16	4,38
1,00	-0,78	-0,64	-1,35	11,60	3,95	0,83	-12,66	19,22	4,38

A Figura 4.39 representa a superfície de resposta para  $MSE$ . A otimização do valor de  $MSE$  consiste na minimização de sua função. Para a análise conjunta das três superfícies de respostas os valores nos fatores axiais mínimos proporcionam um menor valor de  $MSE$ , garantindo um aplainamento com menor média e menor variação possível dos resultados de WPC.

A minimização de  $MSE_{WPC}$  é demonstrado resumidamente na Tabela 4.31. Analisando a otimização de  $MSE_{WPC}$  pode-se observar que o valor é o mesmo identificado com  $w_1 = 0,15$  na Tabela 4.30, ou seja, proporcionando maior peso a função de variância do que a de média. Isso ocorre, pois, a dispersão dos dados na variância é maior do que na média.




Figura 4.39 - Superfícies de resposta para  $MSE_{WPC}$ ,  $\mathbf{X}_{fixo} = \mathbf{X}_{CtPt}$

Tabela 4.31 - Otimização de  $MSE_{WPC}$

Codificados			Decodificados			Respostas			
$v_c$	$v_f$	$a_e$	$v_c$	$v_f$	$a_e$	$E[WPC]$	$Var[WPC]$	$S[WPC]$	$MSE_{WPC}$
			$m \times s^{-1}$	$m \times min^{-1}$	mm				
-0,91	-0,88	-1,11	11,25	3,65	0,95	-12,46	18,70	4,32	-12,66

## 4.9 Experimentos de confirmação

Para o experimento de confirmação foi utilizado os parâmetros encontrados na otimização de WPC. A fim de definir a quantidade necessária de corridas experimentais foi realizado o poder do teste para 2, 3 e 4 corpos de prova para cada nível da variável de ruído conforme representado na Figura 4.40.

Na Figura 4.40 é possível visualizar que o número ideal experimentos para cada nível da variável de ruído é de 4 corridas, possuindo assim um poder de teste de 89,80% de detecção.




Figura 4.40 - Curva do poder do teste para WPC

A Tabela 4.32 apresenta o sequenciamento dos experimentos de confirmação e os resultados obtidos. As variáveis de ruído foram aleatorizadas evitando fatores externos.

Tabela 4.32 - Experimentos de confirmação

Ord. exp.	Variáveis de controle			Ruído	Respostas					
	$v_c$	$v_f$	$a_e$	$U$	$C$	$U$	$M$	$P$	$W$	$E_s$
	$m \times s^{-1}$	$m \times \text{min}^{-1}$	mm	-	[A]	[V]	[N×m]	[kW]	[kJ]	[kJ×cm <sup>-3</sup> ]
1	11,25	3,65	0,95	-1	6,61	117,60	19,36	3,82	9,32	0,31592
2	11,25	3,65	0,95	1	7,13	119,00	22,74	4,52	11,02	0,37406
3	11,25	3,65	0,95	1	7,04	119,25	22,35	4,44	10,82	0,36740
4	11,25	3,65	0,95	-1	7,11	119,14	23,46	4,67	11,39	0,38651
5	11,25	3,65	0,95	1	6,55	116,70	18,30	3,61	8,80	0,29827
6	11,25	3,65	0,95	0	7,33	120,72	24,52	4,88	11,92	0,40422
7	11,25	3,65	0,95	-1	7,43	120,64	24,88	4,97	12,12	0,41076
8	11,25	3,65	0,95	1	6,87	118,17	21,31	4,22	10,30	0,34941
9	11,25	3,65	0,95	0	6,54	117,47	18,90	3,73	9,10	0,30918
10	11,25	3,65	0,95	0	7,24	119,53	24,44	4,87	11,88	0,40251
11	11,25	3,65	0,95	0	6,73	118,35	19,86	3,92	9,57	0,32501
12	11,25	3,65	0,95	-1	6,85	118,44	21,48	4,26	10,38	0,35240

Foi determinado que o teste deveria ter a capacidade de identificar pontos que se distanciasse a 3 desvios padrão, desse modo com o desvio padrão definido em 4,32 os experimentos de confirmação foram capazes identificar oscilação superior a 12,96.

O valor obtido em  $h_m$  foi de 0,0290 mm para as variáveis de controle estabelecidas. As Figura 4.41 até 4.46 representam os testes de variâncias para todas as respostas de aplainamento.




Figura 4.41 - Teste de variâncias para C






Figura 4.42 - Teste de variâncias para  $U$




Figura 4.43 - Teste de variâncias para  $M$




Figura 4.44 - Teste de variâncias para  $P$




Figura 4.45 - Teste de variâncias para  $W$








Figura 4.46 - Teste de variâncias para  $E_s$

A partir dos experimentos de confirmação, pode-se verificar que os parâmetros definidos na otimização multi-objetivo tornam a variância do processo de aplainamento robusto à variação da umidade da madeira para todas as respostas do processo. Dessa forma caso a matéria-prima sofra influência do meio em que está armazenada e sua umidade oscile, o desvio padrão das respostas do aplainamento não irão se alterar significativamente.

As Figura 4.47 até 4.52 representam os testes de médias para todas as respostas de aplainamento.

Figura 4.47 - Teste de médias para  $C$ Figura 4.48 - Teste de médias para  $U$

Figura 4.49 - Teste de médias para  $M$ Figura 4.50 - Teste de médias para  $P$

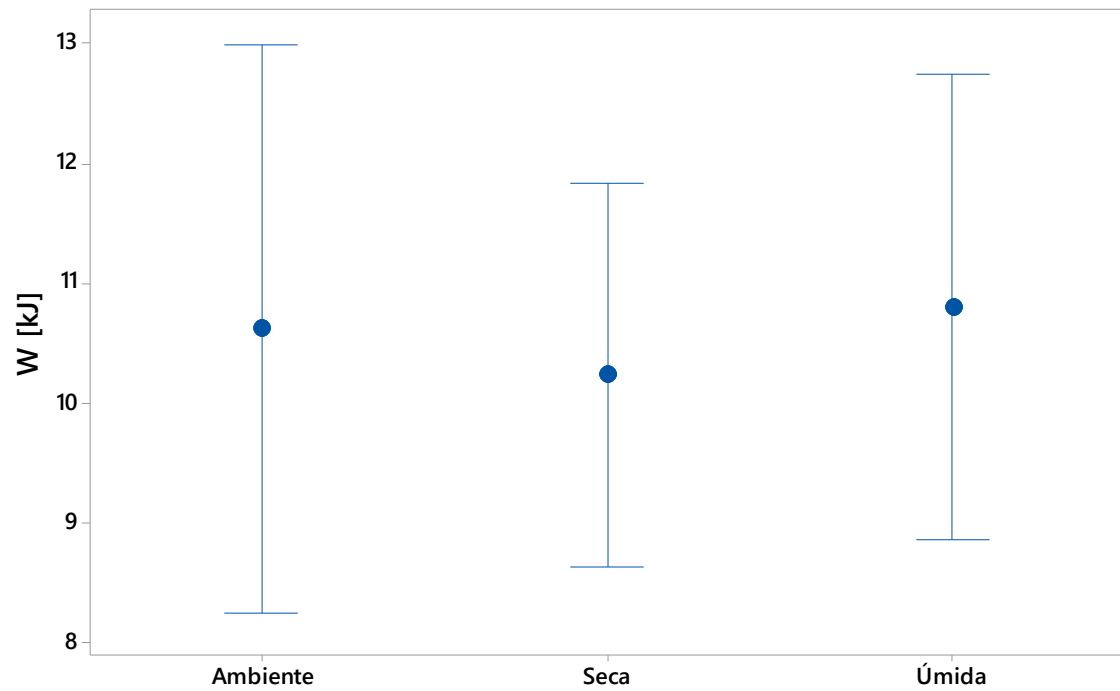


Figura 4.51 - Teste de médias para  $W$




Figura 4.52 - Teste de médias para  $E_s$

Os testes de médias dos experimentos de confirmação demonstraram que a variação da umidade presente no corpo de prova não afetou a média dos resultados do aplainamento. Dessa forma pode-se afirmar que os parâmetros das variáveis de controle utilizado para os experimentos de confirmação minimizaram o efeito mecânico gerado

pela umidade da madeira, tornando assim a variável de umidade presente na madeira não significativo para as respostas analisadas.

A Tabela 4.33 resume os p-valores obtidos através das ANOVAS para as respostas  $C$ ,  $U$ ,  $M$ ,  $P$ ,  $W$  e  $E_s$ . P-valor  $> 0$  indica que a variável de umidade da madeira não afeta as médias das respostas analisadas, confirmam assim os resultados observados nas Figura 4.47 até 4.52.

Tabela 4.33 - Significância das variáveis de ruído pela ANOVA

	$C$	$U$	$M$	$P$	$W$	$E_s$
	p-valores					
$U$	0,908	0,678	0,815	0,815	0,815	0,813

## 5. CONCLUSÕES

Este trabalho abordou a utilização de métodos estatísticos de experimentos e otimização robusta multi-objetivo para o aplainamento da madeira *Pinus taeda*. Foram considerados respostas que abrangem qualidade, produtividade, custo de processo e sustentabilidade, sendo esses analisados pelas respostas de corrente, tensão, torque, potência mecânica, energia consumida, energia específica de corte e espessura média dos cavacos não deformados, de forma a tornar o processo mais robusto a variabilidade causada pela variável de ruído umidade presente no corpo usinado.

Com os resultados apresentados nesse trabalho é possível chegar as seguintes conclusões:

1. As respostas de corrente ( $C$ ), torque ( $M$ ), potência mecânica ( $P$ ), energia consumida ( $W$ ) e energia específica de corte ( $E_s$ ) sofrem influência da variação da umidade presente na madeira;
2. A umidade da madeira possui efeitos de interação com a profundidade de penetração ( $a_e$ ), o que permite identificar parâmetros para  $a_e$  que minimizem o efeito da umidade;
3. O ponto ótimo para corrente ( $C$ ) dentro do espaço que minimiza a umidade da madeira é obtido com as variáveis de controle em  $v_c = 11,67$ ,  $v_f = 4,23$  e  $a_e = 0,78$ , chegando aos valores de  $E(C) = 6,2099$  A e  $Var(C) = 0,1837$  A<sup>2</sup>;
4. O ponto ótimo para torque ( $M$ ) dentro do espaço que minimiza a umidade da madeira é obtido com as variáveis de controle em  $v_c = 11,89$ ,  $v_f = 3,81$  e  $a_e = 0,91$ , chegando aos valores de  $E(M) = 16,062$  N×m e  $Var(M) = 7,447$  (N×m)<sup>2</sup>;
5. O ponto ótimo para potência mecânica ( $P$ ) dentro do espaço que minimiza a umidade da madeira é obtido com as variáveis de controle em  $v_c = 10,05$ ,  $v_f = 4,13$  e  $a_e = 1,06$ , chegando aos valores de  $E(P) = 3,2421$  kW e  $Var(P) = 0,5742$  (kW)<sup>2</sup>;
6. O ponto ótimo para energia ( $W$ ) dentro do espaço que minimiza a umidade da madeira é obtido com as variáveis de controle em  $v_c = 9,99$ ,  $v_f = 5,06$  e  $a_e = 1,03$ , chegando aos valores de  $E(W) = 18,776$  kJ e  $Var(W) = 30,066$  (kJ)<sup>2</sup>;



7. O ponto ótimo para energia ( $E_s$ ) dentro do espaço que minimiza a umidade da madeira é obtido com as variáveis de controle em  $v_c = 10,43$ ,  $v_f = 3,86$  e  $a_e = 1,03$ , chegando aos valores de  $E(E_s) = 0,2795 \text{ kJ} \times \text{cm}^{-3}$  e  $Var(E_s) = 0,0016 \text{ (kJ} \times \text{cm}^{-3})^2$ ;
8. O ponto ótimo para espessura média dos cavacos ( $h_m$ ) é obtido com as variáveis de controle em  $v_c = 15,02$ ,  $v_f = 3,02$  e  $a_e = 1,08$ , chegando ao valor de  $h_m = 0,017 \text{ mm}$ ;
9. A utilização dos componentes principais (PC) permite a redução de 7 respostas para 2 respostas latentes, com explicação de 89,40% da variabilidade total das respostas originais. Desse modo é possível identificar o ótimo global sem a influência de correlação e manipular um menor número de dados;
10. O ponto ótimo para o aplainamento indicado para minimizar o efeito gerado pela umidade da madeira e obtenção dos melhores resultados para as respostas de corrente ( $C$ ), tensão ( $U$ ), torque ( $M$ ), potência mecânica ( $P$ ), energia consumida ( $W$ ), energia específica de corte ( $E_s$ ) e espessura média dos cavacos ( $h_m$ ) são nos parâmetros de  $v_c = 11,25$ ,  $v_f = 3,65$  e  $a_e = 0,95$ .
11. Os experimentos de confirmação comprovaram os dados analisados e otimizados, fazendo com que a variação da umidade da madeira não fosse significativa para nenhuma das respostas do aplainamento utilizando os parâmetros ótimos calculados.

## 5.1 Contribuições do trabalho

A principal contribuição desse trabalho é a otimização multi-objetivo do processo de aplainamento da madeira *Pinus taeda* pelo método NNC. Com o desenvolvimento desse trabalho pode-se destacar os seguintes pontos positivos:

- O estudo do aplainamento da madeira *Pinus taeda*, analisando suas variáveis de controle e de ruído causado nas respostas pelo percentual de umidade presente na madeira usinada;
- A utilização de planejamento experimental, reduzindo o número de corridas experimentais e obtendo resultados significativos;

- A identificação de interações entre as variáveis de controle e entre as variáveis de controle e de ruído;
- A modelagem das respostas envolvendo custo, produtividade, qualidade e sustentabilidade por uma abordagem estatística e robusta;
- A utilização de métodos multivariados para minimizar os efeitos de correlação e reduzir o número de respostas analisadas;
- A otimização multi-objetivo das médias e variâncias de cada resposta do processo de usinagem da madeira *Pinus taeda*;
- A otimização multi-objetivo de todas as respostas coletadas no processo de usinagem da madeira *Pinus taeda*, em que as respostas eram analisadas apenas isoladamente, desconsiderando o efeito de *payoff* entre elas.

## 5.2 Sugestão para trabalhos futuros

A sugestão de trabalhos futuros advém das delimitações definidas para este trabalho, sendo essas das variáveis de controle e de ruído adotadas como também as respostas analisadas, além da expansão dos métodos aplicados para outras áreas de usinagem da madeira. Assim sugere-se para o desenvolvimento de trabalhos futuros no âmbito do processamento da madeira:

- Estudo de aplainamento da madeira *Pinus taeda* considerando as diferentes respostas de rugosidade da superfície obtida.
- Estudo de aplainamento comparando resultados de diferentes madeiras de densidades diferentes;
- Estudo da usinagem da madeira da madeira por serra circular analisando as respostas de corrente ( $C$ ), tensão ( $U$ ), torque ( $M$ ), potência mecânica ( $P$ ), energia consumida ( $W$ ) e energia específica de corte ( $E_s$ ). Juntamente desenvolvendo a otimização multi-objetivo dessas respostas;
- Estudo da usinagem da madeira da madeira por serra de fita analisando as respostas de corrente ( $C$ ), tensão ( $U$ ), torque ( $M$ ), potência mecânica ( $P$ ), energia consumida ( $W$ ) e energia específica de corte ( $E_s$ ). Juntamente desenvolvendo a otimização multi-objetivo dessas respostas.

Em relação às possibilidades no âmbito dos métodos empregados, algumas propostas são:

- Utilização de outros métodos multivariados, como análise fatorial, para o aplainamento da madeira *Pinus taeda*;
- Utilização do arranjo cruzado para a otimização multi-objetivo robusta do processo de aplainamento da madeira *Pinus taeda*;
- Utilização de outros métodos de otimização como NBI e ENNC e confrontar os resultados obtidos;
- Realizar a exploração da fronteira de Pareto considerando  $m \geq 3$ .

## 6. REFERÊNCIAS

ABDI, H.; WILLIAMS, L. J. Principal component analysis. *Wiley Interdisciplinary Reviews: Computational Statistics*, v. 2, n. 4, p. 433-459, 2010.

AGUILERA, A.; MARTIN, P. Machining qualification of solid wood of *Fagus sylvatica* L. and *Picea excelsa* L.: cutting forces, power requirements and surface roughness. *European Journal of Wood and Wood Products*, v. 59, n. 6, p. 483-488, 2001.

AHMADI, A.; MOGHIMI, H.; NEZHAD, A. E.; AGELIDIS, V. G.; SHARAF, A. M. Multi-objective economic emission dispatch considering combined heat and power by normal boundary intersection method. *Electric Power Systems Research*, v. 129, n. 1, p. 32-43, 2015.

AHN, J. W.; WOO, W. S.; LEE, C. M. A study on the energy efficiency of specific cutting energy in laser-assisted machining. *Applied Thermal Engineering*, v. 94, n. 1, p. 748-753, 2016.

AL-GHAMDI, K. A. Robust Parameter Design of an EDM Process. *Quality and Reliability Engineering International*, v. 29, n. 6, p. 921-934, 2013.

AMIRI, S.; SHAKERI, A.; SOHRABI, M. R.; KHALAJZADEH, S.; GHASEMIC, E. Optimization of ultrasonic assisted extraction of fatty acids from *Aesculus hippocastanum* fruit by response surface methodology. *Food Chemistry*, v. 271, n. 1, p. 762-766, 2019.

ANDERSON-COOK, C. M.; BORROR, C. M.; MONTGOMERY, D. C. Response surface design evaluation and comparison. *Journal of Statistical Planning and Inference*, v. 139, n. 2, p. 629-641, 2009.

BALOGUN, V. A.; EDEM, I. F.; ADEKUNLE, A. A.; MATIVENGA, P. T. Specific energy based evaluation of machining efficiency. *Journal of Cleaner Production*, v. 116, n. 1, p. 187-197, 2016.

BARCÍK, Š.; KMINIAK, R.; ŘEHÁK, T.; KVIETKOVÁ, M. The influence of selected factors on energy requirements for plain milling of beech wood. *Journal of Forest Science*, v. 56, n. 5, p. 243-250, 2010.

BARNETT, J. R.; JERONIMIDIS, G. *Wood Quality and its Biological Basis*. 1 ed. New York: John Wiley & Sons, 2009, 240 p.

BELLEVILLE, B.; ASHLEY, P.; OZARSKA, B. Wood planning properties of Australian plantation-grown Eucalypts. *Maderas: Ciencia y Tecnologia*, v. 18, n. 3, p. 425-434, 2016.

BENDIKIENE, R.; KETURAKIS G. The influence of technical characteristics of wood milling tools on its wear performance. *Journal of Wood Science*, v. 63, n. 6, p. 606-614, 2017.

BONDUELLE, A.; CRUZ, S. R.; SILVA, J. R. M. *Processo mecânico da madeira*. Curitiba: Universidade Federal do Paraná, 26 p, 2002. (Notas de aula).

BOX, G. E. P.; WILSON, K. B. On the Experimental Attainment of Optimum Conditions. *Journal of the Royal Statistical Society*, v. 13, n. 1, p. 1-45, 1951.

BRITO, T. G.; PAIVA, A. P.; FERREIRA, J. R.; GOMES, J. H. F.; BALESTRASSI, P. P. A Normal Boundary Intersection Approach to Multiresponse Robust Optimization of the Surface Roughness in End Milling Process with Combined Arrays. *Precision Engineering*, v. 38, n. 3, p. 628-638, 2014.

BRITO, T. G.; PAIVA, A. P.; PAULA, T. I.; DALOSTO, D. N.; FERREIRA, J. R.; BALESTRASSI, P. P. Optimization of AISI 1045 end milling using robust parameter design. *International Journal of Advanced Manufacturing Technology*, v. 84, n. 5, p. 1185-1199, 2015.

BUSSAB, W. O.; MORETTIN, P. A. *Estatística básica*. 8 ed. São Paulo: Saraiva, 2017, 730 p.

CHEN, W.; WIECEK, M. M.; ZHANG, J. Quality utility - a compromise programming approach to robust design. *Journal of Mechanical Design*, v. 121, n. 2, p. 179-187, 1999.

CHETAN, S.; GHOSH, P. V.; RAO, P. V. Specific cutting energy modeling for turning nickel-based Nimonic 90 alloy under MQL condition. *International Journal of Mechanical Sciences*, v. 146-147, n. 1, p. 25-38, 2018.

CHIAO, C. H.; HAMADA, M. Analyzing Experiments with Correlated Multiple Responses. *Journal of Quality Technology*, v. 33, n. 4, p. 451-465, 2001.

CHUERUBIM, M. L.; DA SILVA, I. Analysis of the viability of applying the principal components technique in multivariate data from traffic accidents. *Journal of Engineering & Natural Sciences*, v. 36, n. 4, p. 1023-1033, 2018.

COELHO, C. L.; CARVALHO, L. M. H.; MARTINS, J. M.; COSTA, C. A. V.; MASSON, D.; MÉAUSOONE, P. J. Method for evaluating the influence of wood machining conditions on the objective characterization and subjective perception of a finished surface. *Wood Science Technology*, v. 42, n. 3, p. 181-195, 2008.

COOL, J.; HERNÁNDEZ, R. E. Effects of Peripheral Planing on Surface Characteristics and Adhesion of a Waterborne Acrylic Coating to Black Spruce Wood. *Forest Products Journal*, v. 62, n. 2, p. 124-133, 2012.

COSTA, D. M. D.; BRITO, T. G.; PAIVA, A. P.; LEME, R. C.; BALESTRASSI P. P. A normal boundary intersection with multivariate mean square error approach for dry end milling process optimization of the AISI 1045 steel. *Journal of Cleaner Production*, v. 135, n. 1, p. 1658-1672, 2016.

COTE, W. A. Wood as a substrate for coatings. *Journal of Coatings Technology*, v. 55, n. 1, p. 25-35, 1983.

CUI, P.; SHI, Z. Y.; LI, X.; DUAN, N. M. Evaluation of specific cutting energy considering effects of cutting tool geometry during micro-machining process. *The International Journal of Advanced Manufacturing Technology*, v. 1, n. 1, p. 1-13, 2019.

DARMAWAN, W.; GOTTLÖBER, C.; OERTEL, M.; WAGENFÜHR, A.; FISCHER, R. Performance of helical edge milling cutters in planing wood. *European Journal of Wood and Wood Products*, p. 69, n. 4, p. 565-572, 2011.

DAS, I.; DENNIS, J. E. Normal boundary intersection: a new method for generating the Pareto surface in nonlinear multicriteria optimization problems. *SIAM Journal on Optimization*, v. 8, n. 3, p. 631-657, 1998.

DAVIM, J. P. *Wood Machining*. 1 ed. New York: John Wiley & Sons, 2013, 288 p.

DE MORA, L. F.; COOL, J.; HERNÁNDEZ, R. E. Anatomical evaluation of wood surfaces produced by oblique cutting and face milling. *IAWA Journal*, v. 31, n. 1, p. 77-88, 2010.

DEHNAD, K. *Quality Control, Robust Design, and the Taguchi Method*. 1 ed. Boston: Springer, 1989, 309 p.

DUARTE COSTA, D. M.; BRITO, T. G.; PAIVA, A. P.; LEME, R. C.; BALESTRASSI, P. P. A normal boundary intersection with multivariate mean square error approach for

dry end milling process optimization of the AISI 1045 steel. *Journal of Cleaner Production*, v. 135, n. 1, p. 1658-1672, 2016.

EDEM, I. F.; BALOGUN, V. A. Sustainability analyses of cutting edge radius on specific cutting energy and surface finish in side milling processes. *The International Journal of Advanced Manufacturing Technology*, v. 95, n. 9, p. 3381-3391, 2018.

ESPINOZA, O. A.; BOND, B. H.; LOFERSKI, J. R. Equilibrium moisture content during storage, manufacturing, and shipping of Bolivian wood products. *Forest Products Journal*, v. 57, n. 6, p. 81-87, 2007.

EVANGELARAS, H.; KOUKOUVINOS, C. Robust parameter design: Optimization of combined array approach with orthogonal arrays. *Journal of Statistical Planning and Inference*, v. 136, n. 10, p. 3698-3709, 2006.

EYMA, F.; MÉAUSOONE, P. -J.; MARTIN, P. Strains and cutting forces involved in the solid wood rotating cutting process. *Journal of Materials Processing Technology*, v. 148, n. 2, p. 220-225, 2004.

FERREIRA, D. F. *Estatística Multivariada*. 2 ed. Lavras: Editora UFLA, 2011, 675 p.

FLUKE CORPORATE. *Keeping your word upon drunning*. Holanda: [s.n.], 2000. Disponível em: <[www.fluke.com](http://www.fluke.com)>. Acesso em: 15 jan. 2019.

GAFF, M.; SARVAŠOVÁ-KVIETKOVÁ, M.; GAŠPARÍK, M. Dependence of roughness change and crack formation on parameters of wood surface embossing. *Wood Research*, v. 61, n. 1, p. 163-174, 2016.

GONÇALVES, R.; NÉRI, A. A. Orthogonal cutting forces in juvenile and mature *Pinus taeda* wood. *Scientia Agricola*, v. 62, n. 4, p. 310-318, 2005.

GREMYR, I.; SILVA, V.; RAHARJO, H.; GOH, T. N. Adapting the Robust Design Methodology to support sustainable product development. *Journal of Cleaner Production*, v. 79, n. 1, p. 231-238, 2014.

GRIEBELER, C.; TONDI, G.; SCHNABEL, T.; IGLESIAS, C.; RUIZ, S. Reduction of the surface colour variability of thermally modified *Eucalyptus globulus* wood by colour pre-grading and homogeneity thermal treatment. *European Journal of Wood and Wood Products*, v. 76, n. 5, p. 1495-1504, 2018.

GUEDES, T. O. *Consumo de energia específica de corte em madeiras de diferentes densidades em distintas umidades*. 2016. 83 p. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 2016.

GURLEYEN, L. The study for the strain of hardwood materials against machines and cutters in planning process. *Scientific Research and Essays*, v. 5, n. 24, p. 3903-3913, 2010.

GURLEYEN, L.; BUDAKÇ, M. Determination of machinery and knife strains in the planning of wood-based panels. *Journal of Wood Science*, v. 61, n. 4, p. 391-400, 2015.

HERNÁNDES, R. E. Influence of moisture sorption on the compressive properties of hardwoods. *Wood and Fiber Science*, v. 25, n. 1, p. 103-111, 1993.

HILL, W. J.; HUNTER, W. G. A Review of Response Surface Methodology: A literature Survey. *American Society for Quality*, v. 8, n. 4, p. 571-590, 1966.

HOSSEINI, S. A.; AMJADY, N.; SHAFIE-KHAH, M.; CATALÃO, J. P. A new multi-objective solution approach to solve transmission congestion management problem of energy markets. *Applied Energy*, v. 165, n. 1, p. 462-471, 2016.

HOTELLING, H. Analysis of complex of statistical variables into principal components. *Journal of Educational Psychology*, v. 24, n. 6, p. 417-441, 1933.

IZADBAKHS, M.; GANDOMKAR, M.; REZVANI, A.; AHMADI, A. Short-term resource scheduling of a renewable energy based micro grid. *Renewable Energy*, v. 75, n. 1, p. 598-606, 2015.

JIA, Z.; IERAPETRITOU, M. G. Generate Pareto optimal solutions of scheduling problems using normal boundary intersection technique. *Computers and Chemical Engineering*, v. 31, n. 4, p. 268-280, 2007.

JIN, W.; CAI L. Study and analysis on cutting forces of oblique cutting of wood. *European Journal of Wood and Wood Products*, v. 54, n. 4, p. 283-286, 1996.

JIN W.; CAI L. Study on the normal component force in oblique cutting of wood. *European Journal of Wood and Wood Products*, v. 55, n. 2-4, p. 118-120, 1997.

JOHNSON, R. A.; WICHERN, D. W. Applied multivariate statistical and analysis. 4 ed. New York: Prentice Hall, 1998, 816 p.



KAPLAN, L.; KVIETKOVÁ, M. S.; SEDLECKÝ, M. Effect of the Interaction between Thermal Modification Temperature and Cutting Parameters on the Quality of Oak Wood. *Bioresources*, v. 13, n. 1, p. 1251-1264, 2018.

KISSER, J.; YLINEN, A.; FREUDENBERG, K.; KOLLMANN, F.; LIESE, W.; THUNELL, B.; WINKELMANN, H.; CÔTÉ, W.; KOCH, P.; MARIAN, J.; Stamm, A. History of wood science. *Wood Science and Technology*, v. 1, n. 3, p. 161-190, 1967.

KIVIMAA, E. *Cutting Force in Woodworking*. 18 ed. Michigan: State Institute for Technical Research, 1950, 101 p.

KOCH, P. *Wood Machining Process*. New York: Ronald Press Company, 1964, 530 p.

KOVÁČ, J.; MIKLEŠ, M. The possibilities for measurement of saw blades wearing. *International scientific magazine Acta Universitas Agriculturae et Silviculturae Mendelianae Brunensis*, v. 59, n. 5, p. 137-144, 2011.

KRILEK, J.; KOVAC, J.; KUCERA, M. Wood crosscutting process analysis for circular saw. *BioResources*, v. 9, n. 1, p. 1417-1429, 2014.

KUBŠ, J.; GAFF, M.; BARCÍK, Š. Factors affecting the consumption of energy during the milling of thermally modified and unmodified beech wood. *BioResources*, v. 11, n. 1, p. 736-747, 2016.

KUHN, A. M. Optimizing Response Surface Experiments with Noise Factors Using Confidence Regions. *Quality Engineering*, v. 15, n. 3, p. 419-426, 2003.

LIM, Y. I.; FLOQUET, P.; JOULIA, X. Efficient implementation of the normal boundary intersection (NBI) method on multiobjective optimization problems. *Industrial and Engineering Chemistry Research*, v. 40, n. 2, p. 648-655, 2001.

MALKOÇOĞLU, A.; OZDEMIR, T. The machining properties of some hardwoods and softwoods naturally grown in Eastern Black Sea Region of Turkey. *Journal of Materials Processing Technology*, v. 173, n. 3, p. 315-320, 2006.

MARCHAL R.; MOTHE, F.; DENAUD, L. E.; THIBAUT B.; BLERON L. Cutting forces in wood machining – Basics and applications in industrial processes. A review. *Holzforschung*, v. 63, n. 1, p. 157-167, 2009.

MARTINS, R. A.; MELLO, C. H. P.; TURRIONI, J. B. *Guia para elaboração de monografia e TCC em Engenharia de Produção*. São Paulo: Atlas, 2014.

MATSUURA, S.; SUZUKI, H.; LIDA, T.; KURE, H.; MORI, H. Robust parameter design using a supersaturated design for a response surface model. *Quality and Reliability Engineering International*, v. 27, n. 4, p. 541-554, 2011.

MCKENZIE, W. M. Fundamental aspects of wood cutting process. *Forest Products Journal*, v. 10, n. 9, p. 447-456, 1960.

MESSAC, A.; ISMAIL-YAHAYA, A.; MATTSON, C. A. The normalized normal constraint method for generating the Pareto frontier. *Structural and multidisciplinary optimization*, v. 25, n. 2, p. 86-98, 2003.

MESSAC, A.; MATTSON, C. A. Normal Constraint Method with Guarantee of Even Representation of Complete Pareto Frontier. *AIAA Journal*, v. 42, n. 10, p. 2101-2111, 2004.

MIETTINEN, K. M. *Nonlinear Multiobjective Optimization*. 1 ed. New York: Springer Science & Business Media, 1998, 298 p.

MONTGOMERY, D. C. *Design and Analysis of Experiments*. 8 ed. New York: John Wiley & Sons, 2017, 735 p.

MONTGOMERY, D. C.; RUNGER, G. C. *Applied Statistics and Probability for Engineers*. 6 ed. New York: John Wiley & Sons, 2013, 811 p.

MORADPOUR, P.; DOOSTHOSEINI, K.; SCHOLZ, F.; TARMIAN, A. Cutting forces in bandsaw processing of oak and beech wood as affected by wood moisture content and cutting directions. *European Journal of Wood and Wood Products*, v. 71, n. 6, p. 747-754, 2013.

MOURA, L. F.; HERNÁNDEZ, R. E. Characteristics of sugar maple wood surfaces machined with the fixed-oblique knife pressure-bar cutting system. *Wood Science and Technology*, v. 41, n. 1, p. 17-29, 2007.

MYERS, R. H.; MONTGOMERY, D. C.; ANDERSON-COOK, C. M. *Response surface methodology: Process and product optimization using designed experiments*. 4 ed. New Jersey: Wiley, New Jersey, 2016, 699 p.

MYERS, R. H.; MONTGOMERY, D. C.; VINING, G. G.; BORROR, C. M.; KOWALSKI, S. M. Response surface methodology: A retrospective and literature survey. *Journal of Quality Technology*, v. 36, n. 1, p. 53-77, 2004.

NADERI, N.; HERNÁNDEZ, E. Influence of wood planing on the second-order effects of moisture sorption in sugar maple. *Wood Science and Technology*, v. 33, n. 3, p. 215-222, 1999.

NAIR, V. N.; ABRAHAM, B.; MACKAY, J.; BOX, G.; KACKER, R. N.; LORENZEN, T. J.; LUCAS, J. M.; MYERS, R. H.; VINING, G. G.; NELDER, J. A.; PHADKE, M. S.; SACKS, J.; WELCH, W. J.; SHOEMAKER, A. C.; TSUI, K. L.; TAGUCHI, S.; WU C. F. J. Taguchi's parameter design: a panel discussion. *Technometrics*, v. 34, n. 2, p. 127-161, 1992.

NASIR, V.; COOL, J. A review on wood machining: characterization, optimization, and monitoring of the sawing process. *Wood Material Science and Engineering*, v. 13, n. 2, p. 1-16, 2018.

NAVES, F. L.; DE PAULA, T. I.; BALESTRASSI, P. P.; BRAGA, W. L. M.; SAWHNEY, R. S.; PAIVA, A. P. Multivariate Normal Boundary Intersection based on rotated factor scores: A multiobjective optimization method for methyl orange treatment. *Journal of Cleaner Production*, v. 143, n. 1, p. 413-439, 2017.

NAYLOR, A.; HACKNEY P. A Review of Wood Machining Literature with a Special Focus on Sawing. *BioResources*, v. 8, n. 2, p. 3122-3135, 2013.

NERI, A. C. *Parâmetros de corte na usinagem de madeiras de reflorestamento*. 2003. 154 p. Tese (Doutorado em Engenharia Agrícola) – Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas, Campinas, 2003.

ÖHMAN, M.; GRUBÛI, V.; SANDBERG, D.; EKEVAD, M. Moistening of the wood surface before planing for improved surface quality. *Wood Material Science & Engineering*, v. 11, n. 1, p. 156-163, 2016.

ORLOWSKI, K. A.; OCHRYMIUK, T.; SANDAK, J.; SANDAK A. Estimation of fracture toughness and shear yield stress of orthotropic materials in cutting with rotating tools. *Engineering Fracture Mechanics*, v. 178, n. 1, p. 433-444, 2017.

PAIVA, A. P.; GOMES, J. H. F.; PERUCHI, R. S.; LEME, R.C.; BALESTRASSI, P. P. A multivariate robust parameter optimization approach based on Principal Component Analysis with combined arrays. *Computers & Industrial Engineering*, v. 74, n. 1, p. 186-198, 2014.

PAIVA, A. P.; FERREIRA, J. R.; BALESTRASSI, P. P. A multivariate hybrid approach applied to AISI 52100 hardened steel turning optimization. *Journal of Materials Processing Technology*, v. 189, n. 1, p. 26–35, 2007.

PAIVA, A. P.; PAIVA, E. J.; FERREIRA, J. R.; BALESTRASSI, P. P.; COSTA, S. C. A multivariate mean square error optimization of AISI 52100 hardened steel turning. *The International Journal of Advanced Manufacturing Technology*, v. 43, n. 1, p. 631-643, 2009.

PEARSON, K. On lines and planes of closet fit to systems of points in space. *Philosophical Magazine*, v. 6, n. 2, p. 559-572, 1901.

PEREIRA, R. B. D. *Otimização robusta multi-objetivo do processo de fresamento helicoidal do aço AISI H13 endurecido pelo método da restrição normal*. 2017. 321 p. Tese (Doutorado em Engenharia de Produção) – Instituto de Engenharia de Produção e Gestão, Universidade Federal de Itajubá, Itajubá. 2008.

PEREIRA, R. B. D.; LEITE, R. R.; ALVIM, A. C.; PAIVA, A. P.; FERREIRA, J. R.; DAVIM, J. P. Multi-objective robust optimization of the sustainable helical milling process of the aluminum alloy Al 7075 using the augmented enhanced normalized normal constraint method. *Journal of Cleaner Production*, v. 152, n. 1, p. 474-496, 2017.

PHADKE, M. S. *Quality Engineering Using Robust Design*. 1 ed. New Jersey: Prentice Hall, 1989, 333 p.

PINKOWSKI G.; SZYMAŃSKI, W.; KRAUSS, A.; STEFANOWSK, S. Effect of Sharpness Angle and Feeding Speed on the Surface Roughness during Milling of Various Wood Species. *BioResources*, v. 13, n. 3, p. 6952-6962, 2018.

PODZIEWSKI, P.; SZYMANOWSKI, K.; GÓRSKI, J.; CZARNIAK, P. Relative machinability of wood-based boards in the case of drilling – Experimental study. *BioResources*, v. 13, n. 1, p. 1761-1772, 2018.

PORANKIEWICZ, B. Wood machining investigations: Parameters to consider for thorough experimentation. *BioResources*, v. 9, n. 1, p. 4-7, 2014.

PORANKIEWICZ, B.; GOLI, G. Cutting forces by Oak and Douglas fir machining. *Madeiras: Ciencia y tecnologia*, v. 16, n. 2, p. 199-216, 2014.

PRIARONE, P. C.; ROBIGLIO, M.; SETTINERI, L.; TEBALDO, V. Modelling of specific energy requirements in machining as a function of tool and lubricoolant usage. *CIRP Annals - Manufacturing Technology*, v. 65, n. 1, p. 25-28, 2016

RAMANANANTOANDRO, T.; EYMA, F.; BELLONCLE, C.; RINCÉ, S.; IRLE, S. Effects of machining parameters on raised grain occurring after the application of water-based finishes. *European Journal of Wood and Wood Products*, v. 76, n. 4, p. 1323-1333, 2018.

RATNASINGAM, J.; MA, T. P.; PERKINS, M. C. Productivity in wood machining processes - a question of simple economics? *Holz als Roh- und Werkstoff*, v. 57, n. 1, p. 51-56, 1999.

ROCHA, L. C. S.; PAIVA, A. P.; ROTELA JUNIOR, P.; BALESTRASSI, P. P.; CAMPOS, P. H. S. Robust multiple criteria decision making applied to optimization of AISI H13 hardened steel turning with PCBN wiper tool. *International Journal of Advanced Manufacturing Technology*, v. 89, n. 5, p. 2251-2268, 2016.

SALMON, S. C. *Fundamentals of grinding. Modern grinding process technology*. Ney York: McGraw-Hill, 1992, 225 p.

SARIIŞIK, G.; ÖZKAN, E. Effects of natural rock properties on cutting forces, specific energy and specific cutting energy by four-axis machine. *Arabian Journal of Geosciences*, v. 11, n. 5, p. 1-19, 2018.

SEDLICKÝ, M.; GAŠPARÍK, M. Power Consumption during Edge Milling of Medium-Density Fiberboard and Edge-Glued Panel. *Bioresources*, v. 12, n. 4, p. 7413-7426, 2017.

SEDLICKÝ, M.; KVIETKOVÁ, M. S.; KUBS, J.; KUBOVÁ, P. The effects of milling parameters and thermal modification on power input during the milling of thermally modified spruce and Oak wood. *BioResources*, v. 14, n. 1, p. 669-687, 2019.

SOFUOGLU, S. D. Determination of optimal machining parameters of massive wooden edge glued panels which is made of Scots pine (*Pinus sylvestris* L.) using Taguchi design method. *European Journal of Wood and Wood Products*, v. 75, n. 1, p. 33-42, 2017.

SOUZA, E. M. D.; SILVA, J. R. M. D.; LIMA, J. T.; NAPOLI, A.; RAAD, T. J.; GONTIJO, T. G. Specific cutting energy consumption in a circular saw for Eucalyptus stands VM01 and MN463. *Cerne*, v. 17, n. 1, p. 109-115, 2011.

SUTCU, A. Investigation of parameters affecting surface roughness in CNC routing operation on wooden EPG. *Bioresources*, v. 8, n. 1, p. 795-805, 2013.

TAN, M. H. Y.; NG, S. H. Estimation of the mean and variance response surfaces when the means and variances of the noise variables are unknown. *IIE Transactions*, v. 41, n. 11, p. 942-956, 2009.

THIBAUT, B.; DENAUD, L.; COLLET, R.; MARCHAL, R.; BEAUCHÊNE, J.; MOTHE, F.; MÉAUSOONE, P.; MARTIN, P.; LARRICQ, P.; EYMA, F. Wood machining with a focus on French research in the last 50 years. *Annals of Forest Science*, v. 73, n. 1, p. 163-184, 2016.

TIRYAKI, S.; HAMZAÇEBİ, C.; MALKOÇOĞLU, A. Evaluation of process parameters for lower surface roughness in wood machining by using Taguchi design methodology. *European Journal of Wood and Wood Products*, v. 73, n. 4, p. 537-545, 2015.

TIRYAKI, S.; OZSAHİN, S.; AYDIN, A. Employing artificial neural networks for minimizing surface roughness and power consumption in abrasive machining of wood. *European Journal of Wood and Wood Products*, v. 75, n. 3, p. 347-358, 2017.

UGULINO, B.; HERNÁNDEZ, R. E. Assessment of surface properties and solvent-borne coating performance of red oak wood produced by peripheral planning. *European Journal of Wood and Wood Products*, v. 75, n. 4, p. 581-593, 2017.

VAHIDINASAB, V.; JADID, S. Normal boundary intersection method for suppliers' strategic bidding in electricity markets: An environmental/economic approach. *Energy Conversion and Management*, v. 51, n. 6, p. 1111-1119, 2010.

VINING, G. G.; MYERS, R. H. Combining Taguchi and response surface philosophies: a dual response approach. *Journal of Quality Technology*, v. 22, n. 1, p. 38-45, 1990.

VOBROUČEK, J. The Influence of Milling Tool Geometry on the Quality of the Machined Surface. *Procedia Engineering*, v. 100, n. 1, p. 1556-1561, 2015.

WALKER, J. C. F. *Primary Wood Processing: Principles and Practice*. 2 ed. New Netherlands: Springer Science & Business Media, 2006, 596.

WANG, B.; LIU, Z.; SONG, Q.; WAN, Y.; SHI, Z. Proper selection of cutting parameters and cutting tool angle to lower the specific cutting energy during high speed machining of 7050-T7451 aluminum alloy. *Journal of Cleaner Production*, v. 129, n. 1, p. 292-304, 2016.

WARSI, S.; JAFFERY, S.; AHMAD, R.; KHAN, M.; AGHA, M.; ALI, L. Development and analysis of energy consumption map for high-speed machining of Al 6061-T6 alloy. *The International Journal of Advanced Manufacturing Technology*, v. 96, n. 1, p. 91-102, 2018.

WILLIAMS, R. S.; KNAEBE, M. T.; FEIST W. C. *Finishes for Exterior Wood: Selection, Application & Maintenance*. 1 ed. Madison: Forest Products Research, 1996, 127 p.

WOO, W.; LEE, C. M. A study on the edge chipping according to spindle speed and inclination angle of workpiece in laser-assisted milling of silicon nitride. *Optics and Laser Technology*, v. 99, n. 1, p. 351-362, 2018

WOODSON, G. E.; KOCH, P. *Tool Forces and Chip Formation in Orthogonal Cutting of Loblolly Pine*. Washington: USDA, Forest Service, 1970.

YAN, J.; LI, L. Multi-objective optimization of milling parameters e the trade-offs between energy, production rate and cutting quality. *Journal of Cleaner Production*, v. 52, n. 1, p. 462-471, 2013.

ZOBEL, B. J.; BUIJTENEN. *Wood Variation: Its Causes and Control*. 1 ed. New York: Springer-Verlag, 2012, 363 p.

## **7. APENDECES**

### **Apêndice A. Artigos aprovados para publicação em periódicos**

MELO, D. J.; GUEDES, O. G.; DA SILVA, J. R. M.; PAIVA, A. P. Robust optimization of energy consumption during mechanical processing of wood. *European Journal of Wood and Wood Products*.



## **Apêndice B. Artigos publicados em anais de congressos**

LEITE, R. R.; MELO, D. J.; CARVALHO, H.; OLIVEIRA, L. G.; PAIVA, A. P.

Aplicação de métodos de balanceamento de linha em uma empresa do setor alimentício. In: XXXVIII Encontro Nacional de Engenharia de Produção, 2018, Maceió, AL. A Engenharia de Produção e suas contribuições para o desenvolvimento do Brasil, 2018. DOI: 10.14488/ENEGEP2018\_TN\_STO\_258\_479\_36359

MELO, D. J.; LEITE, R. R.; SILVA, L. A.; SILVA, K. O. A. N.; MONTEVECHI, J. A.

B. Aplicação da programação linear para atendimento de demanda e otimização de recursos em uma empresa de autopeças. In: XXXVII Encontro Nacional de Engenharia de Produção, 2017, Joinville, SC. A Engenharia de Produção e as novas tecnologias produtivas: indústria 4.0, manufatura aditiva e outras abordagens avançadas de produção, 2017. DOI: 10.14488/ENEGEP2017\_TN\_STO\_243\_410\_33560