

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

ESTIMAÇÃO DA RUGOSIDADE GERADA NO PROCESSO DE FRESAMENTO
FRONTAL VIA REDES NEURAS ARTIFICIAIS

por

Henrique Butzlaff Hübner

Dissertação para obtenção do Título de
Mestre em Engenharia

Porto Alegre, fevereiro de 2016.

ESTIMAÇÃO DA RUGOSIDADE GERADA NO PROCESSO DE FRESAMENTO
FRONTAL VIA REDES NEURAIAS ARTIFICIAIS

por

Henrique Butzlaff Hübner

Engenheiro Mecânico

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Mecânica, da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como parte dos requisitos necessários para a obtenção do Título de

Mestre em Engenharia

Área de Concentração: Processos de Fabricação

Orientador: Prof. Dr. André João de Souza

Aprovada por:

Prof. Dr. Alcy Rodolfo dos Santos Carrara

DEMEC / UFRGS

Prof. Dr. Arnaldo Ruben Gonzalez

PROMECC / UFRGS

Prof. Dr. Heraldo José de Amorim

DEMEC / UFRGS

Prof. Dr. Luiz Alberto Oliveira Rocha

Coordenador do PROMEC

Porto Alegre, 16 de fevereiro de 2016.

Dedico este trabalho à minha família,
principalmente aos meus irmãos Laison e Luana.

AGRADECIMENTOS

Ao professor, amigo e orientador, Dr. André João de Souza, pelo apoio, incentivo, orientação e oportunidade de realização deste trabalho.

À comissão de avaliação, Prof. Dr. Alcy Rodolfo dos Santos Carrara, Prof. Dr. Arnaldo Ruben Gonzalez e Prof. Dr. Heraldo José de Amorim, pelas valiosas sugestões de melhorias.

Ao técnico Guilherme Vargas Schirmer, pelo auxílio na execução dos experimentos e companheirismo durante a realização deste trabalho.

Ao técnico Wilbur Trajano, pelo auxílio na metalografia do material.

Aos colegas de laboratório: Bruno, Guilherme, Elias, Marcelo.

À Universidade Federal do Rio Grande do Sul (UFRGS), ao Programa de Pós Graduação em Engenharia Mecânica (PROMEC) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

A Deus, por tudo.

RESUMO

A rugosidade é um parâmetro de acabamento importante nos processos de fabricação por usinagem e é determinado de acordo com a aplicação técnica da superfície usinada. A rugosidade afeta atributos funcionais dos produtos como desgaste, atrito, reflexão da luz, capacidade de manter e espalhar um lubrificante, etc.. Como a inspeção da superfície é normalmente feita com rugosímetros após a operação de usinagem, essa tarefa consome tempo e demanda trabalho, gerando custo adicional ao produto. Assim, este trabalho tem como objetivo estimar os valores das rugosidades média (R_a) e total (R_t) geradas no processo de fresamento frontal a seco do aço SAE 1045 com fresa de topo reto via redes neurais artificiais (RNA). Dessa forma, os valores de rugosidade R_a e R_t podem ser obtidos somente informando os parâmetros do processo ao modelo. Foram considerados como variáveis de entrada do processo a velocidade de corte (v_c), o avanço por dente (f_z) e o raio de ponta da ferramenta (r_ϵ). Após uma análise estatística, constatou-se que as variáveis de saída que melhor se correlacionavam com os valores de rugosidade foram a força média no eixo x (F_x) (direção de avanço) e a variação da força no eixo z (ΔF_z) (direção axial). Os dados de força foram obtidos usando um sistema sensório constituído de plataforma piezométrica, placa de aquisição de dados e computador com software apropriado. Portanto, os cinco parâmetros de entrada utilizados nos 16 modelos testados foram v_c , f_z , r_ϵ , F_x e ΔF_z . O algoritmo de treinamento usado foi o de Levenberg-Marquardt. Dentre os testados, os modelos com topologia 5-10-10-1 (cinco entradas e uma saída) apresentaram as melhores capacidade de estimação para os valores de R_a e R_t , mostrando a eficiência da técnica de modelagem da rugosidade por RNA.

Palavras-chave: rugosidade, fresamento, modelagem, redes neurais artificiais.

ABSTRACT

The surface roughness is an important finishing parameter in the machining manufacturing processes and it is determined according with the technical application of the machined surface. The surface roughness affects functional attributes of parts such as wear, friction, light reflection, ability to spreading and retaining a lubricant etc. As the surface inspection is usually done with the rugosimeter after the machining operation, this task is time consuming and labor demand, generating additional cost to the product. Thus, this work aims to estimate the values of average roughness (R_a) and total roughness (R_t) generated in the dry end milling process of the SAE 1045 steel via artificial neural networks (ANN). Thus, the roughness values of R_a and R_t may be obtained only by informing the process parameters to the model. Cutting speed (v_c), feed per tooth (f_z) and tool nose radius (r_ϵ) were considered as input variables. After statistical analysis, it was found that output variables that best correlate with roughness values were the average force on the x axis (F_x) (feed direction) and the force variation in the z-axis (ΔF_z) (axial direction). The cutting force data signals were obtained using a sensory system composed by piezoelectric platform, data acquisition board and personal computer with appropriate software. Therefore, the five input parameters applied in the 16 models tested were v_c , f_z , r_ϵ , F_x and ΔF_z and the training algorithm used was the Levenberg-Marquardt. Among the models tested, those with 5-10-10-1 topology (five inputs and one output) showed the best capacity for estimation of the R_a and R_t values that can demonstrate the modeling technique effectiveness of the surface roughness using ANN.

Keywords: surface roughness, milling, modeling, artificial neural networks.

ÍNDICE

1	INTRODUÇÃO.....	1
2	FRESAMENTO	5
2.1	Tipos Fundamentais de Fresamento	5
2.2	Tipos de Fresas e Geometrias Obtidas pelo Processo	6
2.3	Grandezas do Processo de Fresamento.....	8
2.3.1	<i>Grandezas de avanço.....</i>	8
2.3.2	<i>Grandezas de penetração</i>	9
2.3.3	<i>Grandezas de velocidade.....</i>	9
2.4	Geometria da Cunha Cortante em Fresas	10
2.5	Aplicação de Meios Lubrificantes em Fresamento	11
3	FORÇAS DE USINAGEM NO PROCESSO DE FRESAMENTO	13
3.1	Equipamento de Medição de Forças.....	15
4	ACABAMENTO SUPERFICIAL	17
4.1	Rugosidade	17
4.2	Parâmetros de Rugosidade.....	18
4.2.1	<i>Rugosidade média (R_a)</i>	18
4.2.2	<i>Rugosidade média parcial (R_z).....</i>	20
4.2.3	<i>Rugosidade máxima (R_y).....</i>	21
4.2.4	<i>Rugosidade total (R_t).....</i>	22
4.3	Medição da Rugosidade.....	23
5	REDES NEURAIS ARTIFICIAIS.....	26
5.1	Histórico sobre Redes Neurais Artificiais [Braga <i>et al.</i> , 2000]	26
5.2	O Cérebro Humano.....	27
5.3	Modelagem Artificial do Neurônio [Haykin, 1999]	29
5.3.1	<i>Tipos de função de ativação</i>	30
5.3.2	<i>Topologia das redes neurais.....</i>	32
5.4	Aprendizagem de Redes Neurais Artificiais.....	33
5.4.1	<i>Algoritmo de treinamento por retropropagação</i>	34
5.4.2	<i>Algoritmo de Gauss-Newton.....</i>	37
5.4.3	<i>Algoritmo de Levenberg-Marquardt.....</i>	38
6	PROJETO DE EXPERIMENTOS	39
6.1	Projetos Fatoriais Completos	39
6.2	Projetos Fatoriais Fracionados.....	41
6.3	Arranjo Composto Central.....	41

7	REVISÃO BIBLIOGRÁFICA	43
7.1	Definição do Problema	45
7.1.1	<i>Escolha do material.....</i>	<i>45</i>
7.1.2	<i>Escolha da ferramenta (fresa).....</i>	<i>47</i>
7.1.3	<i>Escolha dos parâmetros de entrada do modelo</i>	<i>48</i>
7.1.4	<i>Escolha dos parâmetros de saída do modelo</i>	<i>51</i>
7.2	Coleta e Análise dos Dados	53
7.3	Ajuste e Seleção do Modelo	54
7.3.1	<i>Tipos de rede.....</i>	<i>55</i>
7.3.2	<i>Definição da topologia das redes</i>	<i>56</i>
7.3.3	<i>Funções de ativação</i>	<i>57</i>
7.3.4	<i>Algoritmos de treinamento</i>	<i>58</i>
7.3.5	<i>Critérios de parada de treinamento</i>	<i>59</i>
7.3.6	<i>Seleção do melhor modelo.....</i>	<i>61</i>
7.4	Validação do Modelo.....	62
7.4.1	<i>Definição dos erros.....</i>	<i>64</i>
8	ARQUITETURA DO SISTEMA EXPERIMENTAL.....	66
8.1	Aquisição de Sinais de Força.....	69
8.2	Avaliação da Superfície Usinada.....	71
9	DESENVOLVIMENTO DE UM MODELO EM RNA PARA A ESTIMAÇÃO DA RUGOSIDADE	72
9.1	Definição do Problema	72
9.2	Coleta e Análise dos Dados	74
9.2.1	<i>Análise das rugosidades</i>	<i>74</i>
9.2.2	<i>Análise das forças.....</i>	<i>80</i>
9.3	Ajuste e Seleção do Modelo	82
9.4	Validação do Modelo.....	95
10	CONCLUSÕES.....	97
10.1	Sugestões para Trabalhos Futuros	97
	REFERÊNCIAS BIBLIOGRÁFICAS	99
	APÊNDICES	106

LISTA DE FIGURAS

Figura 2.1 – Tipos de fresamento frontal: (a) simétrico de rasgo; (b) simétrico comum; (c) assimétrico com toda superfície sendo fresada; (d) assimétrico	5
Figura 2.2 – Superfícies obtidas pelo processo de fresamento	6
Figura 2.3 – Fresas frontais de facear: a) $\chi_r = 90^\circ$, b) $\chi_r = 45^\circ$	7
Figura 2.4 – Fresas frontais de topo: a) com insertos intercambiáveis ; b) integrais	7
Figura 2.5 – Fresas de topo integrais com arestas arredondadas	7
Figura 2.6 – Fresa cilíndrica: (a) de disco; (b) helicoidal	8
Figura 2.7 – Avanço por dente (f_z) e avanço por volta (f)	9
Figura 2.8 – Profundidades de corte axial (a_p) e radial (a_e)	9
Figura 2.9 – Velocidade de corte no fresamento discordante	10
Figura 2.10 – Características principais da ferramenta de corte: (a) ângulos de folga (α), de cunha (β) e de saída (γ); b) ângulo de posição (χ_r) e raio de ponta (r_ϵ).....	10
Figura 2.11 – Ângulo de hélice (δ) em fresas frontais integrais de topo	11
Figura 3.1 – Fatores que influenciam a força de corte	13
Figura 3.2 – Componentes ortogonais da força de usinagem.....	14
Figura 3.3 – Parcelas estática e dinâmica da força de usinagem em função do tempo de usinagem.....	15
Figura 3.4 – Representação do fenômeno da piezeletricidade	16
Figura 4.1 – Fatores que influenciam a rugosidade	18
Figura 4.2 – Rugosidade média (R_a).....	19
Figura 4.3 – Rugosidade média (R_z)	20
Figura 4.4 – Rugosidade máxima (R_y)	21
Figura 4.5 – Diversas formas de rugosidade com o mesmo valor de R_y	21
Figura 4.6 – Rugosidade total (R_t)	22
Figura 4.7 – Perfil teórico de superfície usinada por fresamento frontal	22
Figura 4.8 – Princípio básico de funcionamento dos instrumentos de medição de textura superficial	23
Figura 4.9 – Componentes de instrumentos de medição de rugosidade e de ondulações através de contato	23

Figura 4.10 – Distorção do perfil devido às dimensões finitas da ponta do apalpador (amplificado)	24
Figura 5.1 – Neurônio biológico e suas conexões.....	28
Figura 5.2 – Modelo não linear de neurônios utilizados na RNA	29
Figura 5.3 – Transformação afim produzida pela presença do <i>bias</i>	30
Figura 5.4 – Topologia de redes <i>Perceptron</i> : (a) com uma única camada; (b) com múltiplas camadas	33
Figura 5.5 – Topologia de redes recorrentes	33
Figura 5.6 – Aprendizado: (a) supervisionado; (b) não supervisionado	34
Figura 5.7 – Sinais de entrada e retropropagação dos erros	35
Figura 5.8 – Gráfico mostrando uma possível superfície do erro com os mínimos locais e o mínimo global	36
Figura 5.9 – Exemplo de uma superfície de erro.....	37
Figura 7.1 – Número de trabalhos publicados com relação ao respectivo ano.	44
Figura 7.2 – Metodologia para o desenvolvimento de um modelo de estimação da rugosidade	44
Figura 7.3 – Número de trabalhos publicados com relação ao material usinado.....	45
Figura 7.4 – Ferramentas de corte utilizadas nos diferentes trabalhos publicados.....	48
Figura 7.5 – Número de trabalhos publicados com relação ao número de entradas utilizadas.....	48
Figura 7.6 – Número de trabalhos publicados com relação à natureza da entrada da rede.....	49
Figura 7.7 – Geometria do corpo de prova avaliada com entrada da rede	50
Figura 7.8 – Número de trabalhos publicados com relação ao número de saídas utilizadas.	51
Figura 7.9 – Número de trabalhos publicados com relação à natureza da saída da rede.	52
Figura 7.10 – Número de trabalhos com relação à metodologia para coleta de dados	54
Figura 7.11 – Numero de trabalhos publicados com relação à RNA utilizada.	55
Figura 7.12 – Número de trabalhos com relação à estratégia para definir a topologia.	56
Figura 7.13 – Número de trabalhos publicados com relação à função de ativação utilizada.	57

Figura 7.14 – Número de trabalhos com relação ao algoritmo de treinamento para redes MLP.....	59
Figura 7.15 – Regra de parada antecipada baseada na validação cruzada	60
Figura 7.16 – Número de trabalhos com relação ao critério de parada do treinamento.....	60
Figura 7.17 – Número de trabalhos publicados com relação ao método para seleção da RNA.	61
Figura 7.18 – Número de trabalhos publicados com relação ao método para validar a RNA.....	63
Figura 8.1 – Arquitetura do sistema experimental.	66
Figura 8.2 – Fresa de topo Mitsubishi APX 3000R.	67
Figura 8.3 – Dimensões do corpo de prova.....	67
Figura 8.4 – Aço SAE 1045: (a) sem ataque; (b) atacado com Nital (composto de 2% de ácido nítrico e 98% de álcool). Ampliação 100×.....	68
Figura 8.5 – Plataforma piezelétrica Kistler 9129AA: (a) foto ilustrativa; (b) detalhe construtivo	69
Figura 8.6 – Software LabVIEW: (a) ambiente de programação; (b) interface gráfica.....	70
Figura 8.7 – Avaliação da superfície: (a) medição de rugosidade; (b) regiões de avaliação; (c) aquisição de imagem.	71
Figura 9.1 – Efeitos do <i>chatter</i> : (a) textura da superfície; (b) textura da superfície com ampliação 200 x; (c) ocorrência de lascamento do inserto.....	73
Figura 9.2 – Perfil da superfície obtido com a ocorrência de <i>chatter</i>	73
Figura 9.3 – Influência dos efeitos principais em: (a) R_a ; (b) R_t	76
Figura 9.4 – Passe 29 ($r_e = 0,8$ mm, $v_c = 140$ m/min, $f_z = 0,07$ mm,): a) perfil da superfície; b) imagem da superfície (ampliação 200 x).	77
Figura 9.5 – Passe 34 ($r_e = 1,2$ mm, $v_c = 110$ m/min, $f_z = 0,08$ mm,): a) perfil da superfície; b) imagem da superfície (ampliação 200x).	77
Figura 9.6 – Passe 2 ($r_e = 0,4$ mm, $v_c = 120$ m/min, $f_z = 0,08$ mm,): a) perfil da superfície; b) imagem da superfície (ampliação 200 x).	78
Figura 9.7 – Passe 14 ($r_e = 0,4$ mm, $v_c = 140$ m/min, $f_z = 0,08$ mm,): a) perfil da superfície; b) imagem da superfície (ampliação 200 x).	78
Figura 9.8 – Interações entre os fatores principais para R_a	79
Figura 9.9 – Interações entre os fatores principais para R_t	79

Figura 9.10 – Passe 53 ($r_e = 1,6$ mm, $v_c = 120$ m/min, $f_z = 0,07$ mm,): a) perfil da superfície; b) imagem da superfície (ampliação 200 x).	80
Figura 9.11 – Passe 55 ($r_e = 1,6$ mm, $v_c = 120$ m/min, $f_z = 0,09$ mm,): a) perfil da superfície; b) imagem da superfície (ampliação 200 x).	80
Figura 9.12 – Exemplo de características extraídas da força em x (F_x).	81
Figura 9.13 – Exemplo de características extraídas da força em y (F_y).	81
Figura 9.14 – Exemplo de características extraídas da força em z (F_z).	81
Figura 9.15 – Topologia das redes empregadas.	83
Figura 9.16 – Metodologia para desenvolver um modelo em RNA.	85
Figura 9.17 – Resultados de R_a experimentais e estimados pela RNA 5-3-1.	86
Figura 9.18 – Resultados de R_a experimentais e estimados pela RNA 5-5-1.	86
Figura 9.19 – Resultados de R_a experimentais e estimados pela RNA 5-10-1.	86
Figura 9.20 – Resultados de R_a experimentais e estimados pela RNA 5-11-1.	87
Figura 9.21 – Resultados de R_a experimentais e estimados pela RNA 5-3-3-1.	87
Figura 9.22 – Resultados de R_a experimentais e estimados pela RNA 5-5-5-1.	87
Figura 9.23 – Resultados de R_a experimentais e estimados pela RNA 5-10-10-1.	88
Figura 9.24 – Resultados de R_a experimentais e estimados pela RNA 5-11-11-1.	88
Figura 9.25 – Resultados de R_t experimentais e estimados pela RNA 5-3-1.	88
Figura 9.26 – Resultados de R_t experimentais e estimados pela RNA 5-5-1.	89
Figura 9.27 – Resultados de R_t experimentais e estimados pela RNA 5-10-1.	89
Figura 9.28 – Resultados de R_t experimentais e estimados pela RNA 5-11-1.	89
Figura 9.29 – Resultados de R_t experimentais e estimados pela RNA 5-3-3-1.	90
Figura 9.30 – Resultados de R_t experimentais e estimados pela RNA 5-5-5-1.	90
Figura 9.31 – Resultados de R_t experimentais e estimados pela RNA para a rede 5-10-10-1.	90
Figura 9.32 – Resultados de R_t experimentais e estimados pela RNA para a rede 5-11-11-1.	91
Figura 9.33 – Evolução do EMQ durante a fase de treinamento da rede para a R_a	92
Figura 9.34 – Dispersão entre a rugosidade R_a experimental e a rugosidade R_a estimada.	92
Figura 9.35 – Evolução do EMQ durante a fase de treinamento da rede para a R_t	93

Figura 9.36 – Dispersão entre a rugosidade R_t experimental e a rugosidade R_t estimada.....	93
Figura 9.37 – Rugosidade R_a : experimental vs. estimada.....	96
Figura 9.38 – Rugosidade R_t : experimental vs. estimada.	96

LISTA DE TABELAS

Tabela 4.1 – Comprimentos de amostragem e medição recomendados para cada faixa de rugosidade média.....	19
Tabela 5.1 – Funções de ativação do neurônio	31
Tabela 6.1 – ANOVA de um projeto fatorial com dois fatores	40
Tabela 7.1 – Resumo dos artigos.....	43
Tabela 8.1 – Especificações dos insertos.....	67
Tabela 8.2 – Resultado da análise química (% em massa).....	68
Tabela 9.1 – Níveis dos fatores controláveis utilizados	72
Tabela 9.2 – Valores experimentais de R_a e R_t	74
Tabela 9.2 (continuação).	75
Tabela 9.3 – Análise de Variância para R_a	75
Tabela 9.4 – Análise de Variância para R_t	76
Tabela 9.5 – Coeficiente de Pearson das características extraídas das forças com as rugosidades média e total.	82
Tabela 9.6 – Valores para o parâmetro μ do algoritmo LM.....	84
Tabela 9.7 – Critérios de parada de treinamento adotados.....	84
Tabela 9.8 – Erro médio quadrático e coeficiente de correlação obtido pelas diferentes topologias utilizadas.	91
Tabela 9.9 – Valores de rugosidade: experimentais vs. estimados.....	94
Tabela 9.10 – Novos dados gerados para a fase de validação.....	95
Tabela 9.11 – Erro percentual com relação ao valor estimado pela RNA.....	96
Tabela A1 – Características extraídas dos sinais captados para os 64 passes realizados.....	106
Tabela A2 – Características extraídas dos sinais captados para os 12 passes adicionais.....	108

LISTA DE SIGLAS E ABREVIATURAS

APC	Aresta postiça de corte
BP	Algoritmo de treinamento Backpropagation
CCD	<i>Central Composite Design</i> (Projeto Composto Central)
CCD*	<i>Charge-Coupled Device</i> (Dispositivo de Carga Acoplada)
DOE	<i>Design of Experiments</i> (Projeto de Experimentos)
EA	Erro absoluto
EP	Erro percentual
EK	Estatística Kappa
EMA	Erro médio absoluto
EMP	Erro médio percentual
EMQ	Erro médio quadrático
EP	Erro percentual
GDA	Algoritmo de treinamento Backpropagation com taxa de aprendizado variável
GDM	Algoritmo de treinamento Backpropagation com termo de momento
GRNN	<i>General Regression Neural Network</i> (Rede Neural de Regressão Geral)
LAUS	Laboratório de Automação em Usinagem
LM	Algoritmo de treinamento de Levenberg-Marquardt
MLP	<i>Multilayer Perceptron</i> (Rede “Perceptron” de Múltiplas Camadas)
MQL	Mínima quantidade de lubrificadorrefrigerante
PRFV	Plástico com reforço de fibra de vidro
RBF	<i>Radial Bases Function</i> (Rede Neural com Função de Base Radial)
Re	Repetitividade
REMQ	Raiz do erro médio quadrático
REQR	Raiz do erro quadrático relativo
RNA	Redes Neurais Artificiais
SLP	<i>Single layer perceptron</i> (Rede “Perceptron” com única camada)

LISTA DE SÍMBOLOS

(Unidades no sistema internacional)

α	Ângulo de folga [°]
β	Ângulo de cunha [°]
γ	Ângulo de saída [°]
δ	Ângulo de hélice [°]
φ	Ângulo de contato da ferramenta com a peça [°]
χ_r	Ângulo de posição [°]
α_b	Taxa de aprendizado do algoritmo Backpropagation [adm]
γ_b	Termo de momento do algoritmo Backpropagation [adm]
μ	Parâmetro do algoritmo de Levenberg-Marquardt [adm]
μ_g	Média geral [adm]
a_e	Profundidade radial de corte [mm]
a_p	Profundidade axial de corte [mm]
b_k	Bias do neurônio k [adm]
d	Diâmetro da fresa [mm]
f	Avanço por volta [mm/volta]
f_z	Avanço por dente [N]
F_a	Força axial [N]
F_r	Força radial [N]
F_t	Força tangencial (força de corte) [N]
F_x	Força na direção x [N]
F_y	Força na direção y [N]
F_z	Força na direção z [N]
h	Espessura do cavaco [mm]
I	Matriz identidade [adm]
J	Matriz jacobiana [adm]
K_{ac}	Coefficiente de pressão específica na direção axial [N/mm ²]
K_{ae}	Constante de borda na direção axial [N/mm]

K_{rc}	Coeficiente de pressão específica na direção radial [N/mm ²]
K_{re}	Constante de borda na direção radial [N/mm]
K_{tc}	Coeficiente de pressão específica na direção tangencial [N/mm ²]
K_{te}	Constante de borda na direção tangencial [N/mm]
l_e	Comprimento de amostragem [mm]
l_m	Comprimento de avaliação [mm]
l_r	Comprimento de amostragem [mm]
n	Rotação da ferramenta [rpm]
N	Número de amostras [adm]
n_f	Número de experimentos da parte fatorial [adm]
p_j	Valor estimado pela rede [μm]
Q	Quantidade de padrões de entrada da rede [adm]
r	Coeficiente de correlação de Pearson [adm]
r_ε	Raio de ponta da ferramenta [mm]
R^2	Coeficiente de determinação
R_a	Rugosidade Média [μm]
R_t	Rugosidade Total [μm]
R_y	Rugosidade Máxima [μm]
R_z	Rugosidade Média [μm]
SS	Soma de quadrados [adm]
SQ	Soma quadrática das respostas [adm]
t_j	Valor experimental [μm]
v_c	Velocidade de corte [m/min]
v_k	Campo local induzido do neurônio k [adm]
w_{kj}	Peso sináptico do neurônio k com relação ao terminal da entrada j [adm]
x_j	Sinal de entrada na sinapse j [adm]
y_k	Sinal de saída do neurônio k [adm]
z	Número de dentes da fresa [adm]
α_n	Distância do centro do arranjo de experimentos ao ponto axial [adm]
$\varphi(\cdot)$	Função de ativação [adm]

1 INTRODUÇÃO

O fresamento se diferencia dos demais processos de usinagem devido a sua cinemática onde a peça translada e a ferramenta gira. A operação de fresamento é aplicada com mais frequência na geração de superfícies planas; no entanto, a aplicação na geração de superfícies mais complexas vem aumentando juntamente com o aumento do emprego de centros de usinagem cinco-eixos [Sandvik, 2012]. Diniz *et al.*, 2013, relatam que o fato de a fresa poder se apresentar nas mais variadas formas confere à operação de fresamento um caráter de versatilidade em termos de geometrias possíveis de serem geradas e que boa parte das superfícies não-planas e de não-revolução somente podem ser geradas por este processo. Segundo Stemmer, 1995, outras vantagens do processo de fresamento são a qualidade dos acabamentos superficiais e a alta taxa de remoção de cavacos (alta produtividade).

Conforme Lou *et al.*, 1999, a qualidade da superfície usinada é bastante importante no fresamento, sendo que uma superfície de “boa” qualidade tem alta resistência à fadiga, alta resistência à corrosão e elevada vida em fluência.

Huang e Chen, 2003, mencionam que o acabamento superficial é o fator chave na avaliação da qualidade de um produto, sendo a rugosidade média (R_a – *Roughness Average*) o parâmetro mais comum usado para quantificar o acabamento superficial. O parâmetro R_a afeta vários atributos funcionais dos produtos fabricados por usinagem incluindo o atrito, o desgaste, a reflexão da luz e a habilidade para distribuir e manter um lubrificante. Um acabamento superficial apropriado para um produto é determinado pela sua função técnica. Um valor de R_a inapropriado reduz a qualidade do produto; portanto, um valor de rugosidade desejado é usualmente especificado para um produto e o processo de fabricação é selecionado e aplicado adequadamente para assegurar a qualidade desejada [Bhushan, 1999].

De acordo com Jansson *et al.*, 1984, a rugosidade não é só um fator utilizado para o controle de qualidade, mas também um parâmetro de saída usado para monitorar o processo de usinagem. Especificações de acabamento superficial são úteis para determinar a estabilidade do processo de fabricação, pois uma deterioração deste acabamento pode ser um sinal da presença de não homogeneidade do material da peça, desgaste progressivo da ferramenta, ou até mesmo lascamentos da ferramenta.

Segundo Benardos e Vosniakos, 2003, há dois principais problemas que os engenheiros enfrentam em processos de fabricação. O primeiro é determinar os parâmetros que irão propiciar as qualidades desejadas do produto final (atender as especificações

técnicas); o segundo é maximizar o desempenho do sistema de fabricação utilizando os recursos disponíveis.

Os fenômenos que ocorrem em usinagem são bastante complexos e interagem com um grande número de fatores. Como as decisões tomadas pelos engenheiros são baseadas em suas experiências, competências e procedimentos com respeito a tais fenômenos, pesquisadores propõem modelos que tentam simular condições de usinagem e estabelecer relações de causa e efeito entre fatores e características desejadas do produto [Benardos e Vosniakos, 2003].

Conforme Aykut, 2011, a inspeção da superfície é normalmente feita com rugosímetros após a operação de usinagem, sendo uma operação que consome tempo e demanda trabalho, levando a um custo adicional no produto. Por conseguinte, tem-se na predição ou estimacão (por modelos e/ou algoritmos) da rugosidade gerada no processo de usinagem uma forma também de diminuir custo e tempo, pois é possível a determinacão da mesma somente informando os parâmetros de entrada do processo ao modelo.

Benardos e Vosniakos, 2003, fizeram uma revisão sobre os principais métodos utilizados para modelar a rugosidade. Segundo os autores, quatro são as principais abordagens utilizadas para esse fim:

- Basear-se na teoria da usinagem para desenvolver modelos analíticos e/ou algoritmos computacionais que representam a superfície usinada.
- Examinar fatores do processo como força, vibraçã, ultrassom, emissão acústica, parâmetros de corte, etc. e estabelecer a correlaçã dos mesmos com a rugosidade.
- Utilizar a metodologia de projeto de experimentos (DOE – *Design of Experiments*).
- Aplicar técnicas de inteligêcia computacional (p. ex. redes neurais artificiais).

Segundo a conclusã dos autores, as abordagens que utilizam redes neurais artificiais (RNA) fornecem os modelos mais precisos.

Zain *et al.*, 2010, resumizam as principais habilidades de uma RNA na estimacão da rugosidade gerada em processos de usinagem:

- A RNA é capaz de lidar com uma forma não linear de aprendizagem que define o mapeamento entre entradas e saídas.
- Quando comparada com abordagens convencionais, a RNA é mais sucedida em termos de velocidade, simplicidade e capacidade de aprender com exemplos, e também não requer muitos dados experimentais.
- O modelo de RNA não precisa de quaisquer suposições preliminares quanto aos mecanismos subjacentes ao processo modelado.

- Aperfeiçoamentos no comportamento dos resultados experimentais são fáceis de compreender em um curto período de tempo a partir do modelo em RNA.
- O desempenho na predição/estimação da rede pode ser também melhorado pela definição de mais níveis nos parâmetros de entrada e repetição do treinamento.
- Existem softwares com pacotes de ferramentas como o MATLAB® Toolbox que pode facilmente ser usado para treinar e testar os dados de usinagem simulados.
- A RNA permite simples complementação do modelo por meio de novos parâmetros de entrada sem modificar a estrutura existente.
- Pesquisadores têm a chance de escolher e comparar diferentes algoritmos de treinamento como o BP (*Back-Propagation*) e RB (*Resilient Back-propagation*) em RNA para obter resultados mais precisos para o modelo de predição/estimação.

Ainda segundo Zain *et al.*, 2010, as seguintes desvantagens podem ser resumidas:

- Experiências empíricas são necessárias na criação de modelos realísticos.
- O aperfeiçoamento da RNA através da definição de mais níveis para os parâmetros de entrada do processo é oneroso e lento.
- Repetir o treinamento da rede para melhorar o modelo não é garantido.

Pontes *et al.*, 2010, fizeram uma revisão focada na predição/estimação de valores de rugosidade nos processos de usinagem que utilizam RNA como técnica de modelagem computacional. Dentre os trabalhos analisados, o processo de usinagem mais estudado foi o torneamento (42,23% dos trabalhos). O segundo mais estudado foi o fresamento (28,88%), seguido pela eletroerosão (11,11%). Os demais trabalhos (17,78% restantes) consistiram em furação, retificação, microusinagem, corte com jato d'água e abrasivo, e usinagem eletroquímica.

O uso de RNA em aplicações de usinagem pode ser dividido em treinamento *on-line* e *off-line*. Para treinamento *off-line* os dados do conjunto não mudam e, uma vez obtida uma solução para a rede, esta deve permanecer fixa. Caso novos dados sejam adicionados ao conjunto, um novo treinamento, envolvendo também os dados anteriores, deve ser realizado para se evitar interferência no treinamento anterior. Por sua vez, no aprendizado *on-line*, o conjunto de dados muda continuamente, e a rede deve estar em contínuo processo de adaptação [Braga *et al.*, 2000; Sick, 2002].

Assim, este trabalho tem como objetivo analisar o potencial da RNA na estimação da rugosidade gerada pelo processo de fresamento frontal a seco do aço SAE 1045 com fresa de topo reto a partir das variações da velocidade de corte, do avanço por dente e do raio de ponta

da ferramenta. Para tanto, o texto está dividido em dez capítulos e um apêndice, conforme descrição que se segue:

- **Capítulo 1.** Contextualização do tema, abordando a relevância do processo de fresamento assim como a importância da modelagem da rugosidade gerada no processo.
- **Capítulo 2.** Descrição sobre tipos fundamentais de fresamento, tipos de fresas, tipos de geometrias das superfícies obtidas pelo processo, grandezas do processo, ângulos da aresta de corte e aplicação de meios lubrificantes no processo de fresamento.
- **Capítulo 3.** Detalhamento sobre a decomposição dos esforços de usinagem no processo de fresamento e dos equipamentos usados para medi-los.
- **Capítulo 4.** Apresentação dos fatores que compõem o acabamento superficial, como também os parâmetros e os equipamentos para quantificá-los e determiná-los.
- **Capítulo 5.** Revisão teórica relativa às redes neurais artificiais, apresentando seus modelos, algoritmos de aprendizagem, características e generalizações.
- **Capítulo 6.** Breve descrição sobre projeto de experimentos.
- **Capítulo 7.** Revisão de artigos que empregaram redes neurais artificiais como técnica de estimação e/ou predição da rugosidade no processo de fresamento.
- **Capítulo 8.** Descrição da arquitetura do sistema experimental, explicando as propriedades dos equipamentos e materiais utilizados, assim como o procedimento adotado.
- **Capítulo 9.** Análise da influência dos parâmetros de entrada sobre o acabamento da superfície fresada e detalhamento do modelo proposto de estimação da rugosidade baseado em redes neurais artificiais.
- **Capítulo 10.** Apresentação das conclusões do trabalho, assim como sugestões para trabalhos futuros.
- **Apêndice.** Ilustração da magnitude das características extraídas dos sinais de força medidos.

2 FRESAMENTO

Fresamento é um processo de usinagem no qual a remoção de material da peça se realiza de modo intermitente pelo movimento de rotação da ferramenta, geralmente multicortante, gerando superfícies usinadas das mais variadas formas. Comumente a peça de trabalho efetua o movimento de avanço, enquanto que a ferramenta, denominada fresa, realiza o movimento de corte, mantendo o eixo de rotação em uma posição fixa [Diniz *et al.*, 2013; Ferraresi, 1977; Stemmer, 1995]. Cada uma das arestas de corte da fresa é responsável pela remoção de certa quantidade de material através do engajamento limitado de cada dente que gera a formação e expulsão do cavaco para fora da região de corte [Sandvik, 2012].

2.1 Tipos Fundamentais de Fresamento

Diniz *et al.*, 2013, citam que a operação de fresamento pode ser classificada de duas formas: conforme a disposição do eixo árvore da máquina-ferramenta e de acordo com a disposição dos dentes ativos da fresa. Com relação à primeira forma, o fresamento pode ser horizontal, fresamento vertical ou fresamento inclinado. Com relação à segunda, o fresamento pode ser tangencial ou frontal.

No fresamento tangencial, o eixo da fresa é paralelo à superfície que está sendo gerada e os dentes ativos estão na superfície cilíndrica da ferramenta. As fresas empregadas são cilíndricas ou tangenciais. No fresamento frontal, o eixo da fresa é perpendicular à superfície gerada e os dentes ativos estão na superfície frontal da ferramenta. As fresas usadas são frontais ou de topo. No corte frontal há diferentes formas de fresar, como mostra a Fig. 2.1.




Figura 2.1 – Tipos de fresamento frontal: (a) simétrico de rasgo; (b) simétrico comum; (c) assimétrico com toda superfície sendo fresada; (d) assimétrico [Diniz *et al.*, 2013].

Conforme se pode observar na Fig. 2.1, a espessura de corte (h) varia conforme o ângulo de contato do dente com a peça (φ). O corte concordante caracteriza-se por apresentar uma espessura máxima no início do corte, variando até uma espessura mínima. No corte discordante, ocorre o inverso: a espessura h é mínima no início do corte e varia até um valor máximo. Pode-se observar na Fig. 2.1(a) que o fresamento simétrico de rasgo apresenta essas duas características, ou seja, corte combinado: como a ferramenta gira no sentido horário, o corte se inicia como discordante ($0^\circ \leq \varphi \leq 90^\circ$) e passa para concordante ($90^\circ \leq \varphi \leq 180^\circ$).

2.2 Tipos de Fresas e Geometrias Obtidas pelo Processo

A Figura 2.2 apresenta diversas geometrias possíveis de serem obtidas por fresamento.




Figura 2.2 – Superfícies obtidas pelo processo de fresamento [adaptado de Diniz *et al.*, 2013]

Os diferentes tipos de geometrias apresentadas na Figura 2.2 permitem ser fabricados devido aos diversos tipos e formas de fresas existentes dentro das maneiras de classificação apresentadas. Em seguida estão especificados alguns exemplos de tipos de fresas e as possíveis superfícies passíveis de serem geradas com base na mesma figura.

- Fresa frontal de facear (Fig. 2.3). Utilizada para obter superfícies planas (vide Fig. 2.2(a)). Quando se almeja obter superfícies como as da Fig. 2.2(b), deve-se usar um ângulo de posição $\chi_r = 90^\circ$ (ver seção 2.4, pág. 11). Já para superfícies como as da Fig. 2.2(i), deve-se utilizar χ_r correspondente ao ângulo do chanfro desejado. Os dentes da fresa (normalmente insertos de metal duro) são montados em um cabeçote fresador, como mostra a Fig. 2.3(a).
- Fresas frontais de topo (Fig. 2.4). Este tipo pode ser usado quando se deseja obter superfícies como as ilustradas nas Fig. 2.2(c) e Fig. 2.2(d). Bolsões, como os ilustrados na Fig. 2.2(f), também podem ser obtidos com este tipo de ferramenta, mas desde que as fresas apresentem arestas até seu centro (vide Fig. 2.4(b)), o que permite iniciar o corte com avanço axial semelhante a uma operação de furação.




Figura 2.3 – Fresas frontais de facear: a) $\chi_r = 90^\circ$, b) $\chi_r = 45^\circ$ [Sandvik, 2012].



Figura 2.4 – Fresas frontais de topo: a) com insertos intercambiáveis [Sandvik, 2012];
b) integrais [Dormer Tools, 2015].

- Fresas frontais de topo com arestas arredondadas (Fig. 2.5). Estas ferramentas são utilizadas quando se deseja obter superfícies como as ilustradas na Fig. 2.2(g) e com bom grau de acabamento. Podem ser integrais ou com insertos intercambiáveis.




Figura 2.5 – Fresas de topo integrais com arestas arredondadas [Sandvik, 2012].

- Fresa cilíndrica de disco (Fig. 2.6(a)). Quando se deseja produzir superfícies como as ilustradas nas Fig. 2.2(c), Fig. 2.2(d) e Fig. 2.2(h), também se pode utilizar este tipo de ferramenta. A escolha entre usar uma fresa cilíndrica de disco e uma fresa frontal de topo vai depender da relação entre profundidade e largura do rasgo e do tipo da máquina

disponível. Caso a razão entre a profundidade e largura de corte for grande, opta-se primeiramente pela fresa de disco.

- Fresa cilíndrica helicoidal (Fig. 2.6(b)). Utiliza-se quando se deseja obter superfícies como a mostrada na Fig. 2.2(e). Nesta ferramenta, os dentes são parcialmente engajados na peça; conseqüentemente, a força e o torque resultantes da operação de corte são menores se comparado a uma fresa cilíndrica de disco.



(a)



(b)

Figura 2.6 – Fresa cilíndrica: (a) de disco; (b) helicoidal [Sandvik, 2012].

2.3 Grandezas do Processo de Fresamento

Para que o processo de usinagem ocorra com a definição da porção de sobrematerial a ser removido e uma eficiente retirada de cavaco, certas grandezas de avanço, de penetração e de velocidade devem ser informadas à máquina-ferramenta.

2.3.1 Grandezas de avanço

São grandezas que resultam do movimento de avanço ilustradas na Fig. 2.7, onde:

- Avanço $f \Rightarrow$ é o percurso de avanço em milímetros em uma volta completa da ferramenta.
- Avanço por dente $f_z \Rightarrow$ é o percurso de avanço por dente, medido na direção de avanço e corresponde à distância entre duas superfícies consecutivas. É dado pela Equação (2.1), onde z é o número de dentes da fresa.

$$f_z = \frac{f}{z} \text{ [mm/dente]} \quad (2.1)$$




Figura 2.7 – Avanço por dente (f_z) e avanço por volta (f) [Sandvik, 2012].

2.3.2 Grandezas de penetração

São grandezas que descrevem geometricamente a relação de penetração entre a ferramenta e a peça (Fig. 2.8), onde:

- Profundidade de corte axial $a_p \Rightarrow$ é a profundidade de penetração da ferramenta em relação à peça, medido perpendicularmente ao plano de trabalho.
- Profundidade de corte radial $a_e \Rightarrow$ é a largura de penetração da ferramenta em relação à peça, medida no plano de trabalho e perpendicular à direção de avanço.




Figura 2.8 – Profundidades de corte axial (a_p) e radial (a_e) [Sandvik, 2012].

2.3.3 Grandezas de velocidade

A velocidade de rotação (n) define o número de voltas que a fresa faz por minuto no eixo árvore. Este é um valor orientado à máquina-ferramenta, calculado a partir do valor de velocidade de corte (v_c) em metros por minuto recomendada para uma operação. No caso, v_c é a velocidade tangencial instantânea resultante dessa rotação (Fig. 2.9).




Figura 2.9 – Velocidade de corte no fresamento discordante [adaptado de Sandvik, 2012].

A velocidade de rotação é definida pela Eq. (2.2), onde d é o diâmetro da fresa [mm]:

$$n = \frac{1000 \cdot v_c}{\pi \cdot d} \text{ [rpm]} \quad (2.2)$$

Já a velocidade de avanço (v_f) representa a velocidade com que a fresa se desloca na direção de avanço com relação à peça fixada na mesa da máquina-ferramenta. A velocidade de avanço também é um valor orientado à máquina e é dada pela Equação (2.3):

$$v_f = f \cdot n \text{ [mm/min]} \quad (2.3)$$

2.4 Geometria da Cunha Cortante em Fresas

Todas as fresas são compostas por arestas (dentes) cortantes. As características principais de cada dente estão ilustrados na Figura 2.10 e descritos a seguir.




Figura 2.10 – Características principais da ferramenta de corte: (a) ângulos de folga (α), de cunha (β) e de saída (γ); b) ângulo de posição (χ_r) e raio de ponta (r_s).

- Ângulo de saída (γ). Tem como função auxiliar o escoamento do cavaco e influenciar a força de corte. Ressalta-se que ferramentas demasiadamente positivas podem quebrar

devido ao enfraquecimento da cunha. No entanto, como vantagens, têm-se a diminuição da força de corte e uma considerável melhora na qualidade da peça.

- Ângulo de cunha (β). Garante a rigidez da ferramenta principalmente se esta estiver submetida a solicitações pesadas.
- Ângulo de folga (α). Reduz o atrito entre a superfície da peça e a superfície de folga.
- Ângulo de posição (χ_r). É o ângulo definido entre a aresta principal de corte e a superfície do corpo de prova. No caso da fresa mostrada na Fig. 2.10 (b), $\chi_r = 45^\circ$. A espessura do cavaco, as forças de corte e a vida da ferramenta são afetadas por este ângulo. De acordo com Sandvik, 2012, a diminuição de χ_r reduz a espessura do cavaco e promove uma entrada gradual do dente na peça, o que reduz a pressão radial e preserva a aresta de corte.
- Raio de ponta (r_e). Afeta diretamente a rugosidade devido a sua contribuição geométrica. Proporciona a junção da aresta principal com a aresta secundária de corte.

As fresas frontais integrais de topo (Fig. 2.11), apresentam também um ângulo de hélice (δ) cuja função é auxiliar na expulsão do cavaco e influenciar nos esforços axiais. Conforme Dormer Tools, 2015, um ângulo de hélice elevado pode causar problema de carga nos mancais e o deslocamento da fresa ao longo do fuso.




Figura 2.11 – Ângulo de hélice (δ) em fresas frontais integrais de topo [Dormer Tools, 2015].

2.5 Aplicação de Meios Lubrificadorrefrigerantes em Fresamento

Durante o corte se desenvolve grande quantidade de calor devido à energia necessária para a deformação do cavaco e à energia devido aos atritos nas interfaces ferramenta-peça e cavaco-ferramenta. A fim de evitar dano térmico à estrutura superficial da peça, desgaste da ferramenta e dilatação térmica da peça (para obter menores tolerâncias na peça), utilizam-se meios lubrificadorrefrigerantes. Estes têm a função de lubrificar (diminuir o coeficiente de atrito) e/ou refrigerar (diminuir o calor gerado) e/ou expulsar o cavaco da região de corte. Conseqüentemente, as forças e a potência de corte podem diminuir [Diniz *et al.*, 2013].

Os meios lubrificadorrefrigerantes são classificados em quatro grupos de acordo com as substâncias ou misturas que os compõem. São eles: meios miscíveis em água (ex.: soluções aquosas e emulsões), meios não miscíveis em água (ex.: óleos graxos e óleos minerais), gases

e névoas (ex.: ar, mínima quantidade de fluído) e os meios sólidos (ex.: bissulfeto de molibdênio). Os principais fatores a serem considerados para a seleção do lubrificador são o material da peça, a severidade da operação (condições de usinagem), o material da ferramenta e a operação de usinagem [Diniz *et al.*, 2013].

Em fresamento, o uso de fluidos de corte (sintéticos, semissintéticos ou emulsões) pode também melhorar o acabamento. No entanto, se forem mal empregados, podem prejudicar a vida da ferramenta, pois os dentes da fresa podem estar sujeitos a variações bruscas de temperatura que são resultantes de o dente hora estar em contato com a peça e hora estar ao ar em contato com a ação refrigerante do fluido [Diniz *et al.*, 2013].

Segundo Sandvik, 2012, quanto maior a temperatura na região de corte, mais inapropriado se torna o uso do fluido de corte em fresamento. Por isso, em operações de acabamento, a aplicação de fluido não reduzirá a vida útil da ferramenta tanto quanto no desbaste, devido ao nível reduzido de calor gerado.

No fresamento a seco, as variações de temperatura também acontecem, porém, permanecem dentro do escopo do projeto para a classe de metal duro. Como vantagens do corte a seco citam-se a eliminação do custo de descarte, melhores condições ambientais e menores impactos ecológicos.

3 FORÇAS DE USINAGEM NO PROCESSO DE FRESAMENTO

As forças de usinagem dependem de um grande número de fatores tais como material da peça, parâmetros de corte, uso de lubrificante e propriedades da ferramenta de corte (geometria e material). Na Figura 3.1 é apresentado o diagrama de causa e efeito (também chamado de diagrama espinha de peixe ou diagrama de Ishikawa) mostrando os fatores que influenciam a força de corte [Bajić *et al.*, 2012].

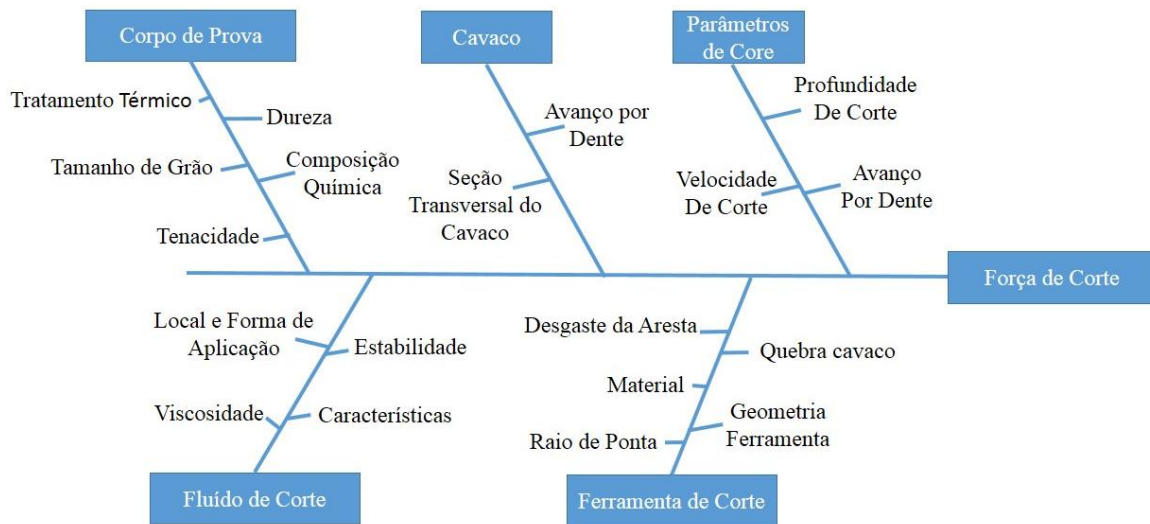


Figura 3.1 – Fatores que influenciam a força de corte [adaptado de Bajić *et al.*, 2012].

Segundo Rigatti, 2010, dentre os erros que podem ser causados pelas variações das forças de usinagem, o que exerce maior influência no acabamento e na tolerância dimensional é a deflexão da ferramenta. O autor relata ainda que a deflexão da ferramenta no fresamento de topo varia durante todo processo, ocorrendo tanto na usinagem de segmentos retos como na usinagem de cantos.

No processo de fresamento a espessura do cavaco (h) varia conforme o ângulo de contato do dente da fresa com a peça (φ) e com o avanço por dente (f_z). De acordo com Lima *et al.*, 2012, a variação da espessura do cavaco pode ser aproximada pela Equação (3.1):

$$h(\varphi) = f_z \cdot \text{sen}(\varphi) \quad (3.1)$$

Altintas, 2000, mostra a decomposição da força de usinagem em três componentes ortogonais (Fig. 3.2) denominadas força tangencial (F_t), radial (F_r) e axial (F_a). As Equações (3.2), (3.3) e (3.4) expressam, respectivamente, tais forças em função do ângulo de contato do dente da fresa com a peça (φ).




Figura 3.2 – Componentes ortogonais da força de usinagem.

$$F_t(\varphi) = K_{tc} \cdot a_p \cdot h(\varphi) + K_{te} \cdot a_p \quad (3.2)$$

$$F_r(\varphi) = K_{rc} \cdot a_p \cdot h(\varphi) + K_{re} \cdot a_p \quad (3.3)$$

$$F_a(\varphi) = K_{ac} \cdot a_p \cdot h(\varphi) + K_{ae} \cdot a_p \quad (3.4)$$

No caso, K_{tc} , K_{rc} e K_{ac} são os coeficientes de pressão específica de corte devido a ação de corte nas direções tangencial, radial e axial, respectivamente, e K_{te} , K_{re} e K_{ae} são as constantes de borda.

As componentes da força de usinagem durante a operação de corte no fresamento estão sujeitas a flutuações dinâmicas ao longo do tempo devido à natureza de corte. Em razão dessas flutuações, Toh, 2004, divide os esforços medidos em duas parcelas: estática e dinâmica. Na Figura 3.3, tem-se que a parcela dinâmica é definida pela dispersão dos valores em torno da média. Para um intervalo de confiança de 95%, tem-se que a repetitividade é dada por $Re = \pm 1,96 \cdot s$, onde s é o desvio-padrão da amostra.

Assim, o valor médio (parcela estática) da força é calculado como sendo a média aritmética dos valores de uma amostra de n dados de força F_i tomados a cada instante t_i , conforme Equação (3.5). Se forem considerados todos os pontos adquiridos, a parcela dinâmica da força passa a ser constituída pelos pontos definidos com a diferença entre a intensidade da força em cada instante e o valor médio calculado (Eq. 3.6) [Souza, 2004].

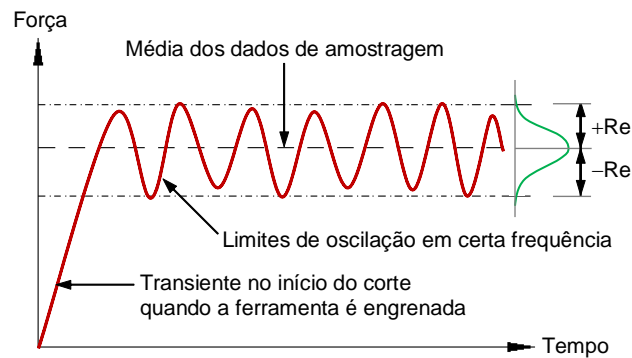


Figura 3.3 – Parcelas estática e dinâmica da força de usinagem em função do tempo de usinagem [adaptado de Souza, 2004].

$$F_{stat} = \frac{1}{N} \sum_{i=1}^n F_i(t_i) \quad (3.5)$$

$$F_{dyn}(t_i) = F_i(t_i) - F_{stat} \quad (3.6)$$

onde N é o número de amostras.

3.1 Equipamento de Medição de Forças

A determinação das forças de usinagem normalmente é feita com o emprego de dinamômetros especificamente projetados para esta finalidade. Conforme Ferraresi, 1977, esses equipamentos podem utilizar diferentes princípios de medida como hidráulicos, pneumáticos, variação da resistência elétrica (*strain-gages*) e por piezeletricidade.

Segundo Castillo, 2005, os sistemas de monitoramento e aquisição de sinais de força mais utilizados em usinagem são os que empregam o princípio da piezeletricidade. Estes transdutores utilizam um fenômeno associado à geração de cargas elétricas na superfície de um material quando a ele é aplicado uma grandeza mecânica (pressão, força e aceleração) suficiente para deformá-lo. Além disso, são também recíprocos, ou seja, há uma correspondente mudança da forma do material quando certa tensão elétrica é aplicada em alguma das suas superfícies (Fig. 3.4) [Ferraresi, 1977, Hoff, 2009]. Alguns exemplos de cristais piezelétricos são o quartzo, sal de Rochelle, titanato de bário e turmalina, dentre outros. A carga produzida é proporcional à força atuante no cristal contido no sensor e a sensibilidade deste é estabelecida em pico-Coulomb por unidade mecânica (pC/U.M.) [Kistler, 2010].




Figura 3.4 – Representação do fenômeno da piezeletricidade [Hoff, 2009].

Conforme relatado por Lima *et al.*, 2012, as três componentes da força de corte no referencial do inserto (F_t , F_r , F_a) estão em direções em que não coincidem com as direções dos eixos coordenados do dinamômetro fixo na máquina-ferramenta. A decomposição das três forças nos eixos do dinamômetro (x, y e z) em função da posição angular, pode ser calculada pelas Equações (3.7), (3.8) e (3.9) respectivamente. Lembrando que é recomendado alinhar os eixos do dinamômetro aos eixos da máquina.

$$F_x(\varphi) = -F_t \cdot \cos(\varphi) - F_r \cdot \sin(\varphi) \quad (3.7)$$

$$F_y(\varphi) = F_t \cdot \sin(\varphi) - F_r \cdot \cos(\varphi) \quad (3.8)$$

$$F_z(\varphi) = F_a \quad (3.9)$$

Onde:

$F_x(\varphi)$ é a decomposição das forças F_t e F_r no eixo x do dinamômetro;

$F_y(\varphi)$ é a decomposição das forças F_t e F_r no eixo y do dinamômetro;

$F_z(\varphi)$ é a decomposição da força F_a no eixo z do dinamômetro.

4 ACABAMENTO SUPERFICIAL

O acabamento de uma superfície é a combinação de vários fatores que podem ser divididos em rugosidade, ondulações e falhas. As ondulações são irregularidades superficiais ou erros geométricos que tem espaçamentos maiores que as irregularidades consideradas rugosidade. Dentre as causas podem ser citadas flexões da ferramenta e/ou peça devido às forças de usinagem, vibrações, temperatura de corte ou também erros de fixação da peça ou ferramenta. As falhas são interrupções na topografia típica de uma superfície e dentre as possíveis causas podem ser os defeitos inerentes do material, como inclusões, trincas, bolhas, ou também surgir durante o processo de corte [Machado *et al.*, 2009].

4.1 Rugosidade

A rugosidade de uma superfície é composta de erros microgeométricos ou irregularidades finas e é resultado da ação inerente ao processo de corte. Segundo Machado *et al.*, 2009, ondulações e falhas devem ser evitadas na fabricação de uma superfície, visto que são considerados erros de fabricação. No entanto, a rugosidade é um parâmetro especificado de acordo com a aplicação da superfície usinada. Para as superfícies que requerem pintura, superfícies de mancais, superfícies que servirão de escoamento de fluidos e gases, etc., ter uma rugosidade baixa é essencial. Já superfícies que trabalham com lubrificação devem ter uma rugosidade característica de modo que favoreça a lubrificação.

A rugosidade depende de vários parâmetros como propriedades da ferramenta de corte, parâmetros de usinagem, propriedade da peça e dos fenômenos de corte [Bajić *et al.*, 2012]. A Figura 4.1 ilustra os parâmetros que influenciam a rugosidade no processo de corte.

As condições de corte têm grande efeito na rugosidade superficial. Em baixas velocidades de corte (v_c), por exemplo, pode ocorrer a formação da aresta postiça de corte (APC) e, durante o corte, partes dela irão cisalhar e permanecerão aderidas à superfície da peça. Como resultado, tem-se um acabamento rugoso. Quando se aumenta o avanço (f) em baixas v_c , o resultado é uma superfície ainda pior. Isto normalmente é atribuído a um acréscimo no tamanho da APC. Logo, o acabamento melhora quando se incrementa v_c , pois a APC desaparece em consequência da diminuição do coeficiente de atrito e do aumento da temperatura na região de corte [Machado *et al.*, 2009].

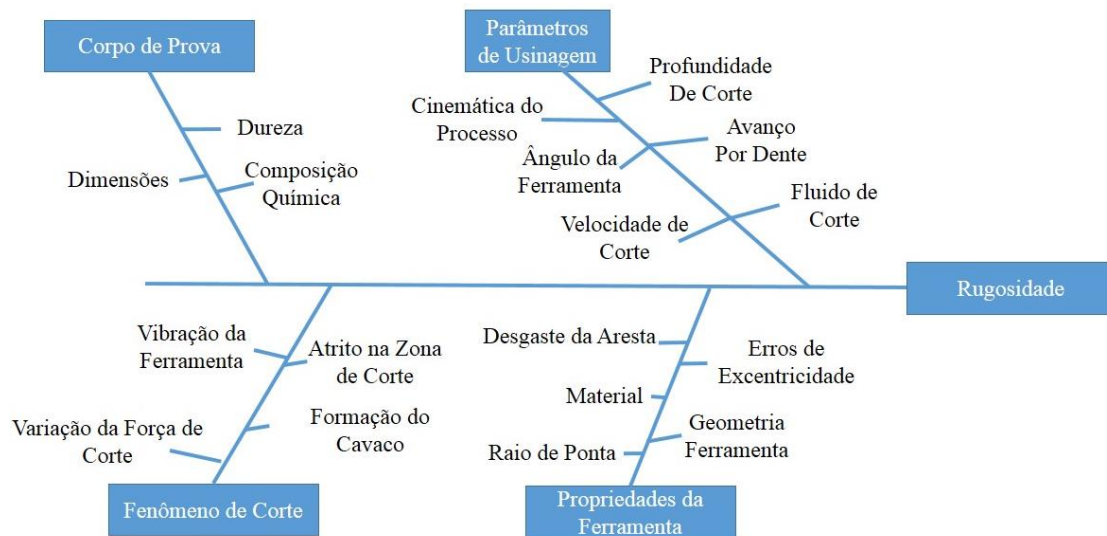


Figura 4.1 – Fatores que influenciam a rugosidade [adaptado de Bajić *et al.*, 2012].

Ainda segundo Machado *et al.*, 2009, outro fator que tem grande influência na rugosidade é o raio de ponta da ferramenta (r_e). Este deve ser suficientemente grande para diminuir o efeito dos dentes da ferramenta nas marcas de avanço, com apreciável melhora na rugosidade. No entanto, um raio de ponta excessivo pode gerar vibrações.

4.2 Parâmetros de Rugosidade

Existem alguns parâmetros pelos quais a rugosidade pode ser avaliada de maneira quantitativa. Os principais são: Rugosidade Média (R_a – *Roughness Average*), Rugosidade Média Parcial (R_z – *Mean Roughness Depth*), Rugosidade Máxima (R_y – *Maximum Roughness Height*) e Rugosidade Total (R_t – *Total Roughness*).

4.2.1 Rugosidade média (R_a)

Corresponde à média aritmética dos valores absolutos das ordenadas de afastamento (y_i) dos pontos do perfil de rugosidade em relação à linha média, dentro do comprimento de medição (l_m) (Fig. 4.2). Segundo a norma ABNT NBR ISO 4287, 2002, o comprimento de amostragem (l_e) – também chamado de *cutoff* – é o comprimento na direção x usado para identificar as irregularidades características do perfil de avaliação; e comprimento de medição (l_m) é definido como sendo o comprimento na direção x usado para estabelecer o perfil de

avaliação e pode conter um ou mais comprimentos de amostragem. Para uma maior confiabilidade dos dados, recomenda-se $l_m = 5 \cdot l_e$.




Figura 4.2 – Rugosidade média (R_a) [Carter, 2015].

A Tabela 4.1 apresenta os valores dos comprimentos de amostragem e medição de acordo com a norma ABNT NBR ISO 4288, 2008.

Tabela 4.1 – Comprimentos de amostragem e medição recomendados para cada faixa de rugosidade média.

Faixa de R_a [μm]	Comprimento de amostragem l_e [mm]	Comprimento de medição l_m [mm]
até 0,02	0,08	0,4
de 0,02 a 0,1	0,25	1,25
de 0,1 a 2	0,8	4
de 2 a 10	2,5	12,5
de 10 a 80	8	40

Carter, 2015, cita que o parâmetro R_a pode ser usado nos casos em que for necessário o controle contínuo da rugosidade nas linhas de produção, em superfícies em que o acabamento apresenta sulcos de usinagem bem orientados (torneamento, fresamento etc.) e em superfícies de pouca responsabilidade (p. ex. acabamentos com fins apenas estéticos). Como vantagens podem-se citar a sua determinação por quase todos os equipamentos de medição de rugosidade devido a sua grande utilização e sua aplicabilidade à maioria dos processos de fabricação. Como desvantagens têm-se os fatos de o valor da R_a não sofrer grande alteração se um pico ou vale atípico aparecer na superfície e de não definir a forma das

irregularidades do perfil (um mesmo valor de R_a pode ser obtido para superfícies geradas por diferentes operações de corte).

Para uma operação de fresamento frontal com fresa de topo o parâmetro R_a pode ser definido teoricamente em função do raio de ponta (r_ϵ) e do avanço por dente (f_z) da ferramenta pela Equação (4.1) [Machado *et al.*, 2009].

$$R_a = \frac{r_\epsilon}{2} - \sqrt{\frac{r_\epsilon^2}{4} - \left(\frac{f_z}{4}\right)^2} \quad (4.1)$$

4.2.2 Rugosidade média parcial (R_z)

Corresponde à média aritmética dos cinco valores da rugosidade parcial (Z_i). Cada valor é definido como o valor absoluto da ordenada do ponto de maior afastamento, acima e abaixo da linha média, existente em cada comprimento de amostragem (l_e), conforme Figura 4.3.




Figura 4.3 – Rugosidade média (R_z) [Carter, 2015].

O parâmetro R_z pode ser empregado nos casos em que pontos isolados não influenciam na função da peça a ser controlada (p. ex. superfícies de apoio e de deslizamento, ajustes prensados etc.; superfícies onde o perfil é periódico e conhecido). Como vantagens, podem ser citadas que ele indica a distribuição média da superfície vertical e que riscos isolados serão considerados apenas parcialmente, de acordo com o número de pontos isolados; além disso, este parâmetro define muito bem a superfície em perfis periódicos. Como desvantagens, cita-se o fato de que nem todos os equipamentos fornecem o parâmetro e pode dar uma imagem errada da superfície, pois avalia erros que muitas vezes não representam a superfície como um todo (p. ex. risco causado após a usinagem que não caracteriza o processo).

Individualmente, o valor de R_z também não representa informação suficiente a respeito da superfície, ou seja, não informa o formato da superfície [Carter, 2015].

4.2.3 Rugosidade máxima (R_y)

Define o maior valor das rugosidades parciais (Z_i) que se apresentam no comprimento de medição (l_m). Na Figura 4.4 observa-se que o maior valor parcial é o Z_3 , que se localiza no terceiro comprimento de amostragem (l_e). Assim, $R_y = Z_3$ nesse caso.




Figura 4.4 – Rugosidade máxima (R_y) [Carter, 2015].

O parâmetro R_y pode ser empregado em superfícies de vedação, assentos de anéis de vedação, superfícies dinamicamente carregadas, tampões em geral, parafusos altamente carregados, superfícies de deslizamento em que o perfil efetivo é periódico. Como vantagens pode-se citar que ele informa a máxima deterioração da superfície vertical da peça e é de fácil obtenção quando o equipamento fornece o gráfico da superfície. Como desvantagens, em algumas aplicações, não é aconselhável a consideração parcial dos pontos isolados, pois um ponto isolado acentuado será considerado somente em 20% do comprimento de medição. Assim como o R_z , este parâmetro não possibilita nenhuma informação sobre a forma do perfil, bem como da distância entre as ranhuras (Fig. 4.5). Além disso, nem todos os equipamentos fornecem esse parâmetro [Carter, 2015].



Figura 4.5 – Diversas formas de rugosidade com o mesmo valor de R_y [Carter, 2015].

4.2.4 Rugosidade total (R_t)

Corresponde à distância vertical entre o pico mais alto e o vale mais profundo no comprimento de medição (l_m), independentemente dos valores de rugosidade parcial (Z_i). Na Figura 4.6 observa-se que o pico mais alto está no primeiro comprimento de amostragem (le_1) e o vale mais fundo encontra-se no terceiro (le_3). Juntos, configuram a rugosidade total R_t .




Figura 4.6 – Rugosidade total (R_t) [Carter, 2015].

O parâmetro R_t tem o mesmo emprego do R_y , mas com maior rigidez, pois considera o comprimento de amostragem (l_e) igual ao comprimento de medição (l_m). Como vantagem, é mais fácil obter R_t através do gráfico de superfície que o parâmetro R_y . Como desvantagem, a rigidez de avaliação leva a resultados enganosos [Carter, 2015].

Para uma operação de fresamento frontal com fresa de topo, o parâmetro R_t pode ser definido teoricamente em função da geometria da ferramenta e do avanço por dente f_z pela Equação (4.2) [Machado *et al.*, 2009], onde C e D são os ângulos definidos em razão da geometria da ferramenta conforme ilustrado na Fig. 4.7.

$$R_t = \frac{f_z}{\tan C + \cot D} \quad (4.2)$$

Normalmente o valor real do acabamento superficial é sempre maior que o teórico porque o segundo não leva em consideração vibrações, possíveis arestas postiças de corte, etc.




Figura 4.7 – Perfil teórico de superfície usinada por fresamento frontal [adaptado de Machado *et al.*, 2009].

4.3 Medição da Rugosidade

O aparelho empregado na medição de parâmetros de rugosidade (com ou sem contato entre o apalpador e a peça) é denominado rugosímetro. A medição com contato é a mais utilizada por ser mais simples, versátil e ter menor custo [Machado *et al.*, 2009].

Na medição com contato, o equipamento consiste de um apalpador que percorre em linha reta uma distância previamente definida denominada comprimento total (l_t) (vide seção 4.2). O deslocamento vertical do apalpador é convertido em sinal elétrico e então amplificado. O resultado pode ser apresentado na forma numérica, pelo gráfico do perfil que representa a superfície analisada e há, ainda, a possibilidade de utilizar filtros para eliminar a influência das ondulações [Santos e Sales, 2007]. A Figura 4.8 ilustra o princípio de funcionamento de medição da rugosidade com contato e os componentes típicos de um instrumento de medição da rugosidade e de ondulação podem ser ilustrados na Fig. 4.9.




Figura 4.8 – Princípio básico de funcionamento dos instrumentos de medição de textura superficial [Santos e Sales, 2007].

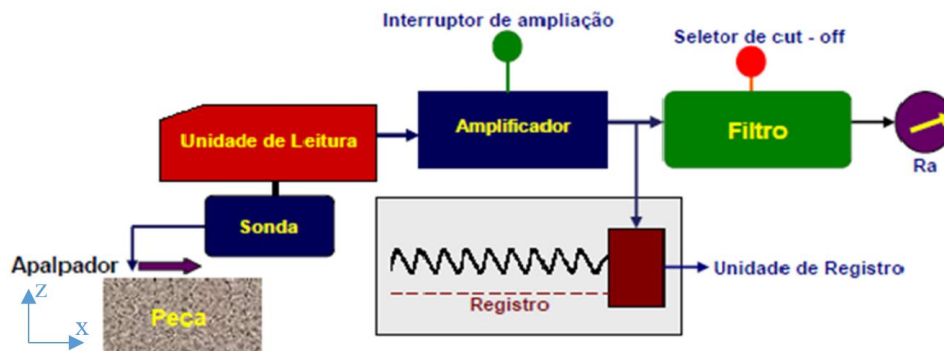


Figura 4.9 – Componentes de instrumentos de medição de rugosidade e de ondulações através de contato [Dagnall, 1986].

O sistema de medição é composto por todos os componentes envolvidos na avaliação da textura superficial, compreendendo mesa, acessórios de fixação, amostra de análise, sonda e unidade de deslocamento. A sonda por sua vez é composta por elementos de medição tais como sensores e transdutores [Dagnall, 1986]. No caso específico de medição por contato através de apalpador, este se desloca dentro de um determinado intervalo de medição, para cima e para baixo na direção Z, em função da característica da superfície. Um transdutor converte o deslocamento vertical do sensor de contato em sinal elétrico que é exportado para um processador e convertido em um sinal digital, permitindo posteriores análises matemáticas e apresentação gráfica do sinal medido [Nunes, 2011].

Como um apalpador com ponta de diamante sempre possui um determinado raio de ponta, este já funciona como um filtro que faz o perfil detectado ser mais suave que o perfil real da peça (Fig. 4.10). Assim, quanto menor o raio de ponta do apalpador, mais fidedigna será a representação do perfil [Bhushan, 1999].

Rugosímetros de uso geral possuem apalpadores com ângulo de ponta de 90° , raio de 5 a $10\ \mu\text{m}$ e velocidade de deslocamento em torno de $2,5\ \text{mm/s}$.

Bhushan, 1999, e Machado *et al.*, 2009, citam como desvantagem do processo de medição com apalpador o fato de a área de contato entre o instrumento e a superfície analisada ser muito pequena. Assim, a pressão de contato é muito elevada, podendo causar danos inaceitáveis em superfícies de materiais macios. Em contrapartida, quando a medição é realizada em materiais muito duros e abrasivos também pode haver um desgaste progressivo da ponta do apalpador, o que gera uma representação cada vez mais inexata da superfície.

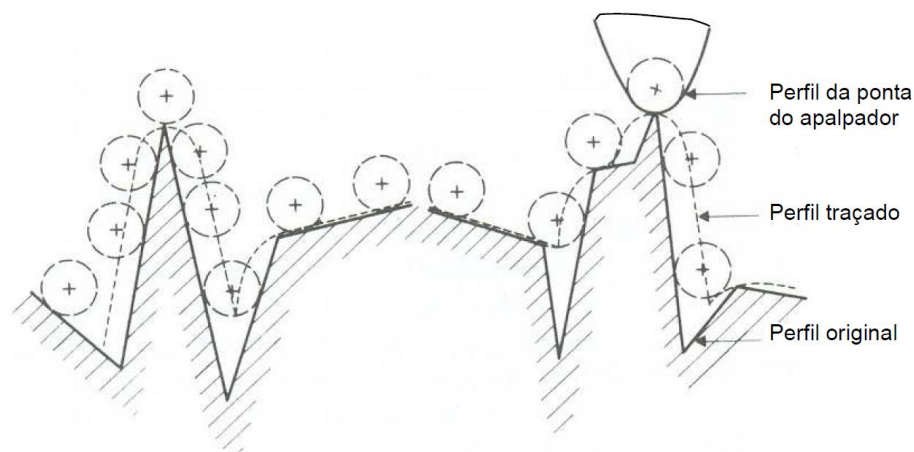


Figura 4.10 – Distorção do perfil devido às dimensões finitas da ponta do apalpador (amplificado) [Bhushan, 1999].

Com o objetivo de superar os inconvenientes supracitados, a medição de rugosidade pode ser realizada alternativamente sem contato com o uso de uma sonda óptica que incide raios infravermelhos sobre a superfície da peça e, posteriormente, detecta a dispersão dessa radiação por meio de uma matriz de fotodiodos. A intensidade da dispersão é calculada e depois correlacionada com os parâmetros de rugosidade. Na prática, sondas ópticas são empregadas em situações nas quais tais apalpadores podem causar danos à superfície (ou vice-versa) como em borrachas, folhas delgadas, discos rígidos e cilindros de fotocopiadoras. Ressalta-se que a sonda óptica exige cuidados no que se refere à limpeza da superfície a ser avaliada, pois qualquer sujeira é interpretada como parte da superfície e podem alterar os resultados [Machado *et al.*, 2009].

5 REDES NEURAIS ARTIFICIAIS

Braga *et al.*, 2000, definem redes neurais artificiais (RNA) como sendo sistemas paralelos distribuídos compostos de unidades de processamentos simples (nodos) que calculam determinadas funções matemáticas (normalmente não lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos, estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede.

O funcionamento destas redes é inspirado no cérebro humano. Assim, na seção 5.1 será apresentado um breve histórico sobre redes neurais artificiais e na seção 5.2 uma concisa descrição do cérebro humano.

5.1 Histórico sobre Redes Neurais Artificiais [Braga *et al.*, 2000]

A primeira tentativa de modelar artificialmente um neurônio biológico foi feita pelos pesquisadores Warren McCulloch e Walter Pitts em 1943. Este trabalho pioneiro se concentrou muito mais em descrever um modelo artificial de um neurônio e apresentar suas capacidades computacionais que propriamente apresentar técnicas de aprendizado.

O primeiro trabalho onde se observa ligação com o aprendizado foi apresentado por Donald Hebb em 1949. Hebb propôs uma teoria com a finalidade de explicar o aprendizado em nodos biológicos baseada no reforço das ligações sinápticas entre nodos excitados. A “Regra de Hebb” foi interpretada sob o ponto de vista matemático e é hoje utilizada em vários algoritmos de aprendizado.

Nos laboratórios das forças militares, em 1957, Frank Rosenblatt apresentou o avô de todas as redes neurais. O *perceptron* simples descrito por Rosenblatt possui três camadas: a primeira recebe entradas do exterior e possui conexões fixas; a segunda recebe impulsos da primeira através de conexões cuja eficiência de transmissão (peso) é ajustável e, por sua vez, envia saídas para terceira camada (resposta). O *perceptron* é o mais simples tipo de rede neural alimentada adiante ou acíclica (*feedforward*) capaz de classificar somente padrões que sejam linearmente separáveis (classificador linear).

Bernard Widrow e seu aluno de doutorado Marcian Hoff propuseram em 1959 uma regra de aprendizado baseada no método do gradiente para minimização do erro na saída de um neurônio com resposta linear. Esta regra ficou conhecida como “Regra de Widrow-Hoff”

ou “Regra Delta”, A RNA apresentada por eles foi batizada de *Adaline* (do inglês *Adaptive Linear Element*) sendo bastante utilizada ainda hoje.

Em 1969, Marvin Minsky e Seymour Papert observaram algumas tarefas que o *perceptron* não era capaz de executar como, por exemplo, não conseguir detectar paridade, conectividade e simetria (problemas não linearmente separáveis). Outra observação feita por eles foi que, mesmo existindo um algoritmo de aprendizado que assegurasse a convergência para modelos com uma única camada de nodos, como o *perceptron* original, igualmente não ocorreria para redes *perceptron* com mais de uma camada.

Na década de 1970, a abordagem conexionista ficou adormecida por causa da grande repercussão do trabalho de Minsky e Papert. No entanto, alguns pesquisadores continuaram trabalhando na área: Igor Aleksander (redes sem pesos) na Inglaterra, Kunihiko Fukushima (*cognitron* e *neocognitron*) no Japão, Steven Grossberg (sistemas auto-adaptativos) nos EUA e Teuvo Kohonen (memórias associativas a auto-organizadas) na Finlândia.

Em 1982, John Hopfield publicou um artigo que foi responsável pela retomada das pesquisas na área. O seu grande feito foi mostrar a relação entre redes recorrentes auto-associativas e sistemas físicos. Ainda assim, a discriminação do algoritmo de treinamento *back-propagation* mostrou que Minsky e Papert tinham uma visão bastante pessimista sobre o *perceptron* e que as RNAs de múltiplas camadas são apropriadas para resolver “problemas difíceis de aprender”. Como consequência, a partir de meados da década de 1980, houve uma explosão de interesse pela RNA na comunidade internacional.

5.2 O Cérebro Humano

O cérebro humano contém aproximadamente 10^{11} células nervosas elementares chamadas de neurônios. Cada um desses neurônios está conectado em cerca de 10^3 a 10^4 outros neurônios. Portanto, estima-se que o cérebro humano teria entre 10^{14} e 10^{15} conexões [Nascimento e Yoneyama, 2000].

Existem neurônios de vários tipos e cada tipo tem sua função, forma e localização específica. Entretanto, os principais componentes de um neurônio de qualquer tipo são o corpo de neurônio (conhecido como soma), os dendritos e o axônio. A Figura 5.1 ilustra um neurônio com seus componentes principais [Nascimento e Yoneyama, 2000].

O corpo do neurônio mede de 5 a 10 μm de diâmetro e contém o núcleo da célula onde é realizada a maioria das atividades bioquímicas (como síntese de enzimas) para manter a vida do neurônio. Os dendritos são prolongamentos dos neurônios e atuam como receptores

dos sinais provenientes de outros neurônios, os mesmos também formam uma estrutura que se espalha em torno do corpo do neurônio denominada árvore dendrítica. O axônio se prolonga a partir do corpo do neurônio e forma uma estrutura com muitos ramos em forma de árvore no seu fim. O axônio também atua como canal de saída e transmissão. Seu comprimento pode ser bastante curto (em torno de 100 μm como no caso dos interneurônios que atuam como pontos de ligação para outros neurônios) ou bastante longo (em torno de 1 m como os neurônios motores usados para estimular músculos) [Braga *et al.*, 2000].




Figura 5.1 – Neurônio biológico e suas conexões.

A sinapse é definida como a conexão do final de um dos ramos do axônio ao dendrito de um neurônio. Ressalta-se que existe um pequeno espaço (em torno de 200 a 500 Å) entre o axônio e o dendrito denominado fenda sináptica que faz com que normalmente a conexão não seja física, mas sim eletroquímica [Braga *et al.*, 2000].

Quando o corpo do neurônio gera atividade elétrica na forma de pulsos de voltagem chama-se potencial de ação. Este é transportado pelo axônio até as sinapses, onde certas moléculas (neurotransmissores) são liberadas e atravessam a fenda sináptica, modificando o potencial da membrana do dendrito. Assim, os sinais recebidos pelos dendritos de vários neurônios se propagam até o corpo do neurônio onde ocorre a soma dos sinais recebidos de vários neurônios. Caso a soma dentro de um pequeno intervalo de tempo for maior que certo limite, o corpo do neurônio gera um potencial de ação que é transmitido pelo axônio aos outros neurônios [Braga *et al.*, 2000].

5.3 Modelagem Artificial do Neurônio [Haykin, 1999]

Uma rede neural artificial (RNA) se assemelha ao cérebro humano em dois aspectos:

- O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
- Forças de conexão entre neurônios, denominados como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido.

Há três elementos básicos que formam um modelo neuronal:

- Um conjunto de sinapses, sendo que cada sinapse é caracterizada por um “peso”.
- Um somador, que efetua a soma dos sinais de entrada; cada entrada é ponderada pela respectiva sinapse do neurônio.
- Uma função de ativação (sendo às vezes também referida como função restritiva), que limita a amplitude da saída de um neurônio a um valor finito.

A Figura 5.2 mostra o modelo de um neurônio que forma a base para o projeto de redes neurais artificiais.

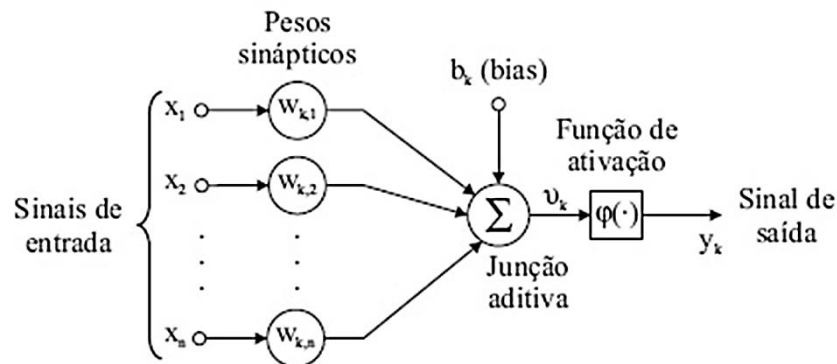


Figura 5.2 – Modelo não linear de neurônios utilizados na RNA [Haykin, 2001].

Na Figura 5.2, observa-se que um sinal x_j na entrada da sinapse $j = \{1, 2, \dots, n\}$ conectado ao neurônio k é multiplicado pelo peso sináptico $w_{k,j}$ (o primeiro índice do peso sináptico (k) refere-se ao neurônio em questão e o segundo (j) refere-se ao terminal de entrada da sinapse à qual o peso se refere). u_k é a saída do combinador linear devido aos sinais de entrada representada pela Equação (5.1).

$$u_k = \sum_{j=1}^n w_{k,j} x_j \quad (5.1)$$

O modelo também inclui um *bias* (b_k) aplicado externamente com a função de aumentar (caso seu valor seja positivo) ou diminuir (caso seja negativo) a entrada líquida da

função de ativação. O *bias* é um parâmetro do neurônio k e seu uso tem o efeito de aplicar uma transformação afim na saída u_k da combinação linear, como mostra a Equação (5.2).

$$v_k = u_k + b_k \quad (5.2)$$

A relação entre o campo local induzido v_k (ou potencial de ativação do neurônio k) e a saída do combinador linear u_k é modificada de acordo com a Fig. 5.3 (dependendo se $b_k < 0$ ou $b_k > 0$). Como resultado, o gráfico de v_k em função de u_k não passa mais pela origem.

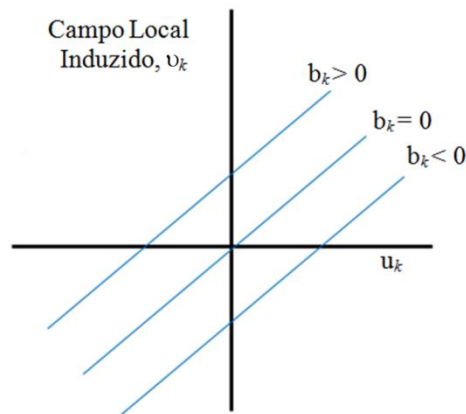


Figura 5.3 – Transformação afim produzida pela presença do *bias* [Haykin, 2001].

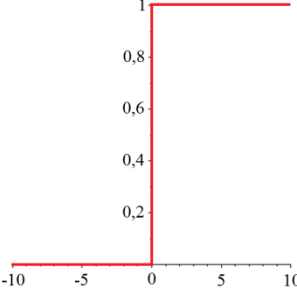
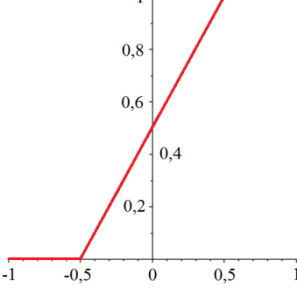
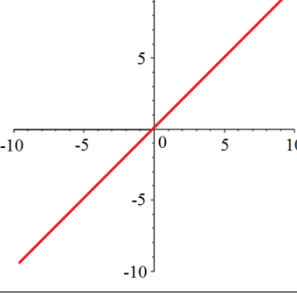
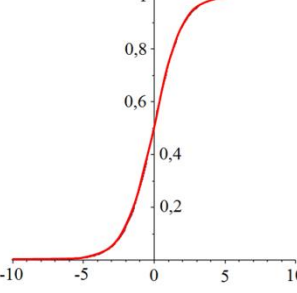
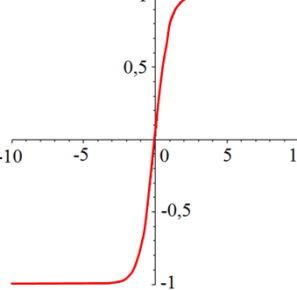
Matematicamente, um neurônio k pode ser descrito pela Equação (5.3), onde $\varphi(\cdot)$ é a função de ativação e y_k é o sinal de saída do neurônio.

$$y_k = \varphi(v_k) \quad (5.3)$$

5.3.1 Tipos de função de ativação

A função de ativação $\varphi(v_k)$ determina a saída de um neurônio em termos do campo local induzido v_k . Podem-se citar quatro tipos básicos de função de ativação: limiar, rampa (linear por partes), linear e sigmoide. A função logística é um exemplo de função sigmoide. Ela fornece uma saída de 0 a 1. Caso seja desejável ter uma função de ativação que forneça uma saída de -1 a 1, assumindo uma forma antissimétrica com respeito à origem, pode-se utilizar a função tangente hiperbólica pela forma correspondente à função sigmoide. Essas funções de ativação são mostradas na Tabela 5.1.

Tabela 5.1 – Funções de ativação do neurônio [adaptado de Haykin, 1999].

<p>Função limiar ou função de Heaviside</p>		$\varphi(v_k) = \begin{cases} 1, & \text{se } v_k \geq 0 \\ 0, & \text{se } v_k < 0 \end{cases}$
<p>Função rampa ou função linear por partes</p>		$\varphi(v_k) = \begin{cases} 1, & \text{se } v_k \geq 0,5 \\ v_k, & \text{se } 0,5 > v_k \geq -0,5 \\ 0, & \text{se } v_k \leq -0,5 \end{cases}$
<p>Função linear (purelin)</p>		$\varphi(v_k) = v_k$
<p>Função logística (logsig): variação da função sigmoide</p>		$\varphi(v_k) = \frac{1}{1 + e^{-v_k}}$
<p>Função tangente hiperbólica (tansig): variação da função sigmoide</p>		$\varphi(v_k) = \tanh(v_k)$

5.3.2 Topologia das redes neurais

Três classes de topologias de rede fundamentalmente diferentes podem ser identificadas: a) redes *Perceptron* com uma única camada; b) redes *Perceptron* com múltiplas camadas; c) redes recorrentes.

a) Redes *Perceptron* com uma única camada (SLP – *Single Layer Perceptron*)

Em uma rede alimentada adiante ou acíclica (*feedforward*), tem-se uma camada de entrada de nós que se projeta sobre uma camada de saída de neurônios conforme ilustrado na Fig. 5.4(a). Esta rede é chamada de rede de camada única sendo que esta designação se refere à camada de saída, pois na camada de entrada não é realizado qualquer computação.

b) Redes *Perceptron* com múltiplas camadas (MLP – *Multilayer Perceptron*)

Distingue-se pela presença de uma ou mais camadas ocultas (ou intermediárias), cujos nós computacionais presentes nestas camadas são chamados de neurônios ocultos ou unidades ocultas. Os nós da camada de entrada da rede fornecem os sinais de entrada aplicados aos neurônios na segunda camada (ou seja, a primeira camada oculta). Os sinais de saída da segunda camada são utilizados como entradas na terceira camada; este procedimento persiste até a camada de saída da rede. Normalmente, os neurônios em cada camada da rede têm como entrada somente os sinais de saída da camada antecedente. A resposta global da MLP é o conjunto de sinais de saída dos neurônios da última camada devido ao padrão de ativação fornecido pelos nós da camada de entrada. Na Fig. 5.4(b) é representada uma rede de múltiplas camadas. Esta rede possui topologia 10-4-2, visto que tem 10 neurônios de fonte, 4 neurônios ocultos e 2 neurônios de saída. A mesma rede ainda é dita totalmente conectada, uma vez que cada um dos nós de uma camada da rede conecta-se a todos nós da camada posterior. No entanto, caso alguns elos das conexões sinápticas estiverem faltando na rede, mencionamos que esta rede é parcialmente conectada.

c) Redes recorrentes

Uma rede neural recorrente tem como particularidade possuir pelo menos um laço de realimentação, ou seja, o sinal de saída de um neurônio serve como entrada para a mesma camada, uma camada anterior ou entre camadas alternadas.

Na Figura 5.5 é ilustrada uma classe de redes recorrentes com neurônios ocultos. Ressalta-se que a realimentação pode ser realizada tanto para frente quanto para trás.




Figura 5.4 – Topologia de redes *Perceptron*: (a) com uma única camada; (b) com múltiplas camadas [Haykin, 2001].




Figura 5.5 – Topologia de redes recorrentes [Oliveira, 2013].

5.4 Aprendizagem de Redes Neurais Artificiais

O objetivo da aprendizagem é determinar a intensidade das conexões entre os neurônios em uma rede neural artificial (RNA). De acordo com Braga *et al.*, 2000, diversos métodos para treinamento de redes foram desenvolvidos, podendo ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não supervisionado.

- **Aprendizado supervisionado.** Neste tipo de aprendizagem, a rede possui um “professor” que possui conhecimento a respeito de determinado ambiente. Dessa forma quando a rede recebe uma informação deste ambiente, o “professor” fornece juntamente a resposta esperada para determinado estímulo. Como ilustrado na Fig. 5.6(a), a rede utiliza como orientação para o ajuste dos pesos sinápticos um sinal de erro gerado pela discrepância entre a saída esperada (fornecida pelo “professor”) e a saída obtida (calculada). A cada par entrada-saída esperada apresentada à rede um sinal de erro é gerado e os pesos sinápticos são ajustados de forma a minimizar o erro de saída da rede.

- **Aprendizado não supervisionado.** Neste caso, não há um “professor” externo para supervisionar o processo de aprendizado: a rede neural extrai informações somente dos padrões de entrada sem a necessidade de uma resposta desejada (Fig. 5.6(b)). A partir do momento em que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características de entrada e criar novas classes ou grupos automaticamente. Este tipo de aprendizado só é possível quando existe redundância nos dados de entrada.

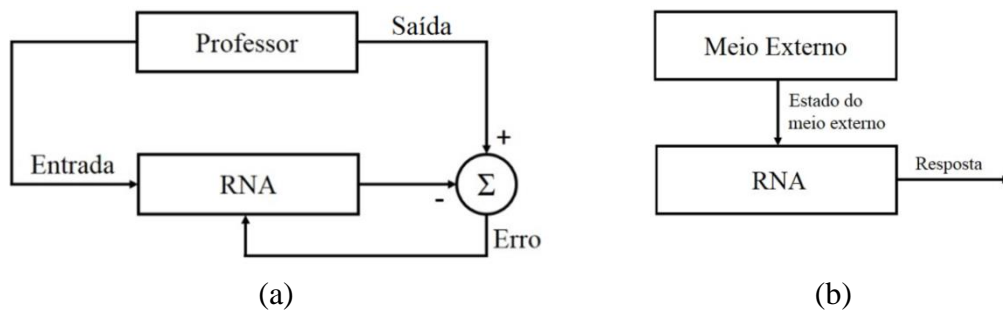


Figura 5.6 – Aprendizado: (a) supervisionado; (b) não supervisionado [Braga *et al.*, 2000].

Os principais algoritmos de treinamento supervisionados citados nas subseções que se seguem são: por retropropagação (BP – *backpropagation*), de Gauss-Newton e de Levenberg-Marquardt.

5.4.1 Algoritmo de treinamento por retropropagação

Pontes *et al.*, 2010, mencionam que o algoritmo de treinamento por retropropagação (BP) é a técnica mais popular de aprendizado supervisionado para aplicações na modelagem da rugosidade nos processos de usinagem. O algoritmo BP utiliza o princípio da minimização de uma função custo; no caso, a soma dos erros médios quadráticos (Eq. 5.4) em um conjunto de treinamento utilizando a técnica do gradiente descendente. Assim, os sinais de entrada são propagados pela rede, camada por camada, até a apresentação do resultado na camada de saída. O resultado obtido é comparado com o desejado. Se a saída obtida não estiver correta, o erro é calculado e retropropagado da saída para a entrada, conforme mostra a Figura 5.7.

$$\varepsilon = EMQ = \frac{1}{Q} \sum_{j=1}^n (p_j - t_j)^2 \quad (5.4)$$

onde Q é a quantidade de padrões de entrada da rede, p_j é o valor estimado pela rede e t_j é o valor experimental.

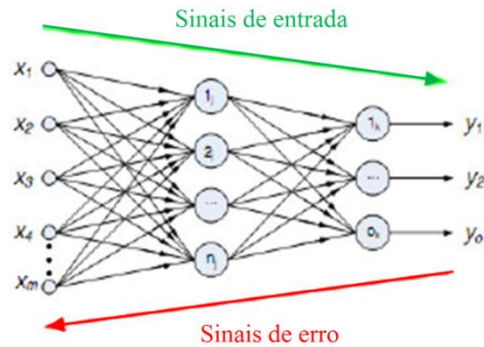


Figura 5.7 – Sinais de entrada e retropropagação dos erros [Silva, 2009].

As Equações (5.5) e (5.6) descrevem o algoritmo de treinamento BP padrão como, segundo Oliveira, 2013:

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha_b \frac{\partial \varepsilon}{\partial w_{i,j}^m} \quad (5.5)$$

$$b^m(k+1) = b^m(k) - \alpha_b \frac{\partial \varepsilon}{\partial b^m} \quad (5.6)$$

Onde:

ε = erro médio quadrático (*EMQ*).

α_b = taxa de aprendizagem. Indica o tamanho do passo na atualização dos pesos. O desempenho do algoritmo é muito sensível a esta taxa: se o seu valor for muito alto, o algoritmo pode oscilar e ficar instável; se o seu valor for muito pequeno, o algoritmo leva muito tempo para convergir.

$w_{i,j}^m$ = peso do neurônio i na camada m , com sinal vindo do neurônio j da camada anterior.

b^m = *bias* da camada m .

Ainda segundo Oliveira, 2013, o método do gradiente descendente, embora robusto e confiável, converge lentamente para a solução ótima. Além disso, possui uma tendência a ficar “perdido” nas regiões que apresentam mínimos locais (Fig. 5.8). Por isso, o método é pouco eficiente quando comparado a outros como os de Gauss-Newton e de Levenberg-Marquardt.

A função que representa o algoritmo de treinamento *backpropagation* no software MATLAB® é a função “`traingd`”.

De acordo com Silva, 2009, há diversas variações do algoritmo BP, apresentadas nos itens que se seguem.




Figura 5.8 – Gráfico mostrando uma possível superfície do erro com os mínimos locais e o mínimo global [Oliveira, 2013].

- **Backpropagation com Termo de Momento.** Destinado a melhorar o algoritmo BP padrão (que utiliza o método do gradiente descendente) utilizando um termo de *momento* (γ_b) com o objetivo de suavizar a trajetória de oscilação sobre a superfície de erro e diminuir a possibilidade de parar o treinamento em um ponto de mínimo local [Hagan *et al.*, 1996]. Adicionando o termo de momento, as Equações (5.5) e (5.6) ficam:

$$w_{i,j}^m(k+1) = \gamma_b w_{i,j}^m(k) - (1 - \gamma_b) \alpha_b \frac{\partial \mathcal{E}}{\partial w_{i,j}^m} \quad (5.7)$$

$$b^m(k+1) = \gamma_b b^m(k) - (1 - \gamma_b) \alpha_b \frac{\partial \mathcal{E}}{\partial b^m} \quad (5.8)$$

A função que representa o algoritmo BP com termo de momento no software MATLAB[®] é a função “traingdm”.

- **Backpropagation com Taxa de Aprendizagem Variável.** Na Figura 5.9 é apresentada uma superfície de erro. O ponto em azul (●) indica o ponto de partida do treinamento, escolhido aleatoriamente e o ponto em vermelho (●) denota o ótimo global. Observa-se que essa superfície tem regiões inclinadas e planas e o caminho em verde (---) representa um possível percurso em busca do ótimo. Os pontos em preto (●) indicam o erro obtido em cada interação pela atualização dos pesos e bias.

Como a forma da superfície pode ser diferente em regiões diversas, o emprego da Taxa de Aprendizagem Variável no algoritmo BP visa aperfeiçoar a convergência durante a etapa de treinamento com o aumento nas regiões planas e seu decréscimo nas regiões inclinadas. No software MATLAB[®] a função “traingda” representa este algoritmo.




Figura 5.9 – Exemplo de uma superfície de erro [Oliveira, 2013].

Observação. É possível ainda utilizar no MATLAB® o algoritmo BP com termo de momento (gdm) e com taxa de aprendizagem variável (gda), ou seja, combinando as duas modificações heurísticas citadas anteriormente. A função “traingdx” representa este algoritmo.

5.4.2 Algoritmo de Gauss-Newton

O algoritmo de Gauss-Newton para atualização dos pesos é representado pela Eq. (5.9).

$$w_{k+1} = w_k - [J^T J]^{-1} J^T e \quad (5.9)$$

Onde:

w = vetor que contém todos pesos e bias da rede.

J = matriz Jacobiana que contém as derivadas primeiras dos erros da rede com relação aos pesos e bias.

$H = J^T J$ = aproximação para o Hessiano, o qual contém as derivadas segundas dos erros da rede com relação aos pesos.

e = vetor que contém os erros da rede.

Segundo Oliveira, 2013, uma limitação do método de Gauss-Newton é que não se pode garantir que a aproximação para a matriz Hessiana $H = J^T J$ será sempre invertível, o que é uma condição necessária para o funcionamento desse método. Ressalta-se que se H for definida positiva então será invertível.

5.4.3 Algoritmo de Levenberg-Marquardt

Conforme Silva, 2009, o algoritmo de treinamento Levenberg-Marquardt (LM) combina as vantagens do método de “Gauss-Newton” e do gradiente descendente (como o BP): utiliza a velocidade de convergência do “gradiente descendente” quando a solução está longe do mínimo global e a velocidade do Gauss-Newton quando a região próxima da função objetivo é alcançada. Para superar o problema da invertibilidade da matriz Hessiana, citada na *Subseção 5.4.2*, o algoritmo de Levenberg-Marquardt apresenta uma modificação e, portanto, a atualização dos pesos é realizada pela Equação (5.10).

$$w_{k+1} = w_k - [J^T J + \mu I]^{-1} J^T e \quad (5.10)$$

Onde:

W = vetor que contém todos pesos e bias da rede.

I = matriz identidade.

J = matriz Jacobiana que contém as derivadas primeiras dos erros da rede com relação aos pesos e bias.

$H = J^T J$ = aproximação para o Hessiano, o qual contém as derivadas segundas dos erros da rede com relação aos pesos.

μ = valor escalar que define qual método de otimização prevalece: quando μ cresce, o método utilizado é o “gradiente descendente”; quando μ diminui, a técnica empregada aproxima-se do “Gauss-Newton”. Assim, a manipulação de μ visa usufruir as vantagens dos dois métodos, minimizando o efeito das suas desvantagens.

e = vetor que contém os erros da rede.

Araújo, 2010, cita que o método de “Levenberg-Marquardt” apresenta convergência em menos iterações, mas requer mais cálculos por iteração devido ao cálculo de matrizes inversas. Apesar do grande esforço computacional, o LM é o algoritmo de treinamento mais rápido para RNA que trabalha com um número moderado de parâmetros da rede.

A função que representa o algoritmo de treinamento “Levenberg-Marquardt” no software MATLAB® é a função “`trainlm`”.

6 PROJETO DE EXPERIMENTOS

Projeto de experimentos (DOE – *Design of Experiments*) é um método estatístico que ajuda a identificar quais fatores podem influenciar variáveis específicas de um produto ou processo. A técnica foi desenvolvida entre 1920 e 1930 por Sir. Ronald A. Fisher, sendo estudada e incrementada por pesquisadores de renome na área estatística como Box, Hunter, Taguchi, entre outros. Segundo Paiva, 2004, DOE é um mecanismo lógico e eficiente no tratamento de problemas aparentemente muito complexos.

Dependendo da quantidade de variáveis, do tipo de resposta do experimento e dos custos dos mesmos, existem diferentes tipos de projetos que se ajustam às necessidades do experimento. Os principais tipos de projetos de experimentos descritos nas seções que se seguem são: Projetos Fatoriais Completos; Projetos Fatoriais Fracionados; e Arranjo Composto Central (CCD – *Central Composite Design*).

6.1 Projetos Fatoriais Completos

Representa-se de modo geral um Projeto Fatorial Completo por n^k , onde “k” é o número de fatores (variáveis independentes) e “n” é o número de níveis (valores das variáveis). Este tipo de projeto faz todas as combinações possíveis dos “n” níveis, sendo desta forma recomendável quando o número de variáveis é pequeno, visto que caso a quantidade de variáveis (ou níveis) seja estabelecido em maior quantidade, o número de testes aumenta consideravelmente (Mendes, 2006).

Segundo Galdámez, 2002, a análise de variância é utilizada para demonstrar quais são os fatores que realmente produzem efeitos (principais e de interação) significativos na resposta de um sistema. Assim, para ilustrar o procedimento, supõe-se um projeto fatorial com dois fatores, cada um deles com apenas dois níveis. O modelo matemático que define a variação da resposta em função dos fatores de controle é dado pela Equação 6.1.

$$y_{ijk} = \mu_g + \tau_i + \beta_j + (\tau\beta)_{ij} + \varepsilon_{ijk} \quad (6.1)$$

onde μ_g é a média dos resultados, τ_i é o efeito principal do fator A, β_j é o efeito principal do fator B, $(\tau\beta)_{ij}$ é o efeito da interação dos fatores A e B, e ε_{ijk} é o erro experimental.

Com a análise de variância procura-se identificar se alguns dos coeficientes desse modelo são reflexos do erro experimental ou se realmente são efeitos significativos. Desse

modo a contribuição de qualquer parâmetro (E_i) no modelo matemático é dado pela soma de quadrados (SS_E), conforme Equação 6.2.

$$SS_{E_i} = \frac{(E_i)^2}{4.n} \quad (6.2)$$

onde n é o número de observações realizadas.

Para determinar a soma quadrática das interações, utiliza-se a Equação 6.3.

$$SS_{E_{12}} = \sum_{i=1}^2 \sum_{j=1}^n \frac{y_{ij}^2}{2.n} - \frac{T^2}{4.n} - SS_{E_1} - SS_{E_2} \quad (6.3)$$

sendo T a soma total das observações e y_{ij} representa as respostas experimentais.

O somatório dos quadrados das diferenças é representado pela Equação 6.4.

$$SS_D = \sum_{i=1}^2 \sum_{j=1}^n y_{ij}^2 - \frac{T^2}{4.n} \quad (6.4)$$

sendo que T é a soma total das observações e y_{ij} representa as respostas experimentais.

A soma quadrática dos erros é dada pela Equação 6.5.

$$SS_R = SS_D - SS_{E_1} - SS_{E_2} - SS_{E_{12}} \quad (6.5)$$

Os resultados da ANOVA são geralmente apresentados em uma tabela (vide Tabela 6.1). Esses resultados representam a análise do experimento fatorial com dois fatores, cada um deles com dois níveis. As colunas desta tabela incluem as fontes de variação, a soma dos quadrados (SS_{E_1} , SS_{E_2} , ..., SS_D), os graus de liberdade ($g.l.$ é a propriedade pela qual qualquer das “ $n-1$ ” observações de uma amostra completamente determinam a outra observação), os quadrados médios, e a estatística do teste F_0 .

Tabela 6.1 – ANOVA de um projeto fatorial com dois fatores [Montgomery, 2000].

Fonte de variação	Soma dos quadrados	$g.l.$	Quadrado médio	F_0
E_1	SS_{E_1}	$a-1$	$MS_{E_1} = SS_{E_1}/a-1$	MS_{E_1}/MS_R
E_2	SS_{E_2}	$b-1$	$MS_{E_2} = SS_{E_2}/b-1$	MS_{E_2}/MS_R
E_{12}	$SS_{E_{12}}$	$(a-1)(b-1)$	$MS_{E_{12}} = SS_{E_{12}}/(a-1)(b-1)$	$MS_{E_{12}}/MS_R$
Erro	SS_R	$abn(n-1)$	$MS_R = SS_R/ab(n-1)$	
Total	SS_D	$abn-1$		

Os parâmetros que possuam F_0 maior que a estatística F crítica são os fatores que exercem influência sobre o valor da média dos resultados. A estatística F segue uma distribuição com ν_1 (numerador) e ν_2 (denominador) graus de liberdade, para um dado nível de significância e são retiradas de tabelas como as apresentadas por Montgomery, 2000.

6.2 Projetos Fatoriais Fracionados

De acordo com Greco e Fabbri, 2003, a utilização da técnica de fracionamento de experimentos permite que as respostas para as questões investigadas sejam obtidas com a realização de apenas uma parte do mesmo, explorando-se a redundância existente quando são considerados muitos fatores. Essa redundância gera efeitos desprezíveis, tanto de fatores principais como de interação entre os fatores. Os efeitos principais desprezíveis aparecem quando são introduzidos no experimento fatores que não possuem influência na variável de resposta. Já os efeitos de interação entre os fatores tendem a obedecer a certa hierarquia em termos de magnitude absoluta. No caso, os efeitos principais dos fatores geralmente apresentam valores maiores que os efeitos de interação entre dois fatores, que por sua vez tendem a apresentar valores superiores aos efeitos de interação entre três fatores, e assim sucessivamente. Dessa forma, interações de alta ordem (p. ex. interações entre quatro fatores) são de difícil interpretação e tendem a se tornar desprezíveis, podendo ser desconsideradas.

O planejamento fatorial fracionário baseia-se na exploração dessa redundância, fazendo uso do sistema de “variáveis desnecessárias” (*confounding variables*) para reduzir o número de ensaios em um experimento. Neste, os efeitos das variáveis de entrada encontram-se acoplados, podendo-se realizar apenas uma fração do experimento, com base na consideração de que interações de alta ordem podem ser desconsideradas [Greco e Fabbri, 2003].

6.3 Arranjo Composto Central

Quando se quer descrever o comportamento de uma resposta de maneira não linear, se faz necessário planejar com no mínimo três níveis para as variáveis analisadas. Dessa forma, o arranjo composto central deve ser utilizado quando se quiser verificar a existência de termos quadráticos no modelo de regressão.

Mendes, 2006, explica que o arranjo composto central (CCD) é formado por três grupos distintos de elementos experimentais: 1) um fatorial completo ou fracionado; 2) um

conjunto de pontos centrais; e 3) um grupo de níveis extras (pontos axiais). A distância do centro do arranjo (0,0) ao ponto axial (denotado por α) confere rotacionalidade e ortogonalidade ao arranjo empregado.

- **Rotacionalidade.** Um arranjo é rotacionável quando $\alpha_n = \sqrt[4]{n_f}$, onde n_f é o número de experimentos na parte fatorial do arranjo. Isto significa que a variância da resposta é constante para todas as variáveis a uma distância α do centro do arranjo.
- **Ortogonalidade.** Isto é requisito para a avaliação de quais efeitos (linear, quadrático ou de interação) são significativos e permite que os efeitos de diferentes variáveis possam ser estimados de maneira independente.

Um CCD rotacionável é aproximadamente ortogonal se foram adotados em torno de cinco pontos centrais o que possibilita uma boa estimativa do erro experimental.

7 REVISÃO BIBLIOGRÁFICA

Realizou-se uma revisão bibliográfica na qual foram selecionados 40 artigos que empregam a metodologia via redes neurais artificiais (RNA) com treinamento *off-line* para a estimação da rugosidade em fresamento. A Tabela 7.1 mostra o resumo dos artigos.

Tabela 7.1 – Resumo dos artigos.

Referência	RNA	Nº de entradas	n ou v_c	f ou f_z	a_p	Nº de saídas	Tipo de saída	Dados normalizados
Al Hazza e Adesta, 2013	MLP	3	X	X	X	4	R_a, R_q, R_z, R_t	
Aykut, 2011	MLP	4	X	X	X	1	R_a	
Bajić <i>et al.</i> , 2012	RBF	3	X	X	X	1	VB, F_c, R_a	X
Bernardos e Vosniakos, 2002	MLP	5		X	X	1	R_a	
Bozdemir e Aykut, 2012	MLP	5	X	X	X	1	R_a	
Bruni <i>et al.</i> , 2009	MLP	9	X	X	X	1	R_a	
Correa <i>et al.</i> , 2008	MLP	7	X	X		4	Classe de R_a	
El-Rahman <i>et al.</i> , 2013	MLP	3	X	X	X	1	R_a	X
Erzurumlu e Oktem, 2007	MLP	5	X	X	X	1	R_a	
Escalona e Marcolpus, 2010	MLP, RBF, GRFF	5	X	X	X	1	R_a	
Hossain <i>et al.</i> , 2008	MLP	3	X	X	X	1	R_a	X
Hossain <i>et al.</i> , 2012	MLP	5	X	X	X	1	R_a	X
Huang e Chen, 2003	MLP	5	X	X	X	1	R_a	X
Kalidass e Palanisamy, 2014	MLP	4	X			1	R_a	X
Karabulut, 2015	MLP	4	X	X	X	1	R_a, F_c	X
Koura e Sayed, 2015	MLP	3	X	X	X	1	R_a, F_f	
Mahdavinejad <i>et al.</i> , 2012	MLP	3	X	X	X	1	R_a	
Moghri <i>et al.</i> , 2014	MLP	3	X	X		1	R_a	X
Mukherjee e Kachawaha, 2015	MLP	3	X	X	X	1	R_a	
Öktem <i>et al.</i> , 2006	MLP	5	X	X	X	1	R_a	
Öktem, 2009	MLP	4	X	X	X	1	R_a	
Ozcelik <i>et al.</i> , 2005	MLP	4	X	X	X	1	R_a	
Palani e Natarajan, 2011	MLP	6	X	X	X	1	R_a	
Parmar e Makwana, 2012a	MLP	3	X	X	X	1	R_a	
Parmar e Makwana, 2012b	MLP	3	X	X	X	1	R_a	
Patel <i>et al.</i> , 2014	MLP	3	X	X	X	1	R_a	
Quintana <i>et al.</i> , 2011	MLP	30	X	X	X	1	R_a	X
Raj <i>et al.</i> , 2012	MLP	3	X	X	X	2	R_a e fator de delaminação	
Rashid e Lani, 2010	MLP	3	X	X	X	1	R_a	
Rajesh e Manu, 2014	MLP	4	X	X	X	2	R_a, R_t	X
Razfar <i>et al.</i> , 2011	MLP	4	X	X	X	1	R_a	X
Samek e Bilek, 2013	MLP	2		X		2	R_a, R_z	X
Sehgal, 2014	MLP	3	X	X	X	1	R_a	X
Simunovic <i>et al.</i> , 2013	MLP	3	X	X	X	1	R_a	X
Sreenivasulu, 2013	MLP	3	X	X	X	2	R_a e fator de delaminação	
Sukumar <i>et al.</i> , 2014	MLP	3	X	X	X	1	R_a	
Topal, 2009	MLP	3, 4	X	X	X	1	R_a	
Tsai <i>et al.</i> , 1999	MLP	4	X	X	X	1	R_a	X
Yilmaz <i>et al.</i> , 2011	MLP	2	X	X		1	R_a	X
Zain <i>et al.</i> , 2010	MLP	3	X	X		1	R_a	X

A Tabela 7.1 mostra as redes específicas utilizadas nos respectivos trabalhos (predomínio da MLP), quantas entradas foram usadas e se aplicaram os parâmetros de entrada rotação (n)/velocidade de corte (v_c), avanço por volta (f) ou por dente (f_z) e profundidade de corte axial (a_p). Também indica quais os parâmetros de rugosidade (e outros de saída) foram usados, assim como se os dados (entrada e/ou saída) foram normalizados.

O número de publicações correspondente ao ano de publicação de cada trabalho pode ser visualizado pelo gráfico da Fig. 7.1. Observa-se que os trabalhos vão de 1999 a 2015, e que a maioria dos trabalhos é recente (80% correspondem aos últimos 7 anos).




Figura 7.1 – Número de trabalhos publicados com relação ao respectivo ano.

Através da análise dos artigos, pode-se constatar que os autores sempre seguem passos semelhantes, como: 1) definição do problema; 2) coleta e análise dos dados; 3) seleção e ajuste do modelo; 4) validação do modelo. Essa sequência é ilustrada na Fig. 7.2.




Figura 7.2 – Metodologia para o desenvolvimento de um modelo de estimação da rugosidade [Montgomery *et al.*, 2008].

Assim, as seções seguintes tratam da mesma metodologia na realização da revisão.

7.1 Definição do Problema

Montgomery *et al.*, 2008, explica que esta fase envolve desenvolver a compreensão de como o modelo será usado (de acordo com as expectativas do usuário) e o nível de exatidão que é requerido (de modo que o usuário possa fazer boas decisões).

Em se tratando dos trabalhos revisados, o problema em si está na modelagem da rugosidade levando em consideração a escolha do material a ser usinado, de qual tipo de ferramenta (fresa) a ser utilizada no fresamento e de quais fatores serão usados como parâmetros de entrada e saída do modelo.

7.1.1 Escolha do material

O gráfico da Figura 7.3 apresenta os materiais dos corpos de prova utilizados nos trabalhos e o respectivo número de publicações que os empregaram. Pode ser visto que alumínio e suas ligas compreendem a maioria dos materiais utilizados (40%). A liga mais utilizada foi a 6061 [Tsai *et al.*, 1999; Huang e Chen, 2003; Rashid e Abdul Lani, 2010; Simunovic *et al.*, 2013; Sukumar *et al.*, 2014], seguida pela 7075 [Öktem *et al.*, 2006; Erzurumlu e Öktem, 2007; Escalona e Marcopolus, 2010] e pela 7039 [Karabulut, 2015].




Figura 7.3 – Número de trabalhos publicados com relação ao material usinado.

Depois do alumínio, os materiais mais usados nos trabalhos foram: a poliamida [Aykut, 2011; Yilmaz *et al.*, 2011; Bozdemir e Aykut, 2012; Moghri *et al.*, 2014;], aços baixo carbono [Parmar e Makwana, 2012(a,b); Rajesh e Manu, 2014; Mukherjee e

Kachawaha, 2015] e aços inoxidáveis [Bruni *et al.*, 2009; Razfar *et al.*, 2011; Samek e Bilek, 2013; Kalidass e Palanisamy, 2014]. Vale ressaltar que a maioria dos autores (67,5%) não justifica a escolha do material a ser usinado.

Escalona e Marcopolus, 2010, relatam que a escolha da liga de alumínio 7075 se deu em razão desse material ser amplamente empregado em aplicações onde é necessário baixo peso como chapas, placas e produtos extrudados usados na indústria aeronáutica. Citam ainda que essa liga tem certas vantagens como boa resistência mecânica, alto limite de resistência à ruptura, é tratável termicamente e tem alta tenacidade. Öktem *et al.*, 2006, justificam o uso da mesma liga na fabricação de moldes para a injeção de plástico.

Karabulut, 2015, justifica o uso do compósito à base de alumínio pela aplicação desse material em diversas áreas da engenharia como automobilística e aeronáutica devido às suas propriedades mecânicas e físicas únicas, como alta resistência mecânica, dureza, resistência ao desgaste e alta razão resistência/peso.

Moghri *et al.*, 2014, explicam o uso de nanocompósitos de poliamida (PA6) devido à maioria dos trabalhos prévios terem focado na usinagem de materiais metálicos, sendo a informação sobre a usinagem de polímeros muito restrita. Afirmam que a poliamida (PA6) é um dos polímeros mais aplicados em engenharia devido à sua rigidez e resistência mecânica. Aykut, 2011 e Yilmaz *et al.*, 2011, justificam o uso da poliamida fundida pelo amplo uso na indústria devido às suas propriedades: baixo peso, alta resistência à corrosão, alta resistência ao impacto, não necessidade de lubrificação e operação silenciosa; segundo os autores, este polímero serve como material substituto ao bronze, latão, alumínio ou aço em peças como roldanas, guias, mancais, engrenagens, rodas dentadas e polias.

Raj *et al.*, 2012 e Sreenivasulu, 2013, afirmam que os compósitos PRFV (polímeros reforçados com fibra de vidro) são bastante usados na indústria aeroespacial, automobilística e marinha devido às suas propriedades (elevada razão resistência/peso, alta rigidez específica, alta resistência à fratura, alta tenacidade, alta resistências térmica e alta resistência à corrosão). Citam que a habilidade do PRFV para usos específicos têm sido uma vantagem e também uma alternativa para certas aplicações em relação aos materiais convencionais. No entanto, explicam que a delaminação das fibras devido aos parâmetros de corte excessivos é um dos maiores problemas em usinagem desse material, pois resulta na redução da carga compressiva máxima, prejudicando sua durabilidade e reduzindo sua vida em fadiga.

Mukherjee e Kachawaha, 2015, citam que a razão da escolha de um aço baixo carbono é o uso cada vez maior deste material pelas suas características de elevada razão

resistência/peso, elevada resistência à fratura, elevada tenacidade e excelente resistência térmica e a corrosão.

Sehgal, 2014, justifica o uso do ferro fundido nodular pelas diversas aplicações desse material na indústria automobilística.

Mahdavinejad *et al.*, 2012, explicam a importância do uso da liga de titânio Ti-6Al-4V no trabalho pelo papel crucial desta liga na indústria aeroespacial. Relatam que esta liga tem alta resistência à corrosão e erosão, grande aplicabilidade em altas temperaturas e excelente razão resistência/peso, o que gera um consumo de combustível eficiente para a operação econômica de voos, bem como maior tempo de vida operacional dos componentes.

Razfar *et al.*, 2011, fundamentam o uso do aço inoxidável martensítico X20Cr13 (AISI 420) pelo amplo uso desse material em aeronaves, na área médica, na indústria química e de turbinas em razão de suas propriedades como boa resistência à corrosão, boa resistência à fadiga e boa tenacidade.

Ozcelik *et al.*, 2005, justificam o uso do Inconel 718 (superliga à base de níquel) pelas diversas aplicações na indústria aeronáutica, química e médica, e pelas boas resistências à tração, à fadiga e à fluência.

Visando testar a influência do fresamento em altas velocidades de corte na rugosidade gerada na superfície de materiais distintos, Koura e Sayed, 2015, aplicaram quatro materiais diferentes (aço fósforo-bronze, aço baixo carbono, bronze e liga de alumínio) como entrada da RNA. Maiores detalhes na *Subseção 7.1.3*.

7.1.2 Escolha da ferramenta (fresa)

Conforme mostra o gráfico da Fig. 7.4, o tipo mais utilizado de ferramenta foi a fresa frontal de topo (65% dos trabalhos revisados). Empregos desse tipo de ferramenta podem ser encontrados nos trabalhos de Rashid e Abdul Lani, 2010; Yilmaz *et al.*, 2011; Parmar e Makwana, 2012(a,b); Patel *et al.*, 2014; Koura e Sayed, 2015. O segundo tipo de fresa mais utilizado foram as fresas frontais de facear (22,5% dos trabalhos revisados), podendo ser constatado nos trabalhos de Bruni *et al.*, 2009; Razfar *et al.*, 2011; Mahdavinejad *et al.*, 2012; Simunovic *et al.*, 2013; Karabulut, 2015. A fresa de topo com arestas arredondadas (fresa *ball nose*) foi empregada em 10% dos trabalhos [Quintana *et al.*, 2011; Hossain e Ahmad, 2012; Samek e Bilek, 2013; Rajesh e Manu, 2014]. Também houve um trabalho onde se empregou uma fresa cilíndrica de disco [Sukumar *et al.*, 2014].




Figura 7.4 – Ferramentas de corte utilizadas nos diferentes trabalhos publicados.

7.1.3 Escolha dos parâmetros de entrada do modelo

A Figura 7.5 ilustra que a maioria dos trabalhos (47,5%) empregam 3 entradas na rede, normalmente sendo parâmetros de entrada do processo de usinagem.




Figura 7.5 – Número de trabalhos publicados com relação ao número de entradas utilizadas.

Os dados mais utilizados como entrada na rede, ou seja, os principais parâmetros utilizados foram os parâmetros de corte (f ou f_z ; n ou v_c ; a_p) conforme mostra a Fig. 7.6. No entanto, alguns autores empregaram parâmetros diferentes dos mais utilizados como variável independente (p. ex. largura de corte “ a_e ”, ângulo de hélice “ δ ” e uso de fluido de corte).

Topal, 2009, relata que normalmente se empregam como principais parâmetros de entrada da RNA a rotação n (ou a velocidade de corte “ v_c ”), o avanço por dente f_z (ou o avanço por volta “ f ”) e a profundidade de corte (a_p), sendo empregado o desgaste da ferramenta, a vibração, a geometria da ferramenta, etc. como parâmetros adicionais. Como inovação, investigou a influência da taxa de penetração de trabalho (*step-over ratio*) na rugosidade (portanto, testou comparativamente redes com 3 e 4 entradas); este parâmetro indica quantas vezes a fresa passa sobre a superfície usinada.




Figura 7.6 – Número de trabalhos publicados com relação à natureza da entrada da rede.

Palani e Natarajan, 2011, empregaram como entrada da rede (além dos parâmetros n , f_z e a_p) a imagem da superfície fresada obtida por um sistema óptico por câmera CCD* (*charge-coupled device*). Segundo os autores, a imagem da superfície fresada foi extraída utilizando um algoritmo desenvolvido no domínio de frequência espacial usando a Transformada de Fourier Bidimensional para extrair as características da textura da imagem.

Huang e Chen, 2003, investigaram em seu trabalho o uso de características extraídas dos sinais das forças obtidas com um dinamômetro como entrada da RNA. As características extraídas foram: força média de pico resultante no plano X-Y (F_{ap}), força média resultante no plano X-Y (equivalente à força de corte: $F_{xy} = F_c = \sqrt{F_x^2 + F_y^2}$) e força média na direção z (F_{zmed}). Através do uso do coeficiente de correlação de Pearson (r), constatou-se que F_{ap} e F_{zmed} possuem maior correlação com a rugosidade; portanto, foram empregadas como entrada.

Outros dois autores também empregaram o dinamômetro para captação das forças em fresamento. Benardos e Vosniakos, 2002, utilizaram a força máxima na direção X (F_{xmax}) e

Correa *et al.*, 2008, a força média resultante no plano X-Y (F_{xy}). No entanto, em nenhum deles foi usado o coeficiente de correlação de Pearson para determinar se as características extraídas tem relação com a rugosidade da superfície.

Ainda com relação ao trabalho de Correa *et al.*, 2008, outros três fatores importantes empregados como entrada na rede foram a geometria usinada no corpo de prova (côncava ou convexa, vide Fig. 7.7), a dureza do corpo de prova (alumínio com a dureza variando de 65 a 152 HB) e o diâmetro da fresa (8, 10, 12, 16 e 20 mm).




Figura 7.7 – Geometria do corpo de prova avaliada com entrada da rede [Correa *et al.*, 2008].

O uso ou não de lubrificador como entrada na RNA foi utilizado por Benardos e Vosniakos, 2002; no trabalho de Quintana *et al.*, 2011, o corte a seco e o uso de MQL foram usados como entrada na rede.

No trabalho de Aykut, 2011, além dos parâmetros de corte (v_c , f_z e a_p), o tipo de ferramenta foi utilizado como entrada na rede. Foram utilizadas fresas com 14 mm de diâmetro: uma de metal-duro com quatro arestas de corte e duas de aço rápido (uma com quatro e outra com seis arestas de corte).

Zain *et al.*, 2010, empregaram, além dos parâmetros v_c e f_z , o ângulo de saída da fresa (γ). Relataram que este parâmetro não tinha sido empregado até então. Foram utilizados cinco diferentes ângulos de saída ($6,2^\circ$, $7,0^\circ$, $9,5^\circ$, $13,0^\circ$ e $14,8^\circ$) para as três fresas de metal-duro utilizadas (uma sem cobertura, uma com cobertura de TiAlN e outra de supernitreto (SN_{tr})).

Alguns autores empregaram os tipos de materiais a serem usinados como entrada na rede. No trabalho de Moghri *et al.*, 2014, o nanocompósito PA6 (poliamida-6/nanoargila) foi usado variando o conteúdo de nanoargila em três níveis. Karabulut, 2015, empregou como uma entrada na rede dois tipos de liga de alumínio-zinco AA 7039: sem e com reforço de partículas de Al₂O₃. Em Koura e Sayed, 2015, foi utilizado aço fósforo-bronze, aço comum, bronze e liga de alumínio. Bozdemir e Aykut, 2012, usaram como entrada da rede a castamida

(um tipo de poliamida) nas condições úmida e seca; outro fator também empregado por eles (além de v_c , f_z e a_p) foi o diâmetro da fresa (10, 14 e 18 mm).

Escalona e Marcolpus, 2010, empregaram os parâmetros comprimento e espessura do cavaco como entrada na rede (além de v_c , f_z e a_p). O coeficiente de correlação de Pearson (r) foi usado para confirmar a correspondência dos mesmos com a rugosidade média (R_a).

O ângulo de inclinação do eixo árvore utilizando fresa de topo de ponta esférica (*ball*) foi empregado por Hossain e Ahmad, 2012, como um dos parâmetros de entrada da rede. Foram utilizados os ângulos 0° , 15° e 30° .

O uso do acelerômetro com o objetivo de utilizar a vibração como entrada na rede foi feito por Tsai *et al.*, 1999, e a característica utilizada foi a vibração média por revolução da fresa. Quintana *et al.*, 2011, também fez o uso de acelerômetros; como características empregadas na entrada da rede foram utilizadas diferentes amplitudes da vibração nos eixos X e Y (em baixa, em média e em alta frequência, e no domínio do tempo) e a amplitude da frequência de passagem dos dentes.

Kalidass e Palanisamy, 2014, empregaram o ângulo de hélice da fresa (δ) como parâmetro de entrada da RNA. Foram utilizados cinco valores: 25° , 30° , 35° , 40° e 45° .

7.1.4 Escolha dos parâmetros de saída do modelo

A Figura 7.8 mostra o número de publicações em função do número de saídas do modelo desenvolvido em redes neurais artificiais (RNA).




Figura 7.8 – Número de trabalhos publicados com relação ao número de saídas utilizadas.

Pode ser constatado que 85% dos trabalhos utilizaram uma única saída para a rede, normalmente o parâmetro R_a (rugosidade média). No entanto, como o valor de R_a representa somente a média da rugosidade em um comprimento de amostragem, este parâmetro não define a forma das irregularidades do perfil; assim, se houver um pico ou um vale não típico, o valor de R_a também não sofrerá grande alteração. Portanto, é necessário o uso de outro parâmetro de rugosidade para caracterizar melhor a superfície [Machado *et al.*, 2009].

A Figura 7.9 mostra que três parâmetros de rugosidade foram usados como saída da rede neural além do parâmetro R_a : a rugosidade média R_z [Samek e Bilek, 2013], a rugosidade total R_t [Rajesh e Manu, 2014] e a rugosidade R_q [Al Hazza e Adesta, 2013].




Figura 7.9 – Número de trabalhos publicados com relação à natureza da saída da rede.

Ainda pela análise da Figura 7.9, observa-se que alguns autores também empregaram outros parâmetros de saída do processo (além da rugosidade) como saída da rede. Bajić *et al.*, 2012 desenvolveram três modelos em RNA: um para a rugosidade média (R_a), um para a força de corte (F_c) e outro para o desgaste de flanco (VB). Os trabalhos de Sreenivasulu, 2013, e de Raj *et al.*, 2012, utilizaram o fator de delaminação gerado no fresamento do plástico com

¹ O parâmetro de rugosidade R_q é definido como a raiz média quadrática (RMS – *root mean square*) dos valores absolutos das ordenadas de afastamento (y_i) dos pontos do perfil de rugosidade em relação à linha média, dentro do percurso de medição l_m (vide Fig. 4.2). Ele é definido pela equação:

$$R_q = \sqrt{\frac{1}{n} \sum_{i=1}^n y_i^2}$$

reforço de fibra de vidro juntamente com a R_a totalizando duas saídas. Karabulut, 2015, desenvolveu um modelo para F_c e outro para a rugosidade média (R_a). Koura e Sayed, 2015, desenvolveram um modelo para a força F_x além de um modelo para a rugosidade média R_a .

7.2 Coleta e Análise dos Dados

Esta fase envolve a busca de dados relevantes para a construção do modelo [Montgomery *et al.*, 2008]. Na Figura 7.10, pode-se observar que a metodologia mais utilizada (75% dos trabalhos) na coleta de dados é o Projeto de Experimentos (DOE).

No trabalho de Hossain *et al.*, 2008, foi usado um projeto fatorial completo de três fatores (a_p , v_c , f_z) a três níveis cada (3^3) totalizando 27 experimentos. Parmar e Makwana, 2012a, usaram um projeto fatorial completo de três fatores (v_c , f e a_p) com 4 níveis para a velocidade de corte (v_c), 7 níveis para o avanço (f) e 3 níveis para a profundidade de corte (a_p), totalizando 84 passes de fresamento. Outros exemplos da utilização de projetos fatoriais completos podem ser achados nos trabalhos de Ozcelik *et al.*, 2005; Öktem *et al.*, 2006; Razfar *et al.*, 2011; Mahdavinejad *et al.*, 2012; Moghri *et al.*, 2014.

Alguns autores empregaram o projeto composto central (CCD) com o objetivo de comparar o modelo obtido por redes neurais artificiais (RNA) com o modelo de regressão. Bajić *et al.*, 2012, mostraram que tanto os modelos de RNA quanto os modelos de regressão chegaram a um erro percentual (EP) de estimação inferior a 10%; no entanto, concluíram que quando o conjunto de dados para treinamento é pequeno, a metodologia de modelagem por RNA oferece melhores resultados, chegando a um erro médio percentual (EMP) de 3,35%. Simunovic *et al.*, 2013, citam que o coeficiente de determinação (R^2) encontrado pelo modelo de regressão foi de 96,5%; já o do modelo por RNA se mostrou superior, com o valor de 99,1%. No trabalho de Kalidass e Palanisamy, 2014, os erros percentuais (EP) dos modelos obtidos por regressão e RNA foram menores que 5%; entretanto, o modelo por RNA teve maior exatidão que o modelo por regressão; além disso, quando comparados os valores obtidos pelo modelo como o valor experimental, o EP é inferior a 2% para a maioria dos passes. Erzurumlu e Öktem, 2007, mencionam que, quando comparados os resultados estimados pelos modelos de RNA e de regressão com o experimental, os valores máximos do EP foram 1,48% e 2,05% respectivamente; citam ainda que, apesar de os modelos por RNA consumirem mais tempo computacional, estes fornecem resultados mais precisos que os de regressão. As equações para determinar os erros EP e EMP , e o coeficiente R^2 , serão vistas na **Seção 7.4.1**.




Figura 7.10 – Número de trabalhos com relação à metodologia para coleta de dados

Em alguns trabalhos pode ser visto ainda o emprego dos arranjos ortogonais de Taguchi (projetos fatoriais fracionados que permitem coletar dados estatísticos significantes com o menor número possível de experimentos) [Benardos e Vosniakos, 2002; Escalona e Marcolpus, 2010; Sreenivasulu, 2013; Sukumar *et al.*, 2014; Karabulut, 2015; Mukherjee e Kachawaha, 2015]. Exemplificando, Karabulut, 2015, relata que o projeto fatorial completo (com três fatores e quatro níveis) demandaria $4^3 = 64$ experimentos; conseqüentemente, seria necessário bastante tempo e exigiria alto custo para executar todas as combinações. Assim, aplicou um arranjo ortogonal L_{18} (18 experimentos) que exige menos experimentos e minimiza os efeitos de fatores que não podem ser controlados.

Ainda com relação à Fig. 7.10, pode-se constatar que oito autores empregaram metodologias semelhantes ao DOE [Bruni *et al.*, 2009; Topal, 2009; Aykut, 2011; Palani e Natarajan, 2011; Bozdemir e Aykut, 2012; Patel *et al.*, 2014; Koura e Sayed, 2015]. No entanto, nenhuma menção ao longo do trabalho sobre o tipo de projeto de experimentos usado é dado. Em dois trabalhos não está claro que metodologia foi usada, pois o arranjo dos fatores é somente sugerido e não mostrado explicitamente, e também não é feita nenhuma menção sobre o tipo de projeto de experimento usado [Yilmaz *et al.*, 2011; Samek e Bilek, 2013].

7.3 Ajuste e Seleção do Modelo

Esta etapa consiste em escolher um ou mais modelos de estimação e ajustar o modelo aos dados [Montgomery *et al.*, 2008].

Em se tratando de redes neurais artificiais, o ajuste significa determinar o valor dos pesos e bias da rede. No entanto, antes é necessário definir o tipo de rede a ser utilizada (MLP, RBF etc.), a topologia (ou arquitetura) da rede (números de camadas e de neurônios nas camadas), as funções de ativação utilizadas nas camadas, o algoritmo de treinamento, o critério de parada de treinamento. Com isso, dá-se a seleção do modelo de RNA.

7.3.1 Tipos de rede

O gráfico da Fig. 7.11 mostra que o tipo de RNA mais utilizado foi a rede *perceptron* de múltiplas camadas (MLP – *Multilayer Perceptron*), totalizando 95% dos trabalhos revisados. A segunda rede mais utilizada foi a RNA com função de ativação de base radial (RBF) encontrada em aproximadamente 5% dos trabalhos. Em um trabalho também foi utilizado uma RNA de regressão geral (GRNN – *General Regression Neural Network*)².




Figura 7.11 – Numero de trabalhos publicados com relação à RNA utilizada.

Estudos também foram feitos comparando as diferentes redes abordadas na Fig. 7.11. Escalona e Marcopolus, 2010, compararam as redes MLP, RBF e GRNN. Através da análise do erro médio quadrático (EMQ), Eq. (7.1), concluiu-se que as MLP fornecem os melhores

² A rede neural artificial de regressão geral (GRNN – *General Regression Neural Network*) constitui-se de uma rede com uma camada oculta com função de ativação de base radial e uma camada de saída com função de ativação linear. É normalmente usada para aproximações de funções [Escalona e Marcopolus, 2010].

resultados. No entanto, precisa-se mais tempo para treinar a MLP se comparado com as outras duas. Outra comparação entre MLP e RBF é feita no trabalho de Correa *et al.*, 2008, onde a rede RBF atingiu os melhores resultados utilizando vários testes de hipóteses.

7.3.2 Definição da topologia das redes

Observa-se na Figura 7.12 que a definição da topologia (ou arquitetura) de uma rede MLP normalmente é feita por tentativa e erro (35%), como mostram os trabalhos de Yilmaz *et al.*, 2011; Samek e Bilek, 2013; Moghri *et al.*, 2014; Rajesh e Manu, 2014; Sehgal, 2014. Para exemplificar, Moghri *et al.*, 2014, relatam que poucos neurônios na camada oculta (intermediária) podem levar ao “subajuste” (perda de convergência da rede durante o treinamento); por outro lado, muitos neurônios podem levar ao “sobreajuste” (perda da capacidade de generalização da rede).

Nove trabalhos (22,5%) apresentam o número de neurônios utilizados na(s) camada(s) oculta(s) sem justificar como se chegou a este número. Exemplos podem ser vistos em Ozelik *et al.*, 2005; Öktem *et al.*, 2006; Öktem, 2009; Sukumar *et al.*, 2014; Karabulut, 2015. Já em sete (17,5%) não está claro como foi definida a topologia da rede.

Em sete trabalhos (17,5%) os autores aumentaram o número de neurônios (*um de cada vez*) da(s) camada(s) oculta(s) até um determinado limite; no final foi selecionada a topologia que melhor satisfizesse os critérios de seleção da rede. Exemplos podem ser vistos em Tsai *et al.*, 1999; Bozdemir e Aykut, 2012; Samek e Bilek, 2013; Sehgal, 2014.




Figura 7.12 – Número de trabalhos com relação à estratégia para definir a topologia.

Por fim, em 3 trabalhos (7,5%) os autores apenas mencionam que foi utilizado um método para otimizar o número de neurônios da(s) camada(s) oculta(s) sem explicitar maiores detalhes [Aykut, 2011; Parmar e Makwana, 2012(a,b)].

7.3.3 Funções de ativação

A Figura 7.13 mostra o número de trabalhos publicados com relação à função de ativação utilizada. Considerando-se a rede MLP, observa-se que 10 trabalhos (25%) utilizam a função logística (*logsig*) como função de ativação nas camadas ocultas (intermediárias) e a função linear (*purelin*) na camada de saída. Exemplos em Bruni *et al.*, 2009; Parmar e Makwana, 2012(a,b); Koura e Sayed, 2015; Mukherjee e Kachawaha, 2015. Em nove trabalhos (22,5%) foi utilizada a função “*logsig*” tanto nas camadas ocultas quanto na camada de saída. Exemplos em Correa *et al.*, 2008; Topal, 2009; Zain *et al.*, 2010; Palani e Natarajan, 2011; Karabulut, 2015. Seis trabalhos (15%) fizeram o uso exclusivo da função tangente hiperbólica (*tansig*) nas camadas ocultas e de saída. Exemplos em Ozcelik *et al.*, 2005; Erzurumlu e Öktem, 2007; Razfar *et al.*, 2011; Mahdavinejad *et al.*, 2012. Já cinco trabalhos (12,5%) utilizam a “*tansig*” como função de ativação nas camadas ocultas e a linear (*purelin*) na camada de saída (p. ex. Quintana *et al.*, 2011; Samek e Bilek, 2013).




Figura 7.13 – Número de trabalhos publicados com relação à função de ativação utilizada.

Raj *et al.*, 2012, apresentam a comparação do uso das funções logística (*logsig*) e tangente hiperbólica (*tansig*) como funções de ativação nas camadas ocultas e a função

linear (`purelin`) na camada de saída em redes MLP. Concluíram que, utilizando “`tansig`” e “`purelin`” como funções de ativação, obtiveram um coeficiente de correlação (r) maior e um tempo computacional de treinamento menor. Sehgal, 2014, ao fazer a mesma comparação, concluiu que o melhor desempenho foi alcançado ao utilizar as mesmas funções de ativação (`tansig` e `purelin`), com um erro médio percentual (EMP, Eq. 7.3) de 0,163% e um erro médio quadrático (EMQ, Eq. 7.1) de 0,007.

Três trabalhos (7,5%) empregaram funções distintas em cada camada da rede. Por exemplo, Hossain e Ahmad, 2012, utilizaram a função “`tansig`” na primeira camada oculta, a função “`logsig`” na segunda camada oculta e a função “`purelin`” na camada de saída.

A rede neural artificial com função de ativação de base radial (RBF) faz uso da função gaussiana como função de ativação e pode ser encontradas em 5% dos trabalhos [Escalona e Marcopolus, 2010; Bajić *et al.*, 2012].

E por fim, em 15% dos trabalhos não está claro qual função de ativação foi utilizada nas camadas da rede.

Normalização dos dados. Funções de ativação não lineares, como as funções logística (`logsig`) e tangente hiperbólica (`tansig`), restringem a possível saída de um neurônio tipicamente em (0,1) ou (-1,1) e a normalização dos dados é frequentemente feita antes do treinamento começar. Quando funções não lineares são usadas nos neurônios de saída, o valor de saída precisa ser transformado dentro de uma faixa da atual saída da rede. Até mesmo se uma função de ativação linear é usada, pode haver vantagens em padronizar tanto as saídas como as entradas da rede para evitar problemas computacionais, satisfazer os requisitos do algoritmo e facilitar o aprendizado da rede [Zhang *et al.*, 1998].

Como pôde ser visto na Tabela 7.1, em 17 dos 40 trabalhos revisados (42,5%) está claro que os dados utilizados foram normalizados antes de efetuar o treinamento da rede. Nos demais, não está claro ou não foram normalizados os dados antes de efetuar o treinamento.

7.3.4 Algoritmos de treinamento

Observa-se na Figura 7.14 que o algoritmo mais utilizado no treinamento de redes MLP é por retropropagação (*backpropagation*), citado em Zain *et al.*, 2010; Parmar e Makwana, 2012(a,b); Moghri *et al.*, 2014; Rajesh e Manu, 2014; Mukherjee e Kachawaha, 2015.




Figura 7.14 – Número de trabalhos com relação ao algoritmo de treinamento para redes MLP.

Também pela Figura 7.14, o segundo algoritmo mais usado é o Levenberg-Marquardt (LM), que pode ser encontrado nos trabalhos de Escalona e Marcopulus, 2010; Quintana *et al.*, 2011; Razfar *et al.*, 2011; Hossain e Ahmad, 2012; Sehgal, 2014.

No trabalho de Raj *et al.*, 2012, foi feita a comparação entre os algoritmos de treinamento BP padrão (`traingd`), BP com termo de momento (`traingdm`), BP com taxa de aprendizado variável (`traingda`) e o LM (`trainlm`); concluiu-se que o algoritmo LM é capaz de fazer a estimação dos resultados com maior precisão que os demais testados.

7.3.5 Critérios de parada de treinamento

Segundo Haykin, 1999, umas das dificuldades no desenvolvimento de uma rede neural artificial (RNA) é determinar o melhor ponto de parada de treinamento. O erro de treinamento inicia com um valor alto, decresce rapidamente e em seguida diminui lentamente, tendendo a atingir um mínimo local na superfície do erro (Fig. 7.15). Portanto, para determinar um ponto de parada de treinamento almejando a melhor capacidade de generalização da rede, utiliza-se a técnica da regra de parada antecipada, com base na validação cruzada. A validação cruzada é uma técnica estatística usada para validar o modelo obtido durante a fase de treinamento da rede utilizando um conjunto diferente de dados dos quais foi utilizado durante o treinamento. O método consiste em acompanhar a evolução do aprendizado nas curvas correspondentes aos subconjuntos de dados de treinamento e de validação. Deste modo, o treinamento é

interrompido quando a curva de validação decresce a um erro mínimo e antes de começar a crescer, conforme o treinamento continua.

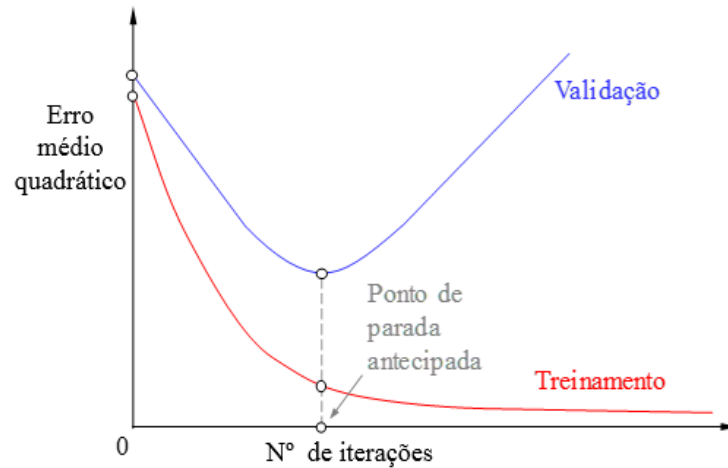


Figura 7.15 – Regra de parada antecipada baseada na validação cruzada [adaptado de Haykin, 1999].

Na Figura 7.16 podem ser observados os critérios de parada de treinamento da rede. Nove trabalhos (22,5%) empregam a regra de parada antecipada com base na validação cruzada (p. ex. Quintana *et al.*, 2011; Parmar e Makwana, 2012b; Rajesh e Manu, 2014; Sehgal, 2014; Mukherjee e Kachawaha, 2015).




Figura 7.16 – Número de trabalhos com relação ao critério de parada do treinamento.

Em cinco trabalhos (12,5%), o treinamento da rede foi interrompido assim que o erro médio quadrático (EMQ , Eq. (7.1)) foi atingido [Öktem, 2009; Topal, 2009; Palani e Natarajan, 2011; Razfar *et al.*, 2011; El-Rahman *et al.*, 2013]. Em cinco trabalhos (7,5%), o treinamento foi interrompido assim que se atingiu o número máximo de iterações ou épocas (*epochs*) [Tsai *et al.*, 1999; Huang e Chen, 2003; Ozcelik *et al.*, 2005; Öktem *et al.*, 2006; Erzurumlu e Öktem, 2007]. Em três trabalhos (7,5%), o critério adotado foi a razão entre o erro (*trade off error*) e o número de épocas (n^o *epochs*), sendo que o treinamento é interrompido assim que o EMQ ou número de iterações é atingido [Escalona e Marcopolus, 2010; Yilmaz *et al.*, 2011; Hossain e Ahmad, 2012]. Em 18 trabalhos (45%) não está claro o critério adotado como parada de treinamento, como em Hossain *et al.*, 2008; Bajić *et al.*, 2012; Parmar e Makwana, 2012a; Samek e Bilek, 2013; Moghri *et al.*, 2014.

7.3.6 Seleção do melhor modelo

Depois de encerrada a fase de treinamento, faz-se necessário selecionar o melhor modelo de RNA. Conforme ilustra o gráfico da Fig. 7.17, em 42,5% dos casos não está claro qual o método estatístico de estimação do erro utilizado para a seleção da rede.




Figura 7.17 – Número de trabalhos publicados com relação ao método para seleção da RNA.

Constata-se pela Fig. 7.17 que o método mais utilizado (25% dos trabalhos) foi o erro médio quadrático (EMQ , Eq. (7.1)) como no trabalho de Benardos e Vosniakos, 2002, em que

foram testados diferentes números de neurônios para a camada oculta (intermediária) e no final foi selecionada a topologia com o menor valor para este parâmetro.

O segundo parâmetro mais utilizado foi o coeficiente de correlação de Pearson (r), Equação (7.5), como no trabalho de Rajesh e Manu, 2014; os autores relatam o teste de topologias variando o número de neurônios na camada oculta (de 10 a 16) e ao final foi selecionada a rede que obteve o coeficiente de correlação próximo de 1.

O terceiro parâmetro (10% dos trabalhos) mais utilizado foi a raiz do erro médio quadrático ($REMQ$, Eq. (7.6)). Um exemplo do emprego desse parâmetro pode ser obtido no trabalho de Tsai *et al.*, 1999, que seleciona duas arquiteturas de rede (com uma e duas camadas ocultas) baseadas neste parâmetro.

Alguns autores empregaram mais de um parâmetro para seleção da rede, como Bozdemir e Aykut, 2012, onde um modelo com 15 neurônios na camada oculta foi selecionado, baseado na raiz do erro médio quadrático ($REMQ$), coeficiente de determinação (R^2) e erro médio percentual (EMP).

Outros menos utilizados foram: erro percentual (EP , Eq. (7.2)); erro médio percentual (EMP , Eq. (7.3)); erro médio absoluto (EMA , Eq. (7.7)); raiz do erro quadrático relativo ($REQR$, Eq. (7.8)); coeficiente de determinação (R^2 , Eq. (7.4)); estatística *Kappa* (EK)³.

7.4 Validação do Modelo

Feita a seleção da rede é necessário fazer a validação do modelo de estimação e/ou predição. Este procedimento faz a avaliação do modelo para determinar qual seu desempenho quando submetido a novos dados não utilizados na fase de ajuste [Montgomery *et al.*, 2008].

Pela análise dos trabalhos revisados foi constatado que 85% dos autores dividiram os dados experimentais em dois conjuntos, um para o treinamento da rede (normalmente contendo 70% dos dados experimentais) e outro para a validação (com os 30% restantes). Nos outros 15% dos trabalhos não está claro que foi feita esta divisão.

A Figura 7.18 ilustra o gráfico mostrando os diferentes métodos de validação das redes neurais artificiais aplicados.

³ A estatística Kappa (EK) é uma medida de concordância usada em escalas nominais que indica quanto as observações se afastam das esperadas. Os valores de EK variam de 0 a 1, sendo que “0” representa não haver concordância, e “1” representa a concordância perfeita [Landis e Koch, 1977].




Figura 7.18 – Número de trabalhos publicados com relação ao método para validar a RNA.

A Figura 7.18 mostra que o parâmetro mais utilizado para validação do modelo, usado em 30% das publicações, é o erro médio percentual (*EMP*), Equação (7.3). Como exemplo, pode-se citar o trabalho de Moghri *et al.*, 2014, onde foi obtido um valor de 2,99% para este parâmetro no conjunto de teste.

O segundo parâmetro mais utilizado (22,5% das publicações) foi o erro percentual (*EP*), Eq. (7.2). Um exemplo se encontra no trabalho de Hossain *et al.*, 2008, onde os autores relatam que quando a rede é submetida ao conjunto de validação o $EP < 12\%$ para todos os dados, sendo considerado um valor razoável segundo o mesmo. Em Kalidass e Palanisamy, 2014, foram realizados seis passes adicionais durante a fase de validação e obteve-se que *EP* entre os dados experimentais e os dados simulados ficaram entre 0,05% e 1,63%.

O terceiro parâmetro mais utilizado (17,5% das publicações) é o erro médio quadrático (*EMQ*), Equação (7.1), presente no trabalho de Escalona e Marcolpus, 2010, onde a rede MLP atingiu um valor para este parâmetro de 5,5%.

O quarto parâmetro mais utilizado (15% das publicações) foi o coeficiente de correlação de Pearson (*r*), Eq. (7.5), como no trabalho de Sehgal, 2014, onde um coeficiente de 0,99 foi obtido, representando a validação do modelo.

Outros parâmetros menos utilizados foram: raiz do erro médio quadrático (*REMQ*, Eq. (7.6)), coeficiente de determinação (R^2 , Eq. (7.4)), e o erro absoluto (*EA*, Eq. (7.9)).

7.4.1 Definição dos erros

Algumas funções para a seleção e para a validação de uma rede neural artificial são representadas pelas Equações (7.1) a (7.9). Nas equações, p_j é o valor estimado/predito pela RNA, t_j é o valor prático obtido por experimentação, \bar{p} é a média dos valores estimados pela rede e \bar{t} é média dos valores obtidos experimentalmente.

$$EMQ = \frac{1}{n} \sum_{j=1}^n (p_j - t_j)^2 \quad (7.1)$$

$$EP = \left| \frac{p_j - t_j}{t_j} \right| \cdot 100 \quad (7.2)$$

$$EMP = \frac{1}{n} \sum_{j=1}^n \left| \frac{p_j - t_j}{t_j} \right| \cdot 100 \quad (7.3)$$

$$R^2 = 1 - \left(\frac{\sum_{j=1}^n (p_j - t_j)^2}{\sum_{j=1}^n (t_j)^2} \right) \quad (7.4)$$

$$r = \frac{\sum_{j=1}^n (p_j - \bar{p})(t_j - \bar{t})}{\left(\sqrt{\sum_{j=1}^n (p_j - \bar{p})^2} \right) \cdot \left(\sqrt{\sum_{j=1}^n (t_j - \bar{t})^2} \right)} \quad (7.5)$$

$$REMQR = \sqrt{\frac{1}{n} \sum_{j=1}^n (p_j - t_j)^2} \quad (7.6)$$

$$EMA = \frac{1}{n} \sum_{j=1}^n |p_j - t_j| \quad (7.7)$$

$$REQR = \sqrt{\frac{\sum_{j=1}^n (p_j - t_j)^2}{\sum_{j=1}^n (t_j - \bar{t})^2}} \quad (7.8)$$

$$EA = |p_j - t_j| \quad (7.9)$$

onde EMQ é o erro médio quadrático, EP é erro percentual, EMP é o erro médio percentual, R^2 é o coeficiente de determinação, r é o coeficiente de correlação de Pearson, REMQ é a raiz do erro médio quadrático, EMA é o erro médio absoluto, REQR é a raiz do erro quadrático relativo e EA é o erro absoluto.

8 ARQUITETURA DO SISTEMA EXPERIMENTAL

Os experimentos consistiram na realização da operação de fresamento frontal a seco em um centro de usinagem utilizando fresa de topo reto no corte de canais em aço.

A ilustração da arquitetura do sistema aplicado durante a experimentação (usinagem e coleta de dados) é apresentada na Figura 8.1.



Figura 8.1 – Arquitetura do sistema experimental.

Como características principais, o centro de usinagem ROMI modelo Discovery 308 (disponível no Laboratório de Automação em Usinagem – LAUS-UFRGS) oferece rotação máxima do eixo-árvore de 4000 rpm e potência máxima de 5,5 kW.

A ferramenta de corte utilizada (fresa de topo) foi constituída de um suporte para insertos intercambiáveis da marca Mitsubishi (Fig. 8.2) com a especificação APX3000R203SA20SA. Esta ferramenta tem diâmetro de 20 mm, haste cilíndrica e fixação mecânica por pinça. Possui acomodação para três pastilhas com ângulo de posição $\chi_r = 90^\circ$. No caso, foram utilizadas quatro combinações de insertos de metal duro com raios de ponta (r_e) distintos da marca Mitsubishi com a especificação AOMT1236 PEER-M. As demais dimensões dos insertos mantiveram-se constantes. A cobertura do inserto (VP15TF) é feita de nitreto de titânio e alumínio (TiAlN), material que propicia uma grande força de adesão do substrato à ferramenta, aumentando assim sua vida. Detalhes na Tab. 8.1.




Figura 8.2 – Fresa de topo Mitsubishi APX 3000R.

Tabela 8.1 – Especificações dos insertos.

Perfil	Código	Cobertura	Dimensões [mm]					Geometria
			L ₁	L ₂	S ₁	F ₁	r _e	
Quebra Cavaco M	AOMT123604 PEER-M	VP15TF	12	6,6	3,6	1,6	0,4	
	AOMT123608 PEER-M	VP15TF	12	6,6	3,6	1,2	0,8	
Uso Geral	AOMT123612 PEER-M	VP15TF	12	6,6	3,6	0,8	1,2	
	AOMT123616 PEER-M	VP15TF	12	6,6	3,6	0,4	1,6	

A peça usinada foi de aço SAE 1045. O corpo de prova, depois de laminado e normalizado, foi cortado em amostras de $102 \times 102 \times 25$ mm e furado para a fixação na plataforma piezolétrica (Fig. 8.3). A dureza média encontrada resultante de cinco ensaios sobre a superfície do corpo de prova foi de 200 HB.




Figura 8.3 – Dimensões do corpo de prova.

A Tab. 8.2 apresenta a análise química do material feita por EDS⁴ (*Energy Dispersive Spectroscopy*) e a Fig. 8.4 ilustra as imagens da microestrutura da amostra do aço SAE 1045 utilizado nos ensaios práticos.

Tabela 8.2 – Resultado da análise química (% em massa).

Elemento \ Amostra	SAE 1045	Padrão ABNT
C	0,490	0,430 – 0,500
Si	0,210	0,150 – 0,350
Mn	0,780	0,300 – 0,600
P	0,022	<0,030
S	0,011	<0,050




Figura 8.4 – Aço SAE 1045: (a) sem ataque; (b) atacado com Nital (composto de 2% de ácido nítrico e 98% de álcool). Ampliação 100×.

Pode-se observar na Fig. 8.4(a) que as inclusões apresentam um achatamento que é resultante do processo de laminação. Na Fig. 8.4(b) observa-se a microestrutura do SAE 1045,

⁴ A espectroscopia de raios X por dispersão em energia utiliza um feixe elétrico para atingir a amostra. Assim, seus átomos são excitados e, ao voltarem para o estado fundamental, emitem fótons com energias características do átomo. Os fótons são então identificados em termos de sua energia e contados pelo detector de raios-X localizado dentro da câmara de vácuo. Desta forma, o conjunto (hardware + software) adquire e gera o espectro relativo ao número de contagens em função da energia, em keV, identificando os elementos químicos presentes na amostra [Williams & Carter, 2009].

composta por 64% de perlita (áreas mais escuras, maior dureza) e 36% de ferrita (áreas mais claras). De acordo com a norma ASTM E112, o número de tamanho de grão da amostra é classificado como 7.

Durante a usinagem, os sinais de força foram adquiridos nas direções dos eixos coordenados (X, Y, Z) e, após os passes, as superfícies fresadas foram inspecionadas quantitativamente (medição de rugosidade) e qualitativamente (microscópio digital).

8.1 Aquisição de Sinais de Força

Os sinais de força em usinagem foram medidos simultaneamente durante os passes de fresamento utilizando um sistema de medição de força constituído por um dinamômetro piezelétrico, um amplificador de cargas multicanal, uma placa de aquisição de dados e um software para processamento dos dados sensórios.

O dinamômetro usado nos experimentos e disponível no Laboratório de Automação em Usinagem (LAUS) é a plataforma piezelétrica Kistler modelo 9129AA (Fig. 8.5(a)). O dinamômetro permite obter as componentes ortogonais da força de usinagem nas direções dos eixos coordenados (F_x , F_y e F_z). A Figura 8.5(b) ilustra os detalhes construtivos da plataforma.





Figura 8.5 – Plataforma piezelétrica Kistler 9129AA: (a) foto ilustrativa; (b) detalhe construtivo [Kistler, 2009].

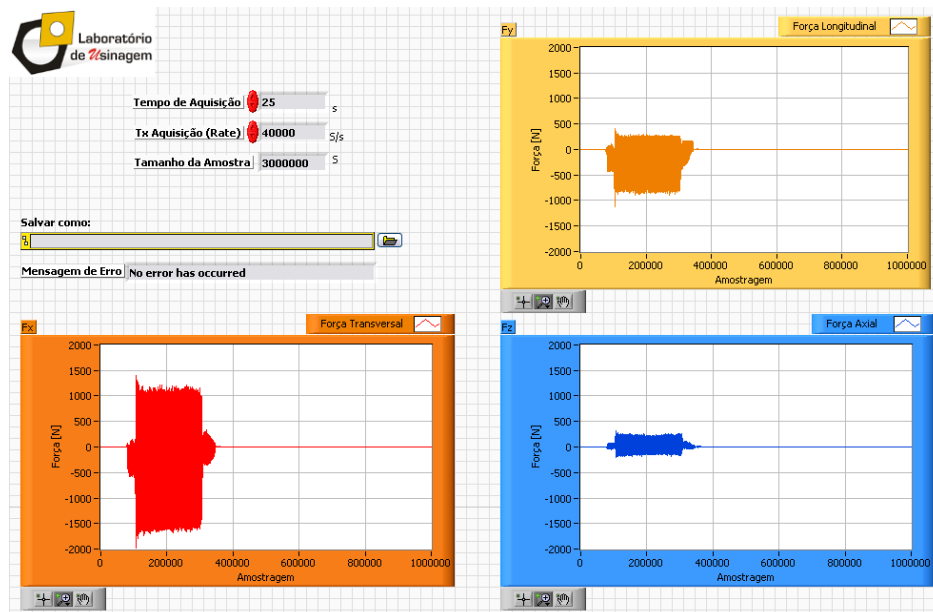
O condicionador de sinais utilizado no LAUS é o amplificador de carga Kistler modelo 5070A, versão 10100 (quatro canais). Este equipamento é caracterizado por ser uma versão de mesa com braço de suporte com entrada para quatro canais. A entrada é uma Fischer 9-pole neg. A faixa de medição é de ± 200 pC até ± 200000 pC, e a sua interface é a RS-232C [Kistler, 2009]. Optou-se por não utilizar filtro no condicionador de sinais durante os ensaios, pois caso houvesse necessidade de aplicação de filtragem no tratamento dos sinais, este seria digital.

A placa de aquisição de sinais usada foi de modelo PCIM-DAS 1602/16, da Measurement Computing (Fig. 8.9). Esta placa, instalada em um microcomputador dedicado, permite a captura de até 100 mil pontos por segundo (100 kS/s) em até oito entradas analógicas diferenciais com 16 bits de resolução [Measurement Computing, 2015].

O processamento dos sinais de F_x , F_y e F_z foi feito utilizando o software LabVIEW 8.6. Foi usada uma VI (Virtual Instrument) desenvolvida no LAUS para a aquisição e visualização dos sinais no processo de fresamento (Fig. 8.6). Para todos os dados de força (F_x , F_y e F_z) fez-se a aquisição a uma taxa de 40 kS/s por canal. A análise e o pós-processamento dos dados de força foram feitos utilizando o software MS Excel.



(a)



(b)

Figura 8.6 – Software LabVIEW: (a) ambiente de programação; (b) interface gráfica [cortesia do LAUS].

8.2 Avaliação da Superfície Usinada


Para a avaliação quantitativa (medição das rugosidades) utilizou-se um rugosímetro portátil Mitutoyo modelo SJ-201. O aparelho possui resolução de $0,01 \mu\text{m}$ e agulha de diamante com raio de ponta $5 \mu\text{m}$. O procedimento de aquisição de dados de rugosidade consistiu da realização de cinco medições de rugosidade média (R_a) e total (R_t) sobre cada amostra gerada no corpo de prova (ou seja, para cada passe gerado) na região central do rasgo gerado (Fig. 8.7(a)). A escolha desta região se deve ao fato de se garantir que neste setor as três arestas atuaram sobre a peça. Desta forma, foi desprezado um comprimento equivalente ao diâmetro da fresa nas regiões de entrada e saída da ferramenta (Fig. 8.7(b)).

Nas medições (para valores de $R_a \leq 2 \mu\text{m}$) utilizou-se um comprimento de amostragem $l_e = 0,8 \text{ mm}$ e um comprimento de avaliação $l_m = 0,8 \times 5 = 4 \text{ mm}$. Já para a faixa de valores de rugosidade média $2 \mu\text{m} < R_a < 10 \mu\text{m}$ foram usados $l_e = 2,5 \text{ mm}$ e $l_m = 12,5 \text{ mm}$.


Para a avaliação qualitativa, a aquisição das imagens para inspeção visual da superfície na região de avaliação foi feita com o microscópio digital USB Dino-Lite modelo AM-413ZT, com resolução de 1024×768 e ampliação de $200\times$, Fig. 8.7(c). O processamento das imagens captadas foi feita com auxílio de um software dedicado (Dino-Capture 2.0).



(a) SJ-201



(b)



(c) AM-413ZT

Figura 8.7 – Avaliação da superfície: (a) medição de rugosidade; (b) regiões de avaliação; (c) aquisição de imagem.

9 DESENVOLVIMENTO DE UM MODELO EM RNA PARA A ESTIMAÇÃO DA RUGOSIDADE

Com base na sequência ilustrada na Figura 7.2 (metodologia para o desenvolvimento de um modelo de estimação da rugosidade), optou-se por seguir os mesmos quatro passos: 1) Definição do problema; 2) Coleta e análise dos dados; 3) Seleção e ajuste do modelo; 4) Validação do modelo.

9.1 Definição do Problema

Neste trabalho optou-se por usar o aço SAE 1045 como material do corpo de prova. Por ser um aço de médio carbono, este possui maior resistência e menor ductilidade do que os aços de baixo carbono. Esse material pode ser encontrado em equipamentos rodoviários, engrenagens, virabrequins e outras peças de máquinas que necessitem de razoável resistência mecânica e ao desgaste, como tenacidade. Além disso, não se encontrou nenhum trabalho onde foi feita a modelagem da rugosidade para este material por RNA, o que enfatiza a importância do seu emprego pela carência de informação com respeito à modelagem da rugosidade gerada na usinagem do mesmo.

Como ferramenta de corte optou-se pela fresa frontal de topo com insertos intercambiáveis de metal-duro devido à sua versatilidade. Empregou-se o raio de ponta (r_ϵ) como um dos fatores controláveis, uma vez que não se observou trabalhos que empregassem este parâmetro para este tipo de ferramenta. Os outros fatores controláveis foram velocidade de corte (v_c) e avanço por dente (f_z), sendo que os níveis dos fatores controláveis foram escolhidos conforme as recomendações do fabricante da fresa. As profundidades de corte axial (a_p) e radial ($a_e = D = 20$ mm) foram mantidos constantes.

A Tabela 9.1 mostra os fatores controláveis utilizados e os respectivos níveis.

Tabela 9.1 – Níveis dos fatores controláveis utilizados

Três Fatores Controláveis	Quatro Níveis			
r_ϵ [mm]	0,4	0,8	1,2	1,6
v_c [m/min]	110	120	130	140
f_z [mm/dente]	0,07	0,08	0,09	0,10

Optou-se inicialmente por uma profundidade de corte axial de 2,0 mm (a ferramenta de corte permite um valor de $a_p \leq 4$ mm). Desta forma, o valor de a_p é maior que todos os raios de ponta utilizados ($0,4 \leq r_\epsilon \leq 1,6$ mm). No entanto, para o valor adotado, registrou-se a ocorrência da vibração regenerativa (*chatter*)⁵ acarretando em um acabamento em forma de “escama de peixe” como mostrado na Fig. 9.1 e no lascamento do inserto.




Figura 9.1 – Efeitos do *chatter*: (a) textura da superfície; (b) textura da superfície com ampliação 200 x; (c) ocorrência de lascamento do inserto.

Pode-se observar que o fenômeno gera certa ondulação na superfície como se mostra no perfil da Figura 9.2, captado com o rugosímetro.




Figura 9.2 – Perfil da superfície obtido com a ocorrência de *chatter*.

⁵ A vibração regenerativa (ou *chatter*) resulta de um mecanismo de autoexcitação na geração da espessura do cavaco durante as operações de usinagem. A profundidade de corte axial representa o ganho no processo de autoexcitação das vibrações. Para um valor suficientemente pequeno da profundidade de corte axial o processo é sempre estável, quando o seu valor limite é ultrapassado o processo torna-se instável [Polli, 2005].

Para determinar a profundidade de corte axial (a_p) que poderia ser usada, fizeram-se alguns testes incrementando-se a_p a partir de 0,5 mm. Chegou-se à conclusão que, ao utilizar $a_p \geq 1$ mm, sinais de *chatter* sobre a superfície começaram a surgir. Por conseguinte, utilizou-se $a_p = 0,8$ mm como a profundidade de corte axial a ser mantida constante nos ensaios.

9.2 Coleta e Análise dos Dados

Para definir a sequência dos ensaios utilizou-se a técnica de projeto de experimentos (DOE). Foi utilizado um projeto fatorial completo, composto de três fatores controláveis (r_ϵ , v_c , e f_z) a quatro níveis cada (4^3), Tab. 9.1, totalizando 64 passes (canais).

9.2.1 Análise das rugosidades

A Tabela 9.2 apresenta os valores médios calculados para as rugosidades média R_a [μm] e total R_t [μm] a partir das cinco medições efetuadas na região de avaliação (Fig. 8.7(b)) para os 64 passes (canais) fresados.

Tabela 9.2 – Valores experimentais de R_a e R_t .

Passe	r_ϵ	v_c	f_z	R_a	R_t
1	0,4	110	0,07	1,92	13,00
2			0,08	1,48	11,61
3			0,09	1,74	12,89
4			0,10	1,43	11,00
5		120	0,07	1,29	10,08
6			0,08	1,27	9,63
7			0,09	1,18	9,02
8			0,10	1,18	8,50
9		130	0,07	1,44	10,52
10			0,08	1,20	10,05
11			0,09	1,13	8,72
12			0,10	0,91	6,78
13		140	0,07	1,12	9,72
14			0,08	0,99	10,69
15			0,09	0,84	6,27
16			0,10	0,97	6,53
17	0,8	110	0,07	0,97	8,09
18			0,08	1,41	14,67
19			0,09	1,53	12,94
20			0,10	2,19	17,54
21		120	0,07	0,78	6,40
22			0,08	0,96	7,40
23			0,09	1,48	11,23
24			0,10	1,35	10,40
25		130	0,07	0,75	5,68
26			0,08	1,17	9,82
27			0,09	0,98	8,40
28			0,10	1,23	11,19
29		140	0,07	0,63	3,64
30			0,08	0,84	4,85
31			0,09	0,94	9,87
32			0,10	1,31	12,41

Tabela 9.2 (continuação).

Passo	r_ϵ	v_c	f_z	R_a	R_t
33	1,2	110	0,07	3,41	22,67
34			0,08	3,60	23,66
35			0,09	3,36	20,98
36			0,10	3,23	21,45
37		120	0,07	2,90	18,84
38			0,08	2,74	17,81
39			0,09	3,11	26,53
40			0,10	2,46	19,67
41		130	0,07	2,12	19,46
42			0,08	3,46	35,76
43			0,09	2,03	17,65
44			0,10	2,04	19,39
45		140	0,07	0,92	12,24
46			0,08	1,29	13,13
47			0,09	0,83	8,74
48			0,10	0,63	7,44

Passo	r_ϵ	v_c	f_z	R_a	R_t
49	1,6	110	0,07	3,91	26,70
50			0,08	3,62	24,48
51			0,09	3,31	21,58
52			0,10	3,31	25,92
53		120	0,07	2,52	18,64
54			0,08	2,03	14,29
55			0,09	2,61	17,62
56			0,10	2,23	18,38
57		130	0,07	1,55	13,00
58			0,08	1,28	9,31
59			0,09	1,23	10,44
60			0,10	1,20	12,30
61		140	0,07	0,87	8,46
62			0,08	0,92	8,31
63			0,09	1,00	8,14
64			0,10	1,48	13,09

Para avaliar quais parâmetros de entrada têm efeito significativo sobre a resposta ou variável de saída R_a [μm] e R_t [μm] realizou-se uma Análise de Variância (Tab. 9.3 e Tab. 9.4), onde se pode observar que, com 95% de confiança, os fatores raio de ponta (r_ϵ) e velocidade de corte (v_c) são os fatores significativos ($F_{\text{tab.}} < F_0$). As interações significativas para R_a e R_t foram “ $r_\epsilon v_c$ ” e “ $r_\epsilon f_z$ ”.

Tabela 9.3 – Análise de Variância para R_a .

Fonte de Variação	$g.l.$	Soma de Quadrados	Quadrado Médio	F_0	$F_{\text{tab.}}$	Signif. ?
r_ϵ	3	17,47	5,82	121,82	2,96	Sim
v_c	3	20,62	6,87	143,80	2,96	Sim
f_z	3	0,05	0,02	0,39	2,96	Não
$r_\epsilon v_c$	9	9,78	1,09	22,72	2,25	Sim
$r_\epsilon f_z$	9	2,39	0,26	5,55	2,25	Sim
$v_c f_z$	9	0,85	0,095	1,98	2,25	Não
Erro	27	1,29	0,049	-	-	-
Total	63	52,46	-	-	-	-

Tabela 9.4 – Análise de Variância para R_t .

Fonte de Variação	<i>g.l.</i>	Soma de Quadrados	Quadrado Médio	F_0	$F_{tab.}$	Signif. ?
r_ϵ	3	1043,25	347,75	48,98	2,96	Sim
v_c	3	670,89	223,63	31,50	2,96	Sim
f_z	3	14,27	4,76	0,67	2,96	Não
$r_\epsilon v_c$	9	416,35	46,26	6,52	2,25	Sim
$r_\epsilon f_z$	9	207,47	23,05	3,25	2,25	Sim
$v_c f_z$	9	89,48	9,94	1,40	2,25	Não
Erro	27	191,68	7,10	-	-	-
Total	63	2633,39	-	-	-	-

A Figura 9.3 ilustra os efeitos dos fatores principais sobre as variáveis de saída R_a e R_t .

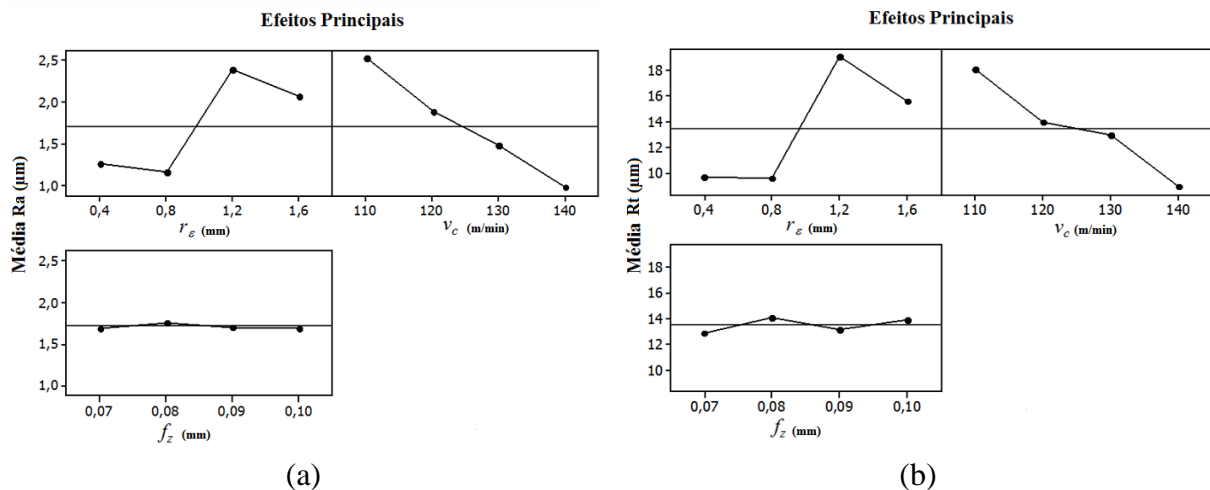


Figura 9.3 – Influência dos efeitos principais em: (a) R_a ; (b) R_t .

Observa-se na Fig. 9.3 que os efeitos dos fatores principais tiveram um comportamento semelhante tanto para R_a e quanto para R_t . Através da análise, constata-se que a ferramenta com raio de ponta $r_\epsilon = 0,8$ mm apresenta a menor média dos valores de rugosidade R_a e R_t e a ferramenta com $r_\epsilon = 1,2$ mm apresenta a maior média dentre os raios de ponta utilizados. Observou-se também uma diminuição dos valores de rugosidade conforme se aumenta a velocidade de corte (v_c). Quanto ao avanço por dente (f_z), não se pôde observar qualitativamente uma variação média da rugosidade R_a e R_t para os valores de f_z utilizados. Porém, as análises de variância (Tab. 9.3 e Tab. 9.4) constataram que a interação “ $r_\epsilon f_z$ ” é

significativa tanto para R_a quanto para R_t . Portanto, para algum raio de ponta, existe o efeito do avanço por dente sobre a rugosidade gerada na superfície usinada.

A Figura 9.4(a) apresenta o perfil medido da superfície para o passe onde se obteve as menores rugosidades R_a e R_t com o inserto $r_\epsilon = 0,8$ mm. Pode-se observar uma baixa intensidade das alturas dos picos e profundidades dos vales. Já na Fig. 9.4(b) observa-se que a superfície fresada está praticamente isenta de rebarbas.




Figura 9.4 – Passe 29 ($r_\epsilon = 0,8$ mm, $v_c = 140$ m/min, $f_z = 0,07$ mm,):
a) perfil da superfície; b) imagem da superfície (ampliação 200 x).

Para comparação, a Fig. 9.5(a) ilustra o perfil de rugosidade para o passe que apresentou maior R_a para o inserto com $r_\epsilon = 1,2$ mm. Pode-se observar um perfil bem irregular com grandes picos e vales profundos. Na Fig. 9.5(b) observa-se a imagem da superfície e pode-se constatar uma superfície cheia de rebarbas.




Figura 9.5 – Passe 34 ($r_\epsilon = 1,2$ mm, $v_c = 110$ m/min, $f_z = 0,08$ mm,):
a) perfil da superfície; b) imagem da superfície (ampliação 200x).

A Figura 9.6(a) e a Fig. 9.7(a) mostram os perfis de rugosidade originados por velocidades de corte distintas ($v_c = 120$ m/min e 140 m/min respectivamente) para o inserto com $r_\varepsilon = 0,4$ mm. Percebe-se que quando se incrementa v_c , a altura dos picos e a profundidade dos vales do perfil passam a ter menor intensidade e começam a ocorrer em intervalos regulares. Na Fig. 9.6(b) e na Fig. 9.7(b) observa-se que com esse aumento ocorre uma diminuição na formação de rebarbas na superfície usinada.




Figura 9.6 – Passe 2 ($r_\varepsilon = 0,4$ mm, $v_c = 120$ m/min, $f_z = 0,08$ mm,):
a) perfil da superfície; b) imagem da superfície (ampliação 200 x).




Figura 9.7 – Passe 14 ($r_\varepsilon = 0,4$ mm, $v_c = 140$ m/min, $f_z = 0,08$ mm,):
a) perfil da superfície; b) imagem da superfície (ampliação 200 x).

Na Fig. 9.8 e na Fig. 9.9 são apresentadas as interações de dois fatores nas rugosidades R_a e R_t , respectivamente. Pode ser visto que, para o inserto com $r_\varepsilon = 0,4$ mm, os valores de R_a e R_t diminuem com o aumento de f_z . Já para o inserto com $r_\varepsilon = 0,8$ mm ocorre o inverso, ou

seja, as rugosidades aumentam com o incremento de f_z . Isto se deve possivelmente à interação entre o raio de ponta (r_ϵ) e a profundidade axial de corte (a_p), o que deve ter proporcionado melhor formação e expulsão do cavaco da região de corte, fazendo com que a rugosidade melhorasse com o incremento do avanço (f_z) para o inserto com $r_\epsilon = 0,4$ mm.




Figura 9.8 – Interações entre os fatores principais para R_a .




Figura 9.9 – Interações entre os fatores principais para R_t .

A Figura 9.10(a) e a Fig. 9.11(a) mostram os perfis gerados nos passes 53 e 55. Apesar de os passes terem valores semelhantes de rugosidade média e total ($R_{a(53)} = 2,52 \mu\text{m}$ e $R_{a(55)} = 2,61 \mu\text{m}$; $R_{t(53)} = 18,64 \mu\text{m}$ e $R_{t(55)} = 17,62 \mu\text{m}$), pode-se observar que com o aumento do avanço por dente (f_z) o perfil apresentou uma forma mais indefinida. Na Figura 9.10(b) e na Fig. 9.11(b) nota-se que as superfícies têm aspectos semelhantes (rebarbas).




Figura 9.10 – Passe 53 ($r_\varepsilon = 1,6$ mm, $v_c = 120$ m/min, $f_z = 0,07$ mm,):

a) perfil da superfície; b) imagem da superfície (ampliação 200 x).




Figura 9.11 – Passe 55 ($r_\varepsilon = 1,6$ mm, $v_c = 120$ m/min, $f_z = 0,09$ mm,):

a) perfil da superfície; b) imagem da superfície (ampliação 200 x).

9.2.2 Análise das forças

As características extraídas dos sinais de força [força RMS (F_{RMS}); força máxima (F_{max}); força mínima (F_{min}); força média (F_{med}); força de corte ($F_c = F_{xy}$); variância da força (σ^2); variação da força ($\Delta F = F_{max} - F_{min}$)] foram geradas para cada uma das três direções ortogonais (x , y , z) num intervalo de tempo em que os sinais já se encontravam estabilizados.

A Figura 9.12, a Fig. 9.13 e a Fig. 9.14 ilustram algumas características extraídas dos sinais adquiridos em x , y e z , respectivamente. Vale ressaltar que foi utilizado um intervalo maior do que o ilustrado para representar as características extraídas.




Figura 9.12 – Exemplo de caraterísticas extraídas da força em x (F_x).




Figura 9.13 – Exemplo de caraterísticas extraídas da força em y (F_y).




Figura 9.14 – Exemplo de caraterísticas extraídas da força em z (F_z).

A Tab. A1 (em anexo) apresenta os valores das características dos 64 passes realizados.

A Tabela 9.5 apresenta o coeficiente de correlação de Pearson (vide Eq. (7.5)) das características extraídas dos sinais de força com a rugosidade média (R_a) e a rugosidade total (R_t). Os resultados mostram que a força média na direção x (F_{xmed}) e a variação da força no eixo z (ΔF_z) são as características do sinal adquirido que apresentam maior coeficiente de correlação (r) com as rugosidades média (R_a) e total (R_t).

Tabela 9.5 – Coeficiente de Pearson das características extraídas das forças com as rugosidades média e total.

	RMS			Max			Min			Med			F_c	ΔF			σ^2		
	F_x	F_y	F_z	F_x	F_y	F_z	F_x	F_y	F_z	F_x	F_y	F_z	F_{xy}	F_x	F_y	F_z	F_x	F_y	F_z
R_a	-0,35	0,04	0,21	0,36	0,03	0,43	-0,12	-0,06	0,06	0,62	-0,03	0,20	-0,15	0,31	0,09	0,53	0,32	0,08	0,29
R_t	-0,31	0,08	0,30	0,35	-0,03	0,46	-0,16	-0,14	0,18	0,59	-0,07	0,30	-0,11	0,32	0,14	0,52	0,33	0,09	0,34

De acordo com Cohen, 1988, as correlações de F_{xmed} e ΔF_z com R_a e R_t podem ser consideradas fortes; mas, segundo Dancey e Reidy, 2005, moderadas⁶. Portanto, estas grandezas serão empregadas como entradas na rede.

9.3 Ajuste e Seleção do Modelo

Para a modelagem da rugosidade empregou-se redes do tipo perceptron de múltiplas camadas. De acordo com o **Capítulo 7 (Revisão Bibliográfica)**, as redes MLP são as mais utilizadas e também apresentam boa concordância entre os resultados experimentais e os obtidos pelo modelo em RNA. A rede foi desenvolvida, treinada e simulada utilizando os recursos da *Neural Network Toolbox* do software MATLAB R2013b.

A definição da topologia (arquitetura) segundo a maioria dos autores citados no **Capítulo 7** é feita por tentativa e erro. No entanto, como este procedimento é bastante

⁶ Para Cohen, 1988, $0,10 \leq r < 0,30$ (fraco); $0,30 \leq r < 0,50$ (moderado); $0,50 \leq r < 1$ (forte). Dancey e Reidy, 2005, apontam para uma classificação ligeiramente diferente: $0,10 \leq r < 0,40$ (fraco); $0,40 \leq r < 0,70$ (moderado); $0,70 \leq r < 1$ (forte).

demorado, optou-se em determinar a topologia conforme Zhang *et al.*, 1998, que recomendam que o número de neurônios da camada oculta (intermediária) deve ser $n/2$, n , $2n$ e $2n+1$ (onde n é o número de entradas na rede).

A Figura 9.15 ilustra a topologia (arquitetura) das oito redes avaliadas.

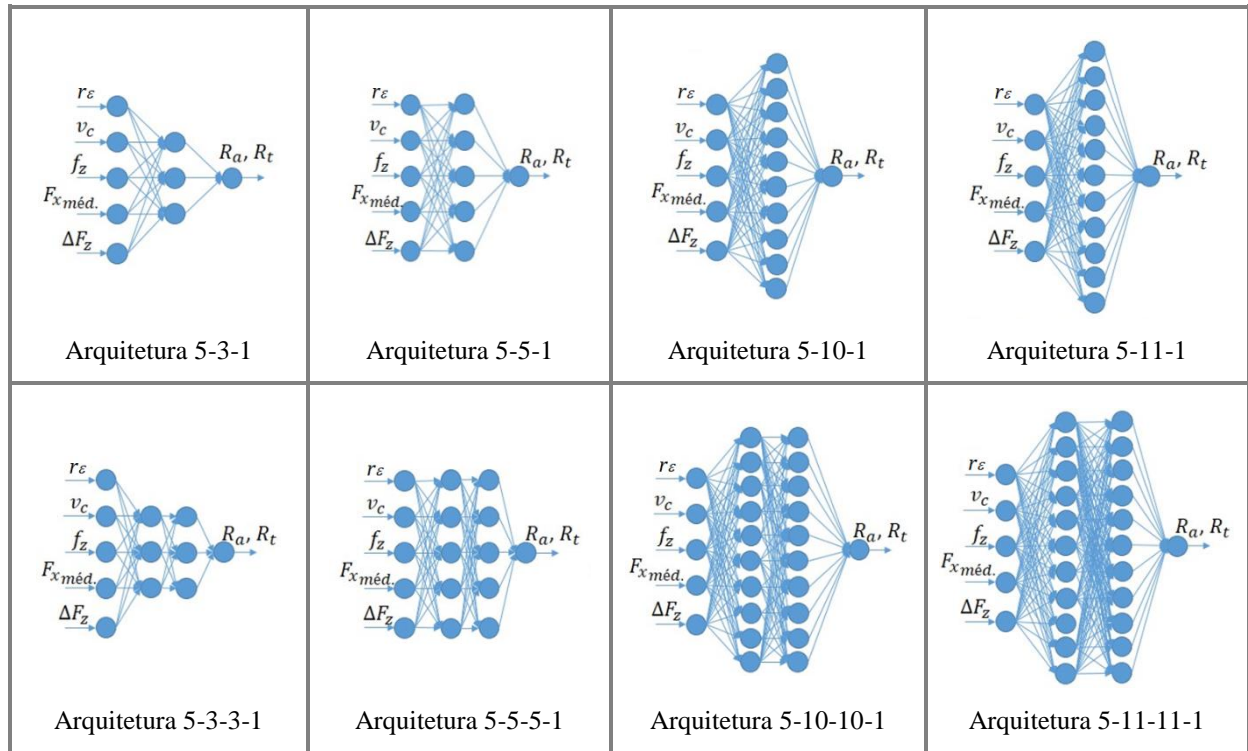


Figura 9.15 – Topologia das redes empregadas.

As funções de ativação utilizadas foram a tangente hiperbólica ($tansig$) nas camadas ocultas e a função linear ($purelin$) na camada de saída. Segundo Raj *et al.*, 2012 e Sehgal, 2014, a utilização dessas funções apresentam melhores resultados se comparadas com as funções logísticas nas camadas ocultas e funções lineares na camada de saída.

Os dados de entrada e saída da rede foram normalizados antes de efetuar o treinamento, conforme recomendado por Zhang *et al.*, 1998.

O algoritmo de treinamento utilizado foi o de Levenberg-Marquardt. Conforme mostrado na Equação (5.8), este algoritmo utiliza um parâmetro adaptativo μ . A Tabela 9.6 mostra seus valores de incremento e decremento além de um limite superior para controle conforme o padrão do software MATLAB.

O critério de parada de treinamento utilizado foi baseado na técnica de validação cruzada. Utilizaram-se 48 dados (75%) para o treinamento, 8 dados (12,5%) para a validação e outros 8 dados (12,5%) para teste. A Tabela 9.7 especifica os critérios de parada adotados.

Tabela 9.6 – Valores para o parâmetro μ do algoritmo LM

Parâmetro μ	Descrição	Valor
μ	Valor inicial para o parâmetro adaptativo de LM.	0,001
Incremento para μ	Fator de incremento para μ .	10
Decremento para μ	Fator de decremento para μ .	0,1
Valor máximo para μ	Limite superior para μ .	10^{10}

Tabela 9.7 – Critérios de parada de treinamento adotados.

Tipo	Descrição	Critério aplicado
Nº de iterações	A rede atingir o valor especificado.	Máximo de 150 iterações
Erro mínimo	A rede atingir o erro médio quadrático (EMQ) mínimo especificado.	≥ 0
Tempo máximo	A rede atingir o tempo máximo especificado.	Infinito
Testes de validação cruzada	A rede atingir o valor especificado de falhas consecutivas de validação.	15 falhas consecutivas
Gradiente mínimo	A rede atingir o valor mínimo do gradiente.	$\geq 10^{-7}$

Oliveira, 2013, ressalta que valores pequenos para o gradiente, em geral, indicam que a rede está próxima do ótimo. No entanto, quando ocorre de o gradiente ser pequeno, mas o erro médio quadrático (EMQ) resultante ser alto, a rede pode estar perdendo a capacidade de generalização.

A metodologia completa para desenvolver o modelo em RNA é resumida na Fig. 9.16.

Os valores das rugosidades médias (R_a) obtidos pelas diferentes topologias de RNA (vide Fig. 9.15) e os respectivos valores experimentais são apresentados da Fig. 9.17 à Fig. 9.24. Acrescidos aos valores experimentais (gráfico em azul) estão as dispersões ($2,78 \cdot s$, onde s é o desvio-padrão da amostra) das cinco medições com relação ao valor médio para cada passe.

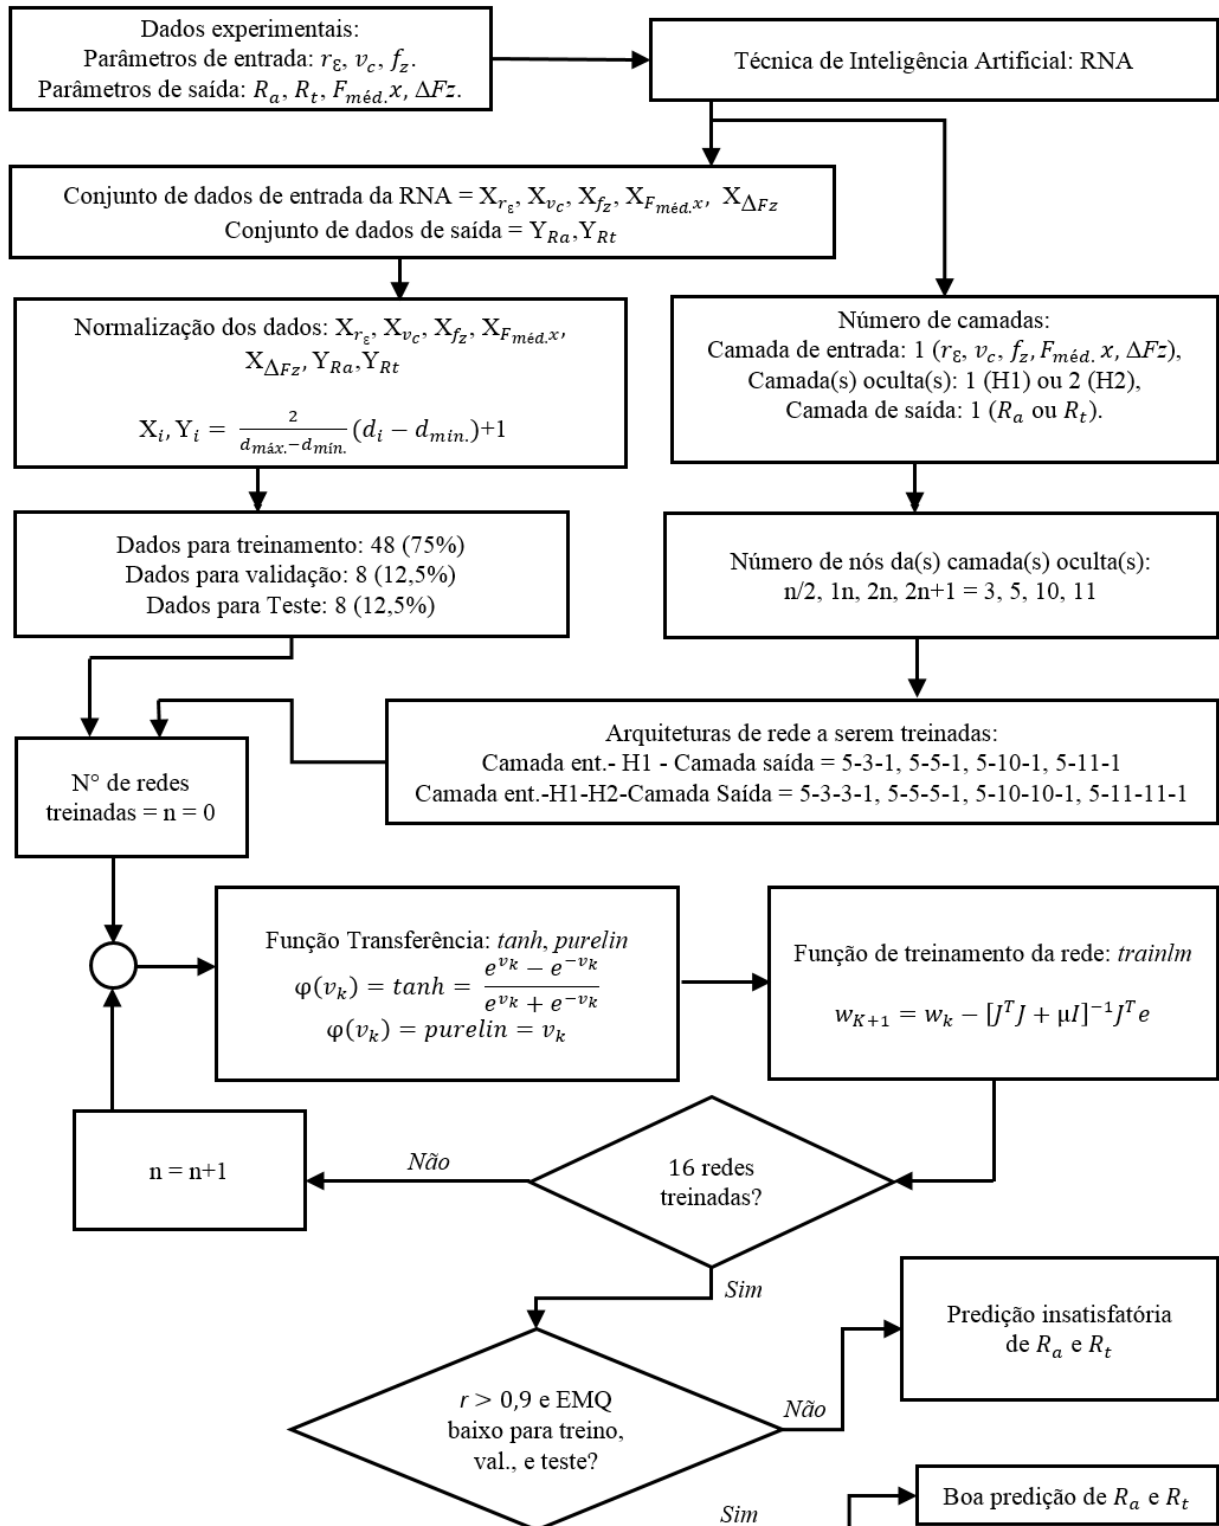


Figura 9.16 – Metodologia para desenvolver um modelo em RNA.




Figura 9.17 – Resultados de R_a experimentais e estimados pela RNA 5-3-1.




Figura 9.18 – Resultados de R_a experimentais e estimados pela RNA 5-5-1.




Figura 9.19 – Resultados de R_a experimentais e estimados pela RNA 5-10-1.




Figura 9.20 – Resultados de R_a experimentais e estimados pela RNA 5-11-1.




Figura 9.21 – Resultados de R_a experimentais e estimados pela RNA 5-3-3-1.




Figura 9.22 – Resultados de R_a experimentais e estimados pela RNA 5-5-5-1.




Figura 9.23 – Resultados de R_a experimentais e estimados pela RNA 5-10-10-1.




Figura 9.24 – Resultados de R_a experimentais e estimados pela RNA 5-11-11-1.

Assim como para as rugosidades médias (R_a), os valores obtidos para a rugosidade total (R_t) pelas diferentes topologias de RNA (Fig. 9.15) e os relativos valores experimentais são mostrados da Fig. 9.25 até a Fig. 9.32.




Figura 9.25 – Resultados de R_t experimentais e estimados pela RNA 5-3-1.




Figura 9.26 – Resultados de R_t experimentais e estimados pela RNA 5-5-1.




Figura 9.27 – Resultados de R_t experimentais e estimados pela RNA 5-10-1.

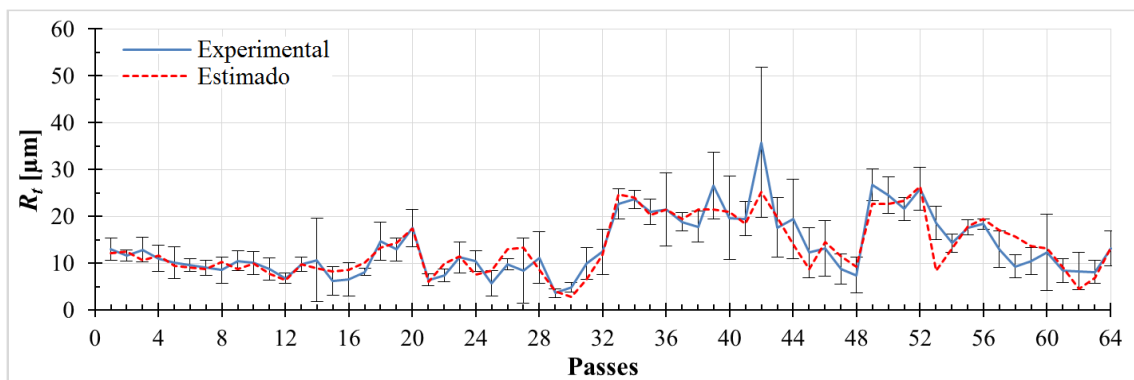


Figura 9.28 – Resultados de R_t experimentais e estimados pela RNA 5-11-1.




Figura 9.29 – Resultados de R_r experimentais e estimados pela RNA 5-3-3-1.




Figura 9.30 – Resultados de R_r experimentais e estimados pela RNA 5-5-5-1.




Figura 9.31 – Resultados de R_r experimentais e estimados pela RNA para a rede 5-10-10-1.




Figura 9.32 – Resultados de R_t experimentais e estimados pela RNA para a rede 5-11-11-1.

Para selecionar a rede que teve melhor desempenho, a Tab. 9.8 apresenta o erro médio quadrático (EMQ) e o coeficiente de correlação (r) calculado para cada conjunto de dados (treinamento, validação, teste e total). O critério de seleção baseia-se nos menores valores de EMQ e nos maiores valores de r . Assim, a topologia que apresentou os melhores resultados de estimação, tanto para R_a quanto para R_t , foi a arquitetura 5-10-10-1.

Tabela 9.8 – Erro médio quadrático e coeficiente de correlação obtido pelas diferentes topologias utilizadas.

		RNA	Erro Médio Quadrático (EMQ)				Coeficiente de Pearson (r)			
		Topologia	Treino	Validação	Teste	Total	Treino	Validação	Teste	Total
Rugosidade	R_a	5-3-1	0,150	0,097	0,054	0,131	0,92	0,95	0,97	0,92
		5-5-1	0,076	0,133	0,070	0,082	0,95	0,91	0,96	0,95
		5-10-1	0,009	0,087	0,336	0,059	0,99	0,94	0,87	0,96
		5-11-1	0,021	0,079	0,028	0,029	0,99	0,96	0,98	0,98
		5-3-3-1	0,069	0,074	0,070	0,069	0,96	0,95	0,97	0,96
		5-5-5-1	0,069	0,013	0,220	0,080	0,96	0,99	0,94	0,95
		5-10-10-1	0,020	0,031	0,020	0,021	0,99	0,98	0,99	0,99
		5-11-11-1	0,016	0,019	0,066	0,023	0,99	0,99	0,97	0,98
	R_t	5-3-1	19,36	6,74	25,44	18,54	0,76	0,92	0,37	0,74
		5-5-1	14,90	5,11	15,39	13,74	0,82	0,93	0,56	0,82
		5-10-1	12,72	4,98	11,26	11,57	0,85	0,93	0,75	0,85
		5-11-1	7,39	6,27	17,66	8,54	0,91	0,92	0,46	0,89
		5-3-3-1	18,34	4,81	11,33	15,77	0,78	0,94	0,84	0,79
		5-5-5-1	9,66	5,13	6,52	8,70	0,90	0,93	0,92	0,89
5-10-10-1		0,60	9,03	7,55	2,52	0,99	0,92	0,95	0,97	
5-11-11-1		10,03	11,00	9,88	10,13	0,88	0,93	0,89	0,87	

A Figura 9.33 ilustra o gráfico da evolução do erro médio quadrático (EMQ) para os conjuntos de **Treino**, **Validação** e **Teste** durante o treinamento da rede **5-10-10-1** para a rugosidade R_a em função do número de iterações. Como foi utilizada a técnica de parada antecipada com base na validação cruzada, observa-se que o menor EMQ para o conjunto de validação ocorreu na sexta iteração, sendo, portanto, o valor dos pesos e bias da rede determinados neste instante.




Figura 9.33 – Evolução do EMQ durante a fase de treinamento da rede para a R_a .

A Figura 9.34 apresenta o diagrama de dispersão entre os valores da rugosidade R_a experimental e a rugosidade estimada pela rede **5-10-10-1**. Pode-se observar um bom ajuste do modelo, visto que $r > 0,9$ tanto no conjunto de **Treino**, quanto nos conjuntos de **Validação** e **Teste**. Ressalta-se que nesta figura a dispersão é referente aos dados normalizados.

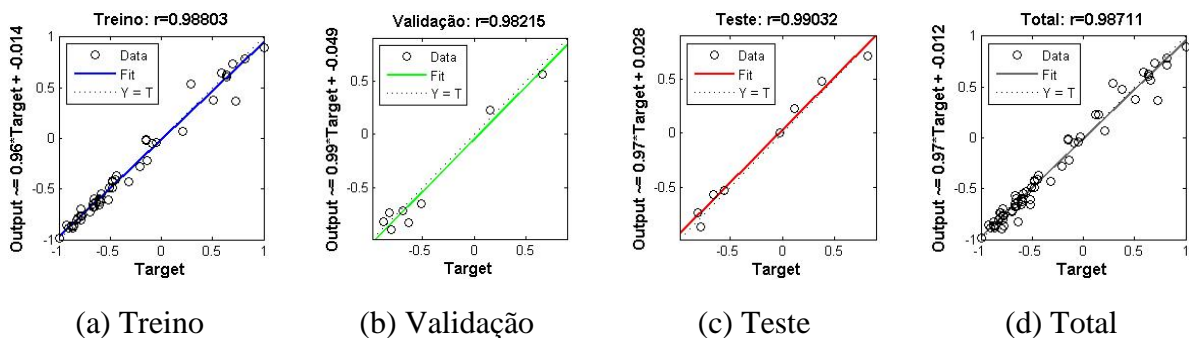


Figura 9.34 – Dispersão entre a rugosidade R_a experimental e a rugosidade R_a estimada.

A Figura 9.35 mostra a evolução do erro médio quadrático (EMQ) para os conjuntos de **Treino**, **Validação** e **Teste** durante o treinamento da rede **5-10-10-1** para a rugosidade R_t em função do número de iterações. Nota-se que o menor EMQ para o conjunto de validação também ocorreu na sexta iteração.




Figura 9.35 – Evolução do EMQ durante a fase de treinamento da rede para a R_t .

A Figura 9.36 ilustra o diagrama de dispersão entre os valores da rugosidade R_t experimental e a rugosidade obtida pela rede **5-10-10-1**. Também se observa um bom ajuste do modelo, pois $r > 0,9$ tanto no conjunto de **Treino**, quanto nos conjuntos de **Validação** e **Teste**. A dispersão também é referente aos dados normalizados.

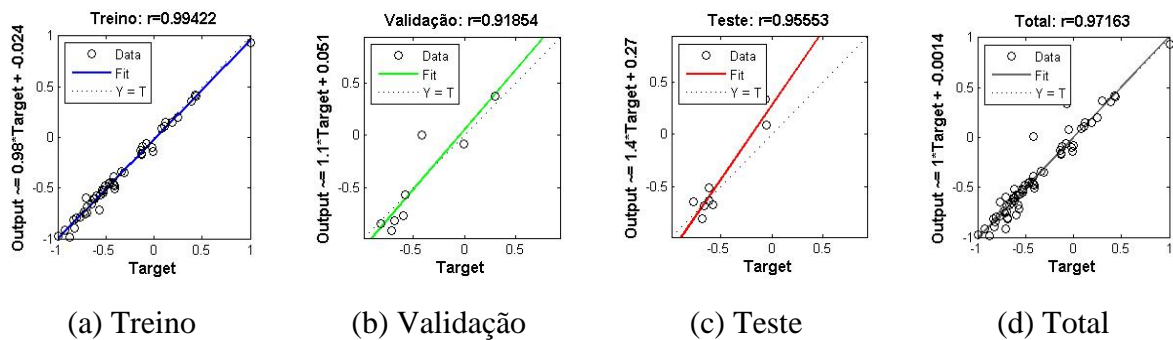


Figura 9.36 – Dispersão entre a rugosidade R_t experimental e a rugosidade R_t estimada.

A Tabela 9.9 indica quais passes foram usados para **Treino**, **Validação** e **Teste** dentre os 64 realizados, assim como o erro percentual (EP) referente aos valores estimado e experimental. Dada a dispersão em torno do valor médio de rugosidade para cada passe (conforme as barras de erro da Fig. 9.17 à Fig. 9.32) conclui-se que um $EP < 15\%$ é um bom resultado para a estimação de R_a . Já para R_t , pode-se considerar satisfatório um $EP < 25\%$ dada a sua maior dispersão em torno do valor médio obtido para cada passe. Assim, a minoria dos dados (9,37%) teve um $EP > 15\%$ para a estimação de R_a . Para R_t , 7,81% dos dados tiveram um $EP > 25\%$. Ainda no final da Tab. 9.9 é apresentado também o erro médio percentual (EMP), onde pode-se constatar que tanto para R_a quanto para R_t tiveram um valor abaixo de 10% (respectivamente 6,43% e 8,43%).

Tabela 9.9 – Valores de rugosidade: experimentais vs. estimados.

	Treino				Treino				Treino				Validação				Teste			
	Passe	R _{a-exp}	R _{a-RNA}	EP	Passe	R _{t-exp}	R _{t-RNA}	EP	Passe	R _{a-exp}	R _{a-RNA}	EP	Passe	R _{t-exp}	R _{t-RNA}	EP	Passe	R _{t-exp}	R _{t-RNA}	EP
	1	1,92	1,81	5,56	1	13,00	12,17	6,45					43	2,03	2,24	10,31	43	17,65	16,95	3,99
	2	1,48	1,58	6,99	2	11,61	12,00	3,32					44	2,04	1,91	6,43	44	19,39	18,17	6,30
	3	1,74	1,57	9,74	3	12,89	12,47	3,26					45	0,92	0,97	5,37	45	12,24	12,30	0,50
	5	1,29	1,27	2,01	4	11,00	11,33	2,99					46	1,29	1,24	3,66	46	13,13	12,05	8,19
	6	1,27	1,28	1,08	6	9,63	9,97	3,60					48	0,63	0,65	4,14	48	7,44	7,10	4,61
	8	1,18	1,20	1,71	8	8,50	8,67	2,04					49	3,91	3,75	4,25	49	26,70	26,25	1,67
	9	1,44	1,47	2,01	9	10,52	8,22	21,82					51	3,31	3,31	0,21	51	21,58	22,05	2,19
	10	1,20	1,16	2,60	10	10,05	10,38	3,26					52	3,31	3,26	1,42	52	25,92	25,47	1,73
	12	0,91	0,94	3,71	12	6,78	6,94	2,38					54	2,03	2,26	11,02	54	14,29	14,26	0,20
	13	1,12	1,07	4,08	14	10,69	10,64	0,49					55	2,61	2,38	8,72	55	17,62	17,22	2,28
	15	0,84	0,84	0,64	15	6,27	6,65	5,95					57	1,55	1,66	7,10	56	18,38	18,68	1,63
	16	0,97	0,95	2,02	17	8,09	7,80	3,58					58	1,28	1,19	6,78	58	9,31	9,21	1,10
	17	0,97	1,02	4,73	18	14,67	14,08	4,03					60	1,20	1,29	7,89	60	12,30	12,48	3,99
	18	1,41	1,27	10,24	19	12,94	13,47	4,09					61	0,87	0,84	3,41	61	8,46	7,71	6,30
	19	1,53	1,60	4,29	20	17,54	17,59	0,28					63	1,00	1,01	1,22	63	8,14	7,48	0,50
	20	2,19	2,21	1,05	21	6,40	5,40	15,64					64	1,48	1,47	0,96	64	13,09	11,61	8,19
	21	0,78	0,82	4,05	23	11,23	10,94	2,58					4	1,43	1,20	15,96	5	10,08	7,29	27,73
	23	1,48	1,57	6,53	25	5,68	3,90	31,27					47	0,83	0,92	11,25	40	19,67	18,42	6,35
	25	0,75	0,87	15,43	26	9,82	9,98	1,69					11	1,13	1,09	3,36	11	8,72	6,63	23,98
	26	1,17	1,16	0,28	27	8,40	10,06	19,72					53	2,52	2,64	4,66	50	24,48	25,69	4,94
	27	0,98	1,12	14,70	28	11,19	11,27	0,68					22	0,96	0,79	17,36	16	6,53	6,16	5,67
	28	1,23	1,23	0,40	29	3,64	4,05	11,34					59	1,23	0,91	25,75	57	13,00	19,80	52,35
	29	0,63	0,66	4,67	30	4,85	5,08	4,66					35	3,36	3,20	4,69	24	10,40	10,49	0,87
	30	0,84	0,81	3,80	32	12,41	12,48	0,57					62	0,92	1,06	14,49	62	8,31	5,06	39,17
	32	1,31	1,37	5,07	33	22,67	22,05	2,76					40	2,46	2,65	7,68	37	18,84	21,05	11,77
	33	3,41	3,47	1,82	34	23,66	22,83	3,51					7	1,18	1,34	14,04	7	9,02	8,76	2,88
	34	3,60	3,56	1,15	35	20,98	21,18	0,95					50	3,62	3,44	4,76	47	8,74	6,76	22,63
	36	3,23	3,34	3,35	36	21,45	21,43	0,11					14	0,99	0,85	13,67	13	9,72	11,45	17,80
	38	2,74	3,16	15,26	38	17,81	18,24	2,39					56	2,23	2,28	2,32	53	18,64	25,13	34,83
	39	3,11	2,90	6,77	39	26,53	26,39	0,54					31	0,94	1,07	13,53	22	7,40	9,29	25,52
	41	2,12	2,18	3,18	41	19,46	17,45	10,34					24	1,35	1,40	3,69	59	10,44	8,81	15,56
	42	3,46	2,88	16,80	42	35,76	34,67	3,05					37	2,90	3,06	5,47	31	9,87	9,47	4,07
									EMP (R_a) = 6,43				EMP (R_t) = 8,43							

9.4 Validação do Modelo

A **Validação** consiste em testar o modelo usando um conjunto de dados diferente do que foi usado durante a fase de treinamento.

Com relação à Tab. 9.9 percebe-se que nos conjuntos de **Teste** e **Validação** para R_a , somente três estimações pela RNA (**5-10-10-1**) tiveram $EP > 15\%$, podendo ser considerado como um “bom” resultado. Nos conjuntos de **Teste** e **Validação** para R_t , cinco estimações da rede tiveram $EP > 25\%$. Logo, conclui-se em primeira análise que a RNA (**5-10-10-1**) desenvolvida para R_t possui uma capacidade de estimação “razoável”, sendo necessário fazer mais testes.

Por conseguinte, para uma melhor avaliação sobre a capacidade de generalização das redes foram feitos 12 passes adicionais para verificar a capacidade de estimação dos modelos. Foram gerados valores aleatórios em um intervalo de avanço por dente (f_z) de 0,07 a 0,10 mm/dente e em um intervalo para a velocidade de corte (v_c) de 110 a 140 m/min utilizando o software MS-Excel. A Tabela 9.10 mostra os valores de f_z e v_c gerados.

Tabela 9.10 – Novos dados gerados para a fase de validação.



Passo	r_ε	v_c	f_z
1	0,4	125	0,083
2	0,4	116	0,076
3	0,4	123	0,093
4	0,8	125	0,073
5	0,8	115	0,094
6	0,8	120	0,089
7	1,2	113	0,083
8	1,2	138	0,096
9	1,2	111	0,085
10	1,6	123	0,091
11	1,6	121	0,083
12	1,6	134	0,075

A Tabela 9.11 apresenta os valores médios das rugosidades média (R_a) e total (R_t), os valores estimados pela RNA e os erros percentuais (EP) correspondentes. Conforme se observa na Tabela 9.11, o erro médio percentual (EMP) foi de 8,34% para a rugosidade média, podendo ser considerado um bom resultado, já que somente dois passes geraram $EP > 15\%$ ($EP_{max} = 21,84\%$). Para a rugosidade total, o $EMP = 11,14\%$; observa-se que apenas o **Passo 3** teve um $EP > 25\%$ ($EP_{max} = 38,79\%$), confirmando uma boa capacidade de generalização da rede para R_t .

Tabela 9.11 – Erro percentual com relação ao valor estimado pela RNA.

Passo	R_a -exp	R_a -RNA	EP	R_t -exp	R_t -RNA	EP	
1	1,08	1,20	11,34	10,008	10,82	8,12	
2	1,19	1,16	2,21	10,216	12,29	20,37	
3	1,03	1,26	21,84	7,700	10,68	38,79	
4	1,25	1,08	13,07	8,034	7,62	5,04	
5	1,93	1,83	5,31	11,110	13,51	21,68	
6	1,63	1,53	6,01	11,114	11,47	3,25	
7	3,25	3,12	4,10	21,902	22,62	3,30	
8	0,96	0,97	0,55	11,240	11,19	0,37	
9	3,32	3,37	1,44	25,352	24,07	5,03	
10	2,13	1,98	7,21	13,894	14,38	3,52	
11	2,50	2,31	7,63	15,618	15,24	2,36	
12	0,96	1,14	19,42	11,064	8,64	21,85	
			EMP = 8,34				EMP = 11,14

A Figura 9.37 e a Fig. 9.38 ilustram os respectivos gráficos das rugosidades obtidas.

Figura 9.37 – Rugosidade R_a : experimental vs. estimada.Figura 9.38 – Rugosidade R_t : experimental vs. estimada.

10 CONCLUSÕES

Este trabalho teve como objetivo modelar a rugosidade gerada no processo de fresamento do aço SAE 1045 via redes neurais artificiais. Para isso utilizou-se os parâmetros de entrada velocidade de corte (v_c), avanço por dente (f_z) e raio de ponta do inserto (r_ϵ) como variáveis independentes do modelo. Investigaram-se também as características extraídas dos sinais das forças de usinagem captados por um sistema sensório com o intuito de utilizá-las como entrada do modelo.

Através da coleta e análise dos dados conclui-se, com uma significância de 5%, que os fatores raio de ponta (r_ϵ) e velocidade de corte (v_c) são os fatores principais que influenciam nos valores de rugosidade. Quanto às características dos sinais das forças de usinagem, verificou-se através do coeficiente de Pearson que a força média na direção x ($F_{x\text{méd.}}$) e a variação da força no eixo z (ΔFz) são as que têm correlação mais forte com a rugosidade.

Das topologias de rede utilizadas, a que forneceu o melhor resultado (menor EMQ e maior r) foi a 5-10-10-1, tanto para R_a quanto para R_t . O erro médio percentual de estimação para todos os 64 passes iniciais foi de 6,43% para R_a e 8,43% para R_t , sendo estes considerados bons resultados.

Para melhor avaliar a capacidade de generalização das redes selecionadas foram feitos 12 ensaios adicionais. Considerando que erros de 15% e 25% são aceitáveis para a estimação de R_a e R_t , respectivamente, constatou-se que somente dois dados estimados tiveram erro maior que 15% para R_a . Já para R_t , um único valor estimado teve erro maior que 25%.

Em síntese, pode-se concluir que os modelos desenvolvidos neste trabalho são capazes de fazer boas estimações da rugosidade e mostra que as redes neurais artificiais são uma técnica poderosa para modelar as relações não lineares existentes entre as variáveis de entrada e saída do processo.

10.1 Sugestões para Trabalhos Futuros

- Complementar o modelo utilizando diferentes níveis para os parâmetros de entrada mantidos constantes como profundidade de corte, largura de corte, tipo de material, condição de lubrificação etc.
- Empregar algum método de otimização como algoritmos genéticos, *firefly*, *ant colony*, etc., para determinar os parâmetros de entrada ótimos que minimizam a rugosidade e maximizam a taxa de remoção de material.

- Desenvolver um modelo empregando características extraídas de outros sensores como os de vibração (20 Hz – 20 kHz), ultrassom (20 kHz – 100 kHz) ou emissão acústica (acima de 100 kHz).
- Comparar o desempenho do modelo desenvolvido em MLP com outros tipos de rede como RBF, GRNN, redes bayesianas etc.

REFERÊNCIAS BIBLIOGRÁFICAS

ABNT NBR ISO 4287. **Termos, Definições e Parâmetros de Rugosidade**, Especificações Geométricas do produto (GPS) – Rugosidade – Método do Perfil, 18p., 2002.

ABNT NBR ISO 4288. **Regras e Procedimentos para Avaliação de Rugosidade**, Especificações Geométricas do produto (GPS) – Rugosidade – Método do Perfil, 10p., 2008.

Al Hazza, M. H. F., Adesta, E. Y. T., Investigation of the effect of cutting speed on the surface roughness parameters in CNC end milling using artificial neural network, **IOP Conference Series: Materials Science and Engineering**, Vol. 53, No. 1, 2013.

Altintas, Y., **Manufacturing Automation – Metal Cutting Mechanics, Machine Tool Vibrations and CNC Design**, Cambridge University Press, Cambridge, United Kingdom, 2000.

Araújo, A. D. Jr, **Predição não linear de curvas de produção de petróleo via redes neurais recursivas**, Dissertação (Mestrado) em Ciência em Engenharia do Petróleo, PPGCEP, Universidade Federal do Rio Grande do Norte, UFRN, Natal, 97p., 2010.

Aykut, S. Surface roughness prediction in machining castamide material using ANN, **Journal of Applied Sciences (Acta Polytechnica Hungarica)**, Vol. 8, No. 2, pp. 21-32, 2011.

Bajić, D.; Celent, L.; Jozić, S., Modeling of the influence of cutting parameters on the surface roughness, tool wear and cutting force in face milling in off-line process control, **Journal of Mechanical Engineering**, Vol. 58, pp. 673-682, 2012.

Benardos, P. G.; Vosniakos, G. C., Prediction of surface roughness in CNC face milling using neural networks and Taguchi's design of experiments, **Robotics and Computer Integrated Manufacturing**, Vol. 18, pp. 343-354, 2002.

Benardos, P.G., Vosniakos, G.-C., Predicting surface roughness in machining: a review, **International Journal of Machine Tools and Manufacture**, Vol. 43, No. 8, pp. 833-844, 2003.

Bhushan, B., **Principles and Applications of Tribology**, John Wiley & Sons, Inc., New York, 1999.

Bozdemir, M.; Aykut, S., Optimization of surface roughness in end milling castamide, **The International Journal of Advanced Manufacturing Technology**, Vol. 62, pp. 495-503, 2012.

Braga, A.P., Ludermir, T. B.; Carvalho, A. C. P. L. F., **Redes Neurais Artificiais: Teoria e aplicações**. Editora LTC, Rio de Janeiro, RJ, 262 p., 2000.

Bruni, C.; d'Apolito, L.; Forcellese, A.; Gabrielli, F.; Simoncini, M., Surface roughness modeling in finish face milling under MQL and dry cutting conditions, **International Journal of Material Forming**, Vol. 1, pp. 503-506, 2009.

Carter, M. A., **Telecurso 2000 – Metrologia – Profissionalizante – Aula 19**, Disponível em: <www.grima.ufsc.br/capp/rugosidade/aula19_ParametrosDeRugosidade.pdf> Acesso em: 04/11/2015.

Castillo, W. J. G. **Furação profunda de ferro fundido GG25 com brocas de metal duro com canais retos**, Dissertação (Mestrado) em Engenharia Mecânica, POSMEC, Universidade Federal de Santa Catarina, UFSC, Florianópolis, 134 p., 2005.

Cohen, J., **Statistical Power Analysis for the Behavioral Sciences**. Hillsdale, NJ, Erlbaum, 1988.

Correa, M.; Bielza, C.; Pamies-Teixeira, J., Comparison of Bayesian networks and artificial neural networks for quality detection in a machining process, **Expert Systems with Applications**, Vol. 36, pp. 7270-7279, 2008.

Dagnall, H., **Exploring Surface Texture**, 2. Ed., Rank Taylor Hobson Ltd., England, 1986.

Dancey, C., Reidy, J., **Estatística Sem Matemática para Psicologia: Usando SPSS para Windows**. Porto Alegre, Artmed, 2006.

Diniz, A. E., Marcondes, F. C., Coppini, N. L. **Tecnologia da Usinagem dos Materiais**, 8. Ed., Artliber, São Paulo, 270 p., 2013.

Dormer Tools, **Manual Técnico**. Disponível em <www.dormertools.com>. Acesso em 05/11/2015.

El-Rahman, H. M. A.; El-Zahry, R. M.; Mahdy, Y. B., Implementation of neural network for monitoring and prediction of surface roughness in a virtual end milling process of a CNC vertical milling machine, **Journal of Engineering and Technology Research**, Vol. 5, pp. 63-78, 2013.

Erzurumlu, T.; Öktem, H., Comparison of response surface model with neural network in determining the surface quality of moulded parts, **Materials & Design**, Vol. 28, pp. 459-465, 2007.

Escalona, P.; Maropoulos, P. G., Artificial neural networks for surface roughness prediction when face milling Al 7075-T7351, **Journal of Materials Engineering and Performance**, Vol. 19, pp. 185-193, 2010.

Ferraresi, D., **Fundamentos da Usinagem dos Metais**. São Paulo: Edgard Blücher, 751 p., 1977.

Galdámez, E. V. C., **Aplicação das técnicas de planejamento e análise de experimentos na melhoria da qualidade de um processo de fabricação de produtos plásticos**, Dissertação (mestrado) em Engenharia de Produção, Escola de Engenharia de São Carlos da Universidade de São Paulo, USP, SP, 133 p., 2002.

Greco, J. A. S., Fabbri, G. T. P., Considerações sobre planejamento e análise de experimentos fatorais fracionários assimétricos – exemplo de aplicação a um caso de infraestrutura de transportes, **IV Encontro Tecnológico da Engenharia Civil e Arquitetura, ENTECA**, pp. 419-430, 2003.

Hagan, M. T.; Demuth, H. B.; Beale, M., **Neural Network Design**. Boston: Thomson Publishing INC., 1996.

Haykin, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 900p. 2001.

Haykin, S., **Neural Networks: A Comprehensive Foundation**, 2 Ed., Prentice Hall, 1999.

Hoff, A. G., **Medição de força de usinagem utilizando um transdutor piezométrico**, Trabalho de Conclusão de Curso em Engenharia Elétrica, Universidade do Vale do Rio dos Sinos, UNISINOS, São Leopoldo, RS, 2009.

Hossain, M. I.; Amim AKM N.; Patwari A. U.; Development of an artificial neural network algorithm for predicting the surface roughness in end milling of Inconel 718 alloy, **Proceedings of the International Conference on Computer and Communication Engineering (ICCCE08)**, Kuala Lumpur, 2008.

Hossain, Md. S. J.; Ahmad, N., Artificial intelligence based surface roughness prediction modeling for three dimensional end milling, **International Journal of Advanced Science and Technology**, Vol. 45, pp. 1-18, 2012.

Huang, B.; Chen, J. C., An in-process neural network-based surface roughness prediction system using a dynamometer in end milling operations, **The International Journal of Advanced Manufacturing Technology**, Vol. 21, pp. 339-347, 2003.

Jansson, D. G.; Rourke, J. M.; Bell, A. C. High-speed surface roughness measurement, **Journal of Engineering for Industry**, Vol. 106, pp. 34–39, 1984.

Kalidass, S.; Palanisamy, P.; Prediction of surface roughness for AISI 304 steel with solid carbide tools in end milling process using regression and ANN models, **The Arabian Journal for Science and Engineering**, Vol. 39, No. 11, pp. 8065-8075, 2014.

Karabulut, S., Optimization of surface roughness and cutting force during AA7039/Al₂O₃ metal matrix composites milling using neural networks and Taguchi method, **Measurement**, Vol. 66, pp. 139-149, 2015.

Kistler. **Cutting Force Measurement: Precise Measuring Systems for Metal-Cutting**, Winterthur, Switzerland, 44 p., 2009.

Kistler. **Multichannel Charge Amplifier for Multi-Component Force Measurement Type 5070A**... Instruction Manual, Winterthur, Switzerland, 77 p., 2010.

Koura, O. M.; Sayed, T. H. Prediction of surface roughness and feed force in milling for some materials at high speeds, **American Journal of Mechanical Engineering**, Vol. 3, pp. 1-6, 2015.

Landis, J. R.; Koch, G. G. The measurement of observer agreement for categorical data, **Biometrics**, vol. 33, p. 159-174, 1977.

Lima, D. O., Araujo, A. C., Silveira, J. L. L. Influência da profundidade de corte e do avanço na força de corte no fresamento de faceamento, **7º Congresso Nacional de Engenharia Mecânica (Anais do VII CONEM)**, 31 Jul. – 03 Ago., São Luís, MA, 2012.

Lou, M. S.; Chen, J. C.; Li, C. M. Surface roughness prediction technique for CNC end-milling, **Journal of Industrial Technology**, Vol. 15, No. 1, p. 1-6, 1999.

Machado, A. R.; Silva, M. B.; Coelho, R. T; Abrão, A. M. **Teoria da Usinagem dos Materiais**, 1. Ed., São Paulo: Blücher, 2009.

Mahdavinejad, R. A.; Khani, N.; Fakhrabadi, M. M. S., Optimization of milling parameters using artificial neural network and artificial immune system, **Journal of Mechanical Science and Technology**, Vol. 26, pp. 4097-4104, 2012.

Measurement Computing, **PCIM-DAS1602/16: 6-Channel, 16-Bit Digital I/O Board with Dual Burst Mode D/As**. Disponível em <www.mccdaq.com/pci-data-acquisition/PCIM-DAS1602-16.aspx> Acesso em 05/11/2015.

Mendes, R. R. A., **Estudo da minimização do custo de usinagem de aço duro usando a metodologia de superfície de resposta**, Dissertação (mestrado) em Engenharia de Produção, PPGE, Universidade Federal de Itajubá, UNIFEI, MG, 96 p., 2006.

Moghri, M.; Madic, M.; Omid, M.; Farahnakian, M.; Surface roughness optimization of polyamide-6/nanoclay nanocomposites using artificial neural network: genetic algorithm approach, **The Scientific World Journal**, pp. 1-7, 2014.

Montgomery, D. C., **Design and Analysis of Experiments**, John Wiley & Sons, New York, 672 p., 2000.

Montgomery, D. C., Jennings, C. L., Kulahci, M., **Introduction to Time Series Analysis and Forecasting**, John Wiley & Sons, New Jersey, 468 p., 2008.

Mukherjee, A.; Kachawaha, A.; Application of neural network to reduce the machining optimization, **Journal of Harmonized Research in Engineering**, Vol. 3, pp. 13-17, 2015.

Nascimento Jr., C. L., Yoneyama, T., **Inteligência Artificial em Controle e Automação**, 1 Ed., São Paulo: Edgar Blücher, 218 p, 2000.

Nunes, L. T., **Análise estatística da influência dos parâmetros de corte na rugosidade no torneamento do aço microligado DIN 38MnSiVS5**. Dissertação (mestrado) em Engenharia Mecânica, FEMEC, Universidade Federal de Uberlândia, UFU, MG, 79 p. 2011.

Öktem, H., An integrated study of surface roughness for modelling and optimization of cutting parameters during end milling operation, **The International Journal of Advanced Manufacturing Technology**, Vol. 43, pp. 852-861, 2009.

Öktem, H.; Erzurumlu, T.; Erzincanlı, F., Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm, **Materials and Design**, Vol. 27, pp. 735-744, 2006.

Oliveira, A. A., **Identificação de madeiras utilizando a espectrometria no infravermelho próximo e redes neurais com a heurística de Levenberg-Marquardt**. Dissertação (mestrado) em Métodos Numéricos em Engenharia, MNE, Departamento de Matemática, Universidade Federal do Paraná (UFPR), Curitiba, 147 p., 2013.

Ozcelik, B.; Öktem, H.; Kurtaran H., Optimum surface roughness in end milling inconel 718 by coupling neural network model and genetic algorithm, **The International Journal of Advanced Manufacturing Technology**, Vol. 27, pp. 234-241, 2005.

Paiva, A. P. **Estudo da minimização de erro nas medições de concentração de emulsões por titração Karl-Fischer utilizando-se projeto de experimentos**. Dissertação (mestrado) em Engenharia de Produção, PPGEF, Universidade Federal de Itajubá, UNIFEI, MG, 195 p. 2004.

Palani, S.; Natarajan, U., Prediction of surface roughness in CNC end milling by machine vision system using artificial neural network based on 2d Fourier transform, **The Int. Journal of Advanced Manufacturing Technology**, Vol. 54, pp. 1033-1042, 2011.

Parmar, J. G.; Makwana, A.; Prediction of surface roughness for end milling process using artificial neural network, **International Journal of Advanced Engineering Research and Studies**, Vol. 1, pp. 47-50, 2012a.

Parmar, J. G.; Makwana, A., Prediction of surface roughness for end milling process using artificial neural network, **International Journal of Modern Engineering Research**, Vol. 2, pp. 1006-1013, 2012b.

Patel, R. D.; Oza, N. V.; Bhavsar, S. N., Prediction of surface roughness in CNC machine by controlling machining parameters using ANN, **International Journal of Mechanical Engineering and Robotics Research**, Vol. 3, pp. 353-359, 2014.

Polli, M. L., **Análise da estabilidade dinâmica do processo de fresamento a altas velocidades de corte**, Tese (doutorado) em Engenharia Mecânica, POSMEC, Universidade Federal de Santa Catarina, UFSC, Florianópolis, 214 p., 2005.

Pontes, F. J.; Ferreira, J. R.; Silva, M. B.; Paiva, A. P.; Balestrassi, P. P. Artificial neural networks for machining processes surface roughness modeling, **The International Journal of Advanced Manufacturing Technology**, Vol. 49, No. 9, pp. 879-902, 2010.

Quintana, G.; Garcia-Romeu, M. L.; Ciurana, J. Surface roughness monitoring application based on artificial neural networks for ball-end milling operations, **Journal of Intelligent Manufacturing**, Vol. 22, pp. 607-617, 2011.

Raj, P. P.; Perumal, A. E.; Ramu P., Prediction of surface roughness and delamination in end milling of GFRP using mathematical model and ANN, **Indian Journal of Engineering & Material Sciences**, Vol. 19, pp. 107-120, 2012.

Rajesh, M.; Manu, R.; Prediction of surface roughness of freeform surfaces using artificial neural network, **Proceedings of the 26th All India Manufacturing Technology, Design and Research Conference (AIMTDR 2014)**, IIT Guwahati, Assam, India, 2014.

Rashid, M. F. F. Ab.; Abdul Lani, M. R., Surface roughness prediction for CNC milling process using artificial neural network, **Proceedings of the World Congress on Engineering (WCE2010)**, London, 2010.

Razfar, M. R.; Zinati, R. F.; Haghshenas M., Optimum surface roughness prediction in face milling by using neural network and harmony search algorithm, **The International Journal of Advanced Manufacturing Technology**, Vol. 52, pp. 487-495, 2011.

Rigatti, A. M. Y., **Avaliação da força de usinagem e energia específica de corte no fresamento com alta velocidade de corte**. Dissertação (mestrado) em Engenharia Mecânica, Universidade Estadual Paulista Júlio de Mesquita Filho, UNESP, Ilha Solteira, 82 p., 2010.

Samek, D.; Bilek, O. Modeling of CNC machining process – artificial neural networks approach, **Recent Advances in Automatic Control, Information and Communications**, Recent Advances in Electrical Series, Vol. 19, WSEAS, pp. 168-173, 2013.

Sandvik. **Manual Técnico de Usinagem, Parte D – Fresamento**, Sandvik Coromant, São Paulo, 197 p., 2012.

Santos, S. C.; Sales W. F.; **Aspectos Tribológicos da Usinagem dos Materiais**, 1. Ed. São Paulo: Artliber, 2007.

Sehgal, M. A. K., Application of artificial neural network in surface roughness prediction considering mean square error as performance measure, **International Journal of Engineering & Technical Research**, Vol. 1, No. 1, pp. 72-76, 2014.

Sick, B., On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research. **Mechanical Systems and Signal Processing**, Vol. 16, No. 4, pp. 487–546, 2002.

Silva, A. M., **Utilização de redes neurais artificiais para classificação de spam**, Dissertação (Mestrado) em Modelagem Matemática e Computacional, MMC, Centro Federal de Educação Tecnológica de Minas Gerais, CETET-MG, Belo Horizonte, 128 p., 2009.

Simunovic, G.; Simunovic, K.; Saric, T., Modelling and simulation of surface roughness in face milling, **International Journal of Simulation Modelling**, Vol. 12, pp. 141-153, 2013.

Souza, A. J., **Aplicação de multisensores no prognóstico da vida da ferramenta de corte em torneamento**, Tese (doutorado) em Engenharia Mecânica, POSMEC, Universidade Federal de Santa Catarina, UFSC, Florianópolis, 210 p., 2004.

Sreenivasulu, R., Optimization of surface roughness and delamination damage of GFRP composite material in end milling using Taguchi design method and artificial neural network, **Procedia Engineering**, Vol. 64, pp. 785-794, 2013.

Stemmer, C. E., **Ferramentas de Corte I**, 4 Ed., Florianópolis: Edufsc, 249 p., 1995.

Sukumar, M. S.; Ramaiah, P. V.; Nagarjuna, A., Optimization and prediction of parameters in face milling of al-6061 using Taguchi and ANN approach, **Procedia Engineering**, Vol. 97, pp. 365-371, 2014.

Toh, C. K. Static and dynamic cutting force analysis when high speed rough milling hardened steel, **Materials & Design**, Vol. 25, pp. 41-50, 2004.

Topal, E. S., The role step-over-ratio in prediction of surface roughness in flat end milling, **International Journal of Mechanical Sciences**, Vol. 51, pp. 782-789, 2009.

Tsai, Y-H.; Chen, J. C.; Lou, S-J., An in-process surface recognition system based on neural networks in end milling cutting operations, **International Journal of Machine Tools & Manufacture**, Vol. 39, pp. 583-605, 1999.

Williams, D. B., Carter, C. B., **Transmission Electron Microscopy: a Textbook for Materials Science**, 2 Ed., Springer, 804 p., 2009.

Yilmaz, S.; Arici, A. A.; Feyzullahoglu E., Surface roughness prediction in machining of cast polyamide using neural network, **Neural Computing and Applications**, Vol. 20, pp. 1249-1254, 2011.

Zain, A. M.; Haron, H.; Sharif, S., Prediction of surface roughness in the end milling machining using artificial neural network, **Expert Systems with Applications**, Vol. 37, pp. 1755-1768, 2010.

Zhang, G.; Patuwo, B. E.; Hu, M. Y. Forecasting with artificial neural networks: the state of the art, **International Journal of Forecasting**, Vol. 14, pp. 35-62, 1998.

APÊNDICES

Tabela A1 – Características extraídas dos sinais captados para os 64 passes realizados.

	RMS_x	RMS_y	RMS_z	F_{x-max}	F_{y-max}	F_{z-max}	F_{x-min}	F_{y-min}	F_{z-min}	F_{x-med}	F_{y-med}	F_{z-med}	F_c	ΔF_x	ΔF_y	ΔF_z	σ_x^2	σ_y^2	σ_z^2
1	88,94	119,79	57,38	48,40	-18,37	105,16	-177,00	-208,68	10,44	-75,52	-114,02	55,72	136,76	225,40	190,31	94,73	6,85	6,06	3,70
2	93,71	133,07	54,26	47,79	-33,39	113,89	-190,86	-215,76	6,04	-80,02	-127,76	52,50	150,75	238,65	182,37	107,85	6,98	6,10	3,70
3	100,11	148,28	57,09	42,91	-49,80	108,15	-208,13	-241,03	13,00	-86,19	-142,97	55,39	166,94	251,04	191,22	95,15	7,14	6,27	3,72
4	107,41	159,20	61,82	42,72	-52,06	122,86	-218,99	-255,62	12,39	-92,61	-153,39	60,12	179,18	261,72	203,55	110,47	7,38	6,53	3,80
5	88,64	115,45	52,11	9,77	-39,12	99,18	-178,89	-201,35	2,99	-79,27	-111,19	50,25	136,55	188,66	162,23	96,19	6,30	5,58	3,72
6	93,75	131,67	52,86	12,08	-58,23	100,65	-189,88	-218,93	7,02	-83,81	-127,51	51,01	152,58	201,97	160,71	93,63	6,48	5,73	3,73
7	101,25	147,31	56,60	17,40	-64,76	110,41	-213,38	-246,46	4,88	-90,44	-142,85	54,66	169,08	230,77	181,70	105,53	6,75	6,00	3,83
8	85,05	124,59	46,11	80,44	28,50	132,63	-259,40	-256,35	-22,58	-94,02	-144,52	55,05	172,41	339,84	284,85	155,21	7,90	9,07	5,43
9	80,48	106,66	55,65	8,97	-35,46	94,97	-165,95	-187,99	4,82	-72,11	-102,89	54,02	125,64	174,93	152,53	90,15	5,98	5,30	3,65
10	93,07	125,17	57,38	15,32	-47,36	104,68	-192,02	-229,00	8,18	-83,53	-120,80	55,64	146,87	207,34	181,64	96,50	6,41	5,73	3,75
11	105,26	146,58	59,07	10,74	-62,99	102,05	-209,84	-258,24	10,68	-94,46	-141,75	57,43	170,34	220,58	195,25	91,37	6,81	6,11	3,72
12	117,45	167,37	60,95	8,79	-79,59	107,97	-225,28	-280,64	12,88	-105,28	-162,22	59,38	193,38	234,07	201,05	95,09	7,22	6,42	3,70
13	98,07	125,87	63,66	23,74	-17,46	103,45	-189,82	-216,86	20,51	-85,61	-118,70	62,37	146,35	213,56	199,40	82,95	6,92	6,47	3,57
14	103,73	137,17	63,74	26,49	-24,90	104,80	-211,12	-236,63	17,21	-90,68	-130,31	62,36	158,76	237,61	211,73	87,59	7,10	6,55	3,63
15	110,12	150,82	65,01	28,14	-39,92	108,95	-214,66	-252,87	18,92	-96,19	-144,11	63,60	173,26	242,80	212,95	90,03	7,32	6,67	3,67
16	117,06	163,91	68,38	28,14	-55,36	109,13	-224,98	-272,64	20,81	-102,16	-157,26	67,02	187,52	253,11	217,29	88,32	7,56	6,80	3,68
17	92,71	117,47	89,81	40,95	-20,51	145,39	-217,16	-197,94	24,41	-81,46	-113,02	87,91	139,31	258,12	177,43	120,97	6,65	5,66	4,28
18	94,82	123,48	91,42	39,61	-34,85	144,90	-204,16	-205,93	32,96	-82,75	-119,04	89,60	144,98	243,77	171,08	111,94	6,80	5,73	4,26
19	100,20	154,97	85,71	52,73	-69,52	141,48	-213,32	-258,54	31,86	-87,57	-150,97	83,63	174,52	266,05	189,03	109,62	6,92	6,03	4,36
20	92,71	117,47	89,81	40,95	-20,51	145,39	-217,16	-197,94	24,41	-88,04	-152,02	87,91	175,67	258,12	177,43	120,97	6,65	5,66	4,28
21	90,71	130,31	85,11	22,77	-55,18	131,41	-184,88	-210,88	26,31	-81,20	-126,91	83,07	150,67	207,64	155,70	105,10	6,36	5,44	4,30
22	95,87	142,04	85,73	28,69	-62,74	134,89	-199,46	-231,57	32,84	-85,76	-138,45	83,55	162,86	228,15	168,82	102,05	6,55	5,63	4,38
23	102,88	158,32	89,54	41,75	-76,42	149,48	-217,83	-263,55	29,24	-91,49	-154,36	87,15	179,44	259,58	187,13	120,24	6,86	5,93	4,53
24	108,86	170,07	93,54	23,38	-86,73	146,91	-226,56	-273,38	41,56	-96,87	-165,84	91,35	192,06	249,94	186,65	105,35	7,05	6,11	4,47
25	85,52	120,18	86,31	32,90	-29,11	138,67	-175,54	-202,09	25,63	-74,01	-115,53	84,31	137,20	208,44	172,97	113,04	6,55	5,75	4,30
26	90,16	129,28	87,96	37,11	-37,66	146,97	-186,58	-217,83	34,06	-78,09	-124,63	85,87	147,07	223,69	180,18	112,92	6,71	5,86	4,36
27	95,91	139,07	94,61	42,79	-50,90	154,91	-196,41	-231,87	39,73	-83,20	-134,30	92,64	157,98	239,20	180,97	115,17	6,91	6,01	4,38
28	101,93	155,84	93,78	36,62	-61,77	148,62	-205,63	-250,67	43,64	-88,41	-151,06	91,76	175,03	242,25	188,90	104,98	7,12	6,19	4,40
29	98,99	134,29	100,43	22,22	-35,40	170,84	-195,25	-220,40	32,04	-87,65	-128,68	97,88	155,69	217,47	185,00	138,79	6,78	6,20	4,74
30	102,80	143,23	97,41	31,92	-49,07	164,43	-206,97	-239,62	38,88	-90,72	-137,88	94,77	165,05	238,89	190,55	125,55	6,95	6,22	4,74

Tabela A1 – Continuação

31	108,61	154,87	97,48	27,89	-60,30	162,54	-214,66	-254,94	42,05	-95,94	-149,64	94,87	177,76	242,55	194,64	120,48	7,13	6,32	4,73
32	117,01	166,26	99,03	29,97	-65,86	166,69	-234,86	-272,40	46,94	-103,33	-160,70	96,44	191,05	264,83	206,54	119,75	7,41	6,53	4,75
33	83,17	125,48	91,08	46,45	-37,41	176,03	-190,86	-212,22	32,84	-65,53	-120,31	88,27	137,00	237,30	174,80	143,19	7,16	5,97	4,74
34	86,20	135,95	94,20	46,81	-50,78	181,64	-213,87	-225,28	35,16	-68,25	-131,11	91,33	147,81	260,68	174,50	146,48	7,26	6,00	4,80
35	91,19	149,15	99,14	38,57	-68,24	183,29	-223,27	-245,97	36,32	-72,90	-144,28	96,37	161,65	261,84	177,73	146,97	7,40	6,15	4,82
36	96,27	162,10	104,58	38,51	-75,13	199,95	-226,26	-279,48	40,77	-77,29	-156,79	101,79	174,81	264,77	204,35	159,18	7,58	6,41	4,90
37	85,11	129,12	91,59	33,39	-42,48	175,84	-202,76	-222,66	25,88	-67,66	-123,76	88,85	141,05	236,15	180,18	149,96	7,19	6,07	4,72
38	89,24	138,80	97,54	36,13	-53,34	175,29	-215,03	-245,67	26,98	-71,44	-133,40	94,76	151,33	251,16	192,32	148,32	7,31	6,19	4,80
39	94,17	153,38	103,31	48,16	-53,59	185,61	-225,77	-275,27	28,75	-75,57	-147,77	100,37	165,97	273,93	221,68	156,86	7,50	6,41	4,95
40	99,07	164,71	108,17	35,10	-72,51	184,02	-227,23	-277,34	34,85	-80,04	-159,13	105,32	178,13	262,33	204,83	149,17	7,64	6,52	4,97
41	86,36	129,67	107,88	39,06	-45,84	177,43	-200,56	-235,66	43,33	-69,74	-123,77	105,50	142,07	239,62	189,82	134,09	7,14	6,22	4,75
42	90,46	140,40	112,18	49,38	-53,28	186,77	-216,49	-265,75	44,25	-73,10	-134,37	109,47	152,97	265,87	212,46	142,52	7,30	6,38	4,95
43	95,17	152,56	116,17	47,00	-68,12	190,80	-221,37	-273,68	45,10	-77,39	-146,78	113,39	165,93	268,37	205,57	145,69	7,44	6,45	5,03
44	100,68	165,42	119,75	36,99	-79,65	188,66	-227,23	-284,00	41,20	-82,28	-159,72	116,88	179,66	264,22	204,35	147,46	7,62	6,56	5,10
45	87,74	132,65	107,17	38,70	-51,39	170,35	-196,96	-235,90	34,00	-71,81	-126,67	104,58	145,62	235,66	184,51	136,35	7,10	6,27	4,84
46	91,65	142,03	111,27	39,98	-58,65	183,04	-211,43	-256,47	35,10	-74,90	-136,04	108,30	155,29	251,40	197,81	147,95	7,27	6,39	5,05
47	97,17	150,33	117,00	32,10	-69,46	185,85	-216,25	-261,78	39,37	-79,31	-144,37	114,08	164,72	248,35	192,32	146,48	7,49	6,47	5,10
48	102,42	166,43	119,49	36,74	-75,74	189,27	-223,14	-280,15	37,23	-83,93	-160,63	116,50	181,23	259,89	204,41	152,04	7,66	6,60	5,16
49	86,89	133,84	99,42	87,46	-18,49	202,58	-193,79	-228,39	23,13	-62,00	-126,21	96,29	140,61	281,25	209,90	179,44	7,80	6,67	4,98
50	90,74	144,74	102,79	89,78	-33,39	204,22	-207,28	-243,65	28,20	-64,72	-137,14	99,60	151,65	297,06	210,27	176,03	7,98	6,80	5,04
51	95,58	156,43	107,94	90,64	-46,69	207,70	-217,47	-251,95	23,38	-68,68	-149,09	104,62	164,15	308,11	205,26	184,33	8,15	6,88	5,16
52	99,69	168,42	114,46	88,01	-50,17	220,64	-227,91	-276,37	38,15	-72,40	-160,84	110,88	176,39	315,92	226,20	182,50	8,28	7,07	5,33
53	98,05	148,07	106,92	85,21	-20,02	193,24	-200,81	-238,83	23,62	-71,07	-138,91	103,75	156,04	286,01	218,81	169,62	8,22	7,16	5,08
54	102,16	157,58	113,52	85,33	-34,55	207,64	-212,04	-251,46	30,33	-74,19	-148,55	110,21	166,04	297,36	216,92	177,31	8,38	7,25	5,22
55	107,68	172,29	120,27	89,23	-45,10	219,73	-238,65	-283,69	28,08	-79,53	-163,53	116,62	181,85	327,88	238,59	191,65	8,52	7,36	5,42
56	113,55	186,43	127,65	89,66	-58,23	215,88	-243,84	-302,25	41,26	-84,91	-177,97	124,03	197,19	333,50	244,02	174,62	8,68	7,45	5,49
57	95,19	141,74	113,94	89,90	-12,51	197,39	-200,20	-237,55	35,77	-69,36	-131,57	110,59	148,73	290,10	225,04	161,62	8,07	7,26	5,24
58	100,22	152,36	121,43	114,44	-23,44	207,34	-220,95	-257,93	42,72	-73,67	-142,38	117,92	160,31	335,39	234,50	164,61	8,24	7,36	5,38
59	104,97	165,75	127,83	94,54	-40,83	217,22	-233,46	-275,21	51,09	-78,04	-156,51	124,19	174,89	328,00	234,38	166,14	8,38	7,39	5,50
60	110,60	178,30	135,50	92,59	-49,80	224,85	-238,16	-299,74	51,64	-83,69	-169,33	131,76	188,88	330,75	249,94	173,22	8,50	7,47	5,62
61	95,79	148,49	122,57	58,53	-39,49	193,73	-200,50	-248,35	49,87	-74,67	-140,17	119,13	158,82	259,03	208,86	143,86	7,75	7,00	5,37
62	101,20	157,39	127,16	72,33	-42,72	210,33	-220,03	-269,59	52,43	-79,03	-149,12	123,52	168,76	292,36	226,87	157,90	7,95	7,10	5,50
63	106,86	171,97	134,52	71,78	-60,36	218,57	-233,34	-293,52	50,42	-83,68	-164,02	130,80	184,13	305,11	233,15	168,15	8,15	7,19	5,61
64	113,44	184,88	142,30	83,86	-68,60	228,76	-245,54	-306,88	58,23	-89,20	-177,01	138,60	198,21	329,41	238,28	170,53	8,37	7,31	5,68

Tabela A2 – Características extraídas dos sinais captados para os 12 passes adicionais.

Passe	1	2	3	4	5	6	7	8	9	10	11	12
F_{x-med}	-92,96	-82,85	-104,24	-77,85	-85,32	-93,70	-72,43	-80,17	-70,72	-80,21	-80,01	-78,56
ΔF_z	91,02	93,82	95,12	113,65	112,58	124,80	151,38	147,83	150,16	190,56	189,65	158,87