

**UNESP – UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA DE BAURU
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

MAURICIO EIJI NAKAI

**AVALIAÇÃO DE MODELOS NEURAI APLICADOS NA ESTIMAÇÃO DE
PARÂMETROS DA RETIFICAÇÃO DE CERÂMICAS AVANÇADAS**

**Bauru
2012**

MAURICIO EIJI NAKAI

**AVALIAÇÃO DE MODELOS NEURAI APLICADOS NA ESTIMAÇÃO DE
PARÂMETROS DA RETIFICAÇÃO DE CERÂMICAS AVANÇADAS**

Dissertação apresentada à Faculdade de Engenharia de Bauru, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Paulo Roberto de Aguiar

**Bauru
2012**

Nakai, Mauricio Eiji.

Avaliação de modelos neurais aplicados na
estimação de parâmetros da retificação de cerâmicas
avançadas/ Mauricio Eiji Nakai, 2012

132 f.

Orientador: Prof. Dr. Paulo Roberto de Aguiar

Dissertação (Mestrado)-Universidade Estadual
Paulista. Faculdade de Engenharia, Bauru, 2012

1. Processo de Retificação. 2. RBF. 3. GRNN. 4.
ANFIS. 5. Cerâmica Avançada. I. Universidade Estadual
Paulista. Faculdade de Engenharia. II. Título.

**ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE Mestrado de MAURICIO EIJI NAKAI,
DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DO(A)
FACULDADE DE ENGENHARIA DE BAURU.**

Aos 06 dias do mês de julho do ano de 2012, às 14:30 horas, no(a) ANFITEATRO DA SEÇÃO DE PÓS-GRADUAÇÃO DA FACULDADE DE ENGENHARIA, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. PAULO ROBERTO DE AGUIAR do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. ROGÉRIO ANDRADE FLAUZINO do(a) Departamento de Engenharia Elétrica / Escola de Engenharia de São Carlos - USP, Prof. Dr. JOSE ALFREDO COVOLAN ULSON do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE Mestrado de MAURICIO EIJI NAKAI, intitulado "AVALIAÇÃO DE MODELOS NEURAI APLICADOS NA ESTIMAÇÃO DE PARÂMETROS DA RETIFICAÇÃO DE CERÂMICAS AVANÇADAS". Após a exposição, o discente foi arguido oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: Aprovado. Nada mais havendo, foi lavrada a presente ata, que, após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.


Prof. Dr. PAULO ROBERTO DE AGUIAR


Prof. Dr. ROGÉRIO ANDRADE FLAUZINO


Prof. Dr. JOSE ALFREDO COVOLAN ULSON

Dedico a minha familia que me apoiou
durantes todos esses anos de estudo.

AGRADECIMENTOS

Aos meus pais Roberto Nakai e Neusa Yoshiko Nakai por me ensinarem o caminho da persistência ao me apoiarem incondicionalmente em todas as minhas decisões e através de todo seu empenho em proporcionarem acesso à educação e ao trabalho. Ao meu irmão Renato Massaru Nakai pela amizade e companheirismo.

Ao Professor Titular Paulo Roberto de Aguiar pela confiança e orientação durante as atividades desta pesquisa.

Aos professores do Programa de Pós-Graduação em Engenharia Elétrica e Engenharia Mecânica e do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Bauru – UNESP – pela inestimável formação profissional.

Aos funcionários da Seção de Pós Graduação, Célia Cristina do Espírito Santo Graminha, Gleison Raphael de Andrade e Gustavo de Oliveira Rodrigues.

Aos meus amigos do curso de mestrado Cesar Henrique Rossinoli Martins, Daniela Fernanda Grizzo Moia, Hildo Guillard Junior, Marcelo Marchi e Thiago Matheus Gerônimo pelo companheirismo e pelas contribuições agregadas a este trabalho.

A mente que se abre a uma nova ideia
jamais volta ao seu tamanho original.

- Albert Einstein.

RESUMO

Cada vez mais se observa a substituição de peças metálicas por peças cerâmicas devido às suas excelentes propriedades físicas, químicas e mecânicas. No entanto, muitas destas características que fazem a cerâmica tão atrativa também dificultam a sua fabricação por métodos tradicionais de usinagem. Esse estudo teve como objetivo o desenvolvimento de modelos neurais baseados nos sinais de emissão acústica (EA) e potência de corte para estimar os valores de rugosidades da peça bem como estimar o desgaste do rebolo durante o processo de retificação de cerâmicas avançadas. Para os ensaios foi utilizada uma máquina retificadora tangencial plana com rebolo diamantado e corpos de prova de cerâmica Alumina. Foram definidas três condições de cortes com profundidades de corte de 120 μ m, 70 μ m e 20 μ m, velocidade do rebolo de 35m/s e velocidade da mesa de 2,3m/s. Foram utilizados quatro modelos neurais, Redes Neurais Perceptron Múltiplas Camadas (MLP), Redes Neurais de Função de Base Radial (RBF), Redes Neurais de Regressão Generalizada (GRNN) e o Sistema de Inferência Adaptável Neuro-Fuzzy (ANFIS). Para melhor comparação entre os desempenhos dos modelos neurais utilizados no estudo foi desenvolvido um algoritmo para executar o treinamento de todas as combinações possíveis de entradas, assim como suas características, tais como a quantidade de neurônios, a quantidade de camadas e o espraçamento (define o tamanho do agrupamento). Os resultados mostraram um ótimo desempenho das redes neurais empregadas. Os erros obtidos foram menores que 0,5% para rugosidade média aritmética e menores que 4% para o desgaste da ferramenta. Os modelos neurais propostos satisfazem as necessidades da estimação da rugosidade bem como do desgaste da ferramenta, viabilizando a implementação futura em um hardware dedicado.

Palavras chave: processo de retificação, RBF, GRNN, ANFIS, cerâmica avançada.

ABSTRACT

Metal parts have increasingly been replaced by ceramics due to its excellent physical, chemical and mechanical characteristics. However, many of these characteristics that make advanced ceramics so attractive also make it difficult to manufacture by traditional machining methods. This study aimed to develop neural models based on signals of acoustic emission (AE) and cutting power as well as statistics derived from them to estimate the workpiece surface roughness and wear of the grinding wheel during the grinding of ceramics. A surface grinding machine with a diamond grinding wheel and alumina ceramic workpieces were used in the experimental tests. Three grinding conditions were applied with depths of cut of 120 μ m, 70 μ m and 20 μ m, grinding wheel speed of 35m/s and table speed of 2.3m/s. Four neural models were used in this work by using Multilayer Perceptron Neural Networks (MLP), Radial Basis Function Neural Networks (RBF), General Regression Neural Networks (GRNN) and Adaptive Neuro-Fuzzy Inference System (ANFIS). An algorithm was developed to train all possible combinations of inputs and other characteristics such as the number of neurons, number of layer and spread in order to better compare the performances of the neural models used in this study. The results showed a good performance of the neural network models employed. The errors obtained were lower than 0.5% for the average surface roughness and lower than 4% for the tool wear. The neural models proposed meet the needs of the estimation of surface roughness and tool wear, enabling a future implementation on dedicated hardware.

Keywords: grinding, RBF, GRNN, ANFIS, advanced ceramics.

SUMÁRIO

Capítulo 1 - INTRODUÇÃO.....	1
1.1 MOTIVAÇÃO	1
1.2 OBJETIVO	2
1.3 PUBLICAÇÕES OBTIDAS	2
Capítulo 2 - REVISÃO BIBLIOGRÁFICA	4
2.1 O PROCESSO DE RETIFICAÇÃO.....	4
2.2 RETIFICAÇÃO DE CERÂMICAS	5
2.3 RUGOSIDADE	7
2.3.1 Valores de Rugosidade Média Aritmética em Manufatura	10
2.4 DESGASTE DA FERRAMENTA	10
2.5 MONITORAMENTO DO PROCESSO DE RETIFICAÇÃO.....	12
2.6 EMISSÃO ACÚSTICA	13
2.7 POTÊNCIA DE CORTE	15
2.8 PROCESSAMENTO DE SINAIS.....	15
2.8.1 Valor Eficaz de um Sinal (RMS).....	16
2.8.2 Média e Desvio Padrão	16
2.8.3 Parâmetro DPO	18
2.9 REDES NEURAIS	18
2.9.1 Redes Neurais Perceptron de Múltiplas Camadas (MLP)	19
2.9.2 Redes Neurais de Bases Radiais (RBF).....	23
2.9.3 Redes Neurais de Regressão generalizada (GRNN).....	26
2.9.4 Sistema de Inferência Neuro Fuzzy Adaptativo (ANFIS).....	29
Capítulo 3 - MATERIAIS E MÉTODOS	32
3.1 MONTAGEM DO BANCO DE ENSAIO	32
3.1.1 PARÂMETROS CONSTANTES DE ENSAIOS E CONFIGURAÇÃO DO BANCO DE ENSAIOS	33
3.1.2 Módulo de Emissão Acústica	35
3.1.3 Módulo de Potência	36
3.1.4 Placa de Aquisição de Dados.....	37
3.1.5 Rugosímetro.....	37
3.1.6 Impressão e Medição do Desgaste.....	38
3.2 PROCEDIMENTO DOS ENSAIOS	41
3.3 PROCESSAMENTO DOS SINAIS DE EMISSÃO ACÚSTICA E DA POTÊNCIA ELÉTRICA	42

3.4	INTERPOLAÇÃO DOS VALORES DE RUGOSIDADE DA PEÇA E DESGASTE DE FERRAMENTA	45
3.5	MODELOS NEURAIIS	45
3.5.1	Redes Neurais Perceptron de Múltiplas Camadas (MLP)	47
3.5.2	Redes Neurais de Bases Radiais (RBF).....	50
3.5.3	Redes Neurais de Regressão generalizada (GRNN).....	52
3.5.4	Sistema de Inferência Neuro Fuzzy Adaptativo (ANFIS)	54
Capítulo 4 - RESULTADOS E DISCUSSÕES.....		56
4.1	PROCESSAMENTO DO SINAL DE ENTRADA.....	56
4.2	RESULTADOS DA INTERPOLAÇÃO DAS CURVAS DE RUGOSIDADE E DESGASTE DIAMETRAL DO REBOLO	60
4.3	MODELOS NEURAIIS	63
4.3.1	Variação do Grupo de Entradas Para a Estimação do Desgaste da Ferramenta.....	64
4.3.2	Variação do Grupo de Entrada Para a Estimação da Rugosidade da Peça	74
4.3.3	Comparação entre as melhores redes e os tipos de modelos neurais.....	84
Capítulo 5 – CONCLUSÃO		89
5.1	Sugestão para os próximos trabalhos.....	91
Referências		92
Anexo I – Norma DIN 4766.....		100
Anexo II – Algoritmo - Modelo neural MLP		101
Anexo III – Algoritmo - Modelo Neural RBF.....		106
Anexo IV – Algoritmo - Modelo Neural GRNN.....		109
Anexo V – Algoritmo - Modelo ANFIS.....		112

LISTA DE ILUSTRAÇÕES

Figura 1 – Rugosidade Média Aritmética (adaptado de MALKIN, 1989).....	8
Figura 2 - Relação entre a rugosidade e o número de peças usinadas (Adaptado de KWAK; HA, 2004)	10
Figura 3 - Mecanismo de desgaste do rebolo: A- desgaste por atrito, B – fratura do grão abrasivo e C – fratura do ligante (modificado de MALKIN, 1989)	12
Figura 4 - Fontes de emissão acústica em retificação (KARPUSCHEWSKI; WEHMEIER; INASAKI, 2000).....	14
Figura 5 – Camadas da Rede Neural de Função de Base Radial (DING et al., 2010)	24
Figura 6 - Problema classe 2 com apenas um agrupamento e para backpropagations com usando 4 neurônios escondidos (MEHROTRA; MOHAN, C. K.; RANKA, 1997)	26
Figura 7 – Camadas da Rede Neural de Regressão Generalizada (DING <i>et al.</i> , 2010)	28
Figura 8 - Estrutura de um modelo ANFIS para duas variáveis de entrada e duas regras	30
Figura 9 - Configuração do banco de ensaios	35
Figura 10 – Configuração da medição de rugosidade média (Ra)	38
Figura 11 – Método de impressão do perfil da face do rebolo	39
Figura 12 – Configuração do sistema para medição dos perfis (a) e resultado típico das medições realizadas (b).....	40
Figura 13 - Sinal adquirido à profundidade de 120µm ainda sem o processamento digital	43
Figura 14 – Sinal de potência elétrica adquirido à profundidade de 120µm sem a o processamento digital	43
Figura 15 - Uma passada isolada da emissão acústica da retificação com profundidade de 120µm.....	44
Figura 16 – Processo de obtenção dos Modelos Neurais.	47
Figura 17 - Algoritmo para Automatizar o Processo de Treinamento dos modelos Neurais MLP	50
Figura 18 - Algoritmo para Automatizar o Processo de Treinamento dos modelos Neurais RBF.....	52
Figura 19 - Algoritmo para Automatizar o Processo de Treinamento dos modelos Neurais GRNN	53
Figura 20 - Algoritmo para Automatizar o Processo de Treinamento dos modelos Neurais ANFIS.....	55

Figura 21 - Média da emissão acústica em função do volume de material removido.....	57
Figura 22 - Média da potência elétrica em função do volume de material removido	57
Figura 23 - Desvio padrão da emissão acústica em função do volume de material removido.....	58
Figura 24 - Desvio padrão da potência elétrica em em função do volume de material removido	59
Figura 25 - Estatística DPO em relação ao volume de material removido	59
Figura 26 – Curvas ajustadas para a rugosidade em função do volume de material removido.....	61
Figura 27 – Curvas ajustadas para o desgaste em função do volume de material removido.	63
Figura 28 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 120µm, modelo neural MLP	65
Figura 29 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 70µm, modelo neural MLP	66
Figura 30 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 20µm, modelo neural MLP	66
Figura 31 – Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 120µm, modelo neural RBF	67
Figura 32 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 70µm, modelo neural RBF	68
Figura 33 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 20µm, modelo neural RBF	68
Figura 34 - Erro e desvio padrão do erro para o desgaste da ferramenta o ensaio de 120µm, modelo neural GRNN	69
Figura 35 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 70µm, modelo neural GRNN.....	70
Figura 36 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 20µm, modelo neural GRNN.....	71
Figura 37 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 120µm, modelo neural ANFIS.	72
Figura 38 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 70µm, modelo neural ANFIS	73
Figura 39 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 20µm, modelo neural ANFIS	74
Figura 40 – Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 120µm, modelo neural MLP.....	75

Figura 41 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça o ensaio de 70 μ m, modelo neural MLP	76
Figura 42 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 20 μ m, modelo neural MLP	76
Figura 43 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 120 μ m, modelo neural RBF	77
Figura 44 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 70 μ m, modelo neural RBF	78
Figura 45 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 20 μ m, modelo neural RBF	79
Figura 46 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 120 μ m, modelo neural GRNN.....	80
Figura 47 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 70 μ m, modelo neural GRNN.....	80
Figura 48 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 20 μ m, modelo neural GRNN.....	81
Figura 49 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça o ensaio de 120 μ m, modelo neural ANFIS.....	82
Figura 50 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça o ensaio de 70 μ m, modelo neural ANFIS.....	83
Figura 51 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 20 μ m, modelo neural ANFIS	83
Figura 87 - Valores de R _a para diferentes processos de fabricação (Adaptado da Norma DIN 4766).....	100

LISTA DE TABELAS

Tabela 1 - Aplicações de cerâmica avançada retirado de (RAHAMAN, 2003).....	6
Tabela 2 – Propriedade mecânica dos corpos de prova de cerâmica (Prof. Carlos Alberto Fortulan – EESC – USP)	33
Tabela 3 – Dimensões e características da ferramenta de corte	33
Tabela 4 – Configuração dos parâmetros de retificação.....	34
Tabela 5 – Configurações do módulo de EA.....	36
Tabela 6 – Configurações do módulo de potência	36
Tabela 7 – Configurações da placa de aquisição	37
Tabela 8 – Configuração do rugosímetro para medição de rugosidade média (Ra).....	38
Tabela 9 – Configuração do rugosímetro para medição do desgaste	40
Tabela 10 – Cálculo da espessura equivalente de corte (h_{eq})	41
Tabela 11 – Resumo do Procedimento e Divisões dos Ensaios	42
Tabela 12 - Configuração dos conjuntos de entrada para os modelos neurais	46
Tabela 13 - Características do modelo neural MLP	48
Tabela 14 – Descrição do algoritmo de treinamento.....	48
Tabela 15 - Distribuição de neurônios em cada camada	49
Tabela 16 - Descrição do algoritmo de treinamento.....	51
Tabela 17 - Descrição do algoritmo de treinamento.....	53
Tabela 18 - Características do modelo neural ANFIS	54
Tabela 19 – Coeficientes estatísticos de ajuste de curvas de rugosidade	61
Tabela 20 – Coeficientes estatísticos de ajuste de curvas de rugosidade	63
Tabela 21 – Configurações das melhores redes para a rede neural MLP	84
Tabela 22 – Configurações das melhores redes para a rede neural RBF	85
Tabela 23 – Configurações das melhores redes para a rede neural GRNN.....	85
Tabela 24 – Configurações das melhores redes para o sistema ANFIS	86
Tabela 25 – Comparação entre os tipos de modelos neurais estudados	86
Tabela 26 – Erros máximos (% e micra) de estimação dos melhores modelos.....	87
Tabela 27 - Tempo de treinamento total e a média por configuração para os modelos neurais....	88

LISTA DE ABREVIATURAS E SIGLAS

<i>R_a</i> : rugosidade média aritmética.	<i>μm</i>
<i>R_q</i> : rugosidade média quadrática.	<i>μm</i>
<i>R_t</i> : máxima distância entre pico a vale.	<i>μm</i>
<i>Sm</i> : média das distâncias entre saliências.	<i>μm</i>
<i>tp</i> : fração de contato.	
<i>G</i> : taxa de material removido em relação ao desgaste do rebolo.	
<i>Z_w</i> : volume de material removido.	<i>μm³</i>
<i>Z_s</i> : volume de rebolo gasto.	<i>μm³</i>
<i>RMS</i> : valor médio quadrático (root mean square).	
<i>σ</i> : desvio padrão.	
<i>s</i> : desvio padrão populacional.	
<i>EA</i> : emissão acústica.	<i>V</i>
<i>POT</i> : potência de corte.	<i>W</i>
<i>mediaEA</i> : média do sinal RMS de emissão acústica.	<i>V</i>
<i>stdEA</i> : desvio do sinal RMS de emissão acústica.	<i>V</i>
<i>mediaPot</i> : média do sinal de potência.	<i>W</i>
<i>stdPot</i> : desvio do sinal de potência.	<i>W</i>
<i>MLP</i> : perceptron de múltiplas camadas.	
<i>MSE</i> : erro médio quadrático (mean square error)	
<i>RBF</i> : função de base radial.	
<i>GRNN</i> : rede neural de regressão generalizada.	
<i>ANFIS</i> : sistema de inferência neuro fuzzy adaptativo.	
<i>Lc</i> : comprimento do contato.	
<i>Ln</i> : altura máxima.	
<i>Vh</i> : ganho horizontal.	
<i>Vv</i> : ganho vertical.	
<i>v_w</i> : Velocidade de avanço da peça	<i>m/s.</i>
<i>v_s</i> : Velocidade de corte	<i>m/s.</i>
<i>a</i> : profundidade de corte	<i>μm.</i>
<i>v_c</i> : Velocidade do fluido refrigerante	<i>m/s.</i>
<i>heq</i> : espessura equivalente de corte	<i>μm.</i>

CAPITULO 1 - INTRODUÇÃO

1.1 MOTIVAÇÃO

Devido à baixa densidade, superior resistência ao desgaste e a corrosão, resistência a altas temperaturas, as cerâmicas estruturais avançadas, tais como o óxido de alumínio, nitreto de silício e a zircônia estão sendo cada vez mais utilizados na engenharia e na medicina. Na engenharia são utilizadas na produção de peças como, por exemplo, em rolamentos, vedação para bombas hidráulicas, como material adiabático de catalizadores, válvulas, rotores e ferramentas de corte, na medicina como juntas artificiais (ALLOR; JAHANMIR, 1996), dentes e ossos (CHANG; KUO, 2007).

A retificação é um dos estágios mais importantes do processo de usinagem da cerâmica avançada, muito complexo e envolve o contato com um grande número de partículas abrasivas com a superfície da peça. A usinagem permite um controle preciso das dimensões e um ótimo acabamento, mas requer a habilidade por parte do operador da máquina (BIANCHI *et al.*, 2003).

O processo de retificação é de grande importância na cadeia produtiva, pois influencia diretamente na rugosidade que é um fator essencial, utilizado para inspeção em várias aplicações industriais, como a produção e processamento de metais, semicondutores, cerâmicas, papel e plástico (DHANASEKAR *et al.*, 2008).

Além da importância da microtopografia da superfície, esta medição in-situ ainda não foi resolvida adequadamente. Ainda hoje, as medidas de rugosidade são realizadas com hastes de prova e perfilômetros óticos (DHANASEKAR *et al.*, 2008; WHITEHOUSE, 2010), portando sua aquisição constante torna-se inviável em uma linha de produção.

Outro fator importante no processo de retificação é o seu custo, mesmo a retificação com rebolo diamantado satisfazendo tanto a precisão dimensional quanto ao acabamento, o seu custo ainda é alto, variando de 60 a 90% do custo total no final do processo (KONIG, 1990; SAMANT; DAHOTRE, 2009). Portanto, qualquer erro nesse processo devido à parada da máquina para a medição de rugosidade pode acarretar em um prejuízo com a perda da peça ou de suas especificações.

Um dos modos de se diminuir a quantidade de paradas da máquina assim como as chances de erro no processo é a estimação da rugosidade através do monitoramento dos sinais provenientes do processo de retificação. Voltado à necessidade de monitoramento e melhora

no processo de retificação, WEBSTER, DONG e LINDSAY (1996) realizaram estudos com sinais de emissão acústica provenientes da retificação, constatando que o sinal de emissão acústica representa com confiabilidade a existência de falhas na superfície da peça e do rebolo, viabilizando sua utilização em mais aplicações.

A investigação do desgaste é essencial para uma avaliação qualitativa da capacidade de rebolo. Segundo FATHIMA *et al.* (2003) o desgaste do rebolo é um processo extremamente complexo que culmina em numerosos eventos de desgaste entre cada simples grão abrasivos da ferramenta de corte e a peça retificada.

O rápido embotamento e desgaste dos diamantes abrasivos da superfície do rebolo podem resultar em frequentes dressagens e, portanto, diminui a vida útil da ferramenta.(LIANG, Z. *et al.*, 2012)

1.2 OBJETIVO

Desenvolvimento de modelos neurais baseados nos sinais de emissão acústica (EA) e potência de corte para estimar os valores de rugosidades da peça e o desgaste do rebolo para o processo de retificação tangencial plana. Para o estudo foram utilizados quatro modelos: rede neural perceptron de múltiplas camadas (MLP), a rede neural de função de base radial (RBF), a rede neural de regressão generalizada (GRNN), e o sistema de inferência neuro-fuzzy adaptativo (ANFIS). Para o treinamento desses modelos neurais foram empregadas estatísticas baseadas nos sinais de emissão acústica e potência de corte do processo de retificação tangencial plana.

1.3 PUBLICAÇÕES OBTIDAS

- ❖ NAKAI, M. E., MARCELINO, A., GUILARDI JR, H., AGUIAR, P. R., BIANCHI, C. E. Modelos Neurais na Estimação da Rugosidade e do Desgaste da Ferramenta em Retificação In: Congresso Nacional de Engenharia Mecânica - CONEM 2012, 2012, São Luís, CONEM2012-0879.
- ❖ NAKAI, M. E.; GUILARDI Jr, H.; SPADOTTO, M. M.; AGUIAR, P. R.; BIANCHI, E. C. ANFIS APPLIED TO THE PREDICTION OF SURFACE ROUGHNESS IN GRINDING OF ADVANCED CERAMICS. In: IASTED Conference on Artificial Intelligence and Soft Computing, 2011, Hersonissos - Creta. v. 1. p. 329-334.

- ❖ NAKAI, M. E.; LUZIA, R. F.; MARCHI, M.; AGUIAR, P. R.; BIANCHI, E. C. DIGITAL SIGNAL PROCESSOR AND MULTI-SENSOR IN MONITORING OF DRESSING OPERATION. In: 21st Brazilian Congress of Mechanical Engineering, 2011, Natal. v. 1. p. 1-10.

- ❖ NAKAI, M. E.; MARTINS, C. H. R.; LUZIA, R. F.; MARCHI, M.; AGUIAR, P. R.; BIANCHI, C. E.. MONITORAMENTO DA OPERAÇÃO DE DRESSAGEM BASEADO EM CONTROLADOR DIGITAL DE SINAIS. In: X Conferência Brasileira de Dinâmica, Controle e Aplicações (DINCON 2011), 2011, Águas de Lindóia, SP.

- ❖ MARCHI, M.; LUZIA, R. F.; NAKAI, M. E.; AGUIAR, P. R.; BIANCHI, E. C.. HARDWARE DSPIC NO MONITORAMENTO E DETECÇÃO DE DANO TÉRMICO EM PROCESSOS DE RETIFICAÇÃO. In: X Congresso Iberoamericano de Engenharia Mecânica (CIBEM 10), 2011, Porto. v. 1. p. 3335-3345.

CAPITULO 2 - REVISÃO BIBLIOGRÁFICA

2.1 O PROCESSO DE RETIFICAÇÃO

A retificação é um processo de usinagem que utiliza um rebolo como ferramenta, o qual consiste de grãos abrasivos unidos por um material ligante. As arestas dos grãos da superfície do rebolo agem como ferramentas de micro corte que de forma mais ou menos aleatória entram em contato com o material a ser cortado (MALKIN, S., 1989).

O processo de retificação, comparado com outros processos de corte tem características únicas da ferramenta de corte e da máquina. O rebolo consiste em um material abrasivo espaçado aleatoriamente e, dessa forma, vários fatores podem resultar em um mau funcionamento no processo de retificação. Estes fatores são qualitativamente relacionados e as suas interações ainda não estão completamente esclarecidas (KWAK; HA, 2004).

O controle do processo de retificação é vital para aumentar o desempenho da ferramenta em termos de acabamento superficial, tolerâncias requeridas e ciclo de operações (LIANG, S. Y.; HECKER; LANDERS, 2004). Tendo em vista uma efetiva redução de custos, juntamente com o aumento da qualidade das peças produzidas, a aplicação de sistemas mais inteligentes em ambientes industriais e, portanto, o controle dos danos causados no processo é crucial e de interesse direto de todos os setores dependentes desse processo.

A retificação automática e inteligente é utilizada por indústrias para a produção de peças com alta qualidade de acabamento e geometria. A rugosidade é um dos fatores mais importantes para se avaliar a qualidade da peça durante o processo de acabamento, pois a qualidade da superfície afeta as características funcionais da peça, tais como a resistência à fratura, fadiga e o atrito (SAMHOURI; SURGENOR, 2005).

O monitoramento inteligente e o controle do processo de retificação e a identificação da rugosidade da peça tem três importantes funções: (i) detectar problemas na rugosidade da peça que pode ocorrer durante o processo de retificação, (ii) prover informação para otimizar e controlar o processo em tempo real, (iii) contribui para estabelecer um banco de dados, que é necessário na determinação das melhores condições de operação (SAMHOURI; SURGENOR, 2005).

Muitos dos fatores que afetam as tolerâncias dimensionais também afetam tolerâncias de forma. Contudo os erros de forma mais significativos são usualmente associados com desgaste excessivo do rebolo, especialmente quando se retifica formas em seções transversais

com canais ou quinas. Melhores formas de controle geralmente necessitam de um rebolo de baixo-desgaste, mas com isso é esperado maiores forças (MALKIN, S., 1989).

2.2 RETIFICAÇÃO DE CERÂMICAS

A resistência a altas temperaturas, maior resistência ao desgaste, elevada dureza, baixa condutividade térmica e elétrica, e estabilidade química são fatores característicos na maior parte das cerâmicas. Muitas destas características que fazem a cerâmica tão atrativa também dificultam a sua fabricação por métodos tradicionais de usinagem (SAMANT; DAHOTRE, 2009).

Cerâmicas, especialmente cerâmicas estruturais, são extremamente difíceis de usar devido a sua dureza e fragilidade. A retificação se tornou o principal processo usado na retificação cerâmica. No entanto, uma série de problemas são encontrados, como baixa precisão e remoção de material devido à deflexão da máquina e degradação devido a danos causados no processo (ZHANG, B. *et al.*, 2000)

A cerâmica cobre uma grande variedade de materiais, e são divididas inicialmente em duas categorias, a cerâmica tradicional e a cerâmica avançada. A cerâmica tradicional engloba os materiais desenvolvidos desde o início das civilizações como, por exemplo, cerâmica de revestimentos, como ladrilhos, azulejos e também potes, vasos, tijolos e outros materiais que não exigem requisitos tão elevados e específicos (RAHAMAN, 2003).

A Tabela 1 apresenta as principais cerâmicas avançadas e suas áreas de aplicação e sua composição.

As cerâmicas avançadas vêm sendo estudadas nos últimos 50 anos, e são utilizadas em aplicações elétricas, magnéticas, eletrônicas, óticas (também referida como cerâmica funcional), térmicas (também referida como cerâmica estrutural) utilizadas em ambientes com elevadas temperaturas (RAHAMAN, 2003).

Muitos defeitos como fissuras, alta rugosidade e ranhuras podem ocorrer durante o processo de sinterização da cerâmica, resultando diretamente na redução da qualidade mecânica da sua estrutura. A retificação remove essa camada defeituosa aumentando, dessa forma, as propriedades da peça (ZHENG, 2000, FISCHER; WEISS; TELLE, 2008).

No entanto, devido à sua alta fragilidade, os componentes cerâmicos invariavelmente sofrem danos, como trincas superficiais ou subsuperficiais durante o processo de remoção de material, resultando em perda de resistência mecânica (MAYER JR; FANG, G. P., 1995; STRAKNA *et al.*, 1996; AYDIN; BRISCOE; SANLITURK, 1997).

Tabela 1 - Aplicações de cerâmica avançada retirado de (RAHAMAN, 2003)

Área de Aplicação	Aplicação
Elétrica	Materiais isolantes (Al ₂ O ₃ , BeO, MgO)
	Materiais ferroelétricos (BaTiO ₃ , SrTiO ₃)
	Materiais piezoelétricos (PZT)
	Materiais semicondutores (BaTiO ₃ , SiC, ZnO-Bi ₂ O ₃ , V ₂ O ₅)
	Materiais ion-condutores (β-Al ₂ O ₃ , ZrO ₂)
Magnético	Soft Ferrite
	Hard Ferrite
Ótica	Alumina translúcida
	Mg-Al translúcida
	Y ₂ O ₃ -ThO ₂ translúcida
	Cerâmica PLZT
Química	Sensor de gás (ZnO, Fe ₂ O ₃ , SnO ₂)
	Sensor de humidades (MgCr ₂ O ₄ -TiO ₂)
	Catalizadores orgânicos
	Eletrodos (titanatos, sulfetos, boretos)
Térmica	ZrO ₂ , TiO ₂
Mecânica	Ferramentas de corte (Al ₂ O ₃ , TiC, TiN, entre outros)
	Materiais resistentes ao desgaste (Al ₂ O ₃ , ZrO ₂)
	Materiais resistentes à temperatura (SiC, Al ₂ O ₃ , Si ₃ N ₄ , entre outros)
Biológica	Cerâmica alumina (implantes, hidroxiapatita, bioglass)
Nuclear	Combustíveis nucleares (UO ₂ , UO ₂ -PuO ₂)
	Materiais de cobrimento (C, SiC, B ₄ C)
	Materiais de proteção (SiC, Al ₂ O ₃ , C, B ₄ C)

TONSHOFF *et al.*, 1998 declaram que o custo envolvido na retificação da cerâmica avançada é a principal parcela do custo final, e dessa forma, a viabilidade econômica da cerâmica avançada depende diretamente da eficiência do processo de retificação. Portanto, a redução do custo da retificação pelo aumento da taxa de remoção de material é limitada pelo

risco imposto à superfície, que conseqüentemente pode comprometer o desempenho da peça em sua aplicação.

Como resultado da retificação de peças de cerâmicas avançadas, verificam-se diferentes tipos de danos em consequência de três mecanismos distintos de remoção de material: fratura intergranular e deslocamentos de grãos; micro fratura e formação de fragmentos de grão através de trincas intragranulares; e remoção de grandes porções de grãos, por meio de lascamentos devido à propagação de trincas transgranulares (SWAIN, 1979; XU; JAHANMIR, 1995)

2.3 RUGOSIDADE

Segundo (HECKER; LIANG, S. Y., 2003), a qualidade da superfície gerada pelo processo de retificação determina muitas características da peça, tais como tolerâncias mínimas, a eficiência da lubrificação, a vida útil da peça produzida, dentre outras. Uma superfície típica é caracterizada por caminhos de corte limpos e material escoado lateralmente (plowing) a algumas ranhuras. Entretanto, muitas outras marcas podem ser encontradas, tais como fraturas produzidas pelo efeito térmico, material transferidos de volta e crateras produzidas pela fratura do grão. Outros fatores que caracterizam uma superfície retificada são as ondulações transversais e longitudinais produzidas pela natureza aleatória do processo de retificação e pela vibração da máquina. Quando se considera todos esses fatores, uma estimativa completa da topografia da superfície se torna um problema complicado.

Ainda, segundo (HECKER; LIANG, S. Y., 2003), um parâmetro típico que tem sido usado para quantificar a qualidade da topografia de uma superfície é a rugosidade, a qual é representada pelo valor médio aritmético, R_a , o valor médio quadrático, R_q , e o valor entre o pico e vale, R_t . Em geral, a rugosidade longitudinal possui um valor menor do que a rugosidade transversal, e, portanto, a última é frequentemente usada na indústria.

A Figura 1 apresenta um esquema da rugosidade média aritmética.

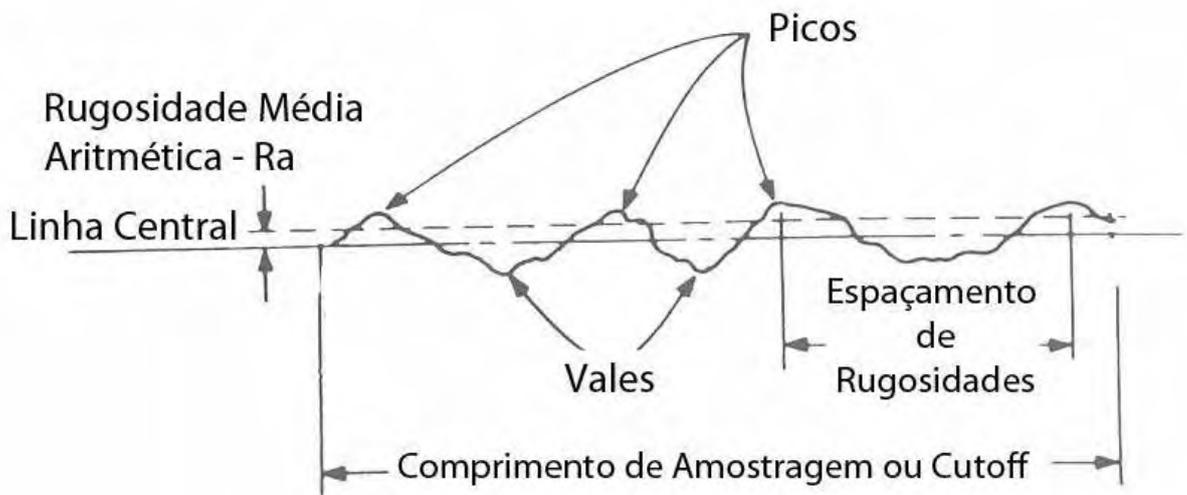


Figura 1 – Rugosidade Média Aritmética (adaptado de MALKIN, 1989)

O rugosímetro é um aparelho eletrônico amplamente empregado na indústria para verificação de superfície de peças e ferramentas (rugosidade). Assegura um alto padrão de qualidade nas medições. Os rugosímetros podem ser classificados em dois grandes grupos:

- Aparelhos que fornecem somente a leitura dos parâmetros de rugosidade (que pode ser tanto analógica quanto digital).
- Aparelhos que, além da leitura, permitem o registro, em papel, do perfil efetivo da superfície.

Os primeiros são mais empregados em linhas de produção, enquanto os segundos têm mais uso nos laboratórios, pois também apresentam um gráfico que é importante para uma análise mais profunda da textura superficial. O equipamento é composto por:

- Apalpador - Também chamado de “pick-up”, desliza sobre a superfície que será verificada, levando os sinais da agulha apalpadora, de diamante, até o amplificador.
- Unidade de acionamento - Desloca o apalpador sobre a superfície, numa velocidade constante e por uma distância desejável, mantendo-o na mesma direção.
- Amplificador - Contém a parte eletrônica principal, dotada de um indicador de leitura que recebe os sinais da agulha, amplia-os, e os calcula em função do parâmetro escolhido.

A morfologia das superfícies retificadas pode variar conforme o material e o tipo de ferramenta utilizada, e são em geral ranhuras sobrepostas causadas pela interação entre a ferramenta de corte com a peça (MALKIN, S., 1989).

A rugosidade é relevante para vários problemas fundamentais como o atrito, a deformação de contato, o aquecimento, a condução de corrente elétrica, o aperto em juntas de contato e a precisão de posicionamento (GADELMAWLA *et al.*, 2002)

O controle da rugosidade nos processos de retificação é realizada pelo gerenciamento e otimização dos processos e suas condições.

A irregularidade é gerada pela interação da topografia da superfície do rebolo com a peça sob movimentos cinemáticos impostos pela máquina. O acabamento obtido depende da maneira complexa da rugosidade do rebolo, sendo esta consequente da dressagem e do seu material, parâmetros de retificação e interações tribológicas entre a peça e pontos de corte do abrasivo (XIAO; MALKIN, S., 1996).

Por meio da condução de ensaios experimentais, (KWAK; HA, 2004) demonstraram que a escolha correta das condições de retificação é muito importante para evitar o aumento da rugosidade e a ocorrência de danos térmicos. A Figura 2 é um exemplo para mostrar o quanto um dano deteriora a rugosidade de uma superfície retificada; no eixo *y* encontram-se os valores de rugosidade média enquanto no eixo *x* apresenta a quantidade de peças retificadas; sem o processo de dressagem o rebolo fica impregnado com cavaco, diminuindo a taxa de remoção de material, podendo ocasionar a queima e, em seguida, a vibração chatter.

A superfície retificada é produzida pela ação de um número elevado de arestas de corte na superfície do rebolo. As ranhuras produzidas na superfície da peça por um único grão refletem a geometria da ponta do grão com pouco fluxo lateral do material. Assim, a avaliação da rugosidade se torna possível a partir das considerações da geometria da ponta do grão. Como o tamanho das arestas de corte na superfície do rebolo é aleatório por natureza, a rugosidade produzida durante o processo de retificação não pode ser estimada de uma forma determinística (AGARWAL; RAO, 2005).

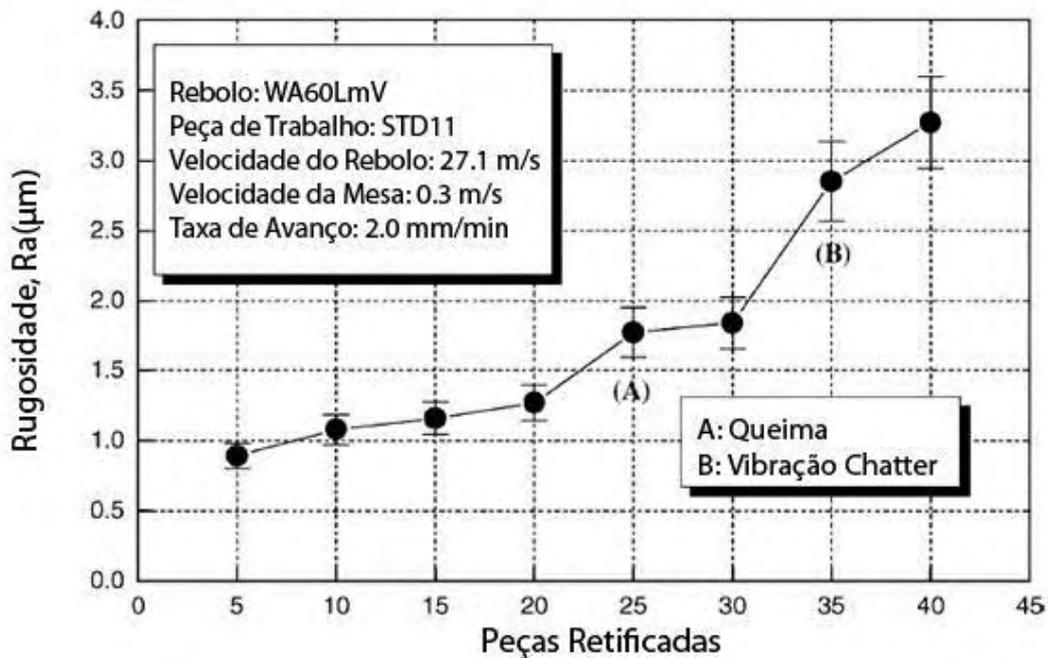


Figura 2 - Relação entre a rugosidade e o número de peças usinadas (Adaptado de KWAK; HA, 2004)

2.3.1 VALORES DE RUGOSIDADE MÉDIA ARITMÉTICA EM MANUFATURA

A norma DIN4766 (ANEXO I) estabelece valores de rugosidade mínimos e máximos normalmente obtidos, e também, valores possíveis de serem encontrados para diversos processos de usinagem. Para o processo de retificação tangencial plana os valores situam-se entre 0,4μm e 1,6μm. Entretanto, valores entre 0,1μm e 6,3μm são possíveis de serem encontrados.

2.4 DESGASTE DA FERRAMENTA

O desgaste total pode ser expresso em termos da relação G, representada pela equação 1, que é a taxa volumétrica de material removido em contraposição ao desgaste do rebolo. (MALKIN, S., 1989).

$$G = \frac{Z_w}{Z_s} \quad (1)$$

Onde:

Z_w : Volume de material removido

Z_s : Volume de rebolo gasto

Segundo (MALKIN, S., 1989), uma importante consequência do desgaste do rebolo, como indicado pela taxa G , ocorre quando a taxa de remoção é menor que a taxa de avanço, uma vez que parte do movimento de avanço corresponde à superfície desgastada após o recuo do rebolo.

O desgaste total do rebolo aumenta com o tempo de corte. Ele pode ser dividido em uma diminuição de raio e em desgaste de quina do rebolo. Se o desgaste não é compensado durante a retificação por um sistema de medição adequado, pode-se ter um erro de medida ou eventualmente surgirem vibrações na superfície da peça.

O desgaste é considerado um processo bastante complexo, resultado de diversos fenômenos que ocorrem devido ao contato entre grãos abrasivos e a peça durante o processo de retificação. O desgaste do rebolo apresenta três fases: uma alta taxa de desgaste inicial, seguida de um crescimento aproximadamente constante da taxa de desgaste e sofrendo uma aceleração elevada nesta taxa num terceiro momento (MALKIN, S., 1989).

O desgaste do rebolo pode ser classificado em três tipos: atrito do grão, fratura do grão e fratura do ligante, conforme Figura 3. Todos os tipos de desgaste ocorrem simultaneamente em maior ou menor grau. O desgaste por atrito envolve a perda de afiação dos grãos abrasivos e crescimento das áreas planas devido ao atrito com o material da peça. A fratura do grão abrasivo provoca a remoção de fragmentos, e a fratura do aglomerante resulta no desalojamento do grão abrasivo inteiro devido aos esforços de corte.

Experimentos realizados por Malkin (1989), para quantificar a contribuição de cada mecanismo de desgaste em relação ao total, revelaram que o desgaste por atrito é responsável por uma pequena fração da perda volumétrica total, enquanto que a fratura do aglomerante é responsável pela maior parte (50 – 90% de acordo com a dureza do rebolo). Também foram constatados nesses experimentos que o aumento da dureza do rebolo favorece o desgaste por fratura dos grãos abrasivos, já que estes estão mais rigidamente ancorados. Por outro lado, rebolos com uma dureza menor tendem a gerar desgastes por fratura do aglomerante.

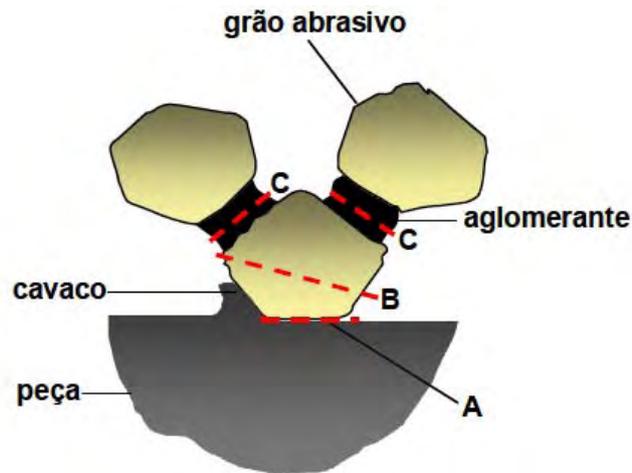


Figura 3 - Mecanismo de desgaste do rebolo: A- desgaste por atrito, B – fratura do grão abrasivo e C – fratura do ligante (modificado de MALKIN, 1989)

2.5 MONITORAMENTO DO PROCESSO DE RETIFICAÇÃO

O monitoramento deve ser capaz de detectar qualquer mau funcionamento que possa ocorrer no processo de retificação, além de formar uma base de dados com as informações sobre os parâmetros obtidos do sistema de monitoramento com o objetivo de aperfeiçoar o processo. O sistema de monitoramento possibilitará a correlação dos sinais entre a entrada e a saída do processo, estabelecendo assim um banco de dados sobre um processo específico (TÖNSHOFF; FRIEMUTH; BECKER, 2002).

A implementação de um sistema de monitoramento requer o questionamento de quais grandezas são mais adequadas para o processo a ser monitorado, o que depende de vários critérios. Primeiramente é importante conhecer os objetivos do sistema, isto é, quais as funções a serem realizadas. Devem ser consideradas as variações do processo de retificação, sendo estas de natureza interna, externa ou de superfície, o tipo de material usinado, a sensibilidade em relação à integridade da superfície e a qualidade geométrica a ser atingida.

Diversas propriedades do sistema de medição, tais como a aplicabilidade, a sensibilidade, a robustez, o comportamento durante o tempo e o tempo de resposta, são características importantes que precisam ser analisadas (TÖNSHOFF; FRIEMUTH; BECKER, 2002).

As principais grandezas utilizadas no monitoramento de processos de retificação citadas por TÖNSHOFF, FRIEMUTH e BECKER, 2002 são: força, potência, aceleração (vibração), emissão acústica e temperatura.

Para captar as informações das grandezas durante o processo são utilizados sensores. Sensores são dispositivos que mudam seu comportamento sob a ação de uma grandeza física, podendo fornecer diretamente ou indiretamente um sinal que indica esta grandeza. Quando operam diretamente, convertendo uma forma de energia em outra, são chamados transdutores. Os sensores de operação indireta alteram suas propriedades, como a resistência, a capacitância ou a indutância, sob ação de uma grandeza física, de forma proporcional (JEMIELNIAK, 2001).

Vários tipos de sensores estão disponíveis para o monitoramento de fenômenos de usinagem (KARPUSCHEWSKI; WEHMEIER; INASAKI, 2000). Os principais utilizados no monitoramento de processos de retificação citados por TÖNSHOFF, FRIEMUTH e BECKER, (2002) são de força, potência, emissão acústica, temperatura e posição.

2.6 EMISSÃO ACÚSTICA

A emissão acústica (EA) pode ser definida como ondas de tensão elástica gerada como resultado da liberação rápida de energia de deformação dentro de um material submetido a um estímulo externo, devido ao rearranjo de sua estrutura. Estas ondas de tensão produzem deslocamentos na superfície do material que podem ser detectados por um sensor piezoelétrico que transforma estes deslocamentos em sinais elétricos (DINIZ *et al.*, 1992)

A aplicação de sensores de emissão acústica tem se tornado popular em todo tipo de processo de usinagem nas últimas décadas. Uma grande variedade de sensores de emissão acústica, especialmente produzidos para propósitos de monitoramento, tem sido aplicada na indústria. Esses sensores reúnem características importantes tais como: baixo custo, fácil montagem, resistência a influências externas, e ainda são capazes de monitorar peças em rotação (MARINESCU *et al.*, 2006).

O parâmetro predominantemente estudado em pesquisas prévias usando emissão acústica tem sido o valor da raiz média quadrática (RMS) do sinal de EA filtrado sobre uma banda de frequência cuidadosamente selecionada. Este sinal tem sido um parâmetro razoável de estudo, pois o processo de retificação é muito rico em ondas sonoras, contendo, portanto, muita informação acústica disponível, sendo por isso utilizado como foco de pesquisas anteriores e atuais e também por limitações tecnológicas.

Aguiar (1997) tem demonstrado que o sinal RMS de emissão acústica e o sinal de potência de corte, combinados, podem fornecer parâmetros expressivos para a indicação da queima da peça na retificação plana. O referido pesquisador tem usado uma configuração

onde se utilizou um sensor fixo de EA acoplado próximo da peça obra e um sensor de potência elétrica do motor de acionamento do rebolo para as medidas da força de corte. Da combinação entre os sinais, obteve um parâmetro indicativo para a queima da peça, denominado DPO, o qual consistia da relação entre o desvio padrão do sinal RMS de emissão acústica e a potência média de corte por passada do rebolo. Embora para a maioria dos ensaios realizados o parâmetro denominado DPO tenha se mostrado um indicador da queima, para alguns casos não se comportou da mesma maneira.

As origens da emissão acústica no processo de retificação são decorrentes principalmente do material e suas mudanças, tais como: impacto elástico, riscamento sem remoção de cavaco, remoção de cavaco, quebra de cavaco, fratura de grão, fratura do ligante, rachaduras, indução térmica por mudanças estruturais, como mostrado na Figura 4 (DINIZ; LIU, J. J.; DORNFELD, D. A., 1992; HUNDT *et al.*, 1994; KARPUSCHEWSKI; WEHMEIER; INASAKI, 2000).

Pesquisadores vêm utilizando o sinal de emissão acústica como, por exemplo, LIAO, (2010), ROBBEN *et al.* (2010), MIN *et al.* (2011), e GIRIDHAR, VIJAYARAGHAVAN e KRISHNAMURTHY (2012).

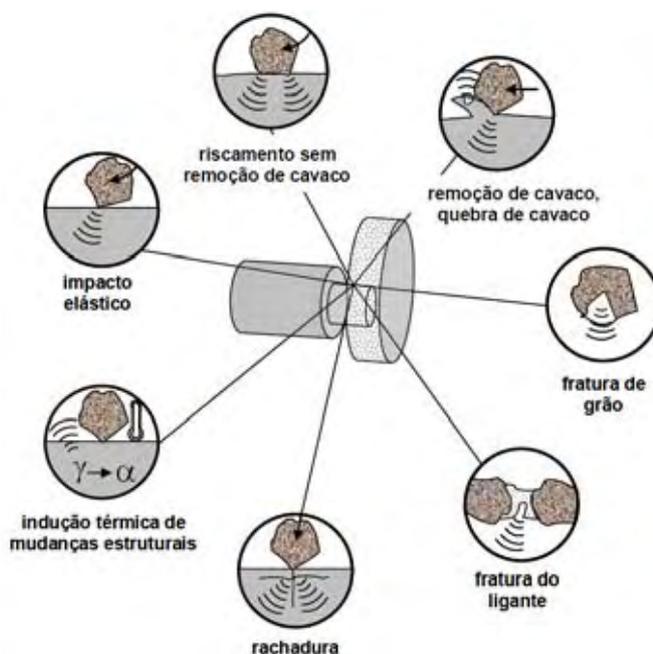


Figura 4 - Fontes de emissão acústica em retificação (KARPUSCHEWSKI; WEHMEIER; INASAKI, 2000)

2.7 POTÊNCIA DE CORTE

O consumo da potência de corte e as forças de retificação são parâmetros característicos da transferência de energia na área de contato (BRINKSMEIER; WERNER, 1992). De acordo com KWAK e HA (2004), a potência de corte tem sido usada como uma forma de monitoramento do processo de retificação. Segundo CHEN e ROWE (1996), os efeitos das condições de retificação, tais como, força e a potência de corte estão relacionados com a espessura do cavaco. Observou-se também que a força e a potência de corte estão relacionadas com a operação de dressagem e com a densidade efetiva das arestas de corte na superfície do rebolo.

Segundo OLIVEIRA e VALENTE (2004), a potência de corte é proporcional à taxa de remoção de material no processo de retificação (MALKIN *et al.*, 1980) e é obtido através da medida da corrente elétrica e da tensão do motor responsável pelo movimento do rebolo. Este método é robusto e de fácil utilização, mas é limitado pela lentidão em seu tempo de resposta. (BYRNE *et al.*, 1995).

A potência de corte obtida consiste na soma da potência estática e dinâmica. Normalmente a potência estática mantém a magnitude do sinal constante com pequenas variações, mas algumas vezes, quando ocorre uma falha, seu nível se modifica. Nos fenômenos de “Chatter” e da queima da peça, a potência dinâmica e estática tem a sua magnitude alterada significativamente em relação aos valores obtidos na da estabilidade, mencionada inicialmente. Dessa forma é possível detectar os diferentes estados do processo de retificação através do monitoramento dos sinais de potência (KWAK; HA, 2004).

2.8 PROCESSAMENTO DE SINAIS

Processamento do sinal consiste do tratamento do sinal analógico, por exemplo: amplificação, filtragem, transformações matemáticas, integração de sinais, conversão de analógico para digital, processamento do sinal digital.

Além da medição, um sistema de aquisição de dados deve garantir a confiabilidade dos dados coletados, assegurando que o desempenho das medições seja próximo aos dados em análise. Para tanto, além dos sensores e transdutores, um sistema de aquisição de dados deve possuir elementos que analisem e validem os dados coletados. Desta forma, esses sistemas devem apresentar uma arquitetura onde os elementos se comunicam e se entendam mutuamente, interagindo entre si. Isso significa que um sinal gerado por um sensor ou

transdutor pode ser analisado pelo condicionador de sinais que tem por função entregar um novo sinal, que se relaciona com o primeiro e pode ser tratado pelo conversor analógico-digital e assim sucessivamente.

Pesquisadores como BIFANO e YI (1992), BERKOVITS e FANG (1995) e DOTTO *et al.* (2006) utilizaram técnicas de aquisição de dados e processamento de sinais em estudos relacionados ao monitoramento do processo de retificação.

2.8.1 VALOR EFICAZ DE UM SINAL (RMS)

O valor RMS (do inglês *Root Mean Square*) de um sinal puro ou bruto S pode ser expresso pela equação 2 e 3, que apresenta as formas contínua e discreta, respectivamente (NILSSON; RIEDEL, 2003).

$$S_{RMS} = \sqrt{\frac{1}{T} \int_{t_0}^{t+T} S^2(t) \cdot dt} \quad (2)$$

$$S_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N S^2(i)} \quad (3)$$

Onde:

T : intervalo do tempo para o cálculo do valor RMS;

t_0 : ponto de início de análise no tempo para cálculo do valor RMS;

N : número discreto de dados do sinal S no intervalo de tempo T ;

S : sinal puro ou bruto;

S_{RMS} : valor RMS.

2.8.2 MÉDIA E DESVIO PADRÃO

A média e o desvio padrão são respectivamente empregados para a determinação do valor médio e da dispersão de um sinal. Estas estatísticas descrevem a amplitude da distribuição, a simetria e a sua forma. Todas essas características são resumidas pelos momentos da distribuição ou derivadas. A média é calculada a partir da equação 4.

(4)

$$x_{medio} = \frac{\sum_{i=1}^n x_i}{n}$$

Onde:

x_i : valor da amostra i ;

x_{medio} : média dos valores no intervalo n .

n : tamanho da população.

O desvio padrão é comumente usado para indicar a variação em um conjunto de amostra (MORETTIN, 1999). O desvio padrão de uma população de valores é definido pela equação 5.

$$\sigma = \sqrt{\frac{(x_i - x_{medio})^2}{N}} \quad (5)$$

Onde:

x_{medio} : média da população;

N : tamanho da população;

x_i : valor da amostra i ;

σ : desvio padrão.

O valor do desvio padrão para uma amostra de população é obtido pela equação 6 (MORETTIN, 1999). Para uma amostra maior ou igual a 30 elementos, a equação 5 pode ser aplicada no lugar da equação 6.

$$s = \sqrt{\frac{\sum(x_i - x_{medio})^2}{n - 1}} \quad (6)$$

Onde:

x_{medio} : média da população;

n : tamanho da população;

s : desvio padrão populacional;

x_i : valor da amostra i ;

2.8.3 PARÂMETRO DPO

AGUIAR, BIANCHI e OLIVEIRA (2002) demonstraram que o sinal RMS de emissão acústica e o sinal da potência de corte, combinados, podem fornecer parâmetros expressivos para a indicação da queima da peça na retificação plana. Da combinação entre os sinais foi obtido um parâmetro indicativo para a queima da peça, denominado DPO, que consiste da relação entre o desvio padrão do sinal RMS de emissão acústica e a potência máxima de corte por passada do rebolo. Essa estatística é determinada pela equação (7).

$$DPO = EA_S * POT_{MAX} \quad (7)$$

Onde:

EA_S : desvio padrão do sinal RMS de emissão acústica;

POT_{MAX} : máximo valor de potência em uma passada de retificação.

Em (AGUIAR, P. R.; DOTTO; BIANCHI, 2005) a estatística DPO é utilizada com sucesso para a detecção do limiar de queima da peça no processo de retificação plana, AGUIAR et al., (2009) utilizam a estatística DPO para o monitoramento do processo de dressagem no processo de retificação plana.

2.9 REDES NEURAIS

A primeira tentativa de se compreender o funcionamento de uma rede neural biológica foi realizada pelos pesquisadores Warren S. McCulloch e Walter H. Pitts – um neurofisiologista e um matemático, respectivamente – em 1943, que criaram um modelo matemático para o funcionamento de um neurônio, onde uma soma ponderada dos estímulos de entrada foi comparada a um limite de ativação, que leva o neurônio a emitir um estímulo de saída. O modelo de McCulloch-Pitts mostrou-se capaz de realizar qualquer cálculo aritmético ou lógico (HAGAN; MENHAJ, 1994).

A rede neural artificial é definida por Kohonen como uma rede interconectada paralelamente de simples elementos, e suas organizações hierárquicas tem como objetivo de interagir com o mundo real assim como uma rede neural biológica (KOHONEN, 1988).

Os componentes básicos da rede neural são os neurônios e seus pesos. Os pesos ajustáveis correspondem a sinapses biológicas. O peso positivo representa uma excitação e o

peso negativo uma inibição. As entradas do neurônio são então pesadas por uma função de ativação que determina o valor de saída (HUANG, 1994).

A habilidade de aprendizado é a principal característica das redes neurais. No entanto, é difícil precisar a definição de aprendizado; nas redes neurais esse termo consiste em achar um conjunto apropriado de pesos que determinam a relação entre os neurônios de camadas adjacentes (KWAK; HA, 2004).

Sendo os modelos neurais eficientes para a correlação dos dados de entrada e saída, assimilação de padrões e interpolação, estes são muito utilizados no processo de usinagem como, por exemplo, DOTTO *et al.* (2006) utilizaram modelos neurais para a detecção do dano térmico; KWAK e HA (2004) empregaram modelos neurais para o diagnóstico do processo de retificação, dentre outros.

2.9.1 REDES NEURAIS PERCEPTRON DE MÚLTIPLAS CAMADAS (MLP)

O modelo perceptron e outras redes de apenas uma camada têm capacidade limitada. No entanto essas limitações podem ser superadas utilizando uma rede de múltiplas camadas *feedforward* com funções não lineares, viabilizando assim sua aplicação em diversas situações. Mas o simples aprendizado perceptron não é facilmente aplicado em uma rede de múltiplas camadas, para isso é necessária uma técnica mais poderosa de aprendizado supervisionado.

A rede *feedforward* (alimentação adiante) de múltiplas camadas consiste em neurônios conectados em camadas na direção entrada-saída em camadas adjacentes. A primeira camada é a camada de entrada, e as unidades de entrada distribuem os sinais para a camada seguinte. Nas camadas seguintes, cada neurônio soma as suas entradas e adiciona um valor de limiar junto a um peso e uma transformação não linear para produzir um sinal de saída. Esta transformação não linear é chamada função de ativação. A camada de saída utiliza uma função de ativação linear. As camadas entre as camadas de entrada e de saída recebem o nome de camadas escondidas (HU, Y. H.; HWANG, 2001).

2.9.1.1 Backpropagation

Backpropagation, ou retropropagação, é um algoritmo de treinamento utilizado em redes neurais *feedforward*. Este algoritmo foi o primeiro que possibilitou o ajuste dos pesos em redes multicamadas *feedforward*, abrindo caminho para a elaboração de redes neurais mais

genéricas. Devido a grande popularidade do método *backpropagation* seu nome é utilizado para denominar as redes que o utilizam no seu treinamento.

Uma das grandes vantagens apresentada pelo método *backpropagation* é que este possui um conjunto de equações bem definidas e explícitas para correção dos pesos da rede. Este algoritmo consiste em realizar a retropropagação do erro gerado na comparação entre a saída da rede e a saída desejada com o objetivo de minimizar o erro total da saída gerada pela rede.

O treinamento de uma rede com o uso deste algoritmo envolve três etapas: a propagação dos dados da camada de entrada para a camada de saída da rede, o cálculo e a retropropagação do erro gerado pela rede, e o ajuste dos pesos (FAUSETT, 1994). Na primeira etapa, estímulos de entrada são apresentados à rede e as ativações fluem até chegarem à camada de saída, gerando um resultado. Já na segunda e terceira etapas, o resultado obtido pela rede é comparado com a saída desejada e o erro gerado é computado para as unidades de saída. Os pesos conectados às unidades de saída são então ajustados para reduzir este erro. Em seguida, o erro da camada de saída é utilizado para derivar estimativas de erro para as unidades da(s) camada(s) oculta(s), para que o erro seja então propagado para trás até a conexão da camada de entrada.

O método *backpropagation* atualiza os pesos incrementalmente, depois de analisar cada par entrada-saída. Depois da apresentação de todos os pares entrada-saída diz-se que uma época foi concluída. Este treinamento, em geral, requer muitas épocas.

A técnica de treinamento *backpropagation* é baseada no gradiente descendente, em que os pesos são modificados na direção que corresponde ao gradiente negativo do cálculo do erro. A grande vantagem do algoritmo *backpropagation*, em relação às técnicas anteriores, é que os erros em camadas mais altas ou mais externas podem ser propagados reversamente pelos neurônios para as camadas mais baixas ou camadas internas. O gradiente desta propagação reversa de erros é utilizado para determinar o ajuste dos pesos (MEHROTRA; MOHAN, C. K.; RANKA, 1997).

2.9.1.2 Taxa de aprendizagem

A mudança dos pesos é proporcional ao gradiente negativo do erro. Essa diretriz determina a mudança relativa que ocorre em diferentes pesos em diferentes camadas e neurônios, quando uma amostra de treinamento é apresentada. Mas a exata magnitude da mudança dos pesos é especificada pela taxa de aprendizagem. Um valor muito alto levará a um aprendizado rápido, e, no entanto, poderá apresentar uma oscilação ao final do

treinamento. Por outro lado, uma taxa de aprendizado baixa implicará em um aprendizado mais demorado.

O valor da taxa de aprendizado depende da aplicação; valores entre 0,1 e 0,9 vem sendo utilizados em varias aplicações (MEHROTRA; MOHAN, C. K.; RANKA, 1997).

2.9.1.3 Momento

O treinamento com o algoritmo *backpropagation* pode direcionar a rede neural para um mínimo local, que diferente do mínimo global, não corresponde aos melhores valores dos pesos dos neurônios para um determinado treinamento. Este é um problema comum quando se tem uma “superfície de erro” irregular com uma grande quantidade de mínimos locais. Pode-se prevenir que o treinamento pare em um mínimo local fazendo o ajuste dos pesos em função do gradiente do erro médio quadrático (MSE) em uma pequena região ao invés de um gradiente preciso em somente um ponto, permitindo que os pesos se modifiquem em uma tendência de decréscimo do MSE.

O calculo das médias pode ser uma tarefa dispendiosa, um atalho sugerido por RUMELHART, HINTON e WILLIAMS (1986) é calcular os pesos da l-ésima iteração em função do peso imediatamente anterior, (l-1)-ésima iteração, resultando em um efeito de média, diminuindo drasticamente a flutuação no ajuste dos pesos em iterações consecutivas. A implementação deste método é realizada adicionando-se o termo momento a regra de atualização dos pesos, conforme equação 8.

$$\Delta w_{k,j}(t + 1) = \eta \delta_k x_j + \alpha \Delta w_{k,j}(t) \quad (8)$$

Onde $\Delta w_{k,j}(t)$ é o ajuste do peso no instante t, e α é o parametro adicional “momento”. O ajuste do peso efetivo é a média sugerida pelo gradiente atual e o ajuste usado na iteração anterior. No entanto, mudanças de peso sugeridas nos estágios iniciais podem influenciar fortemente a tendência dos futuros pesos, podendo restringir o algoritmo de treino a explorar somente uma região do espaço peso.

O uso do termo momento na atualização dos pesos introduz um parâmetro α , cujo valor ótimo depende da aplicação, sendo assim de difícil determinação *a priori*. Valores para o momento podem ser obtidos empiricamente, assim como a taxa de aprendizagem η . A obtenção de um bom valor de α resulta na redução do numero de iterações. Um valor de momento próximo à zero implica na desconsideração dos valores de ajuste obtidos

anteriormente, enquanto que, um valor próximo a 1 sugere que o erro atual tem pouco valor para o ajuste dos pesos (MEHROTRA; MOHAN, C. K.; RANKA, 1997).

2.9.1.4 Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt foi desenvolvido para resolver iterativamente problemas de minimização de funções não-lineares pelo método de mínimos quadrados. Ele é o algoritmo de otimização mais utilizado hoje em dia, superando outros algoritmos em uma grande variedade de problemas.

O método de Levenberg-Marquardt, assim como os métodos quasi-Newton, foi criado para atingir a velocidade de treinamento de métodos de segunda-ordem sem o cálculo da Hessiana. Quando a função objetivo é a soma de quadrados (caso muito comum em redes neurais), a matriz Hessiana pode ser aproximada como $H=J^T J$ e o gradiente como $g=J^T e$, onde J é a matriz Jacobiana, contendo a primeira derivada dos erros da rede em relação ao peso, e e é o vetor dos erros da rede. O Jacobiano pode ser calculado via *backpropagation* padrão, um processo muito menos complexo que o cálculo da Hessiana.

O algoritmo Levenberg-Marquardt usa a aproximação da Hessiana do mesmo modo que o método de Newton conforme equação (9).

$$w^{i+1} = w^i - (J^T J + \mu I)^{-1} J^T e \quad (9)$$

Quando o escalar μ é zero, resulta no método de Newton usando a Hessiana aproximada. Quando o escalar μ é grande, a equação resulta no gradiente descendente com passos pequenos. O método de Newton é mais rápido e mais preciso perto do erro mínimo, então, o objetivo é alterar para o método de Newton o quanto antes. Portanto, μ é decrementado depois de cada passo bem sucedido (redução na função objetivo). Quando o cálculo do Jacobiano se torna altamente proibitivo para grandes redes, o método quasi-Newton é preterido (MUÑOZ, 2009).

O algoritmo controla o valor do fator de ajuste da seguinte forma: começa-se com um valor arbitrário. Calcula-se o erro na situação atual e aplica-se a regra de atualização de pesos. Calcula-se, então, o novo erro. Caso o erro tenha aumentado, deve-se desfazer a atualização e aumentar o fator de ajuste (geralmente multiplicando-o por dez). Em seguida, deve-se recomençar a iteração novamente. Caso o erro tenha diminuído, se aceita a iteração e diminui o fator de ajuste (geralmente dividindo-o por dez).

Desta maneira, conduz-se mais na direção do gradiente quanto mais distante se estiver do ponto mínimo. Ao chegar às proximidades dele, o algoritmo de Newton (MUKHERJEE; ROUTHROY, 2012) será predominante.

Existem deficiências do algoritmo Levenberg-Marquardt. A primeira delas é a clara dificuldade de se calcular a Hessiana da função erro, porém, isso pode ser simplificado considerando que a função é aproximadamente linear nas vizinhanças do ponto em que se calcula a matriz. Essa consideração é incorporada ao algoritmo e sempre é utilizada, fazendo com que o algoritmo se torne heurístico, porém, obtendo na prática excelentes resultados. Além disso, outra clara dificuldade é calcular a matriz inversa presente na regra de atualização, o que é computacionalmente trabalhoso e impossibilita que o algoritmo seja utilizado quando o espaço de parâmetro seja da ordem de alguns milhares. Porém, quando o espaço de parâmetro é da ordem de algumas centenas, o algoritmo é muito mais rápido que os demais.

2.9.2 REDES NEURAIS DE BASES RADIAIS (RBF)

Segundo DING et al. (2010) a rede RBF foi idealizada de forma que os neurônios com funções de base radial ficassem localizados na camada escondida, construindo um espaço de camada oculta. A RBF consiste em uma função não linear que é simétrica no ponto central e distribuída localmente, quando o ponto central da função de base radial é determinado, então o vetor de entrada pode ser diretamente mapeado no espaço escondido. Mas o mapeamento do espaço escondido para a saída é linear, isto é, a soma dos pesos lineares da unidade de saída da rede, onde o peso é o parâmetro ajustável da rede.

A rede RBF é do tipo *feedforward* com três camadas, sendo estas, a camada de entrada, a camada escondida e a camada de saída. A Figura 5 apresenta a topologia da rede RBF. A camada escondida possui a função de base radial como sua função de ativação, geralmente a função Gaussiana.

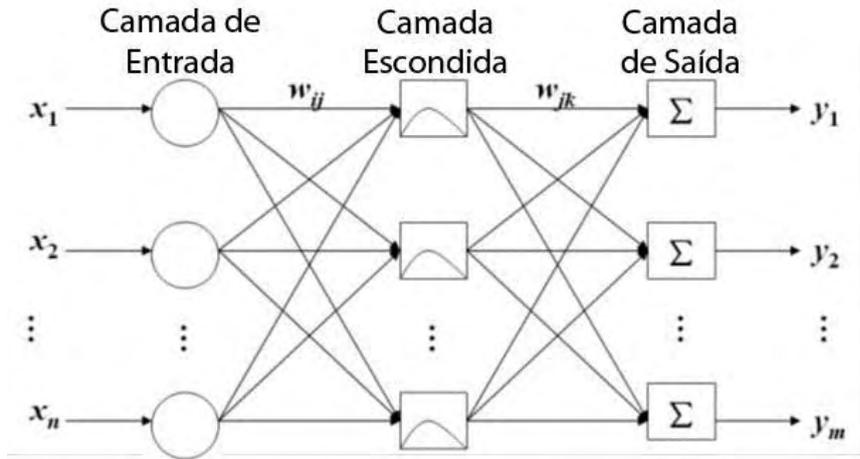


Figura 5 – Camadas da Rede Neural de Função de Base Radial (DING et al., 2010)

Supondo que a rede possui as seguintes características: n entradas e m saídas; a camada escondida possui s neurônios; o peso que conecta a camada de entrada e camada escondida é definido por w_{ij} ; o valor do limiar da camada escondida é definido por b_j ; o peso que conecta a camada escondida com a camada de saída é w_{jk} ; a entrada da camada escondida do j -ésimo neurônio é definida pela equação 10.

$$r_j = \sqrt{\sum_i (w_{ij} - x_i) \times b_j} \quad (10)$$

$(i=1, 2, \dots, m; j=1, 2, \dots, s).$

A saída do j -ésimo neurônio da camada escondida é definida pela equação 11.

$$c_j = \exp\left(-\left(r_j\right)^2\right) = \exp\left(-\left(\|w_{ij} - x_i\| \times b_j\right)^2\right) \quad (11)$$

A entrada da camada de saída realiza a soma dos pesos dos neurônios de cada camada escondida, a função de ativação é puramente linear e a saída é dada pela equação 12.

$$y_k = \sum_{j=1}^s c_j \times w_{jk} \quad (12)$$

$(j=1, 2, \dots, s; k=1, 2, \dots, n)$

A função do erro é definida pela saída da rede como t_k conforme equação 13.

$$e = \sum_{k=1}^n (t_k - y_k)^2 \quad (13)$$

O treinamento da rede RBF pode ser dividido em duas etapas. A primeira etapa consiste na identificação dos pesos w_{ij} de forma não supervisionada, e a segunda etapa é a identificação dos pesos w_{jk} de forma supervisionada. O problema chave está em se obter o número de neurônios na camada escondida. Usualmente o treinamento se inicia com zero neurônio, e seu valor é incrementado automaticamente através da verificação do erro; esse processo é repetido até que se obtenha o erro desejado, ou quando o número máximo de neurônios da camada escondida é atingido.

Comparando-se a rede RBF com a rede treinada com o algoritmo *backpropagation*, observa-se que a rede RBF ajusta a camada escondida adaptativamente na etapa de treinamento de acordo com o problema específico. A alocação dos neurônios da camada escondida pode ser realizada através da capacidade, categoria e distribuição das amostras de treinamento. Os pontos centrais, camada escondida e seus neurônios são identificados dinamicamente, resultando em um rápido treinamento. Por outro lado, a rede *backpropagation* não muda a sua arquitetura durante o treinamento. Existe uma dificuldade em se determinar o número de camadas ocultas e os neurônios nessas camadas, sendo que o processo de convergência é lento. O treinamento da rede *backpropagation* está de certa forma relacionado com as amostras, escolha dos algoritmos e da arquitetura (DING *et al.*, 2010).

Um exemplo da utilização da rede RBF é o problema ilustrado na Figura 6 onde as amostras de uma classe estão agrupadas no centro do espaço amostral. A solução deste exemplo pode ser obtida com apenas uma camada escondida de uma rede feedforward, com função sigmoide e quatro ou cinco neurônios. No entanto também é possível separar as duas classes com apenas um neurônio, se a função utilizada se aproximar de um círculo. (MEHROTRA; MOHAN, C. K.; RANKA, 1997).

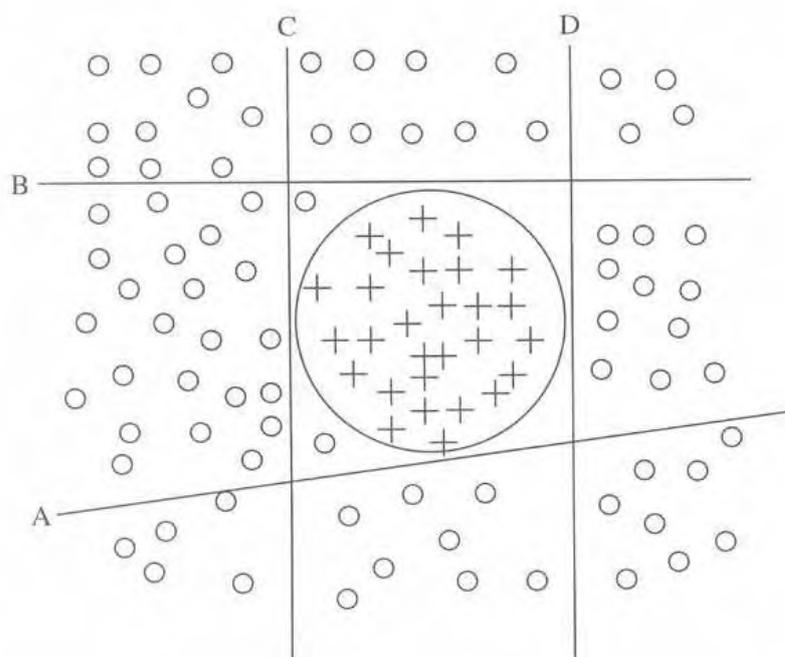


Figura 6 - Problema classe 2 com apenas um agrupamento e para backpropagations com usando 4 neurônios escondidos (MEHROTRA; MOHAN, C. K.; RANKA, 1997)

A rede neural RBF ainda é pouco utilizada em pesquisas voltadas para processos de fabricação; no entanto, é encontrado em várias pesquisas de outras áreas como, por exemplo, ZHANG *et al.* (2011), DANG e TAN (2007), GARG *et al.* (2010), PRAGA-ALEJO *et al.* (2012), HEUER e TRAN (2012) e FERNÁNDEZ-NAVARRO *et al.* (2012).

2.9.3 REDES NEURAIIS DE REGRESSÃO GENERALIZADA (GRNN)

Segundo SENG *et al.* (2002) o modelo da GRNN foi proposto por Donald Specht (SPECHT, 1991) como uma alternativa ao algoritmo *backpropagation* para a rede neural *feedforward*. A rede GRNN é fortemente relacionada com a já conhecida rede neural probabilística (SPECHT, 1996). A regressão, no contexto, pode ser pensada como uma estimativa da média dos mínimos quadrados de um conjunto de dados disponível. Do ponto de vista computacional a GRNN é baseada na estimativa da função densidade de probabilidades da amostra observada usando uma janela de estimativa Parzer (PARZER, 1962).

A GRNN utiliza um modelo probabilístico entre vetor aleatório independente X com dimensão D e o escalar aleatório dependente Y . Assumindo que x e y são valores medidos de X e Y , respectivamente, e $f(X,Y)$ representa a função densidade de probabilidade conjunta; e ainda assumindo que $f(X,Y)$ é também conhecida, o valor esperado de Y dado x (a regressão de Y em x) pode ser estimado como apresentado na equação 14.

$$E[Y|x] = \frac{\int_{-\infty}^{\infty} Y \cdot f(x, Y) dY}{\int_{-\infty}^{\infty} f(x, Y) dY} \quad (14)$$

Assumindo que a densidade subjacente é contínua e a primeira derivada parcial da função avaliada em qualquer x é pequena, dessa forma, baseado em p amostras dos dados de observação (conjunto de treinamento) que é dado por x e y , o estimador de probabilidade pode ser formulado pela equação 15.

$$\hat{f}(x, y) = \frac{1}{(2\pi)^{(D+1)/2} \sigma^{D+1}} \cdot \frac{1}{p} \sum_{i=1}^p \left[\exp\left(-\frac{(\underline{x} - \underline{x}_i)^T (\underline{x} - \underline{x}_i)}{2\sigma^2}\right) \cdot \exp\left(-\frac{(y - y_i)^2}{2\sigma^2}\right) \right] \quad (15)$$

Onde \underline{x}_i e y_i são os i -ésimos dados de treinamento, e \underline{x}_i denota a forma vetorial de x_i . A interpretação física da estimação probabilística $\hat{f}(x, y)$ é que esta atribui a amostra de probabilidade de largura (σ) para cada par de amostras de x_i e y_i , cuja estimação de probabilidade é computada como a soma de amostra probabilística.

Substituindo a equação 14 em 15, a média condicional desejada de Y dado x , é apresentada pela equação (16).

$$\hat{y}(x) = E[Y|x] = \frac{\sum_{i=1}^p [y_i \cdot \exp(d_i)]}{\sum_{i=1}^p \exp(d_i)} \quad (16)$$

Onde d_i é a função da distância entre os vetores de entrada e o centros armazenados nos neurônios da camada padrão, que é dado pela equação (17).

$$d_i = -\frac{(\underline{x} - \underline{x}_i)^T (\underline{x} - \underline{x}_i)}{(\sigma)^2} \quad (17)$$

Na formulação apresentada, todas as variáveis de entrada e neurônios da camada padrão compartilham um único sigma. O sigma (σ) é também conhecido como fator de suavidade ou fator de espraçamento do núcleo da função.

Os procedimentos computacionais da GRNN podem ser vistos como o peso médio de todos os dados observados usando o critério de distância no espaço de entrada. A estrutura geral da GRNN é apresentada na Figura 7. A camada de entrada irá simplesmente direcionar o vetor de entrada à GRNN, e suas distâncias nos padrões armazenados são então calculadas em cada um dos nós padrões da camada padrão. A camada de somatória realizará a soma para o denominador e numerador da equação (16), e a saída final da rede é obtida na camada de saída que possui uma função de normalização.

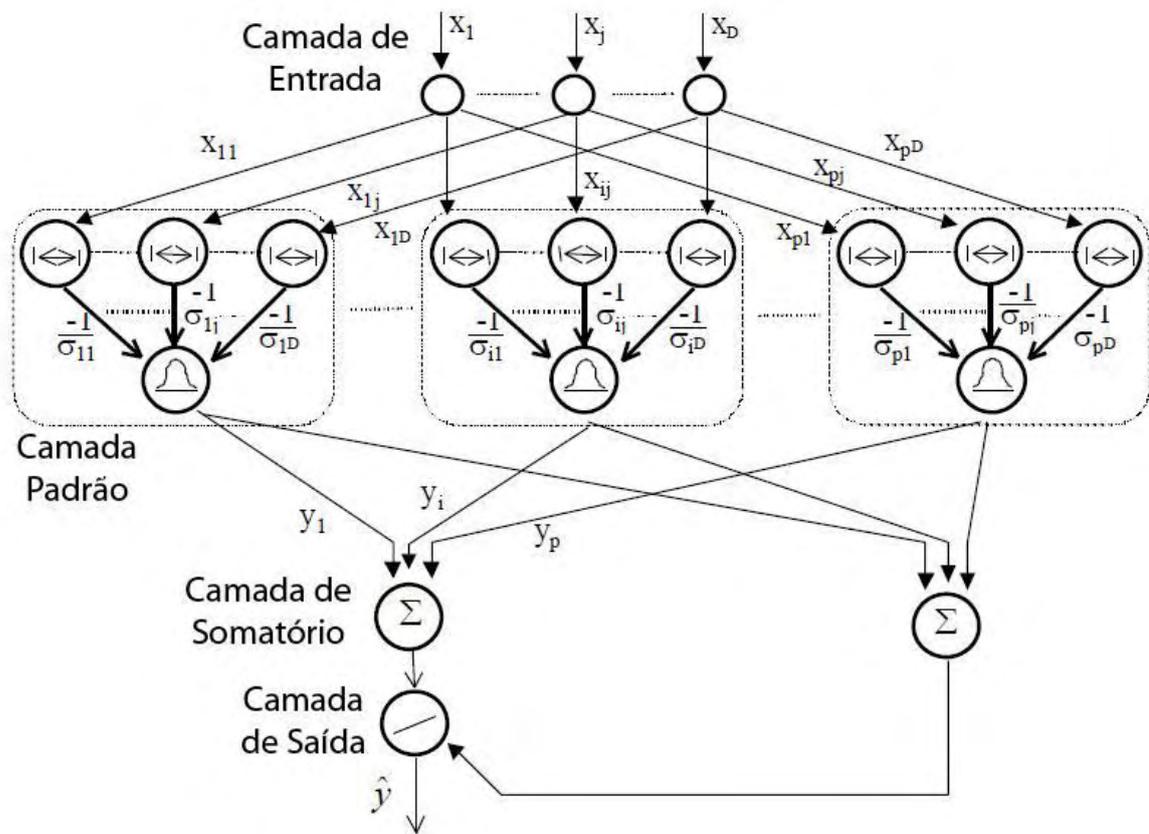


Figura 7 – Camadas da Rede Neural de Regressão Generalizada (DING *et al.*, 2010)

A GRNN é capaz de aproximar qualquer função arbitrária, mesmo relações lineares ou não lineares entre as variáveis de entrada e a saída, criando a função de estimação de saída diretamente (HYUN; NAM, 1995). Esta característica é particularmente vantajosa com dados esparsos em uma aplicação em tempo real, porque a superfície de regressão é definida instantaneamente, mesmo para apenas uma amostra. A técnica de aprendizado da GRNN é diferente das redes neurais mais populares, por exemplo, a regra delta. A GRNN possui um processo de aprendizado que não utiliza uma abordagem de ajuste iterativo para adquirir informação sobre o treinamento, mas aprende quase que instantaneamente com os dados

apresentados para o treinamento. O método de aprendizado GRNN simplesmente armazena os padrões de treinamento e os processa através de uma função de suavização não linear para determinar as funções componentes de densidade de probabilidade de saída.

As superfícies de decisão da GRNN são garantidas pela abordagem das fronteiras de decisão bayesiana ótima conforme o número de amostras de treinamento aumenta (SPECHT, 1996).

A saída da GRNN é sempre delimitada quando os dados de treinamento são delimitados, *i.e.*, a estabilidade do modelo é garantida. Além disso, adicionando uma nova amostra ao conjunto de treinamento a GRNN não necessita de uma nova calibração do modelo. A GRNN é de fácil modificação e atualização de acordo com as necessidades do ambiente, porque cada padrão de aprendizado é armazenado localmente em seus respectivos neurônios padrão (HYUN; NAM, 1995; MASTERS, 1995). Outra vantagem da GRNN é que, durante o processo de treinamento, amostras erradas são toleradas por outros neurônios padrão existentes (PATTON; ILIC, 1993). Estudos relatam que a GRNN tem obtido desempenhos melhores que outras redes neurais e métodos clássicos de modelagem, especialmente na presença de ruídos (MARQUEZ; HILL, 1993).

No entanto, uma das desvantagens da GRNN é que ela requer que todas as amostras de treinamento sejam armazenadas para usos futuros. O tamanho da rede pode crescer substancialmente em uma modelagem em um ambiente dinâmico e contínuo devido a grande quantidade de dados de treinamento em longos períodos de tempo. Alguns algoritmos de agrupamento têm sido propostos para resolver este problema (BURRASCANO, 1991; TRAVEN, 1991). Outra desvantagem da rede GRNN é a não existência de um método intuitivo para a escolha do fator de espraçamento. O método estatístico para a determinação do fator de espraçamento não adequado para a modelagem de sistemas contínuos e dinâmicos.

A rede neural de regressão generalizada é utilizada em várias aplicações por vários pesquisadores tais como SHAO *et al.* (2011), HU *et al.* (2011), REDDY *et al.* (2010), ZHOU e YANG (2010) e XIANG *et al.* (2010).

2.9.4 SISTEMA DE INFERÊNCIA NEURO FUZZY ADAPTATIVO (ANFIS)

A modelagem Neuro Fuzzy é uma ferramenta poderosa que pode facilitar o efetivo desenvolvimento de modelos pela combinação de informação de diferentes fontes, como modelos empíricos, heurísticas e dados. Modelos Neuro Fuzzy são baseados em estruturas de regras que tem origem no sistema fuzzy e partes consequentes funcionais, sendo assim,

qualificando as como fuzzy híbrido e modelos não fuzzy. Modelos neuro fuzzy tem a capacidade de representar não somente o conhecimento qualitativo, mas também a informação quantitativa (JANG; SUN, 1995; MORDJAOUI et al., 2007). A relação que governa a entrada e saída do processo é representada por um sistema fuzzy em termos das regras se-então ou a equação relacional chamada modelo fuzzy. Modelo fuzzy tem excelente capacidade de descrever um dado sistema e persuasão intuitiva para operadores humanos. Modelos neuro fuzzy são transparentes para interpretação e análise provendo soluções tão completas para os usuários assim como a rede neural.

Modelos fuzzy são superiores aos modelos lineares em capacidade de representar um dado sistema desconhecido. Isto é baseado na “Partição Fuzzy” do espaço de entrada e isso pode ser visto como a expansão por partições lineares. A **Erro! Fonte de referência não encontrada.** apresenta um sistema de inferência fuzzy TSK de primeira ordem.

Regra 1: Se x é A_1 e y é B_1 então $f_{11}=p_1x+q_1y+r_1$

Regra 2: Se x é A_2 e y é B_2 então $f_{12}=p_2x+q_2y+r_2$

Onde p_1, p_2, q_1, q_2, r_1 e r_2 são constantes.

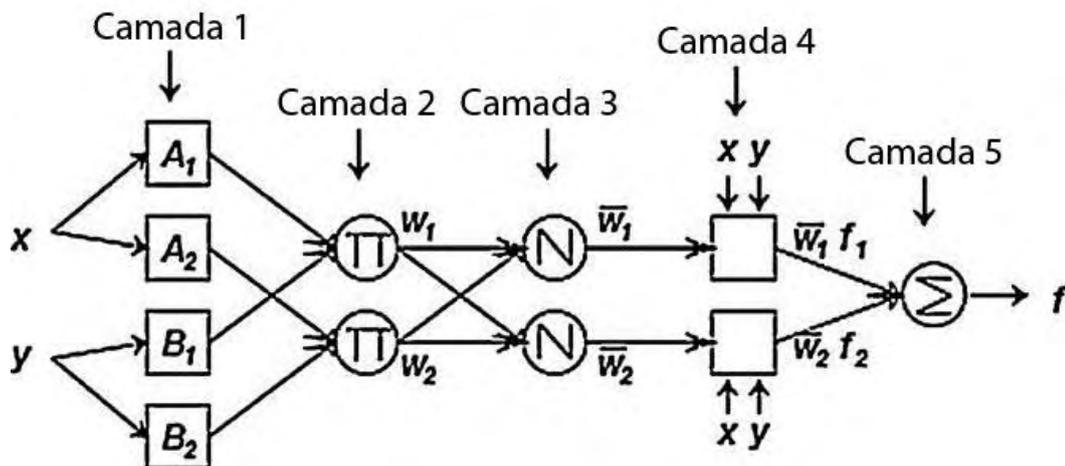


Figura 8 - Estrutura de um modelo ANFIS para duas variáveis de entrada e duas regras

Camada 1: Cada nó nesta camada gera níveis de pertinência de funções linguísticas. A função do i -ésimo nó é apresentada pela equação (18).

$$O_i^1 = m_{A_i}(x) = \max \min \left\{ \left[\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}, 0 \right] \right\} \quad (18)$$

Onde x é a entrada do nó, A_i é a variável linguística (pequena, grande, etc) associada com este nó, e $\{a, b, c, d\}$ é o conjunto de parâmetros que modificam o formato das funções de pertinência. Parâmetros nesta camada são chamadas de parâmetros de premissa.

Camada 2: Cada nó nesta camada calcula o nível de força de cada regra via multiplicação conforme equação (19).

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2 \quad (19)$$

Camada 3: O i -ésimo nó desta camada calcula a divisão do nível de força da i -ésima regra pela soma de todas os níveis de força conforme a equação (20).

$$O_i^3 = w_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (20)$$

Camada 4: Nó i nesta camada tem a seguinte função apresentada pelas equação (21).

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (21)$$

Onde w_i é a saída da camada 3 e $\{p_i, q_i, r_i\}$ é o conjunto de parâmetros que recebem o nome de parâmetros de consequência.

Camada 5: O simples nó nesta camada calcula a saída geral como a soma de todos os sinais gerais de saída.

$$O_i^5 = \text{saída geral (overall output)} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (22)$$

O sistema ANFIS é pesquisado atualmente para os processos de fabricação como, por exemplo, GILL e SINGH (2010), NAZARI (2012), TAJDARI *et al.* (2010) e SALMASNIA *et al.* (2012)

Capítulo 3 - MATERIAIS E MÉTODOS

Neste capítulo serão apresentados os procedimentos para a montagem do banco de ensaios, módulos e sensores, aquisição de dados e informações sobre as medições da rugosidade e desgaste do rebolo serão fornecidas. Em seguida, serão descritos sobre os procedimentos para a realização dos ensaios, o processamento digital dos sinais coletados e o interpolação dos valores de rugosidade e desgaste do rebolo. Por fim, os modelos neurais para cada tipo de rede são apresentados.

3.1 MONTAGEM DO BANCO DE ENSAIO

Os ensaios experimentais deste trabalho foram realizados no Laboratório de Usinagem por Abrasão (LUA), localizado no *campus* de Bauru da Univ. Estadual Paulista. Utilizou-se para os ensaios a retificadora tangencial plana, do fabricante SULMECÂNICA, modelo 1055, disponível no referido laboratório.

Os corpos-de-prova foram doados pelo Prof. Carlos Alberto Fortulan, da Escola de Engenharia de São Carlos – EESC da Universidade de São Paulo – USP. Estes foram fabricados por prensagem e sinterização resultando em barras retangulares de alumina, composta por 96% de óxido de alumínio e 4% de óxidos como o dióxido de silício, o óxido de cálcio e o óxido de magnésio. A **Erro! Fonte de referência não encontrada.** mostra as dimensões, bem como as propriedades mecânicas dos corpos-de-prova.

Devido às características mecânicas dos materiais cerâmicos, foi escolhido um rebolo diamantado sintético, código SD126MN50B2, fabricado pela empresa Dinser Ferramentas Diamantadas. A **Erro! Fonte de referência não encontrada.** mostra as dimensões e características da ferramenta de corte.

Devido a um vazamento de corrente elétrica na máquina retificadora, possivelmente relacionada com o sistema de aterramento local, mediu-se entre a carcaça da máquina e o suporte responsável por fixar a peça à mesa uma tensão de 70 V. Esta tensão pode danificar o sensor de emissão acústica que é aparafusado ao suporte, e ainda, interferir nos sinais coletados. Assim, para solucionar este problema, foi confeccionado um suporte com uma resina isolante, minimizando as interferências eletromagnéticas nas medições e no sensor de emissão acústica.

Tabela 2 – Propriedade mecânica dos corpos de prova de cerâmica (Prof. Carlos Alberto Fortulan – EESC – USP)

Propriedade	Norma	Valor
Dimensões		117x60x8mm
Densidade aparente		3,701±0,002g/cm ³
Principal componente		Alumina (óxido de alumínio)
Resistência à flexão (4 pontos)	ASTM C1161-02	279±11MPa
Tenacidade à fratura	ASTM C1421-01	3,18±0,07MPa·m ^{1/2}
Módulo de elasticidade	JIS R1602-1986	312±4GPa
Microdureza Vickers	JIS R1610-1991	1339±47HV
Tamanho médio de grão	ASTM E1382-97	1,57µm

O sistema de refrigeração possuía um transmissor de pressão e outro de vazão, permitindo o controle dessas duas variáveis ao longo dos ensaios. O bocal utilizado para a lubrificação da zona de retificação tinha seção retangular de 49 mm de comprimento por 3 mm de largura.

Tabela 3 – Dimensões e características da ferramenta de corte

	Código/Especificação
Diâmetro	350mm
Tipo de Grão	SD (Diamante Sintético)
Diâmetro do Grão	126
Dureza do Rebolo	MN (Dureza Média)
Concentração	50B2

3.1.1 PARÂMETROS CONSTANTES DE ENSAIOS E CONFIGURAÇÃO DO BANCO DE ENSAIOS

As condições de retificação e dressagem foram configuradas de acordo com as experiências adquiridas pelo grupo de Usinagem por Abrasão. A velocidade de corte (v_s) foi

ajustada pelo inversor de frequência em 35m/s e a velocidade da peça (v_w), regulada com um tacômetro digital para 2,3m/min. A vazão do fluido de lubrificação era de 27,51 l/min., com pressão menor que 0,2kgf/cm².

O fluido de corte utilizado foi emulsão água-óleo com 4% de concentração, sendo o óleo, do fabricante Shell, tipo DMS 3200 F-1. Para a medição da concentração do fluido de corte foi utilizado o refratômetro N-1E do fabricante Atago.

O dressador aplicado neste trabalho para a operação de perfilamento da ferramenta de corte foi do tipo conglomerado. O avivamento do rebolo foi realizado com uma peça de óxido de alumínio, desgastando o ligante e expondo o grão, aumentando o potencial de corte do rebolo. A **Erro! Fonte de referência não encontrada.** mostra os parâmetros que se antiveram constantes ao longo dos ensaios.

Tabela 4 – Configuração dos parâmetros de retificação

Velocidade de Corte (v_s)	35m/s
Velocidade da Peça (v_w)	2,3m/min.
Vazão do Fluido	27,51 l/min.
Pressão do Fluido	< 0,2Kgf/cm ²
Concentração do Fluido	4%
Profundidade de Dressagem	2 μ m
Passos de Dressagem	8

Antes de cada ensaio foi realizada a dressagem do rebolo diamantado com o dressador conglomerado. Devido ao baixo desgaste do rebolo diamantado eram necessários somente oito (8) passes de dois micra (2 μ m) de profundidade para uniformizar a face de trabalho. Depois da dressagem, era realizado o avivamento da ferramenta de corte, desgastando o ligante com uma peça de óxido de alumínio, resultando na exposição dos grãos de corte.

A aquisição da emissão acústica (EA) foi feita por um sensor do tipo piezelétrico de alta sensibilidade da marca Sensis. Este sensor foi aparafusado ao suporte que fixava a peça à mesa, melhorando a aquisição das informações acústicas ocorridas durante o processo. O sensor foi ligado a um módulo de processamento de EA, modelo DM42, do fabricante Sensis, que possui duas opções de aquisição de sinal: puro ou RMS.

O motor do rebolo foi acionado por um inversor de frequência de 380V e 7,5 CV, modelo CFW-08, fabricado pela WEG. Para a aquisição da potência de corte durante o processo, optou-se por medir a potência na entrada deste inversor. A medição era realizada

por um módulo de potência, desenvolvido pelo grupo de pesquisa em Usinagem por Abrasão da Faculdade de Engenharia de Bauru, da Univ. Estadual Paulista - UNESP. Dentro do módulo, encontram-se dois transdutores de efeito hall, sendo um de corrente e outro de tensão, e durante o processo de retificação os transdutores coletam os sinais de corrente e de tensão instantânea que são multiplicados por um circuito integrado, resultando na potência instantânea do sistema. Em seguida, o sinal de potência instantânea é filtrado e a potência média obtida.

Na Figura 9 é apresentada a configuração do banco de ensaios montado. Nessa figura não são mostrados o rugosímetro portátil para medição de rugosidade e a peça de cerâmica para a impressão do perfil da superfície do rebolo, os quais serão apresentados posteriormente.

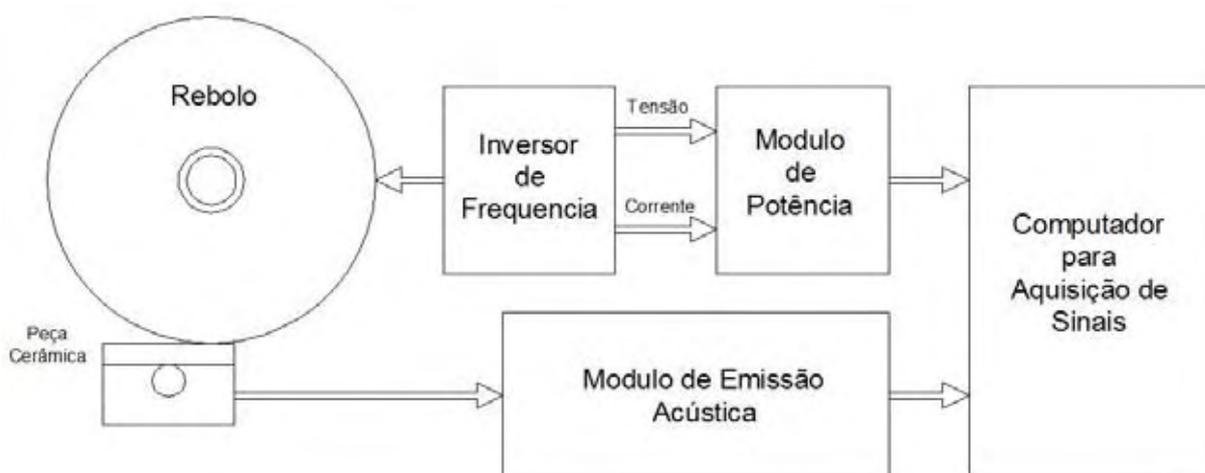


Figura 9 - Configuração do banco de ensaios

3.1.2 MÓDULO DE EMISSÃO ACÚSTICA

Os módulos de aquisição de emissão acústica (DM42) e de potência média foram ligados a um bloco de conectores BNC, modelo BNC2110, que por sua vez foi conectado a uma placa de aquisição.

O cabo do sensor de emissão acústica foi conectado na porta de aquisição RMS do módulo de EA. Esta opção foi escolhida em função dos objetivos deste trabalho de usar o sinal RMS de EA como entrada para os modelos neurais juntamente com o sinal de potência de corte e o parâmetro DPO, sendo este último função dos valores RMS de EA e potência de

corrente. A frequência de aquisição foi configurada para 2kS/s por canal, satisfazendo o teorema da amostragem, pois a frequência mais significativa é a do sinal RMS de EA de 1KHz.

Dependendo da posição do sensor de emissão acústica, que neste caso é do tipo passivo, o sinal coletado pelo módulo pode entrar em saturação, ou seja, acima de um determinado valor não é possível mais realizar a leitura do valor real do sinal. Para que isto não ocorra, o módulo possui uma configuração do ganho de entrada, ajustando-o para que o sinal não sature em uma determinada posição do sensor. Neste trabalho, o melhor valor para o ganho de entrada foi de 10 vezes. **Erro! Fonte de referência não encontrada.** resume os valores ajustados no módulo de aquisição de emissão acústica e o tipo de sensor utilizado.

Tabela 5 – Configurações do módulo de EA

Tipo de Sensor	Passivo
Sinal de Saída	RMS
Ganho de Entrada	10
Constante de Tempo	1ms
Redutor de Ruído	5
Filtro Usado	Passa Alta de 50kHz
Frequência de Aquisição por Canal	2kS/s

3.1.3 MÓDULO DE POTÊNCIA

No módulo de aquisição de potência é possível coletar sinais de corrente instantânea, corrente RMS, tensão instantânea, e potência média. O sinal monitorado foi o de potência média e a taxa de aquisição foi a mesma usada para o sinal de emissão acústica, 2 kS/s. **Erro! Fonte de referência não encontrada.** mostra os valores ajustados no módulo de aquisição de potência.

Tabela 6 – Configurações do módulo de potência

Tipo de Sensor Corrente	Efeito Hall
Tipo de Sensor de Tensão	Efeito Hall
Sinal Coletado	Potência Média
Frequência de Aquisição	2kS/s

3.1.4 PLACA DE AQUISIÇÃO DE DADOS

A placa de aquisição usada para coletar os sinais de EA e potência foi do fabricante National InstrumentsTM, modelo PCI-6035E, 16 bits de resolução, frequência máxima de aquisição de 200 kS/s. Esta placa encontrava-se instalada em um computador localizado ao lado da máquina retificadora e nele estava instalada uma interface gráfica de aquisição de sinais, desenvolvida pelo próprio grupo de pesquisa, sob a plataforma do programa computacional LabVIEW®. A interface gráfica de aquisição de sinais (LABVIEW) foi preparada para coletar os sinais de potência média e emissão acústica RMS concomitantemente. Foi configurada a opção de salvar os arquivos em formato binário de 16 bits. Contudo, para visualização dos valores, era necessário converter os dados coletados em valores reais utilizando a constante de conversão de $20/(2^{16})$ V/b. A **Erro! Fonte de referência não encontrada.** apresenta os parâmetros de configuração da placa de aquisição.

Tabela 7 – Configurações da placa de aquisição

Sinal Coletado	Potência Média/Binário
Sinal Coletado	Emissão Acústica RMS/Binário
Constante de Conversão	$20/(2^{16})$
Frequência de Aquisição	2kS/s

3.1.5 RUGOSÍMETRO

Para a medição de rugosidade foi utilizado um rugosímetro digital, modelo *Surtronic 3+*, fabricado pela Taylor Robson. Para evitar deslocamentos e mudanças das condições dos ensaios o rugosímetro foi colocado em cima de um suporte que permitia o nivelamento da superfície retificada com o apalpador do rugosímetro. Este suporte foi alocado na base magnética da mesa retificadora.

O rugosímetro digital foi configurado para medir os valores da rugosidade média (Ra) na superfície retificada do corpo-de-prova. Os parâmetros ajustados do rugosímetro para as medições estão descritos na Tabela 8. Na Figura 10 pode-se observar o suporte para nivelar o apalpador do rugosímetro com a superfície retificada do corpo-de-prova. O corpo-de-prova possui onze (11) divisões igualmente distribuídas ao longo de seu comprimento e no sentido da medição do apalpador.

Tabela 8 – Configuração do rugosímetro para medição de rugosidade média (Ra)

Parâmetro Medido	Rugosidade Média (Ra)
Unidade de Medida	μm
Resolução do Resultado	0,2 μm
Lc	0,8mm
Ln	4,0mm
Vh	x100
Vv	x1000
↔ deslocamento para medição	12,5mm
Amostragem	100 $\mu\text{m.m/in}$

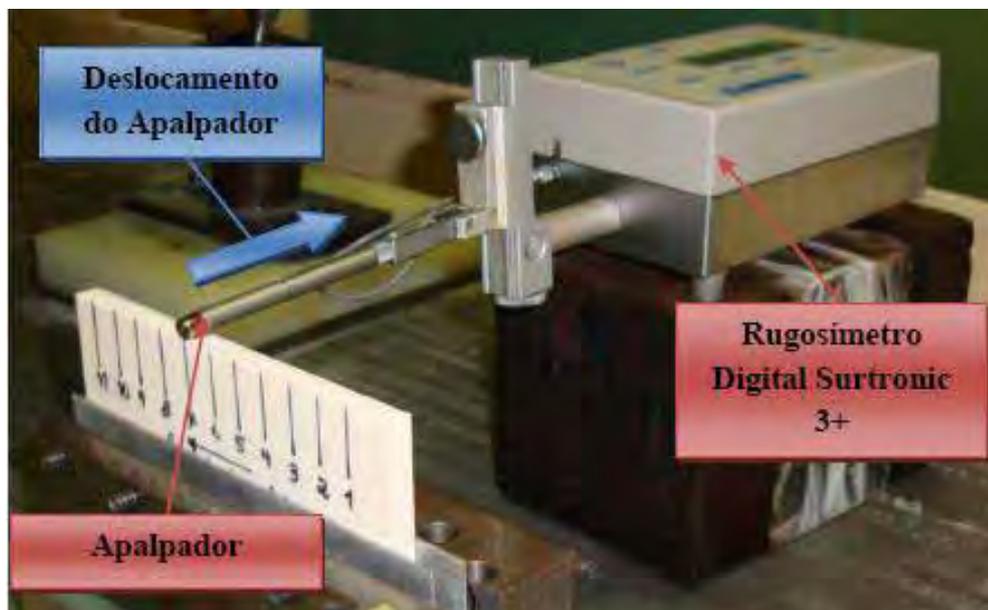


Figura 10 – Configuração da medição de rugosidade média (Ra)

3.1.6 IMPRESSÃO E MEDIÇÃO DO DESGASTE

A primeira etapa da medição do desgaste da ferramenta de corte foi realizada fixando peças de cerâmica, as quais tiveram suas superfícies retificadas. Estas peças tinham o mesmo formato e características dos corpos-de-prova e foram alocadas transversalmente ao deslocamento da mesa. Na segunda etapa, foi utilizado o rugosímetro digital, modelo *Surtronic 3+*, do fabricante Taylor Robson, ligado a um computador que possuía o programa TalyProfile, no qual foram medidos os valores de desgaste do rebolo com o perfil impresso na peça de cerâmica, como apresentado na Figura 11.

O rugosímetro era posicionado com o apalpador em linha com a peça de cerâmica contendo os perfis impressos. Selecionou-se o modo de comunicação do rugosímetro, e determinou-se o comprimento da medição que era de 12,5mm. Onde o rebolo cortou a peça imprimindo sua superfície observou-se uma marca de 8mm que era justamente a largura do corpo-de-prova. Assim, dentro dos 12,5mm do passo da medição visualmente era possível determinar a localização do degrau na superfície do rebolo relacionado com o desgaste da ferramenta no processo de retificação. A **Erro! Fonte de referência não encontrada.** mostra s parâmetros ajustados na leitura dos perfis.

A Figura 12 (a) apresenta a bancada utilizada para as medidas dos perfis impressos na cerâmica, obtendo-se assim valores de desgaste da ferramenta e a Figura 12 (b) apresenta o perfil desgastado da ferramenta de corte obtido através do rugosímetro.

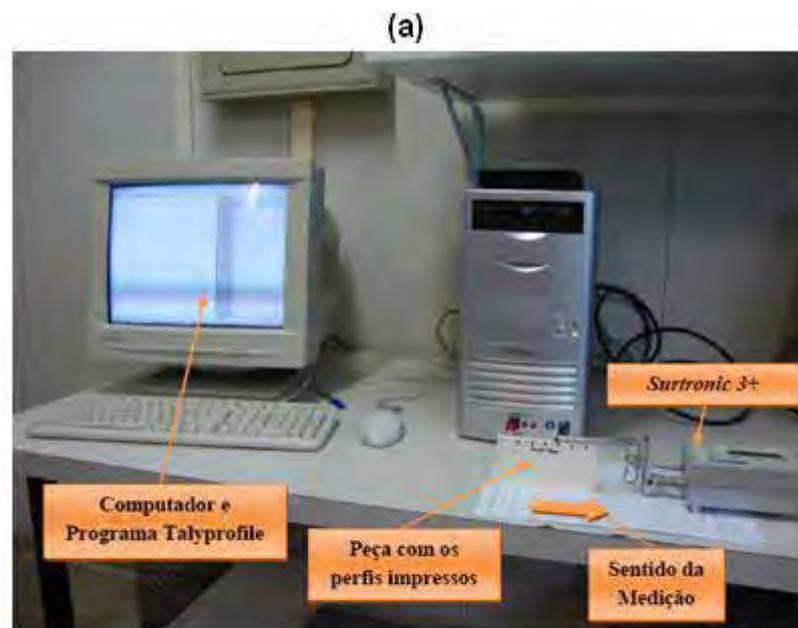
No entanto, vale mencionar que os desgastes seriam medidos com uma máquina de coordenadas tridimensionais, e assim, não foi considerado o tamanho das peças de cerâmica para impressão da superfície do rebolo. Dessa forma, o comprimento do apalpador, que era menor que o comprimento da peça, limitava as medições, obrigando uma rotação na peça, o que resultou em algumas variações nas condições de leitura.



Figura 11 – Método de impressão do perfil da face do rebolo

Tabela 9 – Configuração do rugosímetro para medição do desgaste

Lc	0,80mm
Ln	4,00mm
Vh	x100
Vv	x1000
↔ deslocamento para medição	12,5mm
↕ amostragem	500 μ m/m/in



Perfil de desgaste lido pelo rugosímetro, parte 5 ensaio de 20 μ m

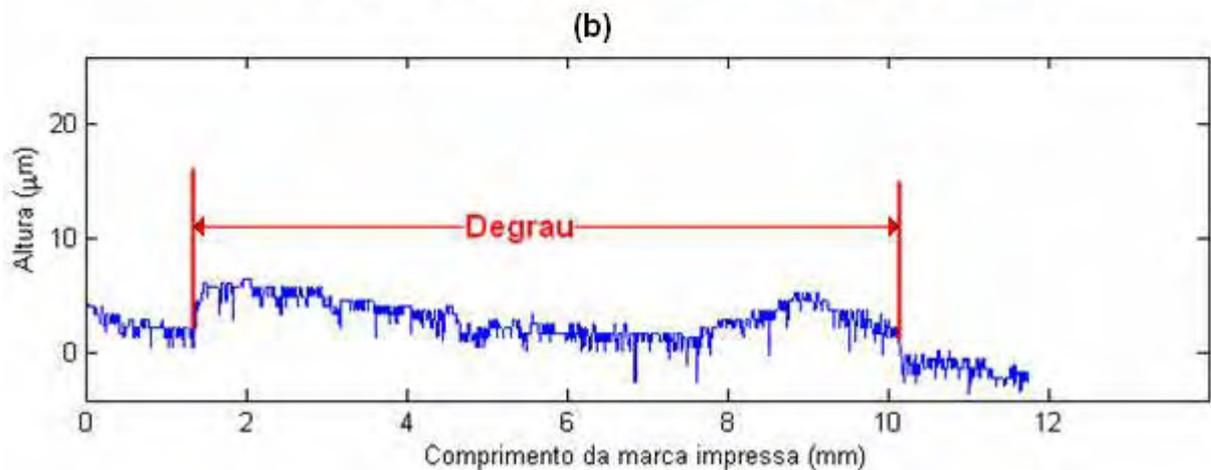


Figura 12 – Configuração do sistema para medição dos perfis (a) e resultado típico das medições realizadas (b)

3.2 PROCEDIMENTO DOS ENSAIOS

Após a montagem do banco de ensaios e configurações dos equipamentos foi realizada a coleta dos sinais e as medições da rugosidade e do desgaste. Foram escolhidas três profundidades de corte (a) diferentes, sendo o primeiro ensaio com $20\mu\text{m}$, o segundo com $70\mu\text{m}$ e o terceiro com $120\mu\text{m}$. Essas profundidades foram escolhidas adotando a metodologia de uma remoção branda de material ($a=20\mu\text{m}$), uma remoção intermediária de material ($a=70\mu\text{m}$) e uma remoção de material severa ($a=120\mu\text{m}$).

Como a velocidade de corte (v_s) e a velocidade da peça/mesa (v_w) não variaram ao longo dos ensaios, a espessura equivalente de corte (h_{eq}) tornou-se dependente da profundidade de corte (a). A **Erro! Fonte de referência não encontrada.** mostra os valores a espessura equivalente de corte para os três ensaios realizados.

Tabela 10 – Cálculo da espessura equivalente de corte (h_{eq})

Ensaio	Profundidade de Corte (a)	Velocidade de Corte (v_s)	Velocidade de Corte (v_w)	h_{eq}
Ensaio 1	$20\mu\text{m}$	35m/s	$2,3\text{m/min}$	$0,02\mu\text{m}$
Ensaio 2	$70\mu\text{m}$	35m/s	$2,3\text{m/min}$	$0,07\mu\text{m}$
Ensaio 3	$120\mu\text{m}$	35m/s	$2,3\text{m/min}$	$0,132\mu\text{m}$

A quantidade de material removido foi igual para os três ensaios, que consistiu no volume de 16.000mm^3 . Devido variação do parâmetro h_{eq} , a quantidade de passes de retificação para a remoção do material foi diferente para cada ensaio. No ensaio 1 ($a=20\mu\text{m}$) foram realizados 860 passes de retificação, enquanto no ensaio 2 ($a=70\mu\text{m}$) e no ensaio 3 ($a=120\mu\text{m}$) decorreram 250 e 150 passes de retificação, respectivamente.

Para cada ensaio a quantidade total de passadas foi dividida igualmente em 10 partes. Antes de iniciar o ensaio e ao final de cada parte foram realizadas medições da rugosidade e do desgaste. O corpo-de-prova era dividido em 11 pontos igualmente espaçados para se garantir os valores da rugosidade média (R_a), pois o valor de R_a deve permanecer constante ao longo do corpo-de-prova. Depois disso, a mesa era acionada até que o rebolo cortasse a peça de cerâmica imprimindo o perfil da superfície contendo o degrau relacionado ao desgaste.

A **Erro! Fonte de referência não encontrada.** apresenta um resumo do procedimento Divisões dos ensaios, com as divisões de partes, passes de retificação, medições da rugosidade e desgaste do rebolo.

Tabela 11 – Resumo do Procedimento e Divisões dos Ensaios

	Ensaio 1	Ensaio 2	Ensaio 3
Número de Partes	10	10	10
Número de Passes por Parte	86	25	15
Número de Medições de Rugosidade	11	11	11
Número de Perfis Impressos	11	11	11
Número Total de Passes no Ensaio	860	250	150

3.3 PROCESSAMENTO DOS SINAIS DE EMISSÃO ACÚSTICA E DA POTÊNCIA ELÉTRICA

De posse dos arquivos dos sinais de emissão acústica e potência de corte dos três ensaios ($a = 20\mu\text{m}$; $a = 70\mu\text{m}$; $a = 120\mu\text{m}$) foi realizado o processamento digital dos sinais, utilizando o software MATLAB, obtendo as estatísticas: média da emissão acústica (mediaEA), desvio da emissão acústica (stdEA), média da potência (mediaPOT), desvio da potência (stdPOT) e o DPO.

Como para cada passe de retificação foram coletados os sinais de emissão acústica e potência de corte, obtiveram-se 150 valores para a profundidade de corte de $120\mu\text{m}$, 250 valores para a profundidade de $70\mu\text{m}$ e 860 valores para a profundidade de corte de $20\mu\text{m}$, totalizando ao final do processamento 1260 valores de cada uma das estatísticas calculadas.

Pode-se ver nas Figura 13 e Figura 14 a aquisição do sinal de emissão acústica e do sinal de potência elétrica do ensaio de profundidade de $120\mu\text{m}$, ainda sem processamento. Nesse exemplo, as passadas não estão separadas, e, portanto, o gráfico obtido se refere a todos os pontos coletados no ensaio. Nessa figura, a passada (ou passe de retificação) pode ser identificada apenas pelos picos ao longo da curva.

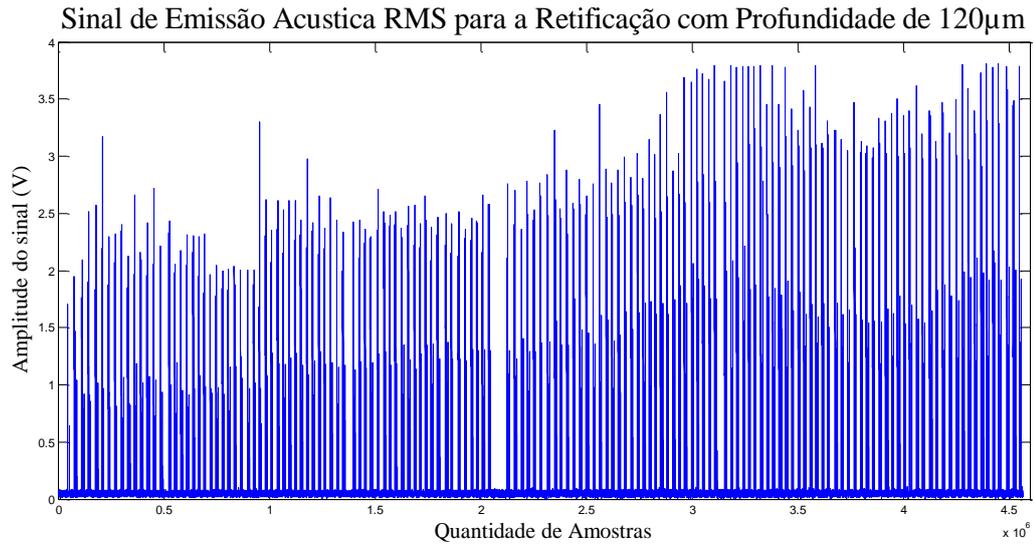


Figura 13 - Sinal adquirido à profundidade de 120µm ainda sem o processamento digital

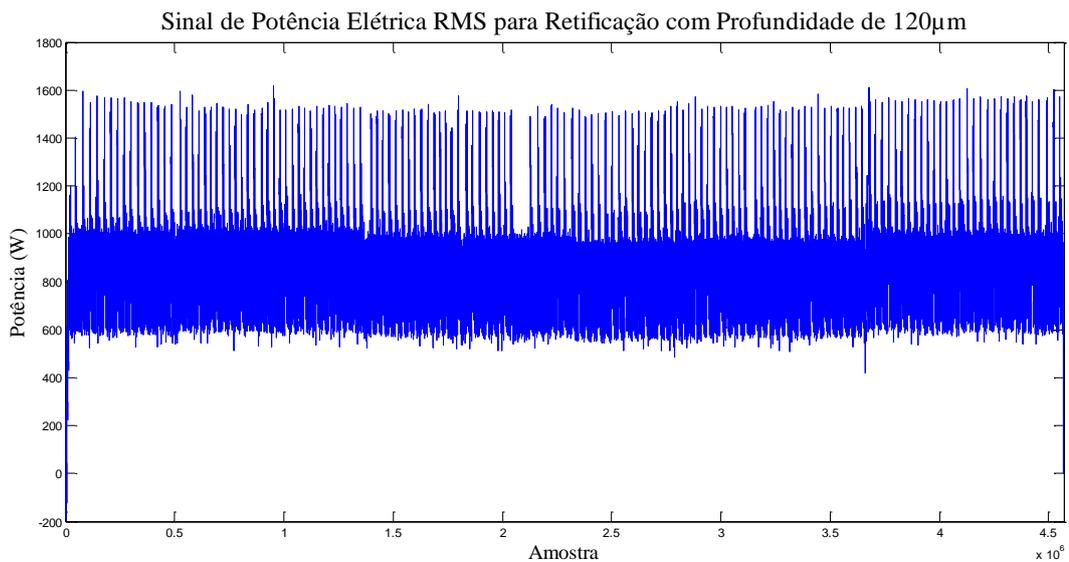


Figura 14 – Sinal de potência elétrica adquirido à profundidade de 120µm sem a o processamento digital

A separação das passadas do sinal de emissão acústica e potência elétrica foi realizada manualmente para todos os sinais armazenados em arquivos binários, e de forma manual no MATLAB. A Figura 15 ilustra uma das passadas dos sinais de emissão acústica e potência elétrica mostrados nas Figura 13 e Figura 14 respectivamente. Nota-se na Figura 15, na parte superior, que a passada é muito bem definida pelo sinal de emissão acústica, indicando claramente a região onde o rebolo corta efetivamente a peça (*spark-in*) e a região onde o rebolo retorna sem o avanço ou profundidade de corte (*spark-out*). Por outro lado, o sinal de

potência elétrica do motor de acionamento do rebolo, parte inferior da Figura 15, apresenta um comportamento muito mais lento, devido à inércia do motor e máquina retificadora. Nesse caso, as regiões de *spark-in* e *spark-out* não são claramente definidas.



Figura 15 - Uma passada isolada da emissão acústica da retificação com profundidade de $120\mu\text{m}$

A seleção do início e fim do *spark-in* foi realizada graficamente utilizando o comando $[X,Y] = \text{ginput}(N)$ no MATLAB, que disponibiliza o valor das coordenadas x e y do gráfico através da posição do ponteiro do mouse. Essa seleção foi realizada manualmente no gráfico da emissão acústica devido aos seus limites mais definidos de início e término do *spark-in*, em relação ao sinal de potência elétrica. Para o sinal de potência, consideraram-se os mesmos valores das coordenadas de cada passada (*spark-in*) extraída do sinal de EA. Assim, obteve-se o mesmo número de pontos (amostras) para ambos os vetores, EA e potência.

Vale ressaltar que para o sinal de potência, o vetor extraído para cada passada não contempla toda a região da passada caracterizada por esse sinal, pois a dinâmica da potência elétrica possui uma constante de tempo muito maior (mais lenta) do que a do sinal de EA, como mencionado anteriormente. No entanto, essa consideração não traz implicação negativa na utilização do sinal médio ou máximo de potência calculado ao longo de cada passada, os quais foram usados nos modelos neurais deste trabalho, pois esse procedimento contempla a tendência de comportamento do sinal de potência.

3.4 INTERPOLAÇÃO DOS VALORES DE RUGOSIDADE DA PEÇA E DESGASTE DE FERRAMENTA

Durante a fase experimental foram coletados 11 valores de rugosidade e 11 perfis impressos para cada ensaio. Os perfis foram medidos conforme descrito no item **Erro! Fonte e referência não encontrada.** e, assim, obtiveram-se os 11 valores de desgaste da ferramenta para cada ensaio. No entanto, 33 valores de rugosidade e 33 valores de desgaste (somando os três ensaios), representam quantidades insuficientes para o treinamento dos modelos neurais, pois cada entrada (EA, Potência ou Estatísticas) deve corresponder a um valor de saída (rugosidade ou desgaste da ferramenta).

Dessa maneira, a fim de se obter um universo maior de amostras de rugosidade e desgaste, foi realizado um ajuste de curvas aos dados coletados. Para isso, foi utilizada a ferramenta *Toolbox Fitting Curve* do programa computacional MATLAB, onde é possível realizar os ajustes dos coeficientes das equações que representam as curvas interpoladas aos valores medidos. Depois do ajuste, a ferramenta fornece os coeficientes estatísticos da interpolação: R-2(%), SSE, RMSE. Com estes valores é possível avaliar a qualidade do ajuste realizado.

Tanto para a rugosidade quanto para o desgaste foram obtidas três curvas, representando o comportamento dos valores em função do número de passadas para cada um dos ensaios. Posteriormente, foi aplicado um coeficiente de conversão de número de passadas para o volume de material removido a fim de se poder analisar melhor o comportamento dos três ensaios.

3.5 MODELOS NEURAIIS

Para o presente estudo foram utilizados quatro modelos neurais: a Rede Neural Perceptron de Múltiplas Camadas (MLP), mais utilizada e estudada para o aprendizado de tendências; a Rede Neural de Função de Base Radial (RBF); ainda pouco utilizada para os processos de fabricação; a Rede Neural de Regressão Generalizada (GRNN); e o Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS).

As entradas utilizadas para esses modelos foram o valor médio da emissão acústica (mediaEA), o desvio padrão da emissão acústica (stdEA), o valor médio da potência de corte (mediaPOT), o desvio padrão da potência de corte (stdPOT), e a estatística DPO.

Para a obtenção das configurações possíveis de conjuntos de entradas, foi utilizada uma combinação binária das cinco (5) estatísticas, resultando em 31 possibilidades de entradas para os modelos neurais. A Tabela 12 mostra as combinações de entradas para os modelos neurais.

Tabela 12 - Configuração dos conjuntos de entrada para os modelos neurais

Índice	Entradas				
1					mediaEA
2				mediaPOT	
3				mediaPOT	mediaEA
4			DPO		
5			DPO		mediaEA
6			DPO	mediaPOT	
7			DPO	mediaPOT	mediaEA
8		stdEA			
9		stdEA			mediaEA
10		stdEA		mediaPOT	
11		stdEA		mediaPOT	mediaEA
12		stdEA	DPO		
13		stdEA	DPO		mediaEA
14		stdEA	DPO	mediaPOT	
15		stdEA	DPO	mediaPOT	mediaEA
16	stdPOT				
17	stdPOT				mediaEA
18	stdPOT			mediaPOT	
19	stdPOT			mediaPOT	mediaEA
20	stdPOT		DPO		
21	stdPOT		DPO		mediaEA
22	stdPOT		DPO	mediaPOT	
23	stdPOT		DPO	mediaPOT	mediaEA
24	stdPOT	stdEA			
25	stdPOT	stdEA			mediaEA
26	stdPOT	stdEA		mediaPOT	
27	stdPOT	stdEA		mediaPOT	mediaEA
28	stdPOT	stdEA	DPO		
29	stdPOT	stdEA	DPO		mediaEA
30	stdPOT	stdEA	DPO	mediaPOT	
31	stdPOT	stdEA	DPO	mediaPOT	mediaEA

Os modelos neurais estudados neste trabalho foram divididos em dois grupos de saídas (rugosidade e desgaste da ferramenta), sendo que cada grupo de saída foi estudado separadamente para cada condição de retificação (profundidade de corte). Assim, para cada tipo de rede neural obteve-se seis (6) modelos neurais distintos, um para cada profundidade de corte. A Figura 16 ilustra o processo de obtenção desses modelos neurais.

Cada modelo neural foi treinado cinco (5) vezes para se verificar a consistência de aprendizagem da rede neural, obtendo-se um valor do erro médio e respectivo desvio padrão.

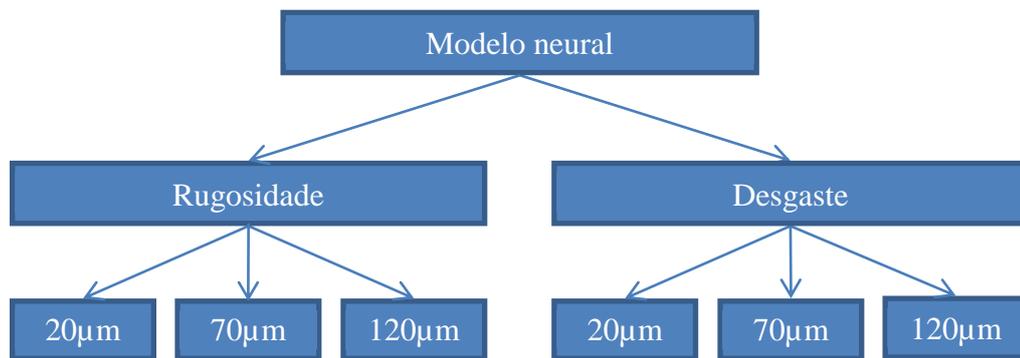


Figura 16 – Processo de obtenção dos Modelos Neurais.

3.5.1 REDES NEURAIS PERCEPTRON DE MÚLTIPLAS CAMADAS (MLP)

As características do modelo neural MLP e as configurações do treinamento utilizadas estão relacionadas na Tabela 13. Para esse tipo de treinamento, os parâmetros, taxa de aprendizagem e momento, não são contemplados devido à utilização do algoritmo de treinamento Levenberg-Marquardt. A função utilizada no MATLAB para a implementação desse algoritmo de treinamento foi a *trainlm*, cuja descrição está na Tabela 14.

Devido às inúmeras possibilidades de configuração do modelo MLP, o algoritmo utilizado foi o mais complexo e custoso computacionalmente. Neste modelo foram utilizadas configurações variadas de quantidade de camadas e quantidade de neurônios em cada camada, conforme mostra a Tabela 15.

Tabela 13 - Características do modelo neural MLP

Função de ativação (camada oculta)	Função Sigmoide
Função de ativação (camada saída)	Função Linear
Algoritmo de Treinamento	Levenberg-Marquardt - backpropagation
Objetivo (Erro)	1e-7
Número Máximo de Épocas	2000
<i>mu</i> Inicial	0,001
Fator de decremento de <i>mu</i>	0.1
Fator de incremento de <i>mu</i>	10
Valor máximo de <i>mu</i>	10 ¹⁰

Tabela 14 – Descrição do algoritmo de treinamento

Comando MATLAB	trainlm
Tipo	nntype.training_fcn
Função	Levenberg-Marquardt
Tipo de Função	Training Function
Título	Levenberg-Marquardt Training Function
Descrição	Levenberg-Marquardt backpropagation
Versão do Código	7
Código	nnet

Com o objetivo de se automatizar o processo de treinamento de todos os modelos neurais possíveis, conforme as combinações de entradas mostradas na Tabela 12 e número de neurônios e camadas ocultas, um programa computacional foi desenvolvido no MATLAB, cujo algoritmo é apresentado no fluxograma da Figura 17. Informações sobre o programa desenvolvido podem ser encontradas no ANEXO I.

Tabela 15 - Distribuição de neurônios em cada camada

Quantidade de neurônios nas camadas															
I	N1	N2	N3	I	N1	N2	N3	I	N1	N2	N3	I	N1	N2	N3
1	5			41	5	15	5	81	15	5	5	121	20	20	5
2	10			42	5	15	10	82	15	5	10	122	20	20	10
3	15			23	5	15	15	83	15	5	15	123	20	20	15
4	20			44	5	15	20	84	15	5	20	124	20	20	20
5	40			45	5	15	40	85	15	5	40	125	20	20	40
6	5	5		46	5	20	5	86	15	10	5	126	20	40	5
7	5	10		47	5	20	10	87	15	10	10	127	20	40	10
8	5	15		48	5	20	15	88	15	10	15	128	20	40	15
9	5	20		49	5	20	20	89	15	10	20	129	20	40	20
10	5	40		50	5	20	40	90	15	10	40	130	20	40	40
11	10	5		51	5	40	5	91	15	15	5	131	40	5	5
12	10	10		52	5	40	10	92	15	15	10	132	40	5	10
13	10	15		53	5	40	15	93	15	15	15	133	40	5	15
14	10	20		54	5	40	20	94	15	15	20	134	40	5	20
15	10	40		55	5	40	40	95	15	15	40	135	40	5	40
16	15	5		56	10	5	5	96	15	20	5	136	40	10	5
17	15	10		57	10	5	10	97	15	20	10	137	40	10	10
18	15	15		58	10	5	15	98	15	20	15	138	40	10	15
19	15	20		59	10	5	20	99	15	20	20	139	40	10	20
20	15	40		60	10	5	40	100	15	20	40	140	40	10	40
21	20	5		61	10	10	5	101	15	40	5	141	40	15	5
22	20	10		62	10	10	10	102	15	40	10	142	40	15	10
23	20	15		63	10	10	15	103	15	40	15	143	40	15	15
24	20	20		64	10	10	20	104	15	40	20	144	40	15	20
25	20	40		65	10	10	40	105	15	40	40	145	40	15	40
26	40	5		66	10	15	5	106	20	5	5	146	40	20	5
27	40	10		67	10	15	10	107	20	5	10	147	40	20	10
28	40	15		68	10	15	15	108	20	5	15	148	40	20	15
29	40	20		69	10	15	20	109	20	5	20	149	40	20	20
30	40	40		70	10	15	40	110	20	5	40	150	40	20	40
31	5	5	5	71	10	20	5	111	20	10	5	151	40	40	5
32	5	5	10	72	10	20	10	112	20	10	10	152	40	40	10
33	5	5	15	73	10	20	15	113	20	10	15	153	40	40	15
34	5	5	20	74	10	20	20	114	20	10	20	154	40	40	20
35	5	5	40	75	10	20	40	115	20	10	40	155	40	40	40
36	5	10	5	76	10	40	5	116	20	15	5				
37	5	10	10	77	10	40	10	117	20	15	10				
38	5	10	15	78	10	40	15	118	20	15	15				
39	5	10	20	79	10	40	20	119	20	15	20				
40	5	10	40	80	10	40	40	120	20	15	40				

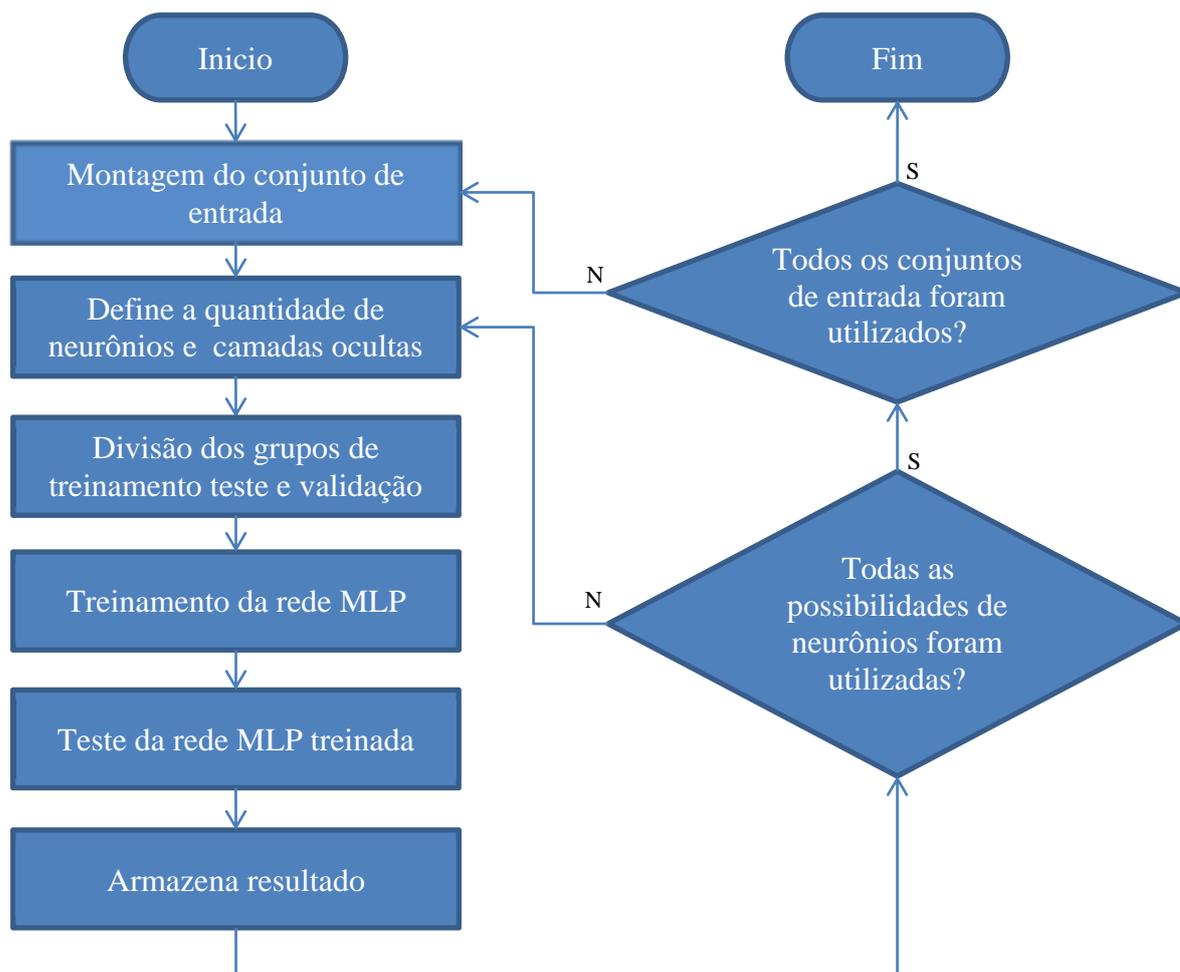


Figura 17 - Algoritmo para Automatizar o Processo de Treinamento dos modelos Neurais MLP

3.5.2 REDES NEURAIIS DE BASES RADIAIS (RBF)

Neste trabalho a função de base radial escolhida foi a gaussiana, conforme descrita pela equação (23).

$$\phi(x) = \exp\left(\frac{-x^2}{\sigma^2}\right) \quad (23)$$

Onde o parâmetro σ controla a região de influência da RBF, e é comumente referido como parâmetro de “spread” ou fator de espraiamento.

A partir de treinamentos preliminares com este tipo de rede usando o MATLAB, variou-se o fator de espraiamento para uma faixa ampla de valores. Os resultados obtidos mostraram que as redes convergiam para algumas faixas de valores para o fator de

espraiamento. Assim, adotou-se a faixa de 0,003 a 19 para o fator de espraiamento nos modelos RBF deste trabalho.

O comando utilizado para o treinamento desse modelo neural no MATLAB foi *newrb*, o qual utiliza os parâmetros mostrados na tabel Tabela 16.

Tabela 16 - Descrição do algoritmo de treinamento

Comando MATLAB	newrb
Tipo	nntype.network_fcn
Função	Radial Basis Network
Tipo de Função	Network Function
Título	Radial Basis Network Network Function
Descrição	Design a radial basis network
Versão do Código	7
Código	nnet

Com o objetivo de se automatizar o processo de treinamento de todos os modelos neurais possíveis, conforme as combinações de entradas mostradas na Tabela 12 e os valores de espraiamento, um programa computacional foi desenvolvido no MATLAB, cujo algoritmo é apresentado no fluxograma da Figura 18. Informações sobre o programa desenvolvido podem ser encontradas no ANEXO II.

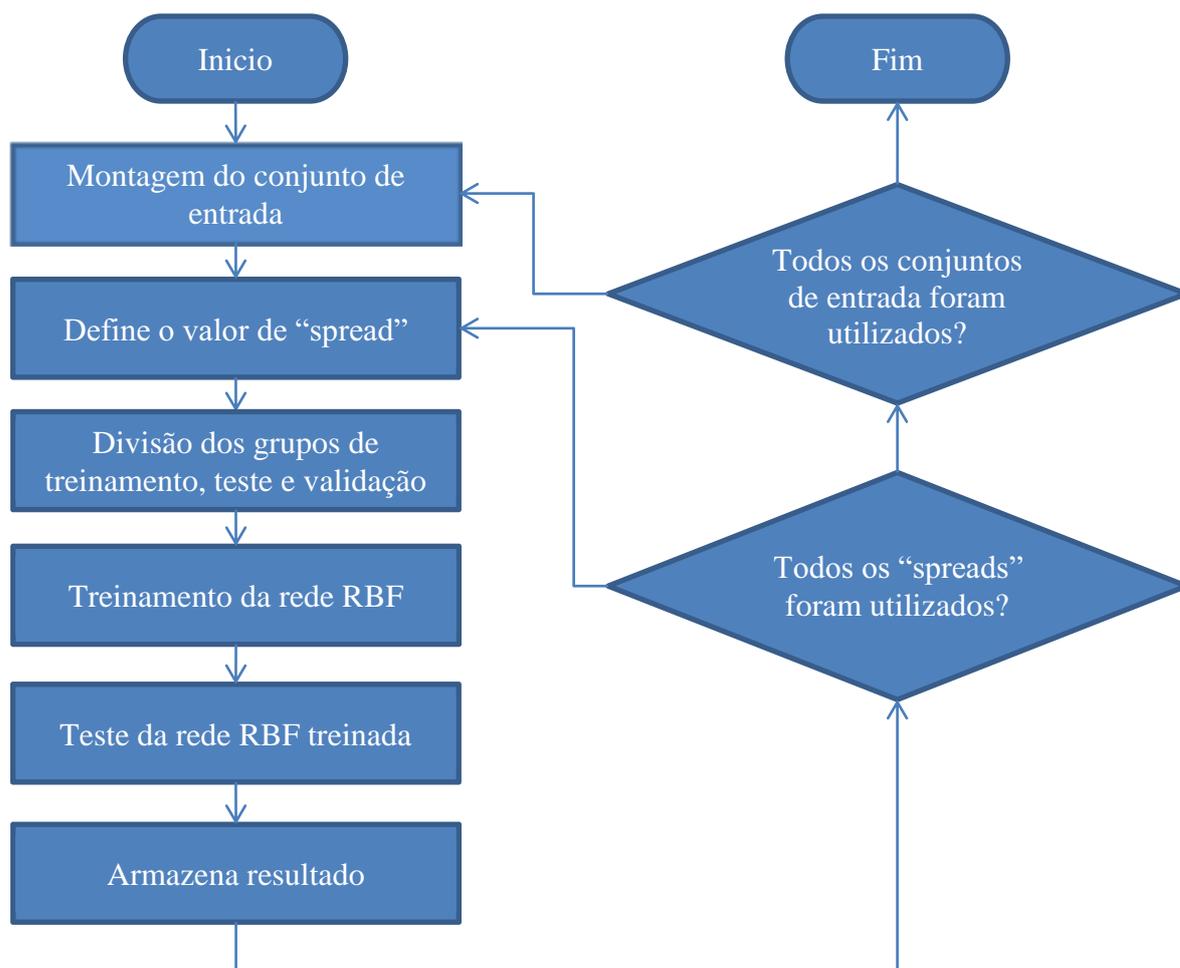


Figura 18 - Algoritmo para Automatizar o Processo de Treinamento dos modelos Neurais RBF

3.5.3 REDES NEURAIIS DE REGRESSÃO GENERALIZADA (GRNN)

Devido às características semelhantes desse tipo de rede com a rede RBF, o parâmetro de configuração ajustado e utilizado neste modelo neural também foi o “spread”, cuja variação permaneceu na faixa de 0,003 a 19. Essa faixa de valores foi escolhida pelo mesmo critério descrito anteriormente para a rede RBF.

O comando utilizado para o treinamento desse modelo neural no MATLAB foi *newgrnn*, o qual utiliza os parâmetros mostrados na tabel Tabela 17.

Para se automatizar o processo de treinamento de todos os modelos neurais possíveis, de acordo com as combinações de entradas mostradas na Tabela 12 e os valores de espraiamento, uma rotina foi desenvolvida no MATLAB, cujo algoritmo é mostrado no

fluxograma da Figura 19. Detalhes do código desenvolvido podem ser encontrados no ANEXO III.

Tabela 17 - Descrição do algoritmo de treinamento

Comando MATLAB	newgrnn
Tipo	nntype.network_fcn
Função	Generalized Regression Neural Network
Tipo de Função	Network Function
Título	Generalized Regression Neural Network Network Function
Descrição	Design a generalized regression neural network
Versão do Código	7
Código	nnet

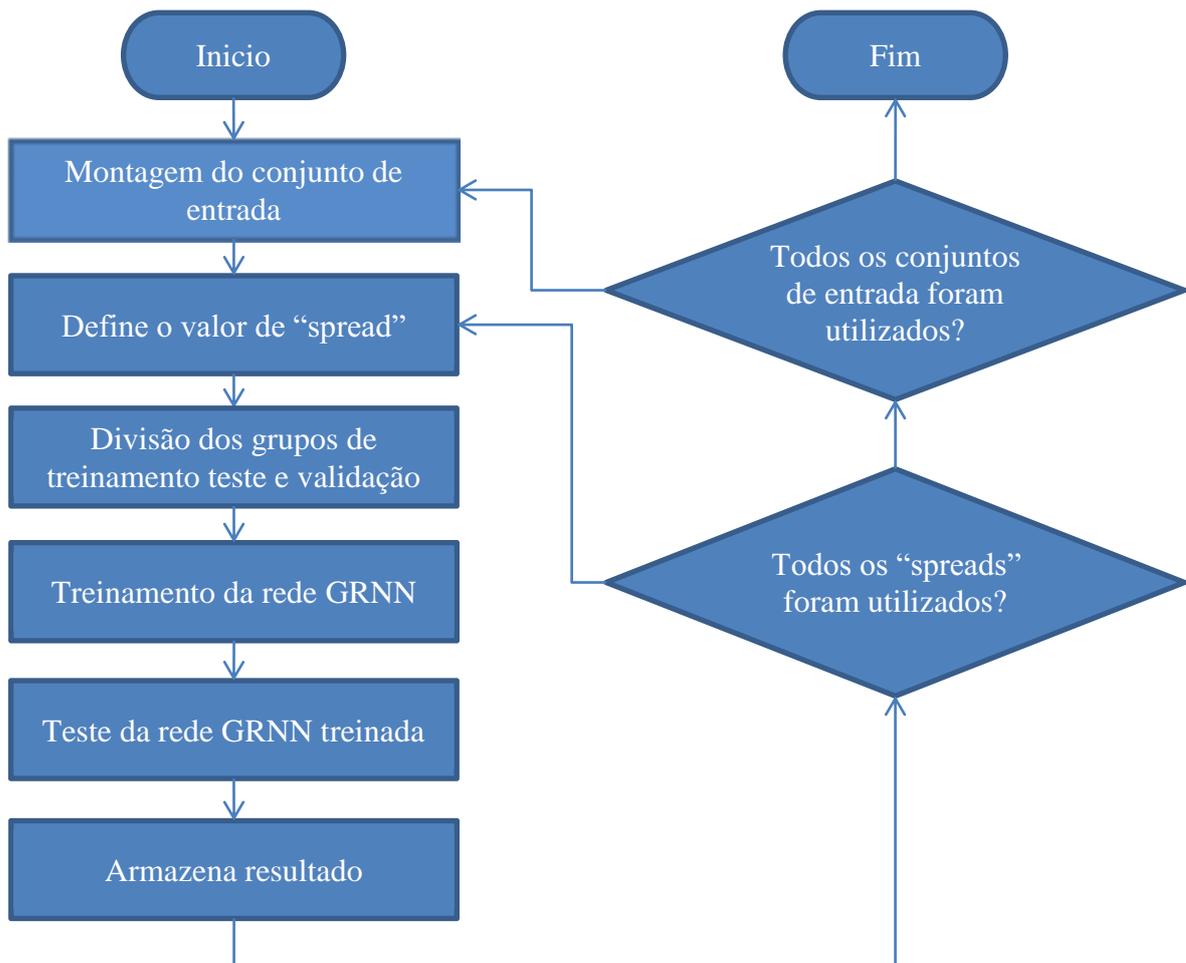


Figura 19 - Algoritmo para Automatizar o Processo de Treinamento dos modelos Neurais GRNN

3.5.4 SISTEMA DE INFERÊNCIA NEURO FUZZY ADAPTATIVO (ANFIS)

O parâmetro de configuração testado para os modelos ANFIS foi a quantidade de funções de pertinência utilizadas, sendo esta variada de 2 a 9. Esses valores foram escolhidos em treinamentos preliminares, pois se verificou que quantidades de funções de pertinência maiores que 9 não faziam com que o erro médio diminuísse.

A Tabela 18 traz as informações relativas dos parâmetros usados para os modelos ANFIS. O comando empregado para o treinamento desses modelos no MATLAB foi o *genfis3*.

Tabela 18 - Características do modelo neural ANFIS

Tipo de Função de Pertinência	Gaussiana
Método de Inferência Fuzzy	Sugeno
Objetivo (Erro)	10e-3
Número Máximo de Épocas	3000
Passo	0,01
Taxa de aumento do Passo	1,1
Taxa de diminuição do Passo	0,9
Número de Funções de Pertinência Testadas	2 a 9

Para tornar o processo automático de treinamento de todos os modelos neurais possíveis, conforme as combinações de entradas mostradas na Tabela 12 e quantidade de funções de pertinência, uma rotina foi desenvolvida no MATLAB, cujo algoritmo é apresentado no fluxograma da Figura 20. O código da referida rotina pode ser encontrado no ANEXO IV.

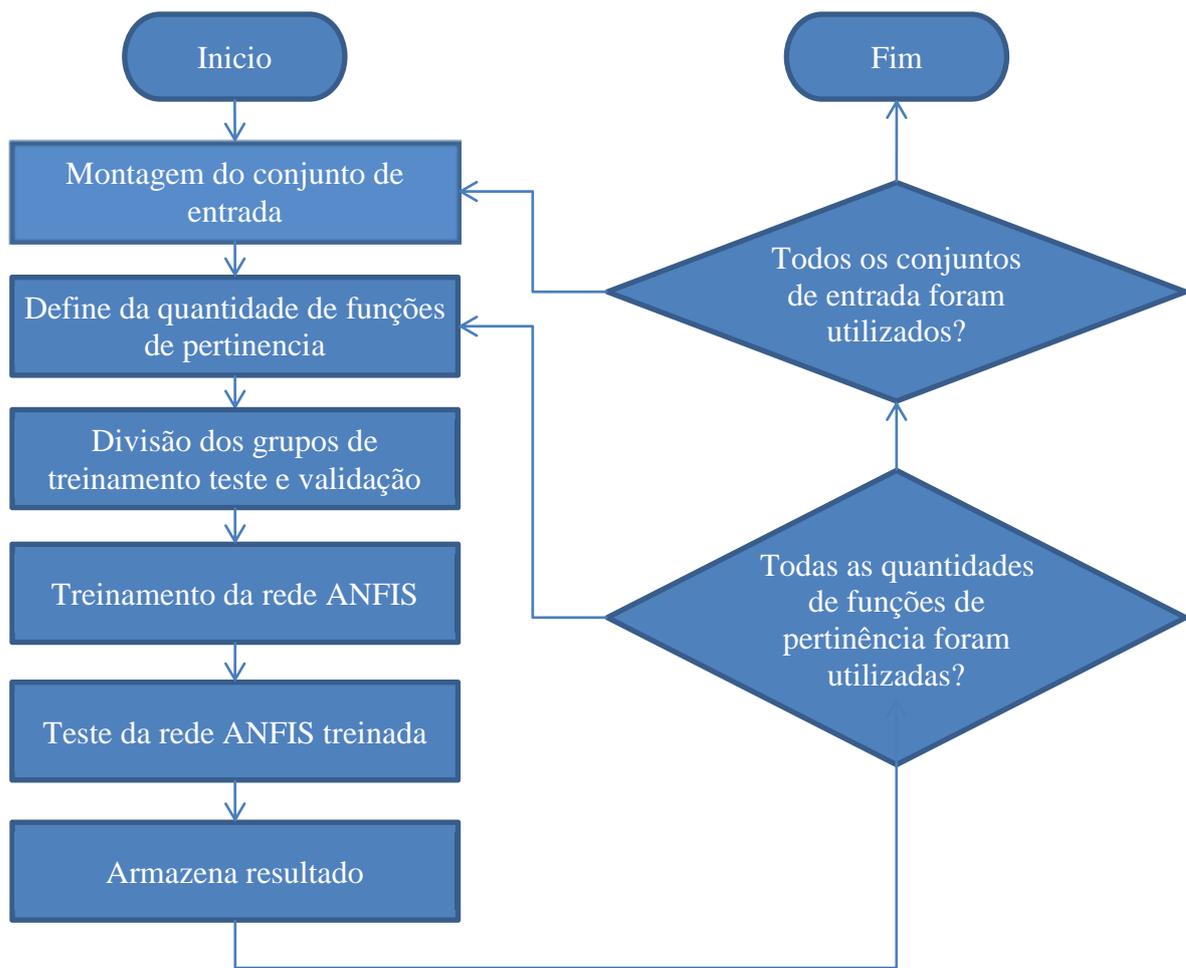


Figura 20 - Algoritmo para Automatizar o Processo de Treinamento dos modelos Neurais ANFIS

CAPITULO 4 - RESULTADOS E DISCUSSÕES

4.1 PROCESSAMENTO DO SINAL DE ENTRADA

A partir dos sinais coletados foram calculadas as estatísticas conforme descrição no item 3.3. Primeiramente, as curvas da média do sinal de emissão acústica em função do volume de material removido foram obtidas para todos os ensaios, conforme mostra a Figura 21. Nessa figura, verifica-se que quanto maior a profundidade de corte maiores são os níveis de emissão acústica. Este comportamento pode ser justificado com base na pesquisa realizada por (DORNFELD, D.; HE, 1984), em que eles constatam que o nível do sinal de EA aumenta com os efeitos combinados de desgaste do rebolo e do seu empastamento, e é proporcional a espessura de corte equivalente (heq), e conseqüentemente a profundidade de corte.

Os níveis do sinal de emissão acústica para o ensaio de 20 μ m apresentam duas quedas abruptas próximas a remoção de aproximadamente 6.000 e 10.000 mm³, respectivamente. Esses níveis ocorreram em função de desajustes no sistema de aquisição do sinal, porém foram corrigidos posteriormente. Além disso, observa-se para esse ensaio quedas abruptas menos significativas a cada 86 passadas, no final das quais se realizava as medições de rugosidade e desgaste do rebolo, acarretando esses erros quando se retomava o ensaio.

Observa-se também para o ensaio de 70 μ m um decréscimo do sinal de EA, quando se atinge uma remoção de 12.800 mm³. É possível que erros de aquisição do sinal de EA também tenham ocorrido a partir desse ponto nesse ensaio.

Cabe salientar que, embora tenham ocorrido alguns erros nos sinais, como descrito anteriormente, utilizou-se esses mesmos dados para alimentar os modelos neurais estudados neste trabalho.

Calculou-se em seguida a média do sinal de potência elétrica em Watts (W) em relação à quantidade de material removido para todos os ensaios, conforme mostra a Figura 22. Assim, como no comportamento das curvas de média para o sinal de emissão acústica, os níveis do sinal de potência elétrica também aumentam com a remoção de material da peça, mas com um crescimento muito pequeno. Este comportamento é esperado, pois a medida que o rebolo remove o material, o mesmo sofre desgaste, e, conseqüentemente, os níveis de força de corte aumentam. Esse aumento de potência é pequeno entre início e o fim de cada ensaio devido às características do rebolo diamantado, que sofre pouco desgaste ao longo do ensaio.

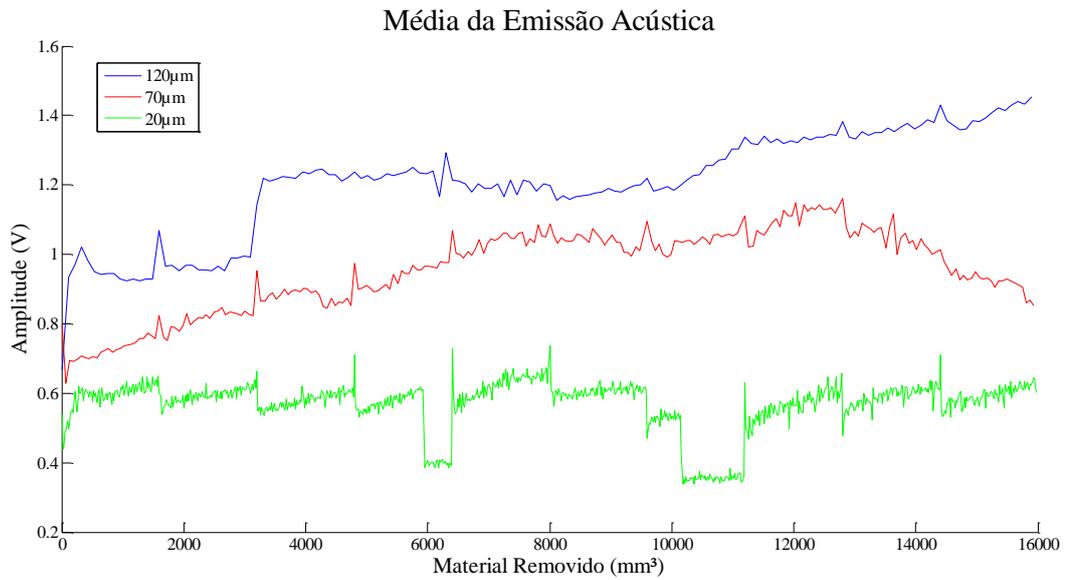


Figura 21 - Média da emissão acústica em função do volume de material removido

As mesmas considerações feitas para a média do sinal de EA quanto às duas quedas abruptas, próximas a remoção de aproximadamente 6.000 e 10.000 mm³, são aplicáveis para o sinal de potência elétrica do ensaio de 20µm. Por outro lado, o sinal de potência não apresentou os outros erros mencionados para o sinal de EA, e apresentou um comportamento mais uniforme e previsível.

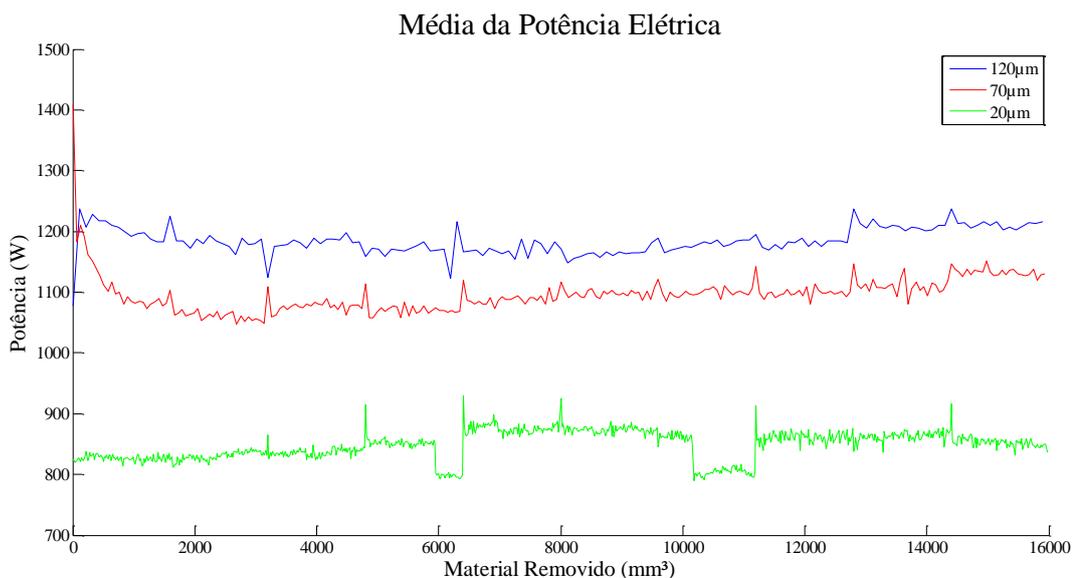


Figura 22 - Média da potência elétrica em função do volume de material removido

Em seguida se obteve o desvio padrão do sinal de emissão acústica e do sinal de potência elétrica para todos os ensaios, cujas curvas são mostradas nas Figura 23 e Figura 24, respectivamente.

Para as curvas do desvio padrão do sinal de EA, Figura 26, observa-se um comportamento ora decrescente ora crescente dos níveis dessa estatística. Isso pode ser explicado pela natureza do desvio padrão em mostrar as variações ocorridas dentro de uma população de amostras. No caso do sinal de EA, essas variações ocorreram em um nível maior ou menor, dependendo do que ocorreu com o sinal ao longo de cada passada. Além disso, houve outras variações devido à alguns erros de medições, como descrito anteriormente, em que o desvio padrão pode, portanto, evidenciar nas oscilações mostradas nessas curvas.

No caso dos resultados obtidos para o desvio padrão de potência elétrica, Figura 27, as curvas apresentam um comportamento sem variações significativas. Isso pode ser explicado pela ausência de oscilações importantes do sinal de potência ao longo de cada passada, devido a própria inércia do sistema motor elétrico de acionamento do rebolo e componentes mecânicos.

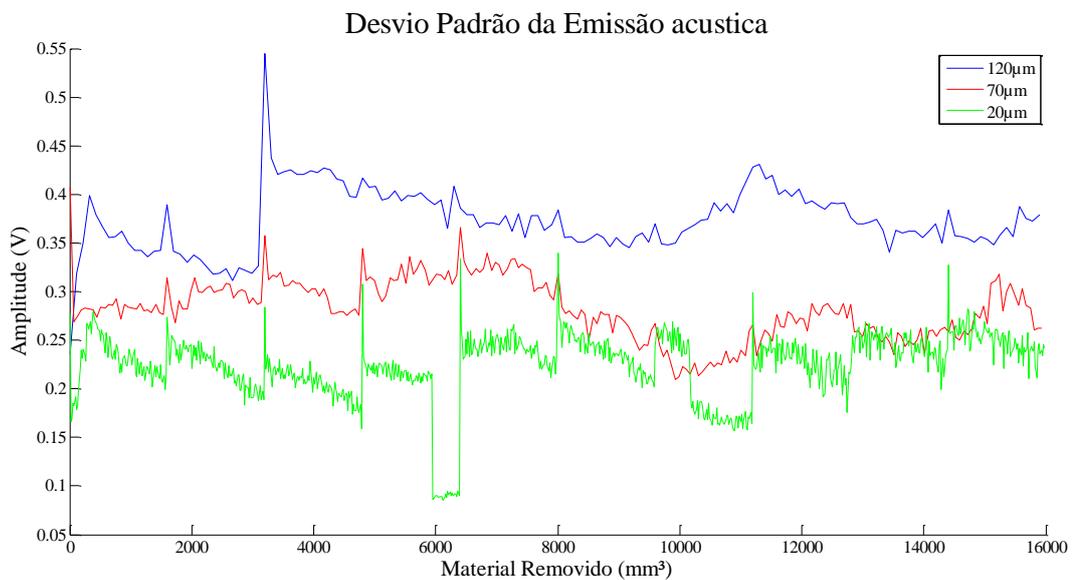


Figura 23 - Desvio padrão da emissão acústica em função do volume de material removido

As curvas da estatística DPO em função do volume de material removido são mostradas na Figura 25 para todos os ensaios. Como essa estatística é proporcional ao desvio padrão do sinal RMS de EA e do valor máximo da potência, os resultados apresentados reúnem, portanto, características do desvio padrão do sinal de EA como comentado anteriormente, bem como informação do maior valor de potência observado ao longo de cada passada. O comportamento das curvas de DPO mostradas na Figura 28 é muito semelhante ao

comportamento das curvas de desvio padrão do sinal de EA. Isto ocorreu devido a baixa variação do sinal de potência ao longo das passadas, e, conseqüentemente, o DPO se comportou, basicamente, como o desvio padrão, já que existe uma proporcionalidade direta dessas estatísticas.

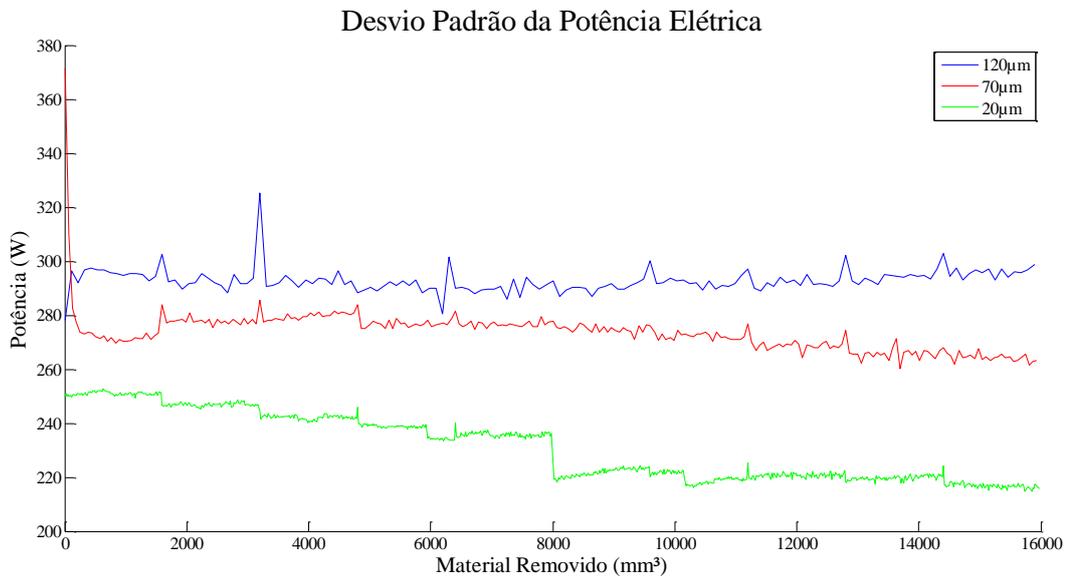


Figura 24 - Desvio padrão da potência elétrica em em função do volume de material removido

As mesmas considerações feitas anteriormente para as outras estatísticas, sobre algumas variações abruptas ocorridas ao longo das curvas, também são válidas para a estatística DPO.

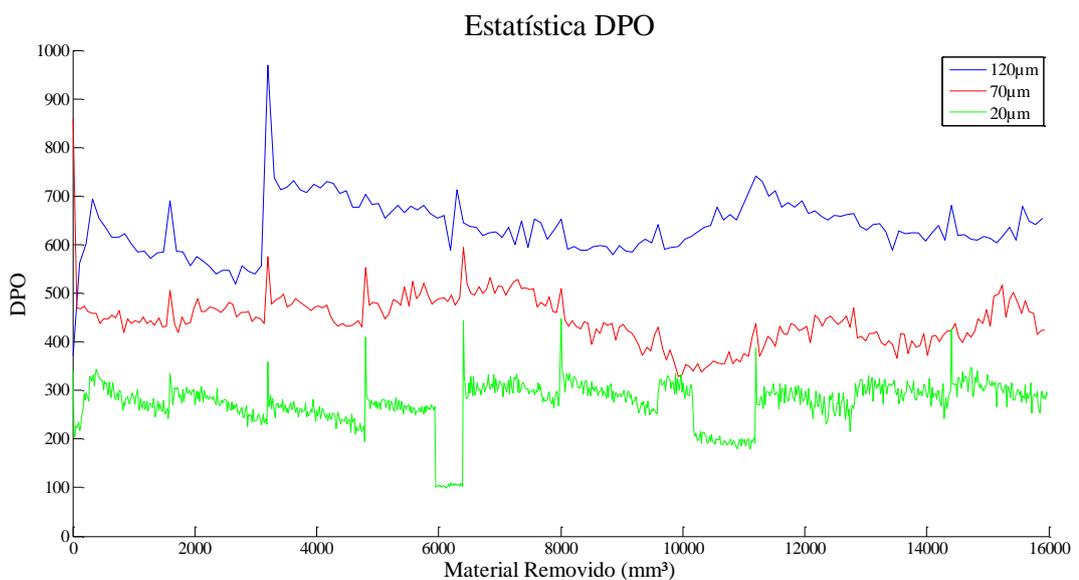


Figura 25 - Estatística DPO em relação ao volume de material removido

4.2 RESULTADOS DA INTERPOLAÇÃO DAS CURVAS DE RUGOSIDADE E DESGASTE DIAMETRAL DO REBOLO

A partir dos valores mensurados de rugosidade e desgaste do rebolo durante os ensaios, foi possível construir as curvas de tendência desses parâmetros em função do volume removido de material. Esse procedimento permitiu a geração de uma quantidade maior de dados a serem usados nos modelos neurais.

As equações (24), (26) e (28) representam os polinômios obtidos, no *Toolbox Fitting Curve* do MATLAB, para a rugosidade em função do número de passadas, para os ensaios com profundidades de corte de 20 μ m, 70 μ m e 120 μ m, respectivamente. As equações (25), (27), e (29) relacionam o número da passada (p) com o volume removido (m) até a passada (p), para os ensaios de 20 μ m, 70 μ m e 120 μ m, respectivamente.

$$r_{20}(p) = -1,453 \cdot 10^{-14} \cdot p^5 + 3,221 \cdot 10^{-11} \cdot p^4 - 2,575 \cdot 10^{-8} \cdot p^3 + 9,819 \cdot 10^{-6} \cdot p^2 - 2,349 \cdot 10^{-3} \cdot p + 8,914 \cdot 10^{-1} \quad (24)$$

$$p(m) = \frac{860}{16000} \cdot m \quad (25)$$

$$r_{70}(p) = +2,934 \cdot 10^{-10} \cdot p^4 - 2,171 \cdot 10^{-7} \cdot p^3 + 5,597 \cdot 10^{-5} \cdot p^2 - 5,871 \cdot 10^{-3} \cdot p + 7,339 \cdot 10^{-1} \quad (26)$$

$$p(m) = \frac{250}{16000} \cdot m \quad (27)$$

$$r_{120}(p) = -1,865 \cdot 10^{-7} \cdot p^3 + 6,523 \cdot 10^{-5} \cdot p^2 - 8,178 \cdot 10^{-3} \cdot p + 1,036 \quad (28)$$

$$p(m) = \frac{150}{16000} \cdot m \quad (29)$$

Onde:

$r_{20}(p)$, $r_{70}(p)$ e $r_{120}(p)$: rugosidade em função do número da passada nos ensaios 20 μ m, 70 μ m e 120 μ m;

p : número da passada;

m : volume removido no ensaio até a passa p , em mm³

A Figura 26 mostra as curvas obtidas para a rugosidade a partir das equações (24 a (29). Os coeficientes de correlação R-2 obtidos para os ajustes de curvas foi de 94,95% de exatidão para o ensaio de 20 μ m, 92,09% para o ensaio de 70 μ m, e 87,49% para o ensaio de 120 μ m. A Tabela 19 apresenta, além dos valores para o coeficiente R-2, os valores dos índices SSE e RMSE de ajustes das curvas, onde se observa valores muito baixos para esses índices, reforçando um excelente ajuste das curvas de rugosidade para todos os ensaios.

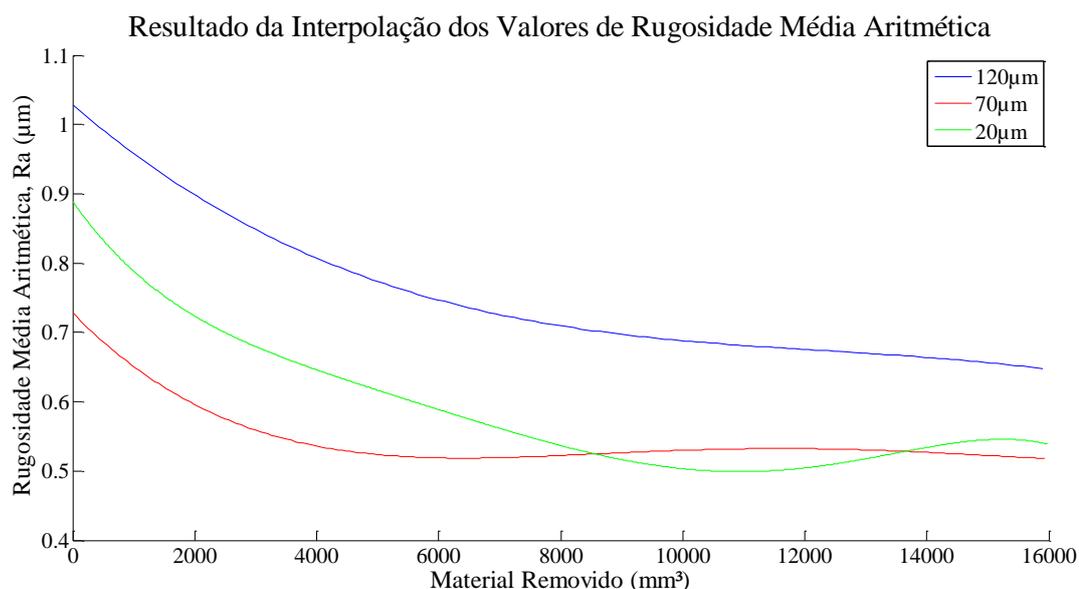


Figura 26 – Curvas ajustadas para a rugosidade em função do volume de material removido

Tabela 19 – Coeficientes estatísticos de ajuste de curvas de rugosidade

Coeficientes	Profundidades de Corte		
	20 μ m	70 μ m	120 μ m
R-2 (%)	94,95	92,09	87,49
SSE	0,007947	0,003705	0,02222
RMSE	0,03987	0,02485	0,05634

De forma semelhante a rugosidade, obteve-se os ajustes das curvas do desgaste do rebolo. As equações (30), (32) e (34) aproximam as curvas de desgastes aos dados dos ensaios de 20 μ m, 70 μ m e 120 μ m, respectivamente. As equações (31), (33) e (35) relacionam o número da passada (p) com o volume removido (m) até a passada (p), para os ensaios de 20 μ m, 70 μ m e 120 μ m, respectivamente.

A Figura 27 mostra as curvas obtidas para o desgaste do rebolo a partir das equações (30) a (35). Novamente, os coeficientes estatísticos obtidos para os ajustes das curvas

mostram que as mesmas representam muito bem os dados medidos. O menor valor de R-2 encontrado foi para o ensaio de 120µm com 98,94%, chegando a 100% para o ensaio de 20µm. Os A Tabela 20 mostra os valores obtidos para os índices de ajustes das curvas.

$$d20(p) = -3,316 \cdot 10^{-6} \cdot p^2 + 6,383 \cdot 10^{-3} \cdot p - 1,617 \cdot 10^{-3} \quad (30)$$

$$p(m) = \frac{860}{16000} \cdot m \quad (31)$$

$$d70(p) = 3,139 \cdot 10^{-7} \cdot p^3 - 1,163 \cdot 10^{-4} \cdot p^2 + 2,704 \cdot 10^{-2} \cdot p - 3,327 \cdot 10^{-2} \quad (32)$$

$$p(m) = \frac{250}{16000} \cdot m \quad (33)$$

$$d120(p) = -1,058 \cdot 10^{-6} \cdot p^3 + 1,607 \cdot 10^{-4} \cdot p^2 + 3,293 \cdot 10^{-2} \cdot p - 1,712 \cdot 10^{-2} \quad (34)$$

$$p(m) = \frac{150}{16000} \cdot m \quad (35)$$

Onde:

$d20(p)$, $d70(p)$ e $d120(p)$: desgaste em função do número da passada nos ensaios 20µm, 70µm e 120µm;

p : número da passada;

m : quantidade de material removido no ensaio em mm³, usado para gerar o gráfico.

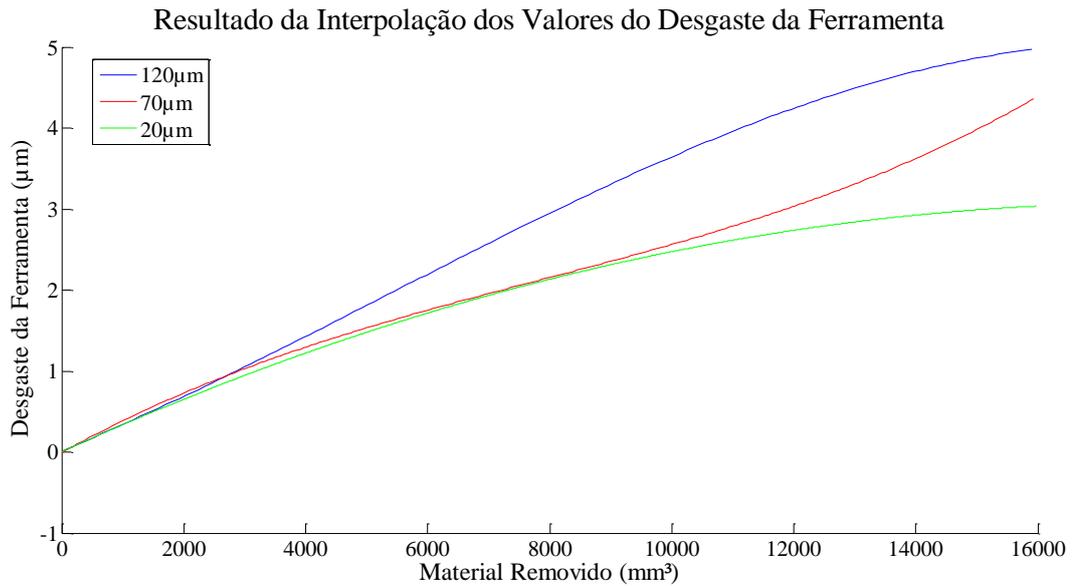


Figura 27 – Curvas ajustadas para o desgaste em função do volume de material removido.

Tabela 20 – Coeficientes estatísticos de ajuste de curvas de rugosidade

Coeficiente	Profundidades de Avanço		
	20µm	70µm	120µm
R-2 (%)	100	99,49	98,94
SSE	0,00015	0,0655	0,3278
RMSE	0,012	0,128	0,216

4.3 MODELOS NEURAI

Para o treinamento foram utilizados quatro modelos neurais, a rede neural MLP, mais utilizada e estudada para o aprendizado de tendências, a rede neural RBF, ainda pouco utilizada para os processos de fabricação, rede neural GRNN, variação da rede neural RBF, e o sistema ANFIS, um conjunto entre rede neural e sistema fuzzy, relativamente bem utilizada em processos de fabricação.

A partir da análise dos resultados, os quais serão mostrados a seguir, será possível escolher os melhores conjuntos de entradas para cada tipo de saída (rugosidade e desgaste), bem como realizar um processo de comparação entre os tipos de modelos neurais e tempos computacionais envolvidos.

4.3.1 VARIAÇÃO DO GRUPO DE ENTRADAS PARA A ESTIMAÇÃO DO DESGASTE DA FERRAMENTA

Com a utilização do algoritmo para automatizar o processo de treinamento, descrito no capítulo 3.5, realizou-se o treinamento dos modelos neurais para cada um dos ensaios. Cada treinamento foi repetido 5 vezes, obtendo-se a média e o desvio padrão do erro dessas repetições. Isto possibilitará a escolha da melhor combinação de entradas e parâmetros do modelo neural estudado.

4.3.1.1 Redes Neurais Perceptron de Múltiplas Camadas (MLP)

As Figura 28, Figura 29 e Figura 30 exibem os erros percentuais dos melhores grupos de entradas para o desgaste de ferramenta, nas profundidades de 120 μ m, 70 μ m e 20 μ m, respectivamente. Os grupos de entradas são representados no eixo y na ordem crescente do erro percentual médio. O erro percentual médio e o desvio padrão das 5 repetições são mostrados no eixo x.

Na Figura 28 se observa uma variação muito grande entre o maior e menor erro encontrado para as possíveis combinações neurais deste tipo de rede. O modelo neural com maior erro (39%) também foi o que apresentou maior desvio padrão, significando que os erros ocorridos nas 5 repetições realizadas sofreram variações muito grandes, e, conseqüentemente reflete uma modelo impreciso e de baixa convergência. Esse modelo considerou apenas o desvio padrão do sinal de potência, o qual apresentou um comportamento com pouca variação, alta repetibilidade.

Outros resultados com grandes erros são observados quando o sinal de potência e ou seu desvio padrão são considerados como entradas dos modelos neurais. Assim, o sinal de potência não traz características de bom aprendizado para os modelos neurais.

Por outro lado, o modelo que apresentou melhor erro (4,19%), cujas entradas são a média do sinal de EA, DPO e desvio padrão de EA, produziu um desvio padrão pequeno do erro, estimando o desgaste com uma precisão muito boa. Observa-se ainda, nesse gráfico, que vários modelos apresentaram valores de erros próximos ao de menor erro. No entanto, esses modelos além de apresentarem um erro médio maior, embora essa diferença seja pequena, apresentaram um valor de desvio padrão maior. Esses modelos que apresentaram erros relativamente pequenos possuem, em geral, a média do sinal de EA, DPO e ou desvio padrão de EA como entradas. Isto significa que o sinal de EA e ou as estatísticas derivas desse sinal favorecem significativa o aprendizado dos modelos neurais estudados.

O menor desvio padrão do erro percentual médio foi de 0,64%, cuja entrada foi a média do sinal de EA, DPO e o desvio padrão do sinal de EA. O maior desvio padrão do erro percentual médio foi de 10,46%, cuja entrada é o desvio padrão da potência.

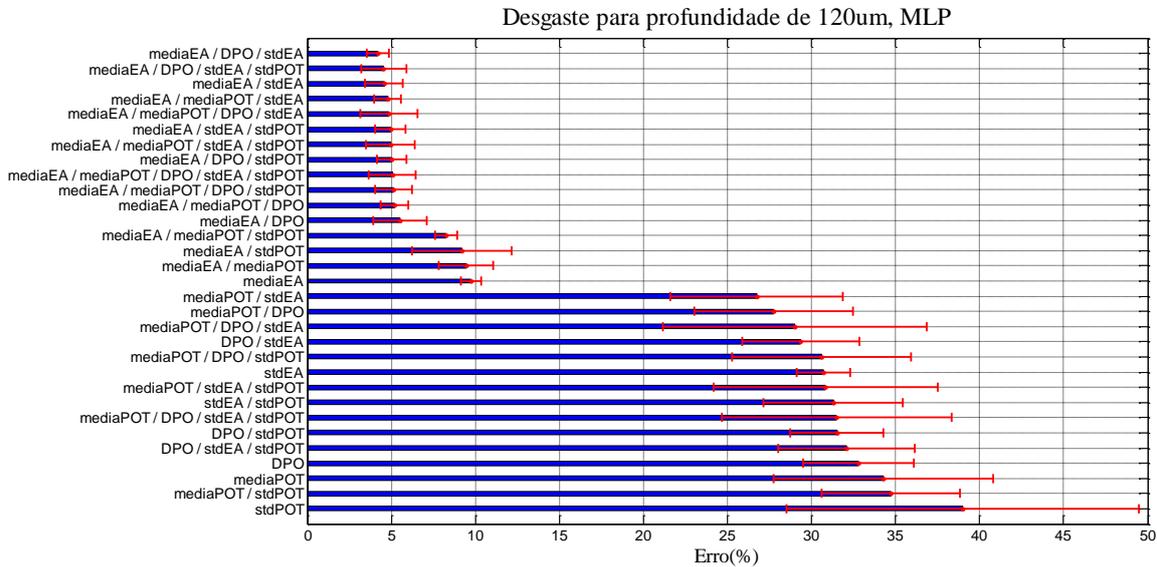


Figura 28 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 120µm, modelo neural MLP

Na Figura 29 o menor erro percentual obtido foi de 4,8%, cujas entradas são a média do sinal de EA, média da potência, DPO e o desvio padrão da potência. O maior erro percentual foi de 30,44% usando a estatística DPO como entrada. Neste ensaio observa-se que a média do sinal de EA e o desvio padrão da potência estão presentes nos 5 modelos de melhor desempenho. Isto significa que estes dois sinais favoreceram significativamente o aprendizado dos modelos neurais estudados.

Observa-se, também, que os 2 modelos neurais de melhor desempenho possuem 4 entradas e o terceiro melhor modelo possui 5 entradas, demonstrando que a quantidade de entradas também foi significativa para o aprendizado da rede.

Na Figura 30, o menor erro obtido foi de 4,04%, cujas entradas são a média do sinal de EA, a média da potência, DPO, desvio padrão do sinal de EA e o desvio padrão da potência, e o maior erro obtido foi de 38,73% com o desvio padrão de EA apenas como entrada do modelo. Observa-se que a média do sinal de EA e o desvio padrão da potência estão presentes nos 6 melhores modelos, demonstrando que esses sinais são muito significativos para o aprendizado dos modelos neurais estudados. Estes 6 melhores modelos apresentam erros percentuais médios muito próximos, variando de 4,04% a 4,79%.

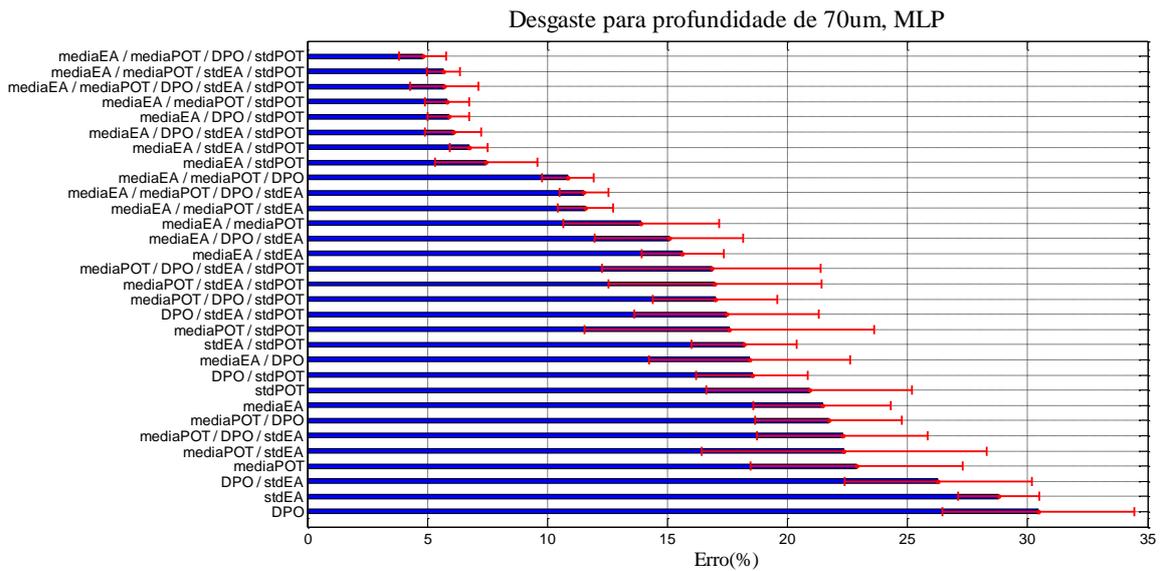


Figura 29 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 70 μ m, modelo neural MLP

Os desvios padrões obtidos no ensaio de 20 μ m foram menores que os obtidos nos demais ensaios, devido à quantidade de passadas utilizadas para o treinamento. O valor total de passadas utilizadas para o ensaio de 20 μ m foi de 860, valor muito maior que 150 e 250 passadas utilizadas nos ensaios de 120 μ m e 70 μ m, respectivamente.

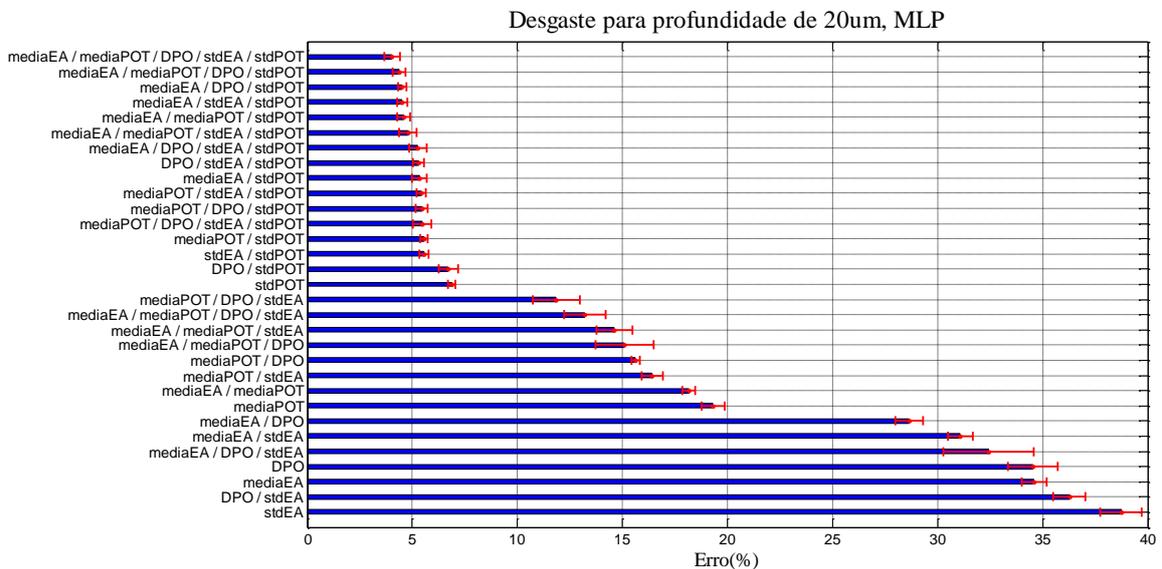


Figura 30 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 20 μ m, modelo neural MLP

4.3.1.2 Redes Neurais de Bases Radiais (RBF)

Nas Figura 31, Figura 32 e Figura 33 podem-se verificar os erros percentuais da rede em relação ao conjunto de entrada, para as profundidades de 120 μ m, 70 μ m e 20 μ m, respectivamente, sendo os grupos de entrada representados no eixo y e o erro percentual no eixo x. O erro percentual médio e o desvio padrão das 5 repetições são mostrados no eixo x.

Na Figura 31 o melhor erro percentual obtido foi de 6,07% e seu desvio padrão foi de 1,19%, cujas entradas foram a média do sinal de EA e o desvio padrão do sinal de EA. O segundo melhor modelo neural obteve erro percentual de 12,74%. As demais redes obtiveram erros percentuais médios maiores que 20% demonstrando que a rede neural RBF só tem desempenho satisfatório para o modelo com menor erro percentual obtido. O maior erro percentual obtido foi de 49,55%.

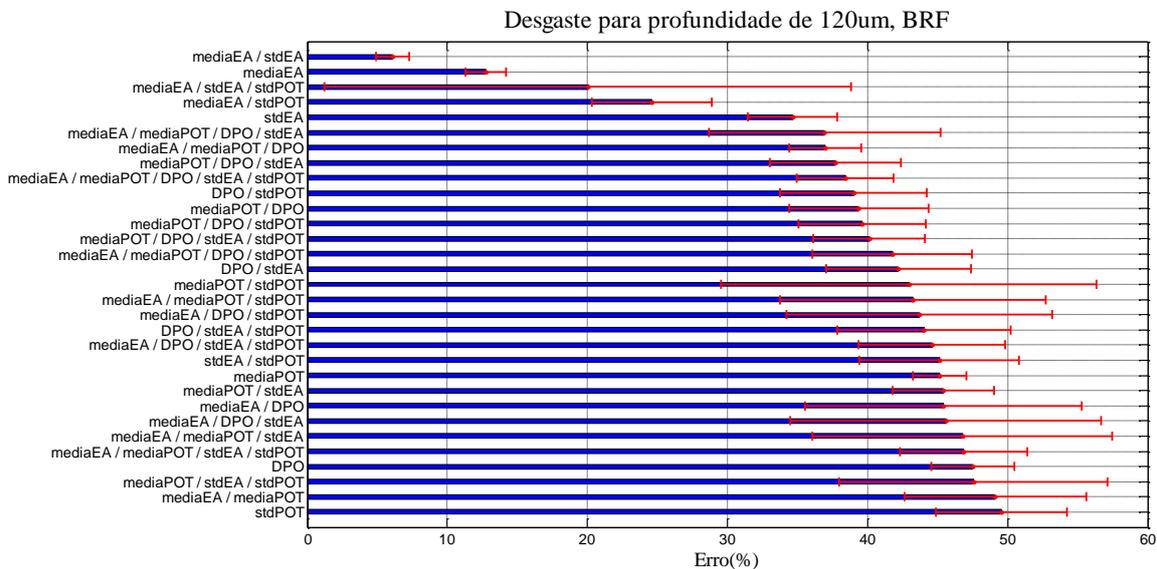


Figura 31 – Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 120 μ m, modelo neural RBF

Na Figura 32 observa-se um comportamento parecido com o obtido na Figura 31, onde o melhor modelo obteve erro percentual médio de 4,87%, cujas entradas são a média do sinal de EA, desvio padrão do sinal de EA e o desvio padrão da potência, e o segundo modelo neural obteve erro percentual médio de 6,09%. Os demais modelos neurais obtiveram erros percentuais médios maiores que 15%, chegando a 55,37%. Os desvios padrões também foram pequenos para os dois melhores modelos neurais, 0,61 e 0,95, respectivamente. O maior desvio padrão do erro percentual obtido foi de 17,61% cujas entradas são a média do sinal de EA, DPO, desvio padrão do sinal de EA e o desvio padrão da potência.

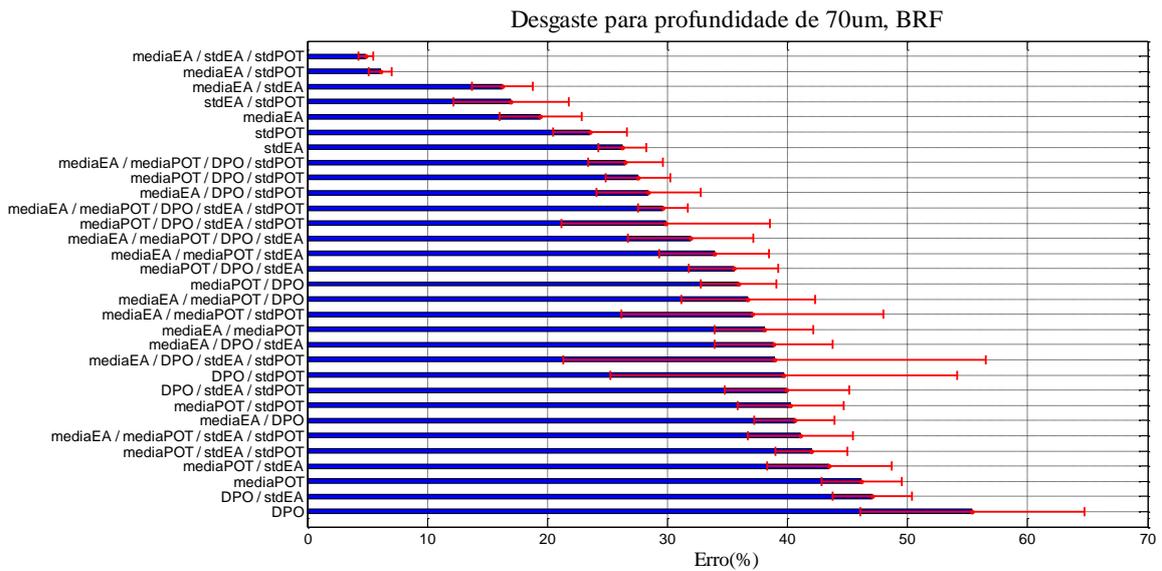


Figura 32 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 70µm, modelo neural RBF

Na Figura 33 o menor erro percentual médio obtido foi de 3,83%, com desvio padrão de 0,22%, tendo como entradas a média do sinal de EA, o desvio padrão do sinal de EA e o desvio padrão da potência. Somente os 3 melhores modelos obtiveram erros percentuais menores que 5%. O maior erro percentual médio obtido foi de 442.31% cuja entrada é a estatística DPO, com desvio padrão do erro percentual de 600%, demonstrando que este modelo neural não convergiu. Este valor foi omitido do gráfico, pois inviabilizava a visualização dos erros dos demais modelos neurais.

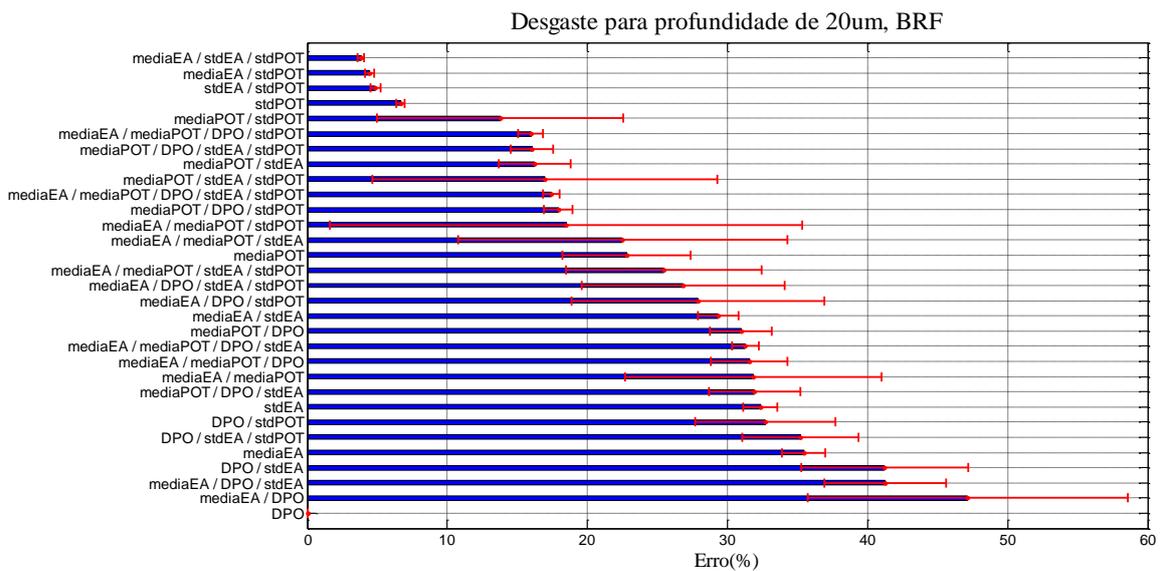


Figura 33 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 20µm, modelo neural RBF

Este ensaio obteve os melhores e os piores valores de erro percentual para a rede neural RBF na estimação do desgaste da ferramenta.

4.3.1.3 Redes Neurais de Regressão Generalizada (GRNN)

Os erros percentuais em relação ao conjunto de entrada podem ser visualizados nas Figura 34, Figura 35 e Figura 36, para as profundidades de 120µm, 70µm e 20µm, respectivamente; o conjunto de entradas está representado no eixo y e o erro percentual no eixo x. O erro percentual médio e o desvio padrão das 5 repetições são mostrados no eixo x.

Na Figura 34 se observa o mesmo comportamento da Figura 31, possivelmente por ser a rede GRNN derivada da rede RBF. O melhor erro percentual obtido foi de 5,35% com desvio padrão de 0,96%, cujas entradas são a média do sinal de EA e o desvio padrão do sinal de EA. O maior erro percentual obtido foi de 42,11%, com desvio padrão do erro de 2,23%, cuja entrada é o desvio padrão da potência.

Como se pode observar, apenas um modelo obteve bom desempenho, os demais obtiveram erros percentuais maiores que 10%, sendo que o maior desvio padrão foi de 10,57% para o modelo cujas entradas são a média do sinal de EA, DPO, desvio padrão do sinal de EA e desvio padrão do sinal de potência.

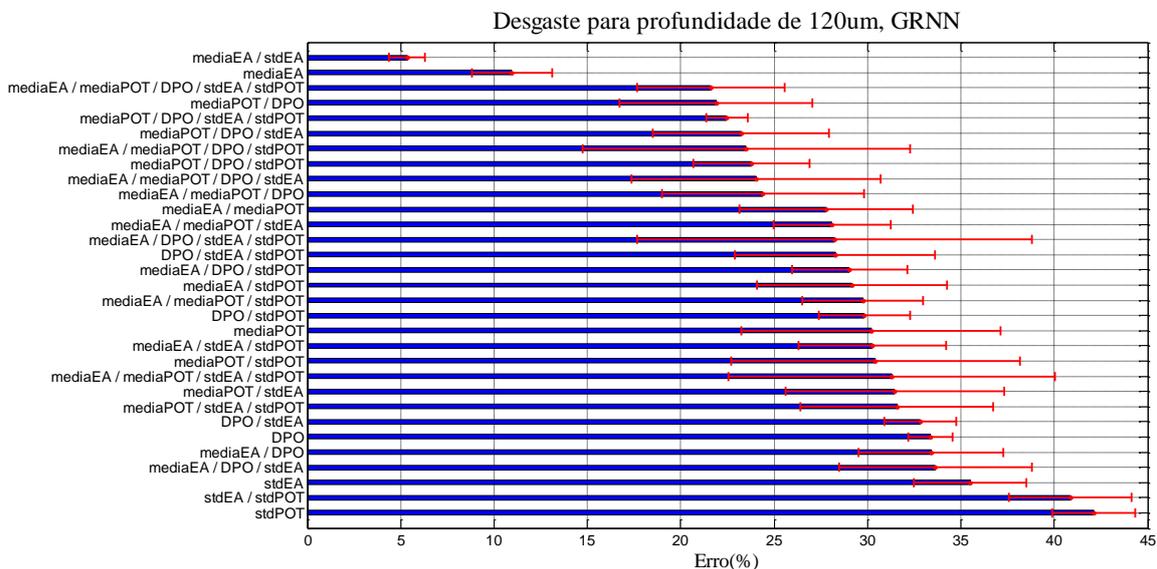


Figura 34 - Erro e desvio padrão do erro para o desgaste da ferramenta o ensaio de 120µm, modelo neural GRNN

Na Figura 35, o menor erro percentual foi de 8,05% para o modelo cujas entradas são a média do sinal de EA, e o desvio padrão do sinal de EA, e o maior erro percentual obtido foi de 28,75% para o modelo cuja entrada é o desvio padrão da emissão acústica.

Apesar de não possuir erro percentual baixo, o desvio padrão máximo foi de 3,96%, demonstrando uma menor variação nos resultados de treinamentos que as redes RBF, para a mesma profundidade de corte de 70µm (Figura 32), que obteve desvio padrão máximo de 17,61%.

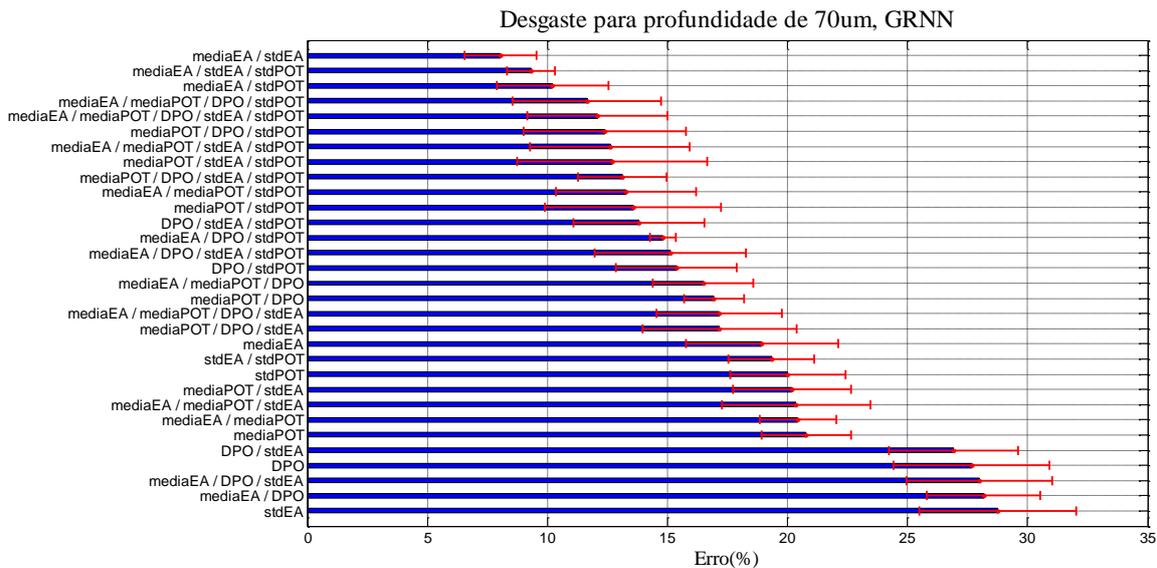


Figura 35 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 70µm, modelo neural GRNN

Na Figura 36 o erro percentual mínimo obtido foi de 4,84%, cujas entradas são a média do sinal de EA, média da potência, DPO e desvio padrão da potência. O maior valor obtido foi de 36,73%, cuja entrada do modelo é a média do sinal de EA.

Observa-se um comportamento parecido com a rede MLP para o mesmo ensaio (Figura 30), os 13 primeiros modelos neurais obtiveram erros percentuais próximos (4,84% a 5,24%).

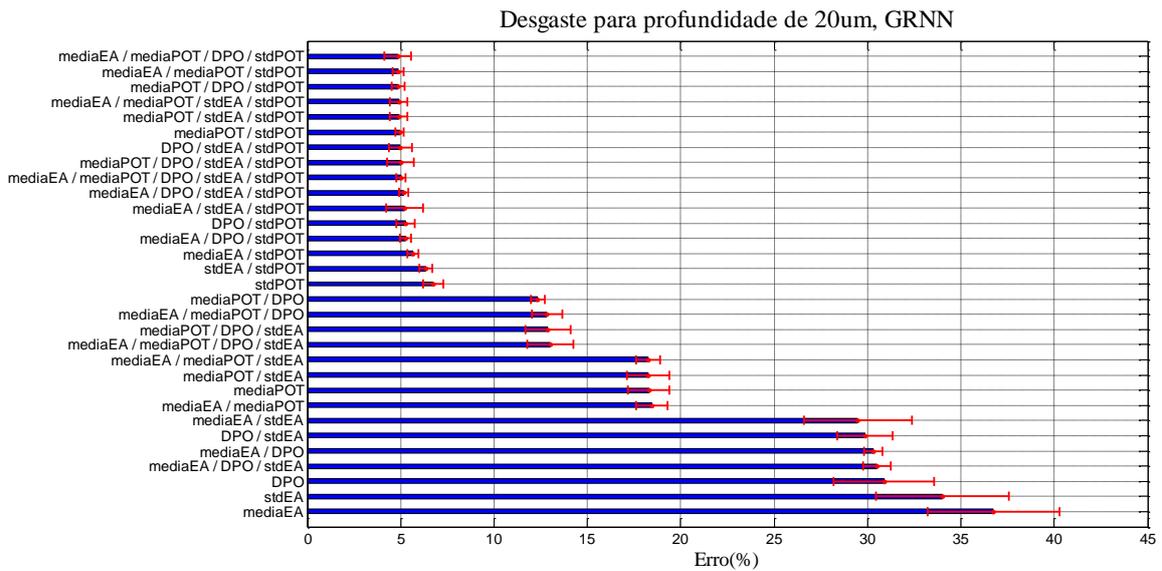


Figura 36 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 20µm, modelo neural GRNN

4.3.1.4 Sistema de Inferência Neuro Fuzzy Adaptativo (ANFIS)

As

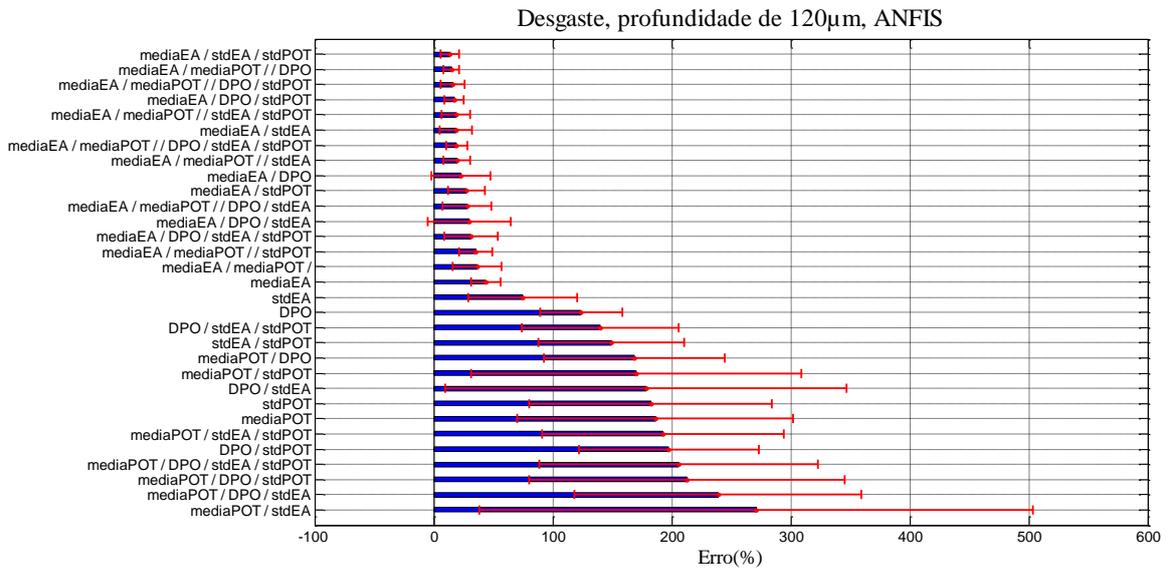


Figura 37, Figura 38 e Figura 39 exibem os resultado do treinamento do sistema ANFIS para as os ensaios de 120µm, 70µm e 20µm, respectivamente, sendo o grupo de entradas representado no eixo y e o erro percentual no eixo x. O erro percentual médio e o desvio padrão das 5 repetições são mostrados no eixo x.

Os erros percentuais e os desvios padrões obtidos neste tipo de modelo neural foram os maiores entre os tipos de modelos neurais estudados, demonstrando que o modelo ANFIS não é uma boa ferramenta para a estimação do desgaste do rebolo.

Na Figura 37, o menor erro percentual obtido foi de 13,70% para o modelo cujas entradas são a média do sinal de EA, o desvio padrão do sinal de EA, e o desvio padrão da potência. O maior erro percentual obtido foi de 271,26%, e o desvio padrão do erro variou de 6,54% a 232,54%.

Na Figura 38 o menor erro percentual obtido foi de 5,48% para o modelo cujas entradas são a média do sinal de EA, o desvio padrão do sinal de EA, e o desvio padrão da potência. O maior erro obtido foi de 242,88%, e o desvio padrão variou entre 1,34% e 295,32%.

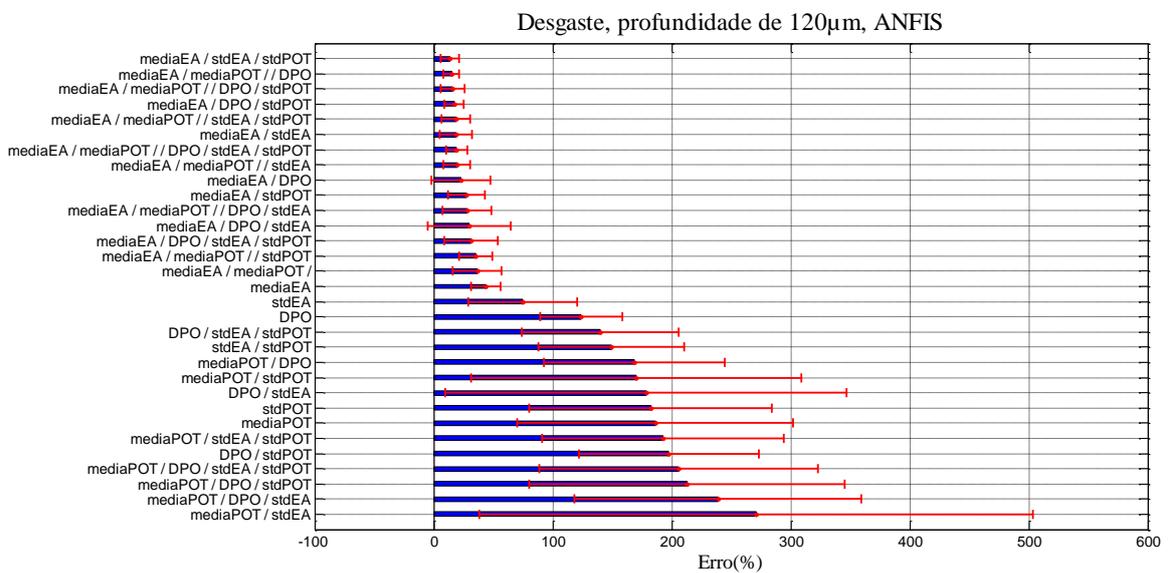


Figura 37 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 120µm, modelo neural ANFIS.

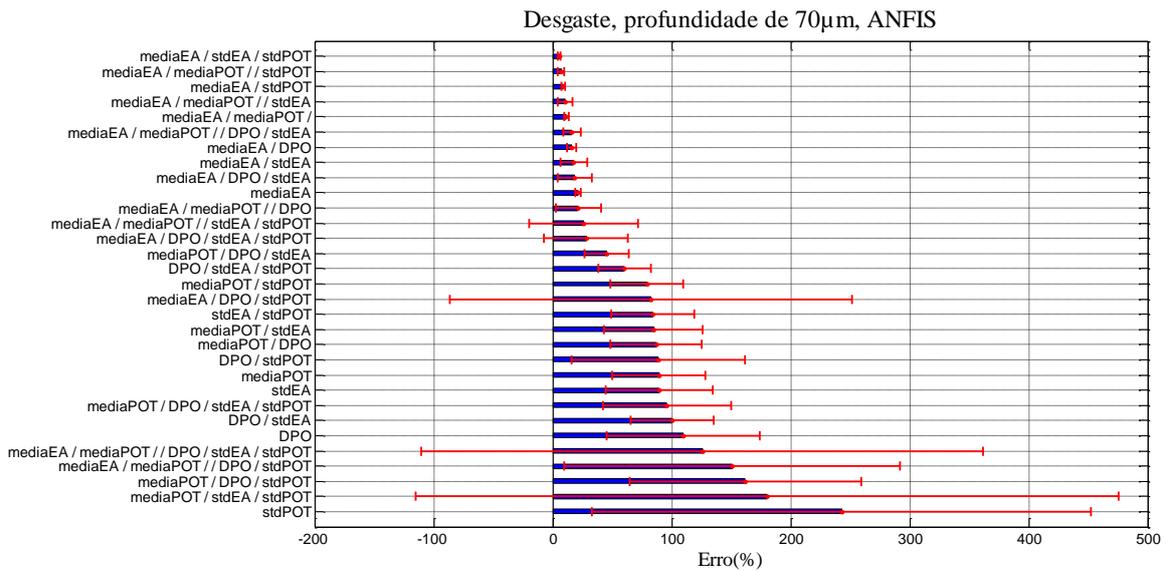


Figura 38 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 70 μ m, modelo neural ANFIS

Na Figura 39 o menor erro percentual foi de 8,87% cujas entradas utilizadas são a média do sinal de EA, média da potência, desvio padrão do sinal de EA, e desvio padrão da potência. O maior erro percentual obtido foi de 150,50%, e o desvio padrão variou entre 0,83% e 71,37%.

Entre os três ensaios treinados com o modelo ANFIS, esse foi o que obteve o melhor desempenho, pois a quantidade de passadas utilizadas para o treinamento foi a maior, ou seja, 860 passadas. No entanto, o sistema ANFIS apresentou um desempenho inferior comparado com os outros tipos de modelos neurais estudados, demonstrando que o mesmo não constitui uma boa ferramenta para a estimação do desgaste do rebolo.

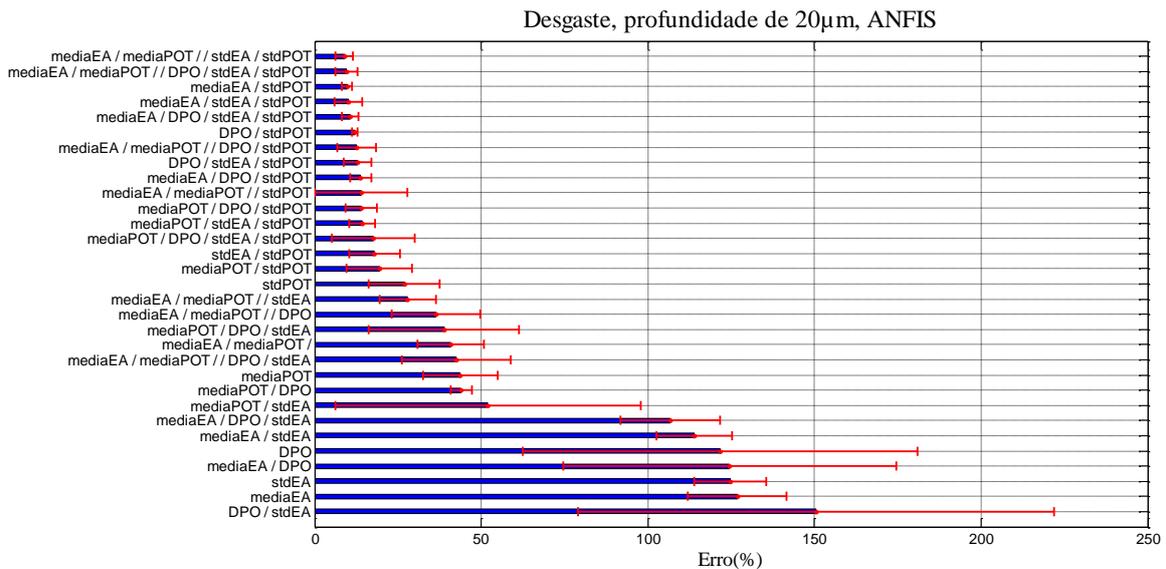


Figura 39 - Erro e desvio padrão do erro para o desgaste da ferramenta para o ensaio de 20 μ m, modelo neural ANFIS

4.3.2 VARIAÇÃO DO GRUPO DE ENTRADA PARA A ESTIMAÇÃO DA RUGOSIDADE DA PEÇA

Os erros percentuais e os desvios padrões foram obtidos através do algoritmo descrito no item 3.5. Cada treinamento foi repetido 5 vezes, obtendo-se a média e o desvio padrão do erro dessas repetições. Com a média do erro foi possível organizar os grupos de entrada em função do erro percentual médio.

4.3.2.1 Redes Neurais Perceptron de Múltiplas Camadas (MLP)

As Figura 40, Figura 41 e Figura 42 exibem os erros percentuais médios dos melhores grupos de entradas para os ensaios de 120 μ m, 70 μ m e 20 μ m, respectivamente. Os grupos de entrada treinados estão representados no eixo y e os erros médios percentuais no eixo x.

Na Figura 40 o melhor erro percentual obtido foi de 1,02%, com desvio padrão de 0,17% para o modelo cujas entradas são a média do sinal de EA, média da potência, DPO e o desvio padrão do sinal de EA. O maior erro percentual médio obtido foi de 9,49% para o modelo neural cuja entrada é o desvio da potência.

Pode-se verificar que as 9 melhores redes possuem erros muito próximos, variando entre 1,02% e 1,11%, sendo que a média do sinal de EA faz parte de todas essas redes, demonstrando que sua contribuição foi significativa para o aprendizado da rede neural.

Os desvios padrões variaram de 0,11% a 1,66%, demonstrando a repetibilidade desses modelos neurais para a estimação da rugosidade da peça.

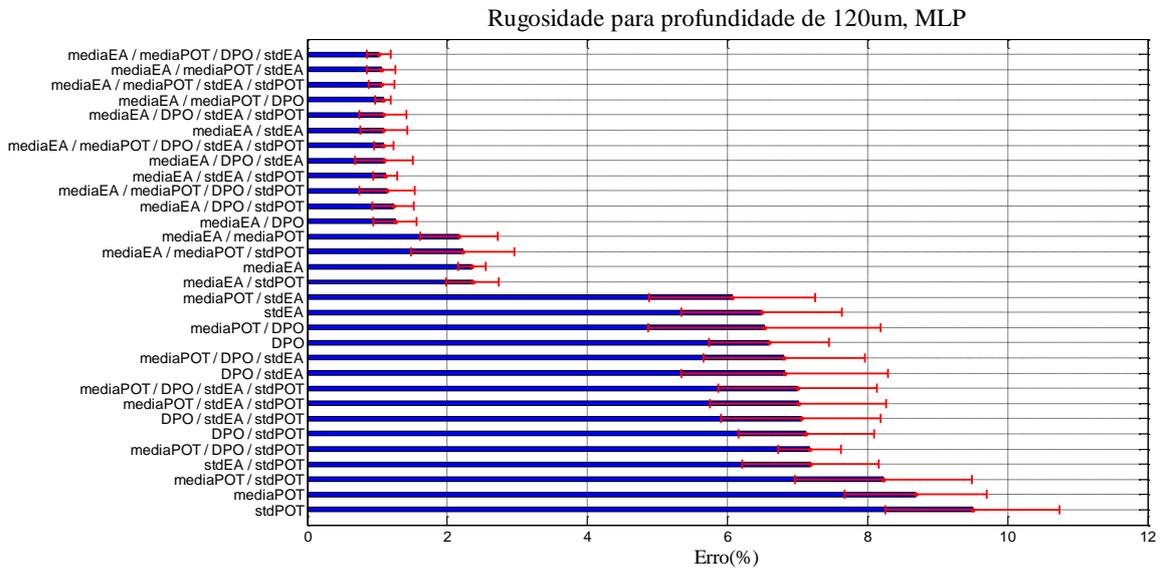


Figura 40 – Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 120µm, modelo neural MLP

Na Figura 41, o menor erro percentual obtido foi de 0,51%, com desvio padrão de 0,10% para o modelo cujas entradas foram a média do sinal de EA, média da potência, desvio padrão do sinal de EA, e desvio padrão da potência. O maior erro percentual obtido foi de 6,42%.

O desvio padrão teve variação de 0,08% a 0,84%, demonstrando a repetibilidade da rede neural MLP em relação à estimação da rugosidade.

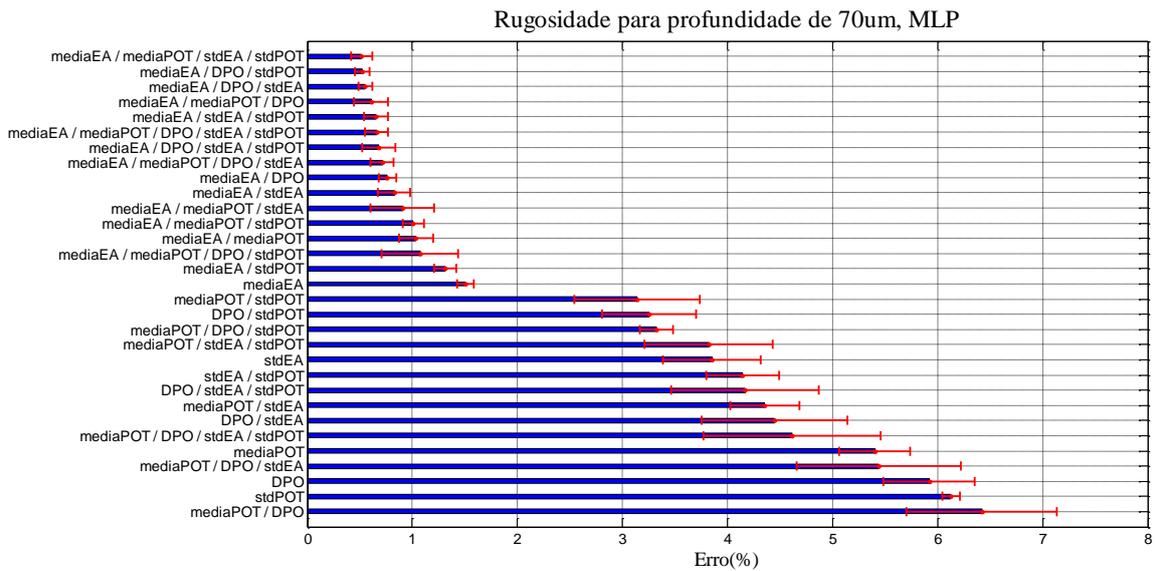


Figura 41 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça o ensaio de 70um, modelo neural MLP

Na Figura 42, o menor erro percentual obtido foi de 1,00%, com desvio padrão de 0,11% para o modelo cujas entras foram a média do sinal de EA, desvio padrão do sinal de EA, e desvio padrão da potência. O desvio padrão foi o menor entre todos os ensaios treinados com a rede MLP, que possui variação entre 0,01% a 0,35%, demonstrando uma ótima repetibilidade.

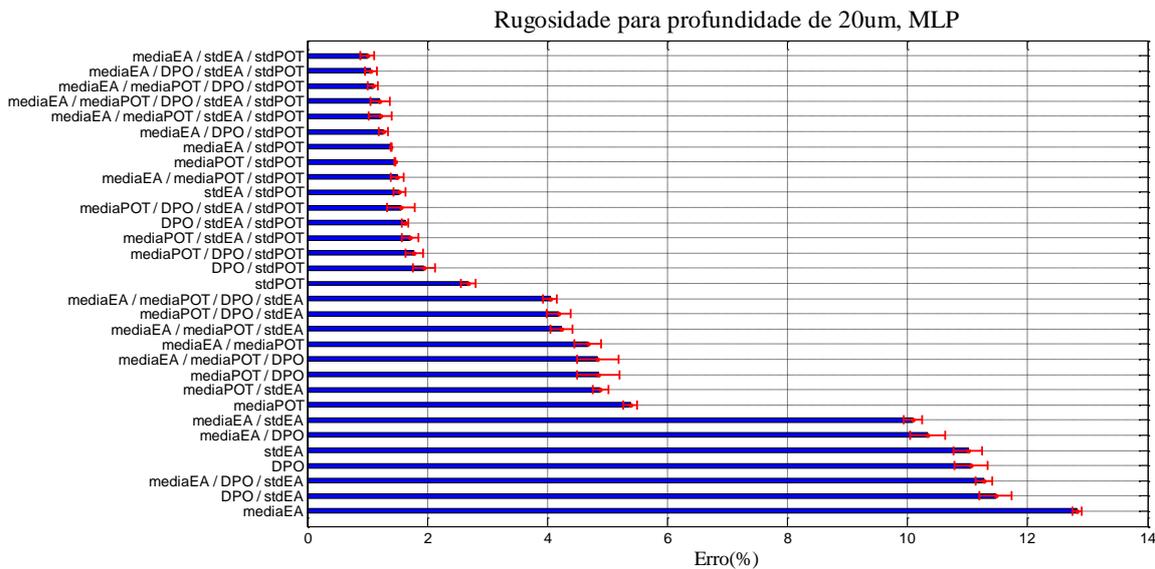


Figura 42 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 20um, modelo neural MLP

4.3.2.2 Redes Neurais de Bases Radiais (RBF)

As Figura 43, Figura 44 e Figura 45 exibem os erros percentuais médios dos grupos de entradas para os ensaios de 120 μ m, 70 μ m e 20 μ m, sendo que o eixo y representa os grupos de entrada e o eixo x o erro percentual médio.

Na Figura 43, o menor erro percentual obtido foi de 1,14% com desvio padrão de 0,18%. O maior erro percentual foi de 11,88%, e o desvio padrão variou de 0,18% a 2,42%. Observa-se que maior parte dos modelos testados obtiveram erros maiores que 6%, erros muito maiores que os obtidos na rede neural MLP, onde vários conjuntos obtiveram resultados menores que 1,5% (Figura 40).

Os desvios padrões obtidos na rede MLP também foram menores, demonstrando que a rede RBF possui grande variação nos resultados obtidos. O sinal de EA também se mostrou bastante significativo no aprendizado da rede RBF neste ensaio.

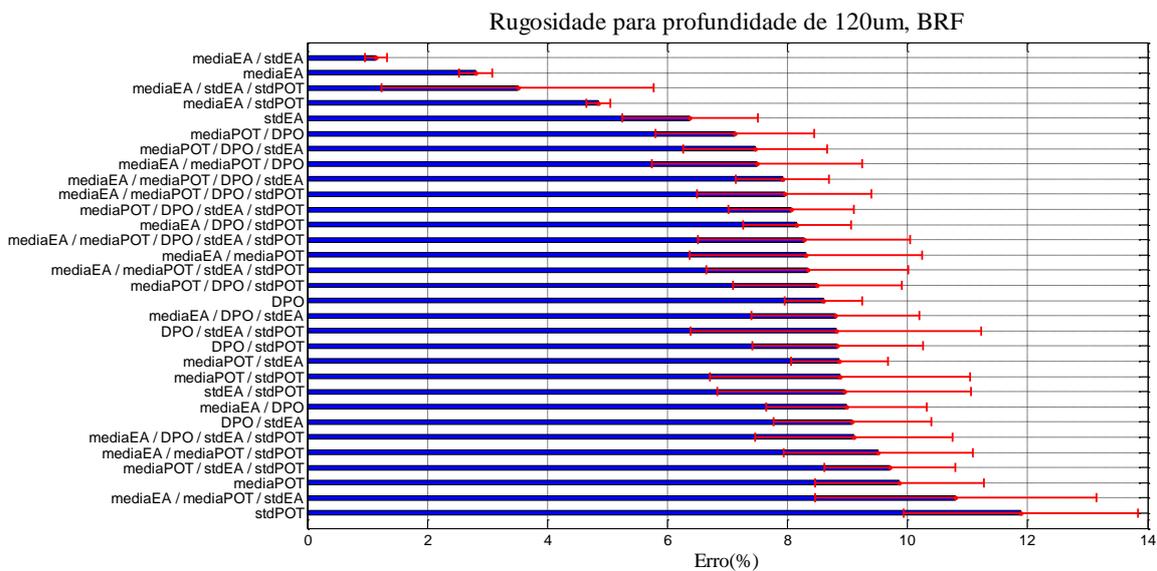


Figura 43 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 120 μ m, modelo neural RBF

Na Figura 44, o menor erro médio obtido foi de 0,57% com um desvio padrão de 0,11% para o modelo cujas entradas utilizadas foram a média do sinal de EA e o desvio padrão do sinal de EA. O maior erro percentual obtido foi de 5,43%.

O comportamento da rede pra esse ensaio obteve um desempenho geral melhor do que o ensaio de 120 μ m (Figura 43). Os 4 melhores modelos neurais obtiveram erros menores que 1,00%. Os desvios padrões obtidos estão entre 0,43% e 1,58%, maiores que os valores obtidos com a rede MLP, para o mesmo ensaio (Figura 41), demonstrando uma menor repetibilidade da

rede RBF. A média do sinal de EA também se mostrou importante para o aprendizado da rede RBF neste ensaio.

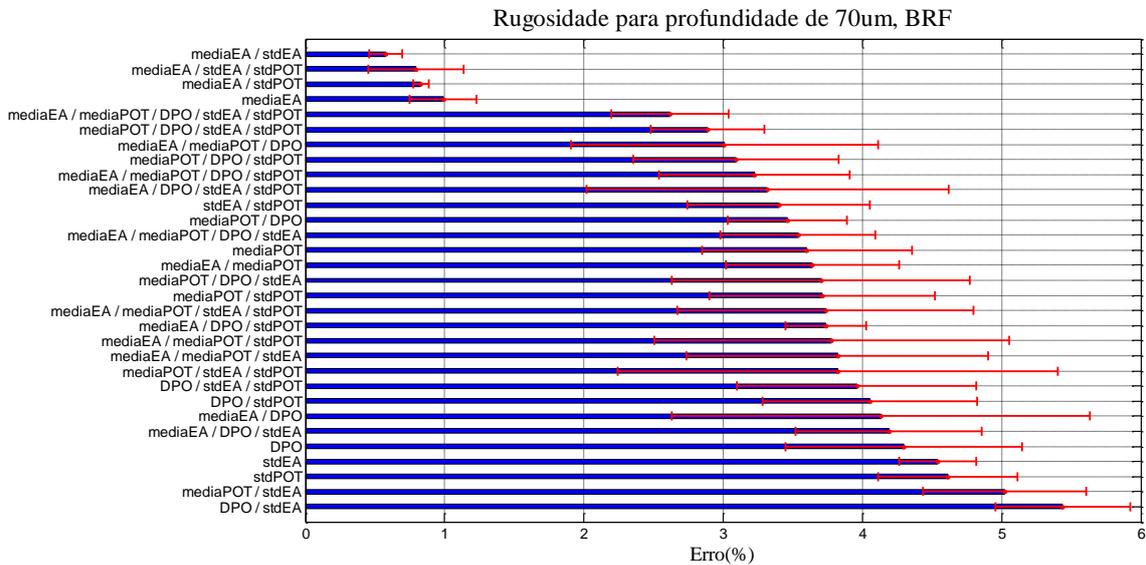


Figura 44 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 70µm, modelo neural RBF

Na Figura 45, o menor erro percentual obtido foi de 0,79% com desvio padrão de 0,57%, para o modelo cujas entradas foram a média do sinal de EA, o desvio padrão do sinal de EA e o desvio padrão da potência. O desvio padrão variou entre 0,05% a 40,35%

A estatística DPO obteve erro percentual médio de 88,18% e desvio padrão de 40,35%. Estes valores foram omitidos da figura para não prejudicar a visualização dos demais erros percentuais e desvios padrões. Este comportamento também é verificado na Figura 33, mas com erro percentual diferente. Também é possível observar que os quatro melhores modelos obtidos na Figura 33 são semelhantes aos obtidos na estimação da rugosidade da peça.

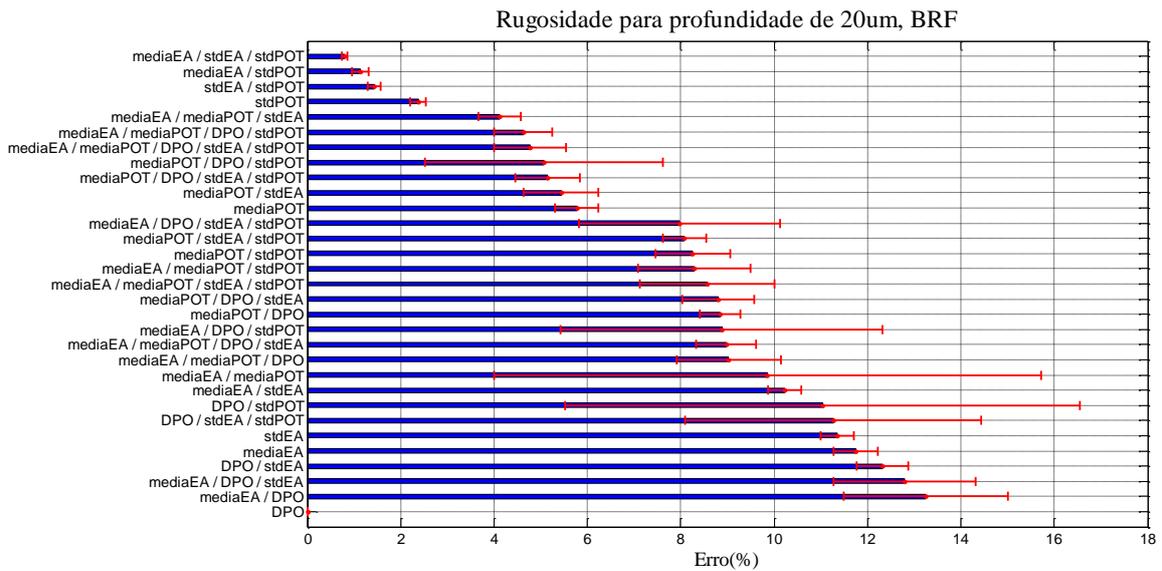


Figura 45 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 20µm, modelo neural RBF

4.3.2.3 Redes Neurais de Regressão Generalizada (GRNN)

A classificação dos erros percentuais é apresentada nas Figura 46, Figura 47 e Figura 48, para os ensaios de 120µm, 70µm e 20µm, respectivamente, sendo que o eixo y representa os grupos de entradas e o eixo x representa o erro percentual médio.

Na Figura 46, o menor erro percentual obtido foi de 1,29% com desvio padrão de 0,17%, para o modelo cujas entradas são a média do sinal de EA e o desvio padrão do sinal de EA. O maior erro percentual obtido foi de 9,78%, e o desvio padrão variou de 0,17% a 2,65%.

O resultado foi parecido com o obtido na rede RBF, onde é possível perceber um aumento significativo do erro percentual a partir do segundo melhor modelo, ou seja, erros maiores que 5,00%.

As redes que utilizaram a média do sinal de EA obtiveram melhores resultados, demonstrado a importância deste sinal na estimação da rugosidade da peça, neste modelo neural.

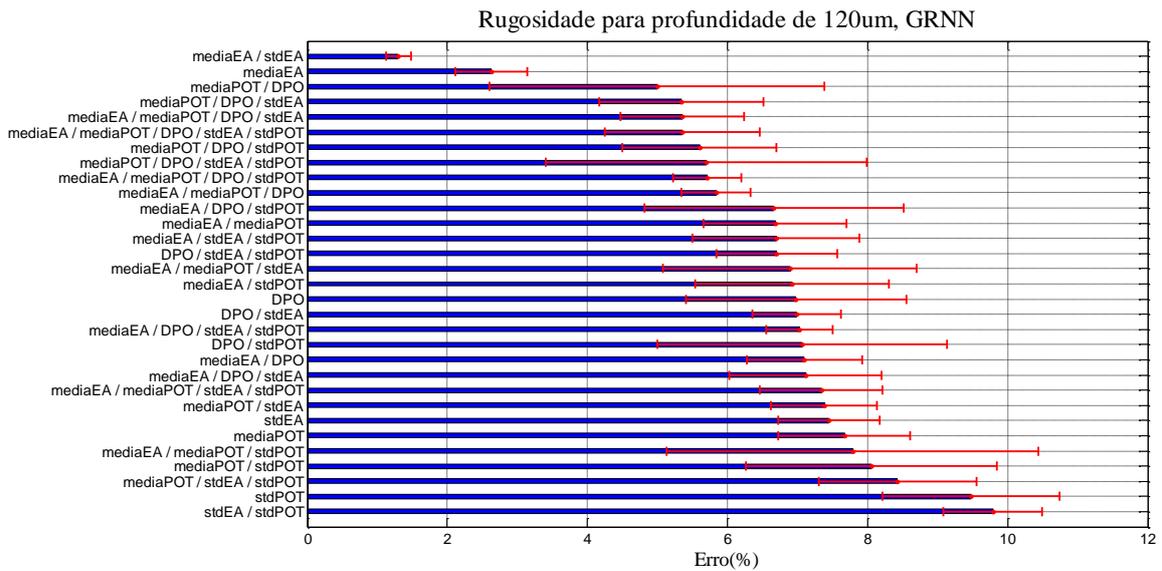


Figura 46 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 120µm, modelo neural GRNN

Na Figura 47, o menor erro percentual obtido foi de 0,53% com desvio padrão de 0,22%, para o modelo neural cujas entradas são a média do sinal de EA e o desvio padrão do sinal de EA. O maior erro percentual foi de 4,71% e o desvio padrão variou de 0,17% a 1,14%.

Assim como no ensaio anterior, a média do sinal de EA está presente na entrada dos melhores modelos neurais. Observa-se um aumento significativo do erro percentual médio, sendo que no quinto melhor modelo os erros percentuais já são maiores que 2%.

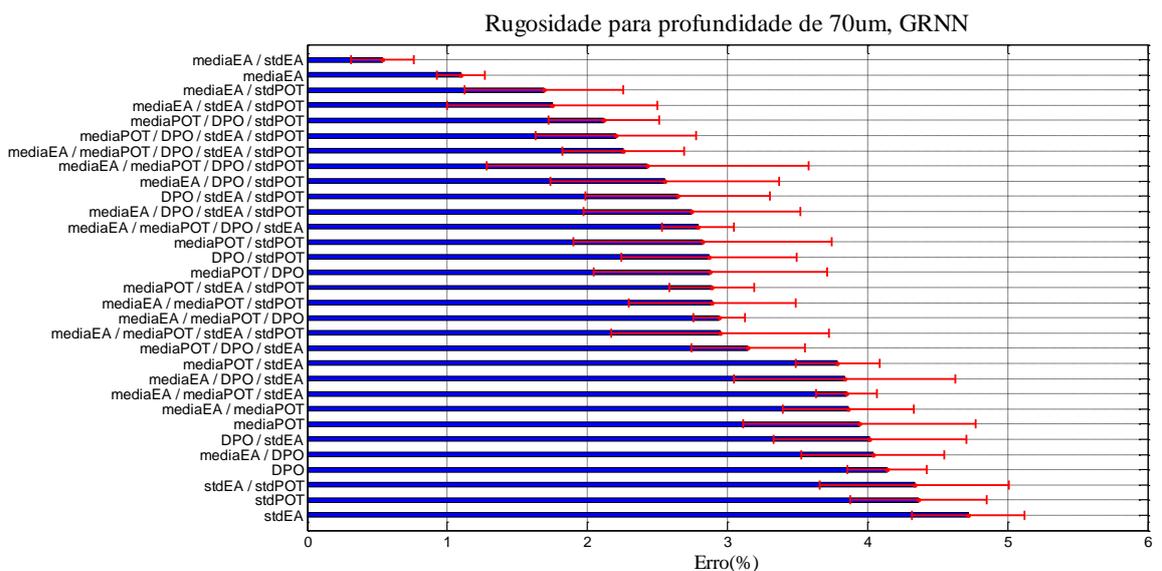


Figura 47 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 70µm, modelo neural GRNN

Na Figura 48, o menor erro obtido foi de 1,49% com desvio padrão de 0,20%, para o modelo neural cujas entradas são a média da potência, DPO, desvio padrão do sinal de EA e desvio padrão da potência. O maior erro obtido foi de 12,31% e a variação do desvio padrão foi entre 0,06% e 0,87%, demonstrando uma repetibilidade muito boa se comparada com os outros ensaios.

Observa-se também que as 14 melhores redes têm erros muito próximos, variando entre 1,49% e 1,73%. Nessas redes, a média do sinal de EA e o desvio padrão da potência estão sempre presentes, e a tendência do gráfico se assemelha muito com os resultados obtidos na Figura 36.

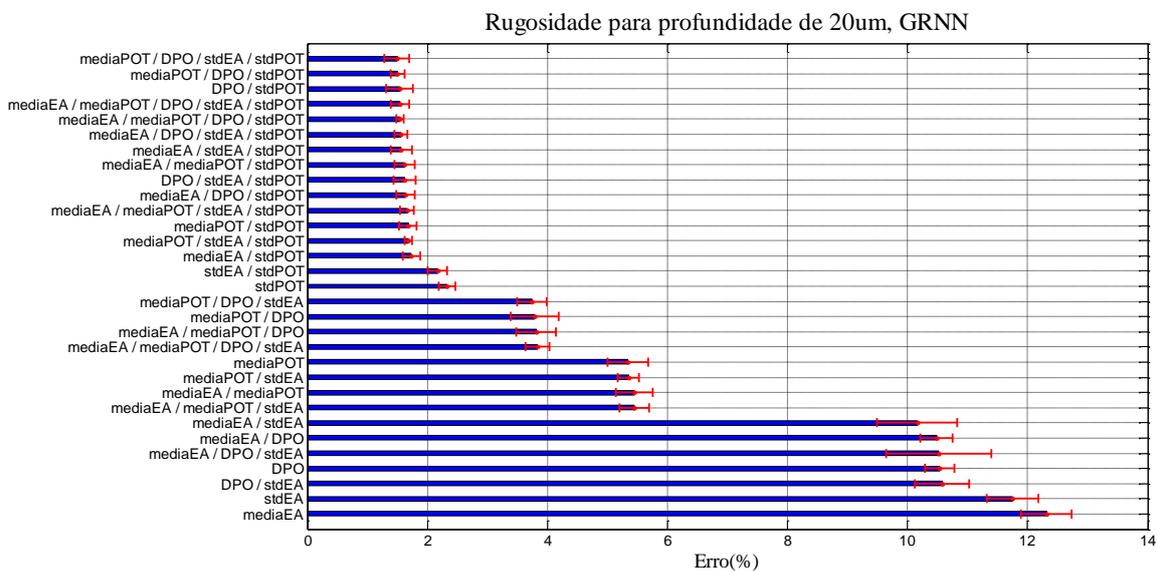


Figura 48 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 20µm, modelo neural GRNN

4.3.2.4 Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS)

Nas Figura 49, Figura 50 e Figura 51 são apresentados os erros percentuais e os desvios padrões para os ensaios de 120µm, 70µm e 20µm, respectivamente. O conjunto de entradas é representado no eixo y e o erro percentual no eixo x.

Na Figura 49, o menor erro obtido foi de 1,16% com desvio padrão de 0,19%, para o modelo neural cujas entradas são a média do sinal de EA e o desvio padrão do sinal de EA. O maior erro percentual obtido foi de 10,80%, e o desvio padrão variou entre 0,19% e 1,73%.

Assim como nos outros tipos de redes neurais, o sinal de EA está presente nos melhores modelos, se mostrando de importância significativa para o aprendizado.

Se comparado com os outros tipos de redes neurais estudados, o desempenho do modelo ANFIS foi satisfatório para a estimação da rugosidade, diferente do desgaste como é possível observar na Figura 37, onde o modelo ANFIS demonstrou pouca repetibilidade com erros percentuais altos.

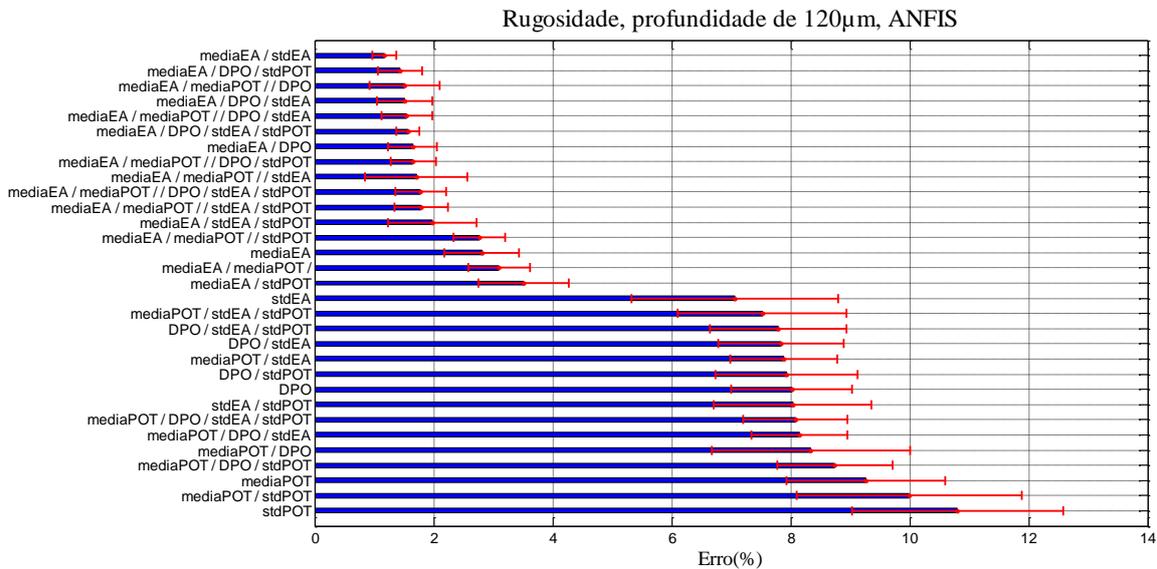


Figura 49 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça o ensaio de 120µm, modelo neural ANFIS

Na Figura 50, o menor erro percentual obtido foi de 0,40% com desvio padrão de 0,09%, para o modelo cujas entradas são a média do sinal de EA, média da potência, desvio padrão do sinal de EA e desvio padrão da potência. O maior erro percentual obtido foi de 4,46%, e o desvio padrão variou de 0,07% a 1,25%, demonstrando uma boa repetibilidade nos resultados.

O modelo ANFIS obteve um desempenho bom, sendo possível a sua utilização na estimação da rugosidade, diferente da Figura 38 para a estimação do desgaste. As entradas derivadas do sinal de EA também se mostraram significativas para este ensaio, estando presente nas melhores redes.

Na Figura 51, o menor erro obtido foi de 1,00% com desvio padrão de 0,02%, para o modelo neural cujas entradas são a média do sinal de EA, desvio padrão do sinal de EA e o desvio padrão da potência. O maior erro obtido foi de 11,77% e a variação do desvio padrão ocorreu entre 0,02% e 0,82%, demonstrando uma repetibilidade dos resultados muito boa.

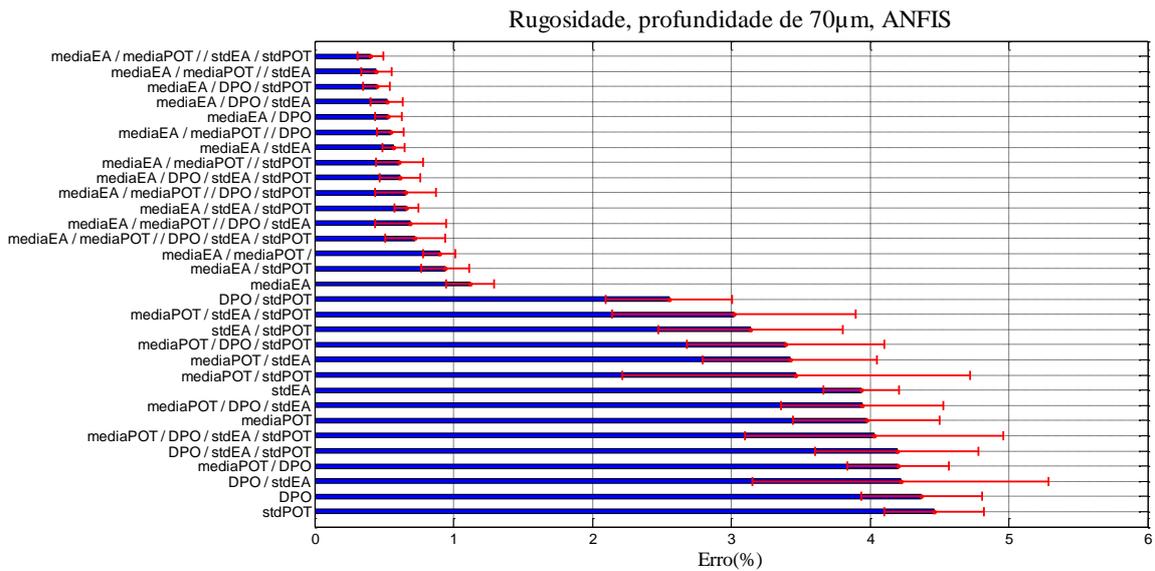


Figura 50 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça o ensaio de 70 μ m, modelo neural ANFIS

A variação dos erros das primeiras 15 redes foi pequena, ocorrendo entre 1,00% e 1,70%. Os desvios padrões também foram pequenos, mostrando que o modelo ANFIS é uma boa ferramenta para a estimativa da rugosidade.

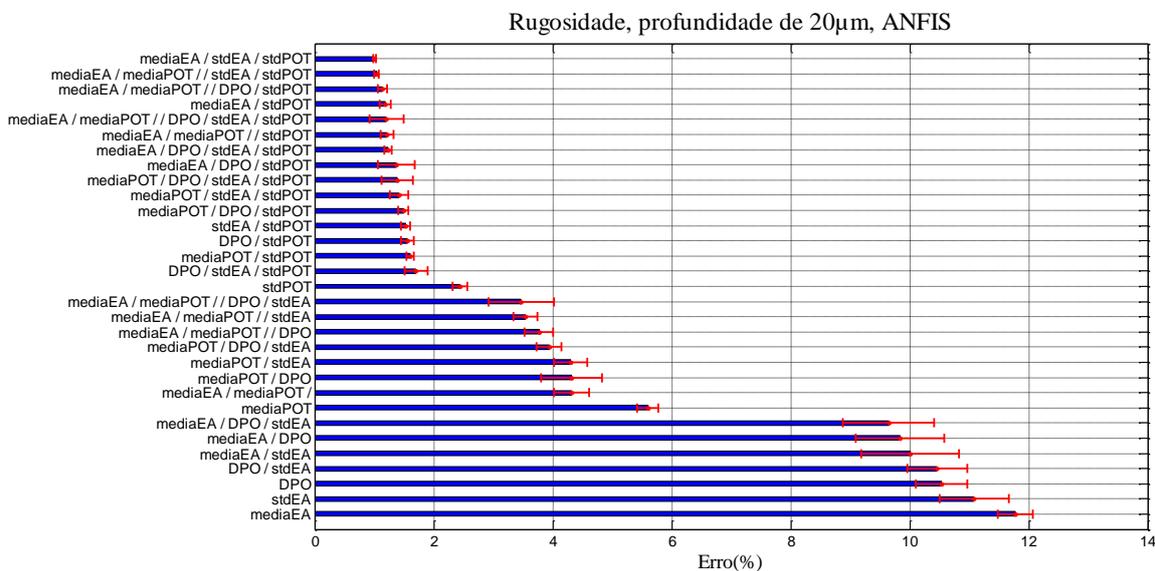


Figura 51 - Erro e desvio padrão do erro para a rugosidade média aritmética da peça para o ensaio de 20 μ m, modelo neural ANFIS

4.3.3 COMPARAÇÃO ENTRE AS MELHORES REDES E OS TIPOS DE MODELOS NEURAIS

As configurações das melhores redes obtidas nos itens 4.3.1 e 4.3.2 são apresentadas nas Tabela 21, Tabela 22, Tabela 23 e Tabela 24 para as redes MLP, RBF, GRNN e o sistema ANFIS, respectivamente.

A Tabela 21 apresenta as configurações resultantes do treinamento realizado com a rede neural MLP. A primeira coluna especifica a saída treinada; na segunda coluna mostra os ensaios usados no treinamento; na terceira coluna os grupos de entradas que obtiveram melhores erros percentuais; as colunas C1, C2 e C3 apresentam a quantidade de neurônios nas camadas escondidas. As duas colunas seguintes representam o erro percentual e desvio padrão obtidos para os modelos.

Verifica-se que somente o modelo neural que tem como saída o desgaste, para o ensaio de 70 μ m, utilizou o número máximo de neurônios (40) da camada escondida estabelecido no item 3.5.1, demonstrando que a faixa de variação para o número de neurônios da camada escondida para os modelos de estimação foi adequada. O valor zero (0) na terceira camada escondida da rugosidade, para o ensaio de 70 μ m, representa a utilização de apenas duas camadas neste modelo neural.

Os erros percentuais do desgaste estão muito acima dos erros obtidos para a rugosidade, demonstrando a melhor adequação das redes ao comportamento da rugosidade. Observa-se que a média do sinal de EA está presente em todos os melhores modelos, ressaltando sua importância no processo de retificação.

Tabela 21 – Configurações das melhores redes para a rede neural MLP

MLP							
	Ensaio	Grupos de Entrada	C1	C2	C3	Erro (%)	Desv. P (%)
Desgaste	120 μ m	mediaEA / DPO / stdEA	20	20	20	4,190	0,647
	70 μ m	mediaEA / mediaPOT / DPO / stdPOT	5	40	10	4,805	0,969
	20 μ m	mediaEA / mediaPOT / DPO / stdEA / stdPOT	10	10	10	4,037	0,358
Rugosidade	120 μ m	mediaEA / mediaPOT / DPO / stdEA	10	10	0	1,019	0,171
	70 μ m	mediaEA / mediaPOT / stdEA / stdPOT	5	5	0	0,517	0,103
	20 μ m	mediaEA / stdEA / stdPOT	15	15	5	1,005	0,114

A Tabela 22 apresenta as configurações da rede neural RBF. Observa-se que o menor erro percentual para o desgaste foi do ensaio de 70 μ m (3,829%) e para a rugosidade o ensaio de 20 μ m (0,577%). Este fato reforça as análises realizadas nos itens 4.3.1 e 4.3.2, onde se pode verificar que as estatísticas derivadas do sinal de EA contribuíram significativamente para o aprendizado da rede RBF

Tabela 22 – Configurações das melhores redes para a rede neural RBF

RBF					
	Ensaio	Grupos de Entrada	Spread	Erro(%)	Desv. P(%)
Desgaste	120 μ m	mediaEA / stdEA	1,984	6,075	1,194
	70 μ m	mediaEA / stdEA / stdPOT	16,901	4,874	0,613
	20 μ m	mediaEA / stdEA / stdPOT	12,753	3,829	0,220
Rugosidade	120 μ m	mediaEA / stdEA	3,499	1,147	0,183
	70 μ m	mediaEA / stdEA	0,837	0,577	0,117
	20 μ m	mediaEA / stdEA / stdPOT	6,114	0,795	0,057

A Tabela 23 apresenta as melhores redes GRNN. Os melhores resultados foram obtidos para o desgaste no ensaio de 20 μ m (4,84%) e para a rugosidade no ensaio de 70 μ m (0,53%). Os sinais derivados do sinal de EA também contribuíram significativamente para o aprendizado da rede GRNN.

Tabela 23 – Configurações das melhores redes para a rede neural GRNN

GRNN					
	Ensaio	Grupos de entrada	Spread	Erro(%)	Desv. P
Desgaste	120 μ m	mediaEA / stdEA	0,0090	5,353	0,962
	70 μ m	mediaEA / stdEA	0,0060	8,047	1,483
	20 μ m	mediaEA / mediaPOT / DPO / stdPOT	1,5311	4,843	0,697
Rugosidade	120 μ m	mediaEA / stdEA	0,0120	1,299	0,176
	70 μ m	mediaEA / stdEA	0,0090	0,536	0,223
	20 μ m	mediaPOT / DPO / stdEA / stdPOT	1,6081	1,492	0,207

Na Tabela 24, observa-se que os melhores erros foram obtidos para a estimação do desgaste no ensaio de 70 μ m (5,48%) e para a rugosidade no ensaio de 70 μ m (0,40%). As estatísticas derivadas do sinal de EA também contribuíram significativamente para o aprendizado da rede ANFIS. A coluna NFP apresenta a quantidade de funções de pertinência utilizadas no treinamento da rede.

Tabela 24 – Configurações das melhores redes para o sistema ANFIS

ANFIS					
	Ensaio	Grupos de Entrada	NFP	Erro(%)	Desv. P
Desgaste	120 μ m	mediaEA / stdEA / stdPOT	4	13,701	7,564
	70 μ m	mediaEA / stdEA / stdPOT	6	5,484	1,343
	20 μ m	mediaEA / mediaPOT / stdEA / stdPOT	6	8,872	2,552
Rugosidade	120 μ m	mediaEA / stdEA	2	1,167	0,197
	70 μ m	mediaEA / mediaPOT / stdEA / stdPOT	7	0,400	0,094
	20 μ m	mediaEA / stdEA / stdPOT	9	1,007	0,020

A Tabela 25 apresenta os melhores valores de erros percentuais obtidos nas tabelas anteriores. Separando as redes por ensaio, verifica-se que a rede MLP obteve melhor desempenho em 4 ensaios: para o desgaste, os ensaios de 120 μ m e 70 μ m, e para a rugosidade, os ensaios de 120 μ m e 20 μ m. A rede RBF possui melhor desempenho no desgaste para o ensaio de 20 μ m, e a rede ANFIS para a rugosidade no ensaio de 70 μ m (valores destacados em amarelo).

No entanto, em vários casos os erros percentuais estão próximos, como por exemplo, as redes RBF e MLP para a estimação do desgaste nos ensaios de 70 μ m. Outros casos são as redes MLP e ANFIS para a estimação da rugosidade no ensaio de 20 μ m. Portanto, a escolha para a implementação dessas redes dependerá de outros fatores, tais como o tempo de processamento, e a repetibilidade do modelo, avaliado pelo desvio padrão do erro.

Tabela 25 – Comparação entre os tipos de modelos neurais estudados

	Profundidade de corte	MLP	RBF	GRNN	ANFIS
DESGASTE ERRO (%)	120 μ m	4.1903	6.0753	5.3533	13.7014
	70 μ m	4.8058	4.8747	8.0476	5.4847
	20 μ m	4.0377	3.8298	4.8430	8.8723
RUGOSIDADE ERRO (%)	120 μ m	1.0199	1.1473	1.2993	1.1679
	70 μ m	0.5176	0.5772	0.5363	0.4008
	20 μ m	1.0053	0.7950	1.4925	1.0072

Com base nos menores valores de erros obtidos, conforme Tabela 25, e, considerando os valores máximos medidos para a rugosidade (1,03 μ m) e desgaste (5,0 μ m), obtêm-se os valores de erros máximos, em micra, dos referidos parâmetros, mostrados na Tabela 26.

Tabela 26 – Erros máximos (% e micra) de estimação dos melhores modelos

	Profundidade de corte	Erro percentual	Erro máximo em micra
DESGASTE	120 μ m	4.1903	0,21
	70 μ m	4.8058	0,24
	20 μ m	3,8298	0,19
RUGOSIDADE	120 μ m	1.0199	0,0105
	70 μ m	0,4008	0,004
	20 μ m	1.0053	0,010

Observa-se na Tabela 26 que os maiores erros, em micra, correspondem aproximadamente à precisão do instrumento de medida (rugosímetro). Assim, verifica-se que os melhores modelos apresentaram 100% de sucesso na estimação dos parâmetros estudados.

A Tabela 27 apresenta o tempo de processamento do algoritmo descrito no item 3.5, onde pode se observar o tempo total e o tempo médio de cada rede treinada. Observa-se que para todos os tipos de redes estudadas, o tempo de processamento foi maior para o ensaio de 20 μ m. Este fato pode ser explicado pelo maior número de amostras para o treinamento das redes neurais desse ensaio (860 passadas), comparado com os outros ensaios.

O sistema ANFIS obteve o maior tempo médio de processamento, de 170 segundos, para o desgaste e para a rugosidade no ensaio de 20 μ m. Para o ensaio de 120 μ m o tempo médio de processamento foi de 31,973 segundos para o desgaste e 29,830 segundos para a rugosidade. Os menores tempos foram obtidos para a rede GRNN, com o tempo médio de 0,792 segundos para o ensaio de 120 μ m na estimação do desgaste e 0,809 segundos na rugosidade.

Assim, a rede GRNN foi a que apresentou a maior velocidade de treinamento, seguida pelas redes RBF, MLP e ANFIS.

Tabela 27 - Tempo de treinamento total e a média por configuração para os modelos neurais

	Profundidade de corte	MLP 4805 redes		RBF 31000 redes		GRNN 31000 redes		ANFIS 279 redes	
		Total	Média	Total	Média	Total	Média	Total	Média
		(horas)	(seg)	(horas)	(seg)	(horas)	(seg)	(horas)	(seg)
DESGASTE	120µm	11,676	8,748	7,734	0,898	6,822	0,792	2,478	31,973
Tempo de	70µm	14,627	10,959	8,111	0,942	7,556	0,877	3,898	50,291
Processamento	20µm	18,869	14,137	16,144	1,875	7,926	0,920	13,249	170,961
RUGOSIDADE	120µm	10,442	7,823	7,738	0,899	6,964	0,809	2,312	29,830
Tempo de	70µm	11,779	8,825	8,169	0,949	7,529	0,874	3,844	49,602
Processamento	20µm	17,243	13,349	15,988	1,857	7,870	0,914	13,199	170,304

Capítulo 5 – CONCLUSÃO

Os temas abordados na revisão bibliográfica desta pesquisa permitem-nos concluir que:

- 1) Os processos de fabricação voltados para a retificação tangencial plana é um assunto bastante explorado. No entanto, devido à complexidade do processo, diversidade das ferramentas e suas características, diversidade de materiais retificados, configurações de profundidades de avanço, velocidade da mesa, refrigeração, entre outros, ainda é uma área que possui enorme potencial para novas pesquisas. A utilização de modelos neurais para o monitoramento agrega melhorias no processo possibilitando sua automação e, conseqüentemente, sua otimização.
- 2) A retificação é considerada o principal processo de usinagem de cerâmicas. No entanto, muitos problemas ocorrem na retificação desse material devido a sua alta dureza e fragilidade, resultando em trincas superficiais e sub-superficiais. Novos materiais cerâmicos estão sendo constantemente pesquisados para as mais diversas aplicações, tornando o estudo de seu processo de fabricação essencial para a diminuição de custo, tempo de fabricação e melhorias nas características gerais da peça.
- 3) As utilizações de modelos neurais nos processos de fabricação permitem seu monitoramento e automatização, resultando na diminuição do custo final e na melhoria da qualidade do produto final. No entanto, não há ainda um estudo comparativo entre vários modelos neurais para estimação de rugosidade e desgaste do rebolo no processo de retificação, recaindo-se, quase sempre, nos modelos neurais mais populares ou convencionais.
- 4) As medidas de desgaste da ferramenta e da rugosidade da peça são de difícil realização, exigindo-se que o processo seja interrompido para realiza-las. Portanto, a utilização de modelos neurais confiáveis para a estimação da rugosidade e desgaste do rebolo resulta, conseqüentemente, na diminuição do tempo de máquina parada, diminuição do custo, aumento da vida útil da ferramenta, e menos dependência das habilidades do operador da máquina.

Em relação aos métodos e resultados apresentados neste trabalho pode-se afirmar que:

- 1) Os materiais e metodologias foram escolhidos corretamente. Os equipamentos utilizados nesse trabalho apresentaram comportamento adequado, atendendo a todas as necessidades do trabalho e possibilitando a realização correta das medidas. As estatísticas utilizadas representaram muito bem as grandes medidas, principalmente as estatísticas derivadas do sinal de EA. A potência não foi tão significativa devido à pequena área de contato entre a peça e o rebolo e à inércia do sistema rebolo-motor. O método utilizado para a composição de todos os modelos neurais estudados nesse trabalho se mostrou adequado, pois se obteve uma grande faixa de modelos com diferentes tipos de resultados, dentre os quais se escolheu os melhores.
- 2) Dentre todos os modelos neurais obtidos, os melhores produziram excelentes resultados. Verificou-se que os vários tipos de redes estudados se complementam, ou seja, a rede neural MLP possui maior repetibilidade, mas sua configuração é mais complexa. As redes BRN e GRNN possuem alta velocidade de aprendizado, mas baixa repetibilidade. A rede ANFIS é de simples configuração, mas possui aprendizado lento e repetibilidade baixa.
- 3) Os resultados dos melhores modelos produziram valores de erros muito baixos, correspondentes, praticamente, na faixa de precisão do instrumento de medida (rugosímetro). Desta forma, pode afirmar que esses modelos obtiveram 100% de acertos na estimação dos valores de rugosidade e desgaste do rebolo.
- 4) Os melhores modelos neurais apresentaram alta tolerância aos erros experimentais ocorridos em algumas passadas, sendo esta característica muito importante num sistema de monitoramento de retificação.

5.1 SUGESTÃO PARA OS PRÓXIMOS TRABALHOS.

- ❖ Emprego de redes neurais que contemplem todas as condições de retificação, de forma a se ter a estimação desses parâmetros em um único modelo;
- ❖ Propostas de modelos neurais para estimação de outros parâmetros importantes na retificação cilíndrica de cerâmicas, tais como circularidade, tensão residual (tração e compressão), fratura, dentre outros.
- ❖ Implementação de modelos neurais para estimação dos parâmetros de estimação estudados neste trabalho em um hardware dedicado, utilizando, por exemplo, um processador DSP.

REFERÊNCIAS

- AGARWAL, S.; RAO, P. V. **A probabilistic approach to predict surface roughness in ceramic grinding.** International Journal of Machine Tools and Manufacture, v. 45, n. 6, p. 609–616, 2005.
- AGUIAR, P. R.; BIANCHI, E. C.; OLIVEIRA, J. F. G. **A method for burning detection in grinding process using acoustic emission and effective electrical power signal.** CIRP Journal of Manufacturing Systems, v. 31, n. 3, 2002.
- AGUIAR, P. R.; DOTTO, F. R. L.; BIANCHI, E. C. **Study of thresholds to burning in surface grinding process.** Journal of the Brazilian Society of Mechanical Sciences and Engineering, v. 27, n. 2, p. 150–156, 2005.
- AGUIAR, P. R.; SOUZA, A. G. O.; BIANCHI, E. C.; LEITE, R. R.; DOTTO, F. R. L. **Monitoring the dressing operation in the grinding process.** International Journal of Machining and Machinability of Materials, v. 5, n. 1, p. 3–22, 2009.
- ALLOR, R. L.; JAHANMIR, S. **Current problems and future directions for ceramic machining.** American Ceramic Society Bulletin, v. 75, n. 7, 1996.
- AYDIN, I.; BRISCOE, B. J.; SANLITURK, K. Y. **Dimensional variation of die-pressed ceramic green compacts: Comparison of a finite element modelling with experiment.** Journal of the European Ceramic Society, v. 17, n. 10, p. 1201 – 1212, 1997.
- BERKOVITS, A.; FANG, D. **Study of fatigue crack characteristics by acoustic emission.** Engineering Fracture Mechanics, v. 51, n. 3, p. 401 – 416, 1995.
- BIANCHI, E. C.; AGUIAR, P.; SILVA, E. J.; SILVA JR, C. E.; FORTULAN, C. **Advanced ceramics: evaluation of the ground surface.** Cerâmica, v. 49, n. 311, p. 174–177, 2003.
- BIFANO, T. G.; YI, Y. **Acoustic emission as an indicator of material-removal regime in glass micro-machining.** Precision Engineering, v. 14, n. 4, p. 219 – 228, 1992.
- BRINKSMEIER, E.; WERNER, F. **Monitoring of Grinding Wheel Wear.** CIRP Annals - Manufacturing Technology, v. 41, n. 1, p. 373 – 376, 1992.
- BURRASCANO, P. **Learning vector quantization for the probabilistic neural network.** Neural Networks, IEEE Transactions on, p. 458 – 461, 1991.
- BYRNE, G.; DORNFELD, D.; INASAKI, I. et al. **Tool Condition Monitoring (TCM) — The Status of Research and Industrial Application.** CIRP Annals - Manufacturing Technology, v. 44, n. 2, p. 541 – 567, 1995.

- CHANG, C.-W.; KUO, C.-P. **An investigation of laser-assisted machining of Al₂O₃ ceramics planing.** International Journal of Machine Tools and Manufacture, v. 47, n. 3–4, p. 452 – 461, 2007.
- CHEN, X.; ROWE, W. B. **Analysis and simulation of the grinding process. Part I: Generation of the grinding wheel surface.** International Journal of Machine Tools and Manufacture, v. 36, n. 8, p. 871 – 882, 1996.
- DANG, X.; TAN, Y. **RBF neural networks hysteresis modelling for piezoceramic actuator using hybrid model.** Mechanical Systems and Signal Processing, v. 21, n. 1, p. 430 – 440, 2007.
- DHANASEKAR, B.; MOHAN, N. K.; BHADURI, B.; RAMAMOORTHY, B. **Evaluation of surface roughness based on monochromatic speckle correlation using image processing.** Precision Engineering, v. 32, n. 3, p. 196 – 206, 2008.
- DING, S.; JIA, W.; SU, C.; CHEN, J. **Research of neural network algorithm based on FA and RBF.** Computer Engineering and Technology (ICCET), 2010 2nd International Conference on, v. 7, p. V7–228, 2010.
- DINIZ, A. E.; LIU, J. J.; DORNFELD, D. A. **Correlating tool life, tool wear and surface roughness by monitoring acoustic emission in finish turning.** Wear, v. 152, n. 2, p. 395 – 407, 1992.
- DORNFELD, D.; HE, G. C. **An Investigation of Grinding and Wheel Loading Using Acoustic Emission.** J. Eng. Ind. (Trans. ASME)., v. Vol. 106, p. 28–33, 1984.
- DOTTO, F. R. L.; AGUIAR, P. R.; BIANCHI, E. C.; SERNI, P. J. A.; THOMAZELLA, R. **Automatic system for thermal damage detection in manufacturing process with internet monitoring.** Journal of the Brazilian Society of Mechanical Sciences and Engineering, v. 28, n. 2, p. 153–160, 2006.
- FATHIMA, K.; KUMAR, A. S.; RAHMAN, M.; LIM, H. S. **A study on wear mechanism and wear reduction strategies in grinding wheels used for ELID grinding.** Wear, v. 254, n. 12, p. 1247 – 1255, 2003.
- FAUSETT, L. V. **Fundamentals of Neural Networks: Architectures, Algorithms, and Applications.** Prentice-Hall, 1994.
- FISCHER, H.; WEISS, R.; TELLE, R. **Crack healing in alumina bioceramics.** Dental materials : official publication of the Academy of Dental Materials, v. 24, n. 3, p. 328–32, 2008.

- GADELMAWLA, E. S.; KOURA, M. M.; MAKSOUD, T. M. A.; ELEWA, I. M.; SOLIMAN, H. H. **Roughness parameters.** Journal of Materials Processing Technology, v. 123, p. 133–145, 2002.
- GARG, S.; PATRA, K.; KHETRAPAL, V.; PAL, S. K.; CHAKRABORTY, D. **Genetically evolved radial basis function network based prediction of drill flank wear.** Engineering Applications of Artificial Intelligence, v. 23, n. 7, p. 1112 – 1120, 2010.
- GILL, S. S.; SINGH, J. **An Adaptive Neuro-Fuzzy Inference System modeling for material removal rate in stationary ultrasonic drilling of sillimanite ceramic.** Expert Systems with Applications, v. 37, n. 8, p. 5590 – 5598, 2010.
- GIRIDHAR, D.; VIJAYARAGHAVAN, L.; KRISHNAMURTHY, R. **Acoustic emission response of sintered alumina zirconia composite during grooving process.** NDT & E International, v. 46, n. 0, p. 55 – 62, 2012.
- HAGAN, M. T.; MENHAJ, M. B. **Training feedforward networks with the Marquardt algorithm.** Neural Networks, IEEE Transactions on, v. 5, n. 6, p. 989–993, 1994.
- HECKER, R. L.; LIANG, S. Y. **Predictive modeling of surface roughness in grinding.** International Journal of Machine Tools and Manufacture, v. 43, n. 8, p. 755 – 761, 2003.
- HEUER, N.; TRAN, T. **Radial basis functions for the solution of hypersingular operators on open surfaces.** Computers & Mathematics with Applications, v. 63, n. 11, p. 1504 – 1518, 2012.
- HU, G.-N.; LIU, C.-C.; CHUANG, K.-W.; YU, S.-S.; TSUI, T.-S. **General Regression Neural Network utilized for color transformation between images on RGB color space.** Machine Learning and Cybernetics (ICMLC), 2011 International Conference on, v. 4, p. 1793 –1799, 2011.
- HU, Y. H.; HWANG, J. N. **Handbook of Neural Network Signal Processing.** Taylor & Francis, 2001.
- HUANG, S. **Artificial neural networks in manufacturing: concepts, applications, and perspectives.** and Manufacturing Technology, Part A, v. 17, n. 2, p. 212–228, 1994.
- HUNDT, W.; LEUENBERGER, D.; REHSTEINER, F.; GYGAX, P. **An Approach to Monitoring of the Grinding Process Using Acoustic Emission (AE) Technique.** CIRP Annals - Manufacturing Technology, v. 43, n. 1, p. 295 – 298, 1994.
- HYUN, B. G.; NAM, K. **Faults Diagnoses of Rotating Machines by Using Neural Networks: GRNN and BPN.** IEEE IECON, p. p1456–1461., 1995.

- JANG, J. S. R.; SUN, C. T. **Neuro-fuzzy modeling and control**. Proceedings of the IEEE, v. 83, n. 3, p. 378–406, 1995.
- JEMIELNIAK, K. **Some aspects of acoustic emission signal pre-processing**. Journal of Materials Processing Technology, v. 109, n. 3, p. 242–247, 2001.
- KARPUSCHEWSKI, B.; WEHMEIER, M.; INASAKI, I. **Grinding monitoring system based on power and acoustic emission sensors**. CIRP Annals-Manufacturing Technology, v. 49, n. 1, p. 235–240, 2000.
- KOHONEN, T. **An introduction to neural computing**. Neural networks, v. 1, n. 1, p. 3–16, 1988.
- KONIG, W. **Machining of New Materials**. CIRP Annals - Manufacturing Technology, v. 39, n. 2, p. 673–681, 1990.
- KWAK, J. S.; HA, M. K. **Neural network approach for diagnosis of grinding operation by acoustic emission and power signals**. Journal of Materials Processing Technology, v. 147, n. 1, p. 65–71, 2004.
- LIANG, S. Y.; HECKER, R. L.; LANDERS, R. G. **Machining Process Monitoring and Control: The State-of-the-Art**. Journal of Manufacturing Science and Engineering, v. 126, n. 2, p. 297–310, 2004.
- LIANG, Z.; WANG, X.; WU, Y. et al. **An investigation on wear mechanism of resin-bonded diamond wheel in Elliptical Ultrasonic Assisted Grinding (EUAG) of monocrystal sapphire**. Journal of Materials Processing Technology, v. 212, n. 4, p. 868–876, 2012.
- LIAO, T. W. **Feature extraction and selection from acoustic emission signals with an application in grinding wheel condition monitoring**. Engineering Applications of Artificial Intelligence, v. 23, n. 1, p. 74–84, 2010.
- MALKIN, S. **Grinding technology: theory and applications of machining with abrasives**. Society of Manufacturing Engineers, 1989.
- MALKIN, STEPHEN; KOREN, Y.; BER, A. **Off-Line Grinding Optimization with a Micro-Computer**. CIRP Annals - Manufacturing Technology, v. 29, n. 1, p. 213–216, 1980.
- MARINESCU, I. D.; HITCHINER, M.; UHLMANN, E.; INASAKI, I. **Handbook of machining with grinding wheels**. CRC, 2006.

- MARQUEZ, L.; HILL, T. **Function approximation using backpropagation and general regression neural networks**. System Sciences, 1993, Proceeding of the Twenty-Sixth Hawaii International Conference on, v. 4, p. 607 – 615, 1993.
- MASTERS, T. **Advanced algorithms for neural networks: a C++ sourcebook**. Wiley, 1995.
- MAYER JR, J.; FANG, G. P. **Effect of grinding parameters on surface finish of ground ceramics**. CIRP Annals-Manufacturing Technology, v. 44, n. 1, p. 279–282, 1995.
- MEHROTRA, K.; MOHAN, C. K.; RANKA, S. **Elements of artificial neural networks**. MIT Press, 1997.
- MIN, S.; LIDDE, J.; RAUE, N.; DORNFELD, D. **Acoustic emission based tool contact detection for ultra-precision machining**. CIRP Annals - Manufacturing Technology, v. 60, n. 1, p. 141 – 144, 2011.
- MORDJAOUI, M.; CHABANE, M.; BOUDJEMA, B.; ZAIER, H. **Neuro-fuzzy modeling for dynamic ferromagnetic hysteresis**. 4th International Conference on Computer Integrated Manufacturing CIP 2007.
- MORETTIN, L. G. **Estatística Básica - Probabilidade e Inferencia: Volume Unico**. MAKRON, 1999.
- MUKHERJEE, I.; ROUTROY, S. **Comparing the performance of neural networks developed by using Levenberg–Marquardt and Quasi-Newton with the gradient descent algorithm for modelling a multiple response grinding process**. Expert Systems with Applications, v. 39, n. 3, p. 2397 – 2407, 2012.
- MUÑOZ, L. A. B. **Learning in Feed-Forward Artificial Neural Networks I**. Encyclopedia of Artificial Intelligence. IGI Global, 2009.. p.1004–1011.
- NAVARRO, F. F.; MARTÍNEZ, C. H.; GUTIÉRREZ, P. A.; BARRAGÁN, J. M. P.; GRANADOS, F. L. **Parameter estimation of q-Gaussian Radial Basis Functions Neural Networks with a Hybrid Algorithm for binary classification**. Neurocomputing, v. 75, n. 1, p. 123 – 134, 2012.
- NAZARI, A. **Application of ANFIS for analytical modeling of tensile strength of functionally graded steels**. Materials Research, p. 0 – 0, 2012.
- NILSSON, J. W.; RIEDEL, S. A. **Circuitos Eléctricos**. LTC, 2003.
- OLIVEIRA, J. F. G.; VALENTE, C. M. O. **Fast Grinding Process Control with AE Modulated Power Signals**. CIRP Annals - Manufacturing Technology, v. 53, n. 1, p. 267–270, 2004.

- PARZER, E. **On Estimation of a Probability Density Function and Mode.** The Annals of Mathematical Statistics, v. Vol. 33, p. 1065–1076, 1962.
- PATTON, J. B.; ILIC, J. **Identification of static distribution load parameters using general regression neural networks.** Circuits and Systems, 1993., Proceedings of the 36th Midwest Symposium on, p. 1023 – 1026, 1993.
- PRAGA-ALEJO, R. J.; TORRES-TREVIÑO, L. M.; GONZÁLEZ-GONZÁLEZ, D. S.; ACEVEDO-DÁVILA, J.; CEPEDA-RODRÍGUEZ, F. **Analysis and evaluation in a welding process applying a Redesigned Radial Basis Function.** Expert Systems with Applications, v. 39, n. 10, p. 9669 – 9675, 2012.
- RAHAMAN, M. N. **Ceramic Processing and Sintering.** M. Dekker, 2003.
- REDDY, P. V. B.; KUMAR, C. H. R. V.; REDDY, K. H. **Modeling of wire EDM process using back propagation (BPN) and General Regression Neural Networks (GRNN).** 2010. Anais... 2010.
- ROBBEN, L.; RAHMAN, S.; BUHL, J.-C.; DENKENA, B.; KONOPATZKI, B. **Airborne sound emission as a process monitoring tool in the cut-off grinding of concrete.** Applied Acoustics, v. 71, n. 1, p. 52 – 60, 2010.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation.** Parallel Distributed Processing, p. 318–362, 1986.
- SALMASNIA, A.; KAZEMZADEH, R. B.; TABRIZI, M. M. **A novel approach for optimization of correlated multiple responses based on desirability function and fuzzy logics.** Neurocomputing, v. 91, n. 0, p. 56 – 66, 2012.
- SAMANT, A. N.; DAHOTRE, N. B. **Laser machining of structural ceramics—A review.** Journal of the European Ceramic Society, v. 29, n. 6, p. 969–993, 2009.
- SAMHOURI, M. S.; SURGENOR, B. W. **Surface roughness in grinding: on-line prediction with adaptive neuro-fuzzy inference system.** Transactions of NAMRI/SME, v. 33, p. 57–64, 2005.
- SENG, T. L.; KHALID, M.; YUSOF, R. **Adaptive GRNN for the modelling of dynamic plants.,** p. 217 – 222, 2002.
- SHAO, S.-C.; CHEN, W.-H.; CHEN, J.-H. **A noisy data regression model based on general regression neural networks.** 2011. Anais... 2011.
- SPECHT, D. F. **A general regression neural network.** Neural Networks, IEEE Transactions on, v. 2, n. 6, p. 568–576, 1991.

- SPECHT, D. F. **Chapter 3 - Probabilistic and General Regression Neural Networks.** Fuzzy Logic and Neural Network Handbook. McGraw-Hill Companies, 1996.
- STRAKNA, T. J.; JAHANMIR, S.; ALLOR, R. L.; KUMAR, K. V. **Influence of Grinding Direction on Fracture Strength of Silicon Nitride.** Journal of Engineering Materials and Technology, v. 118, n. 3, p. 335–342, 1996.
- SWAIN, M. V. **Microfracture About Scratches in Brittle Solids.** Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences, v. 366, n. 1727, p. 575–597, 1979.
- TAJDARI, M.; MEHRABAN, A. G.; KHOOGAR, A. R. **Shear strength prediction of Ni-Ti alloys manufactured by powder metallurgy using fuzzy rule-based model.** Materials & Design, v. 31, n. 3, p. 1180 – 1185, 2010.
- TÖNSHOFF, H. K.; FRIEMUTH, T.; BECKER, J. C. **Process Monitoring in Grinding.** CIRP Annals - Manufacturing Technology, v. 51, n. 2, p. 551 – 571, 2002.
- TONSHOFF, H.; KARPUSCHEWSKI, B.; MANDRYSCH, T.; INASAKI, I. **Grinding Process Achievements and their Consequences on Machine Tools Challenges and Opportunities.** CIRP Annals - Manufacturing Technology, v. 47, n. 2, p. 651–668, 1998.
- TRAVEN, H. G. C. **A neural network approach to statistical pattern classification by 'semiparametric' estimation of probability density functions.** Neural Networks, IEEE Transactions on, p. 366 – 377, 1991.
- WEBSTER, J.; DONG, W.; LINDSAY, R. **Raw acoustic emission signal analysis of grinding process.** CIRP Annals-Manufacturing Technology, v. 45, n. 1, p. 335–340, 1996.
- WHITEHOUSE, D. J. **Handbook of Surface and Nanometrology, Second Edition.** Taylor and Francis, 2010.
- XIANG, Y.; TIAN, J.; ZHANG, Z.; DAI, Y. **Diagnosis of endometrial cancer based on near infrared spectroscopy and general regression neural network.** 2010. Anais... 2010.
- XIAO, G.; MALKIN, S. **On-Line Optimization for Internal Plunge Grinding.** Cycle, v. 45, n. 1, 1996.
- XU, H. H. K.; JAHANMIR, S. **Microfracture and material removal in scratching of alumina.** Journal of Materials Science, v. 30, n. 9, p. 2235–2247, 1995.

- ZHANG, B.; YANG, F.; WANG, J.; ZHU, Z.; MONAHAN, R. **Stock removal rate and workpiece strength in multi-pass grinding of ceramics.** Journal of Materials Processing Technology, v. 104, p. 178–184, 2000.
- ZHANG, K.; LI, Y.; SCARF, P.; BALL, A. **Feature selection for high-dimensional machinery fault diagnosis data using multiple models and Radial Basis Function networks.** Neurocomputing, v. 74, n. 17, p. 2941 – 2952, 2011.
- ZHENG, Y. **Relationship between flexural strength and surface roughness for hot-pressed Si₃N₄ self-reinforced ceramics.** Journal of the European Ceramic Society, v. 20, n. 9, p. 1345–1353, 2000.
- ZHOU, J.; YANG, K. **General regression neural network forecasting model based on PSO algorithm in water demand.** 2010. Anais... 2010.

ANEXO I – NORMA DIN 4766

Grupo Principal	Método de Manufatura Designação do Método	Valores atingíveis médios de R_a em μm													
		0,006	0,012	0,025	0,05	0,1	0,2	0,4	0,8	1,6	3,2	6,3	12,5	25	50
Fundição	Fundição em molde de areia	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Fundição em molde de casca	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Fundição em coquilha	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Fundição sob pressão	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Fundição por cera perdida	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Conformação	Forjamento em matriz fechada	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Laminação plana	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Estampagem profunda de chapas	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Extrusão	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Estampagem	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Laminação de perfis	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Corte por serra	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Separação	Torneamento longitudinal	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Faceamento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Abertura de ranhuras	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Aplainamento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Contorno com plaina limadora	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Alisamento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Furação	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Mandrilhamento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Escareamento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Alargamento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Fresamento tangencial	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Fresamento de topo	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Brochamento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Limagem	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Retificação circular longitudinal	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Retificação circular de superfícies	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Retificação circular de mergulho	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Retificação superficial tangencial	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Retificação superficial de topo	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Retificação-polimento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Brunimento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Acabamento finíssimo	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Polimento circular com disco	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Polimento de superfícies com disco	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Usinagem por ultra-som	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Polimento	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Jateamento de abrasivo	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Tamboreamento, rebarbação	■	■	■	■	■	■	■	■	■	■	■	■	■	■
	Corte por chama	■	■	■	■	■	■	■	■	■	■	■	■	■	■

Legenda ■ Valores comuns
□ Valores possíveis

Figura 52 - Valores de R_a para diferentes processos de fabricação (Adaptado da Norma DIN 4766)

ANEXO II – ALGORITMO - MODELO NEURAL MLP

```
% *****
% Departamento De Engenharia Elétrica - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% Mauricio Eiji Nakai
% *****

%matlabpool
tic

clear all
close all

load vetores20;
load target;
load tabelaNeurônios;

% mediaEA = mediaEA120;
% mediaPOT = mediaPOT120;
% DPO = DPO120;
% stdEA = stdEA120;
% stdPOT = stdPOT120;

mediaEA = mediaEA20;
mediaPOT = mediaPOT20;
DPO = DPO20;
stdEA = stdEA20;
stdPOT = stdPOT20;

% mediaEA = mediaEA70;
% mediaPOT = mediaPOT70;
% DPO = DPO70;
% stdEA = stdEA70;
% stdPOT = stdPOT70;

Indice = 0;
possibilidades = '11111';

if exist('continuaerro.mat','file') & exist('continuaprocessamento.mat',...
                                             'file')
    load continuaerro;
    load continuaprocessamento;
    inicio = k;
    tempoanterior = tempo;
    tempo = 0;
else
    inicio = 1;
    Indice = 0;
    tempoanterior = 0;
    tempo = 0;
    ErroRugo = 0;
end

for k=inicio:bin2dec(possibilidades)

    tempo = toc+tempoanterior;
```

```

save continuaprocessamento k Indice tempo %salva informação para
save continuaerro ErroRugo %continuação do process.

binario = double(dec2bin(k));
while length(binario)<5
    binario = cell2mat([48] [binario])
end
entrada = 0;
%%
if binario(5) == '1'
    entrada = mediaEA;
end
%%
if binario(4)=='1'
    if entrada == 0
        entrada = mediaPOT;
    else
        entrada = cell2mat ([entrada];[mediaPOT]) ;
    end
end
%%
if binario(3) == '1'
    if entrada == 0
        entrada = DPO;
    else
        entrada = cell2mat ([entrada];[DPO]) ;
    end
end
%%
if binario(2) == '1'
    if entrada == 0
        entrada = stdEA;
    else
        entrada = cell2mat ([entrada];[stdEA]) ;
    end
end
%%
if binario(1) == '1'
    if entrada == 0
        entrada = stdPOT;
    else
        entrada = cell2mat ([entrada];[stdPOT]) ;
    end
end
%%
saida = cell2mat([r20]);

[trainP,valP,testP,trainIND,valIND,testIND] = dividerand(entrada,...
    0.8,0.0,0.2);
[trainT,valT,testT] = divideind(saida,trainIND,valIND,testIND);

for j=1:9
    for k=1:5
        for neuronios=1:length(TabelaNeuronios(:,1))
            Momento=j/10;

            %Variação da taxa de aprendizagem (Learning Rate)
            learn_rate=0;
            if k==1
                learn_rate=0.05;
            end
        end
    end
end

```

```

end

if k==2
    learn_rate=0.15;
end

if k==3
    learn_rate=0.30;
end

if k==4
    learn_rate=0.50;
end

if k==5
    learn_rate=0.90;
end

%*****
for m=1:5
    [trainP,valP,testP,trainIND,valIND,testIND] = ...
        dividerand(entrada,0.8,0.0,0.2);
    [trainT,valT,testT] = divideind(saida,trainIND,...
        valIND,testIND);

    if (TabelaNeuronios(neuronios,2)==0) & ...
        (TabelaNeuronios(neuronios,3)==0)
        NumNeuronios = TabelaNeuronios(neuronios,1);
        net = newff(trainP,trainT,[NumNeuronios]);
    end

    if (TabelaNeuronios(neuronios,3)==0) & ...
        (TabelaNeuronios(neuronios,2)~=0)
        NumNeuronios = TabelaNeuronios(neuronios,1:2);
        net = newff(trainP,trainT,[NumNeuronios]);
    end

    if TabelaNeuronios(neuronios,3)>0
        NumNeuronios = TabelaNeuronios(neuronios,1:3);
        net = newff(trainP,trainT,[NumNeuronios]);
    end

    net.trainParam.mc = Momento;
    net.trainParam.lr = learn_rate;
    net.trainParam.show = 5;
    net.trainParam.goal = 1e-7;
    net.trainParam.epochs = 2000;
    net.trainParam.showWindow = 0;
    net.trainParam.showCommandLine = 0;

    net = trainlm(net,trainP,trainT);
    Y(m, :, :) = sim(net,testP);
    testeT(m, :, :) = testT;

end
clc
Indice= Indice+1
ErroRugo(Indice,1)=binario(1);      %Entradas
ErroRugo(Indice,2)=binario(2);
ErroRugo(Indice,3)=binario(3);

```

```

ErroRugo (Indice, 4)=binario (4);
ErroRugo (Indice, 5)=binario (5);
ErroRugo (Indice, 6)=TabelaNeuronios (neuronios, 1);
ErroRugo (Indice, 7)=TabelaNeuronios (neuronios, 2);
ErroRugo (Indice, 8)=TabelaNeuronios (neuronios, 3);
ErroRugo (Indice, 9)= Momento;
ErroRugo (Indice, 10)= learn_rate;

Erro1= mean(abs (testeT (1, :)-Y (1, :))); %primeiro treino
ErroRugo (Indice, 15) = Erro1;
Erro2= mean(abs (testeT (2, :)-Y (2, :))); %segundo treino
ErroRugo (Indice, 16) = Erro2;
Erro3= mean(abs (testeT (3, :)-Y (3, :))); %terceiro treino
ErroRugo (Indice, 17) = Erro3;
Erro4= mean(abs (testeT (4, :)-Y (4, :))); %quarto treino
ErroRugo (Indice, 18) = Erro4;
Erro5= mean(abs (testeT (5, :)-Y (5, :))); %quinto treino
ErroRugo (Indice, 19) = Erro5;
ErroRugo (Indice, 20) = std ([Erro1 Erro2 Erro3 Erro4 Erro5]);
ErroRugo (Indice, 11) = mean ([Erro1 Erro2 Erro3 Erro4
Erro5]);

Erroper1 = Erro1/mean (testeT (1, :))*100; %primeiro treino
ErroRugo (Indice, 21) = Erroper1;
Erroper2 = Erro2/mean (testeT (2, :))*100; %segundo treino
ErroRugo (Indice, 22) = Erroper2;
Erroper3 = Erro3/mean (testeT (3, :))*100; %terceiro treino
ErroRugo (Indice, 23) = Erroper3;
Erroper4 = Erro4/mean (testeT (4, :))*100; %quarto treino
ErroRugo (Indice, 24) = Erroper4;
Erroper5 = Erro5/mean (testeT (5, :))*100; %quinto treino
ErroRugo (Indice, 25) = Erroper5;
ErroRugo (Indice, 26) = std ([Erroper1 Erroper2 Erroper3 ...
Erroper4 Erroper5]);
ErroRugo (Indice, 12) = mean ([Erroper1 Erroper2 Erroper3 ...
Erroper4 Erroper5]);

tempodecorrido = (tempoanterior+toc)/60;
if tempodecorrido > 120
    tempodecorrido = tempodecorrido/60;
    disp (['tempo dercorrido ', num2str (tempodecorrido), ...
' horas']);
else
    disp (['tempo dercorrido ', num2str (tempodecorrido), ...
' minutos']);
end

qtde = 45*length (TabelaNeuronios (:, 1))*31;
tempoestimado = (((tempoanterior+toc)/Indice)*...
(qtde-Indice))/60;
if tempoestimado > 120
    tempoestimado = tempoestimado/60;
    disp (['tempo estimado ', num2str (tempoestimado), ...
' horas']);
else
    disp (['tempo estimado ', num2str (tempoestimado), ...
' minutos']);
end
end
end

```

```
        end
    end
end

tempo = toc+tempoanterior;
save continuaprocessamento j Indice tempo %salva informação para
save continuaerro ErroRugo %continuação do processamento
```

ANEXO III – ALGORITMO - MODELO NEURAL RBF

```
% *****
% Departamento De Engenharia Elétrica - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% Mauricio Eiji Nakai
% *****

tic

clear all
close all

load vetores120;
load target;

mediaEA = mediaEA120;
mediaPOT = mediaPOT120;
DPO = DPO120;
stdEA = stdEA120;
stdPOT = stdPOT120;

% mediaEA = mediaEA20;
% mediaPOT = mediaPOT20;
% DPO = DPO20;
% stdEA = stdEA20;
% stdPOT = stdPOT20;

% mediaEA = mediaEA70;
% mediaPOT = mediaPOT70;
% DPO = DPO70;
% stdEA = stdEA70;
% stdPOT = stdPOT70;

Indice = 0;
possibilidades = '11111';
qtdetestes = .001:.001:1;
valdeteste = (20.^qtdetestes)-1;

if exist('continuaerro.mat','file') & exist('continuaprocessamento.mat',...
                                             'file')
    load continuaerro;
    load continuaprocessamento;
    inicio = k;
    tempoanterior = tempo;
    tempo = 0;
else
    inicio = 1;
    Indice = 0;
    tempoanterior = 0;
    tempo = 0;
    ErroRugo = 0;
end
for k=inicio:bin2dec(possibilidades)

    tempo = toc+tempoanterior;
    save continuaprocessamento k Indice tempo %salva informação para
    save continuaerro ErroRugo %continuação do process
```

```

binario = double(dec2bin(k));
while length(binario)<5
    binario = cell2mat({[0] [binario]})
end
entrada = 0;

if binario(5) == '1'
    entrada = mediaEA;
end

if binario(4)=='1'
    if entrada == 0
        entrada = mediaPOT;
    else
        entrada = cell2mat ([entrada];[mediaPOT]) ;
    end
end

if binario(3) == '1'
    if entrada == 0
        entrada = DPO;
    else
        entrada = cell2mat ([entrada];[DPO]) ;
    end
end
%%
if binario(2) == '1'
    if entrada == 0
        entrada = stdEA;
    else
        entrada = cell2mat ([entrada];[stdEA]) ;
    end
end
%%
if binario(1) == '1'
    if entrada == 0
        entrada = stdPOT;
    else
        entrada = cell2mat ([entrada];[stdPOT]) ;
    end
end
%%
saida = cell2mat({[d120]});

for i=1:length(valdeteste)
    for m=1:10

        [trainP,valP,testP,trainIND,valIND,testIND] = ...
            dividerand(entrada,0.8,0.0,0.2);
        [trainT,valT,testT] = divideind(saida,trainIND,valIND,testIND);

        spread = valdeteste(i);
        net = newrbe(trainP,trainT,spread); % RBF exata
        Y(m, :, :) = sim(net,testP);
        testeT(m, :, :) = testT;
    end
end
clc

```

```

Indice= Indice+1
ErroRugo (Indice,1)=binario (1);           %entradas
ErroRugo (Indice,2)=binario (2);
ErroRugo (Indice,3)=binario (3);
ErroRugo (Indice,4)=binario (4);
ErroRugo (Indice,5)=binario (5);
ErroRugo (Indice,6)= spread;

Erro1= mean (abs (testeT (1, :)-Y (1, :)));
ErroRugo (Indice,15) = Erro1;
Erro2= mean (abs (testeT (2, :)-Y (2, :)));
ErroRugo (Indice,16) = Erro2;
Erro3= mean (abs (testeT (3, :)-Y (3, :)));
ErroRugo (Indice,17) = Erro3;
Erro4= mean (abs (testeT (4, :)-Y (4, :)));
ErroRugo (Indice,18) = Erro4;
Erro5= mean (abs (testeT (5, :)-Y (5, :)));
ErroRugo (Indice,19) = Erro5;
ErroRugo (Indice,20) = std ([Erro1 Erro2 Erro3 Erro4 Erro5]);
ErroRugo (Indice,11) = mean ([Erro1 Erro2 Erro3 Erro4 Erro5]);

Erroper1 = Erro1/mean (testeT (1, :))*100;
ErroRugo (Indice,21) = Erroper1;
Erroper2 = Erro2/mean (testeT (2, :))*100;
ErroRugo (Indice,22) = Erroper2;
Erroper3 = Erro3/mean (testeT (3, :))*100;
ErroRugo (Indice,23) = Erroper3;
Erroper4 = Erro4/mean (testeT (4, :))*100;
ErroRugo (Indice,24) = Erroper4;
Erroper5 = Erro5/mean (testeT (5, :))*100;
ErroRugo (Indice,25) = Erroper5;
ErroRugo (Indice,26) = std ([Erroper1 Erroper2 Erroper3 Erroper4 ...
                             Erroper5]);
ErroRugo (Indice,12) = mean ([Erroper1 Erroper2 Erroper3 Erroper4 ...
                             Erroper5]);

tempodecorrido = (tempoanterior+toc)/60;
if tempodecorrido > 120
    tempodecorrido = tempodecorrido/60;
    disp (['tempo dercorrido ', num2str (tempodecorrido), ' horas']);
else
    disp (['tempo dercorrido ', num2str (tempodecorrido), ' minutos']);
end

qtde = (length (valdeteste)-1)*bin2dec (possibilidades);
tempoestimado = (((tempoanterior+toc)/Indice)*(qtde-Indice))/60;
if tempoestimado > 120
    tempoestimado = tempoestimado/60;
    disp (['tempo estimado ', num2str (tempoestimado), ' horas']);
else
    disp (['tempo estimado ', num2str (tempoestimado), ' minutos']);
end

end

end

save continuaprocessamento k Indice tempo %salva informação para
save continuaerro ErroRugo %continuação do processamento

```

ANEXO IV – ALGORITMO - MODELO NEURAL GRNN

```
% *****
% Departamento De Engenharia Elétrica - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% Mauricio Eiji Nakai
% *****

tic

clear all
close all

load vetores120;
load target;

mediaEA = mediaEA120;
mediaPOT = mediaPOT120;
DPO = DPO120;
stdEA = stdEA120;
stdPOT = stdPOT120;

% mediaEA = mediaEA20;
% mediaPOT = mediaPOT20;
% DPO = DPO20;
% stdEA = stdEA20;
% stdPOT = stdPOT20;

% mediaEA = mediaEA70;
% mediaPOT = mediaPOT70;
% DPO = DPO70;
% stdEA = stdEA70;
% stdPOT = stdPOT70;

Indice = 0;
possibilidades = '11111';
qtdetestes = .001:.001:1;
valdeteste = (20.^qtdetestes)-1;
% qtdetestes = .0001:.1:1;
% valdeteste = (20.^qtdetestes)-1;
%plot(valdeteste)

if exist('continuaerro.mat','file') & exist('continuaprocessamento.mat',...
                                            'file')
    load continuaerro;
    load continuaprocessamento;
    kinicio = k;
    tempoanterior = tempo;
    tempo = 0;
else
    kinicio = 1;
    Indice = 0;
    tempoanterior = 0;
    tempo = 0;
    ErroRugo = 0;
end
for k=kinicio:bin2dec(possibilidades)

    tempo = toc+tempoanterior;
```

```

save continuaprocessamento k Indice tempo %salva informação para
save continuaerro ErroRugo %continuação do process

binario = double(dec2bin(k));
while length(binario)<5
    binario = cell2mat([0] [binario])
end
entrada = 0;
%%
if binario(5) == '1'
    entrada = mediaEA;
end
%%
if binario(4)=='1'
    if entrada == 0
        entrada = mediaPOT;
    else
        entrada = cell2mat ([entrada];[mediaPOT]) ;
    end
end
%%
if binario(3) == '1'
    if entrada == 0
        entrada = DPO;
    else
        entrada = cell2mat ([entrada];[DPO]) ;
    end
end
%%
if binario(2) == '1'
    if entrada == 0
        entrada = stdEA;
    else
        entrada = cell2mat ([entrada];[stdEA]) ;
    end
end
%%
if binario(1) == '1'
    if entrada == 0
        entrada = stdPOT;
    else
        entrada = cell2mat ([entrada];[stdPOT]) ;
    end
end
%%
saida = cell2mat([d120]);

for i=1:length(valdeteste)
    for m=1:10

        [trainP,valP,testP,trainIND,valIND,testIND] = ...
            dividerand(entrada,0.8,0.0,0.2);
        [trainT,valT,testT] = divideind(saida,trainIND,valIND,testIND);

        spread = valdeteste(i);
        net = newgrnn(trainP,trainT,spread); % GRNN
        Y(m, :, :) = sim(net,testP);
        testeT(m, :, :) = testT;
    end
end

```

```

clc
Indice= Indice+1
ErroRugo (Indice,1)=binario (1);           %entradas
ErroRugo (Indice,2)=binario (2);
ErroRugo (Indice,3)=binario (3);
ErroRugo (Indice,4)=binario (4);
ErroRugo (Indice,5)=binario (5);
ErroRugo (Indice,6)= spread;

Erro1= mean (abs (testeT (1,:) -Y (1,:)));
ErroRugo (Indice,15) = Erro1;
Erro2= mean (abs (testeT (2,:) -Y (2,:)));
ErroRugo (Indice,16) = Erro2;
Erro3= mean (abs (testeT (3,:) -Y (3,:)));
ErroRugo (Indice,17) = Erro3;
Erro4= mean (abs (testeT (4,:) -Y (4,:)));
ErroRugo (Indice,18) = Erro4;
Erro5= mean (abs (testeT (5,:) -Y (5,:)));
ErroRugo (Indice,19) = Erro5;
ErroRugo (Indice,20) = std ([Erro1 Erro2 Erro3 Erro4 Erro5]);
ErroRugo (Indice,11) = mean ([Erro1 Erro2 Erro3 Erro4 Erro5]);

Erroper1 = Erro1/mean (testeT (1,:))*100;
ErroRugo (Indice,21) = Erroper1;
Erroper2 = Erro2/mean (testeT (2,:))*100;
ErroRugo (Indice,22) = Erroper2;
Erroper3 = Erro3/mean (testeT (3,:))*100;
ErroRugo (Indice,23) = Erroper3;
Erroper4 = Erro4/mean (testeT (4,:))*100;
ErroRugo (Indice,24) = Erroper4;
Erroper5 = Erro5/mean (testeT (5,:))*100;
ErroRugo (Indice,25) = Erroper5;
ErroRugo (Indice,26) = std ([Erroper1 Erroper2 Erroper3 Erroper4 ...
                             Erroper5]);
ErroRugo (Indice,12) = mean ([Erroper1 Erroper2 Erroper3 Erroper4 ...
                             Erroper5]);

tempodecorrido = (tempoanterior+toc)/60;
if tempodecorrido > 120
    tempodecorrido = tempodecorrido/60;
    disp(['tempo dercorrido ', num2str(tempodecorrido), ' horas']);
else
    disp(['tempo dercorrido ', num2str(tempodecorrido), ' minutos']);
end

qtde = (length(valdeteste)-1)*bin2dec(possibilidades);
tempoestimado = (((tempoanterior+toc)/Indice)*(qtde-Indice))/60;
if tempoestimado > 120
    tempoestimado = tempoestimado/60;
    disp(['tempo estimado ', num2str(tempoestimado), ' horas']);
else
    disp(['tempo estimado ', num2str(tempoestimado), ' minutos']);
end

end
end

save continuaprocessamento k Indice tempo %salva informação para
save continuaerro ErroRugo %continuação do processamento

```

ANEXO V – ALGORITMO - MODELO ANFIS

```
% *****
% Departamento De Engenharia Elétrica - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% Mauricio Eiji Nakai
% *****

clc
tic

clear all
close all

load target;
load tabelaNeuronios;

% mediaEA = mediaEA120;
% mediaPOT = mediaPOT120;
% DPO = DPO120;
% stdEA = stdEA120;
% stdPOT = stdPOT120;

% mediaEA = mediaEA20;
% mediaPOT = mediaPOT20;
% DPO = DPO20;
% stdEA = stdEA20;
% stdPOT = stdPOT20;

load vetores70;
mediaEA = mediaEA70;
mediaPOT = mediaPOT70;
DPO = DPO70;
stdEA = stdEA70;
stdPOT = stdPOT70;

Indice = 0;
possibilidades = '11111';

if exist('continuaerro.mat','file') & exist('continuaprocessamento.mat',...
                                             'file')
    load continuaerro;
    load continuaprocessamento;
    inicio = k;
    tempoanterior = tempo;
    tempo = 0;
else
    inicio = 1;
    Indice = 0;
    tempoanterior = 0;
    tempo = 0;
    ErroRugo = 0;
end

for k=inicio:bin2dec(possibilidades)

    tempo = toc+tempoanterior;
    save continuaprocessamento k Indice tempo %salva informação para
```

```

save continuaerro ErroRugo %continuação do proce.

binario = double(dec2bin(k));
while length(binario)<5
    binario = cell2mat([48] [binario]);
end
binario
entrada = 0;
%%
if binario(5) == '1'
    entrada = mediaEA;
end
%%
if binario(4)=='1'
    if entrada == 0
        entrada = mediaPOT;
    else
        entrada = cell2mat ([entrada];[mediaPOT]) ;
    end
end
%%
if binario(3) == '1'
    if entrada == 0
        entrada = DPO;
    else
        entrada = cell2mat ([entrada];[DPO]) ;
    end
end
%%
if binario(2) == '1'
    if entrada == 0
        entrada = stdEA;
    else
        entrada = cell2mat ([entrada];[stdEA]) ;
    end
end
%%
if binario(1) == '1'
    if entrada == 0
        entrada = stdPOT;
    else
        entrada = cell2mat ([entrada];[stdPOT]) ;
    end
end

saida = abs(cell2mat([d70]));

for nfp = 2:9
    for rep=1:5

        [trainP,valP,testP,trainIND,valIND,testIND] = dividerand(...
            entrada,0.8,0.0,0.2);
        [trainT,valT,testT] = divideind(saida,trainIND,valIND,testIND);
        trainP = trainP';
        trainT = trainT';
        testP = testP';
        testT = testT';
        dados = cell2mat({trainP trainT});
    end
end

```

```

in_fis = genfis3(trainP, trainT, 'sugeno',nfp);

mf = 0;

epoch_number = 3000;
error_goal = 10e-3;
step_size = 0.01;
decrease_rate = 0.9;
increase_rate = 1.1;

% Treino ANFIS
saidaanfis = 0
erro=0;

[out_fis, erro] = anfis(dados,in_fis,epoch_number);
try
    saidaanfis = evalfis(testP,out_fis);
    erro_fim(rep) = mean(abs(testT-saidaanfis));
    erropercentual_fim(rep) = mean(abs(testT-saidaanfis)./...
        testT)*100;
catch
    rep = rep-1;
end
end

clc
Indice= Indice+1
ErroRugo(Indice,1)=binario(1);           %Entradas utilizadas
ErroRugo(Indice,2)=binario(2);
ErroRugo(Indice,3)=binario(3);
ErroRugo(Indice,4)=binario(4);
ErroRugo(Indice,5)=binario(5);
ErroRugo(Indice,6)=nfp;                  %N de funções de pertinencia

ErroRugo(Indice,7)= erro_fim(1);          %primeiro treino
ErroRugo(Indice,8)= erro_fim(2);          %segundo treino
ErroRugo(Indice,9)= erro_fim(3);          %terceiro treino
ErroRugo(Indice,10)= erro_fim(4);         %quarto treino
ErroRugo(Indice,11)= erro_fim(5);         %quinto treino
ErroRugo(Indice,12) = mean(erro_fim(1:5)); %media dos erros
ErroRugo(Indice,13) = std(erro_fim(1:5)); %desvio padrão
ErroRugo(Indice,14) = erropercentual_fim(1);
ErroRugo(Indice,15) = erropercentual_fim(2);
ErroRugo(Indice,16) = erropercentual_fim(3);
ErroRugo(Indice,17) = erropercentual_fim(4);
ErroRugo(Indice,18) = erropercentual_fim(5);
ErroRugo(Indice,19) = mean(erropercentual_fim(1:5));
ErroRugo(Indice,20) = std(erropercentual_fim(1:5));

Tempodecorrido

= (tempoanterior+toc)/60;
if tempodecorrido > 120
    tempodecorrido = tempodecorrido/60;
    disp(['tempo dercorrido ',num2str(tempodecorrido),' horas']);
else
    disp(['tempo dercorrido ',num2str(tempodecorrido),' minutos']);
end

```

```

qtde = 9*31;
tempoestimado = (((tempoanterior+toc)/Indice)*(qtde-Indice))/60;
if tempoestimado > 120
    tempoestimado = tempoestimado/60;
    disp(['tempo estimado ', num2str(tempoestimado), ' horas']);
else
    disp(['tempo estimado ', num2str(tempoestimado), ' minutos']);
end

end

tempo = toc+tempoanterior;
save continuaprocessamento k Indice tempo %salva informação para
save continuaerro ErroRugo %continuação do processamen.

end

```